POVEZANOST KVALITETE MOBILNOG BANKARSTVA I REPUTACIJE BANAKA

Starešinić, Berislava

Doctoral thesis / Disertacija

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:148:757767

Rights / Prava: Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb







Sveučilište u Zagrebu

SVEUČILIŠTE U ZAGREBU
EKONOMSKI FAKULTET ZAGREB

Berislava Staršinić

POVEZANOST KVALITETE MOBILNOG BANKARSTVA I REPUTACIJE BANAKA

DOKTORSKI RAD

Mentor:
Prof. dr. sc. Mislav Ante Omazić

Zagreb, 2019.



University of Zagreb

UNIVERSITY OF ZAGREB
FACULTY OF ECONOMICS AND BUSINESS ZAGREB

Berislava Starešinić

RELATIONSHIP OF QUALITY OF MOBILE BANKING AND REPUTATION OF BANKS

DOCTORAL THESIS

Supervisor:
Professor Mislav Ante Omazić, PhD.

Zagreb, 2019

Berislava Starešinić

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je **DOKTORSKI RAD** isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Doktorand/ica:

U Zagrebu, 07.03.2019. godine

(vlastoručni potpis)

SAŽETAK

Doktorski rad istražuje na koji se način može povezati sigurnost, dostupnost i jednostavnost korištenja mobilnog bankarstva sa percipiranom kvalitetom usluge mobilnog bankarstva banke te postoji li povezanost između percipirane kvalitete usluge mobilnog bankarstva i reputacije banaka. Primarni podaci istraživanja prikupljeni su uz pomoć anketnog upitnika. Hipoteze rada testirane su i potvrđene metodom višestrukih modela jednostavne i složene linearne regresije. Istraživanje omogućuje pogled u razvoj novih spoznaja bankarske industrije koji se temelje na ključnim odrednicama o poslovanju financijskog tržišta Republike Hrvatske. Sukladno navedenom definirane su karakteristike bankarskog tržišta i uloga tehnologije u financijskoj industriji Republike Hrvatske.

PROŠIRENI SAŽETAK

Istraživanje omogućuje pogled u razvoj novih spoznaja bankarske industrije koji se temelje na ključnim odrednicama uloge tehnologije u poslovanju financijskog tržišta Republike Hrvatske. Osnovna zadaća rada je istražiti i adekvatno argumentirati utjecaj mobilnog bankarstva na reputaciju banaka Republike Hrvatske. Istraživanje ima za cilj doprinijeti definiranju područja za korištenje informacijsko-komunikacijskih tehnologija u mobilnom bankarstvu koji u najvećoj mjeri utječu na reputaciju banaka te definirati aspekte mobilnog bankarstva (sigurnost, jednostavnost korištenja i dostupnost usluge) koji u najvećoj mjeri utječu na reputaciju banaka. Temeljni ciljevi istraživanja su empirijski utvrditi povezanost percipirane kvalitete usluge mobilnog bankarstva i reputacije banke, empirijski utvrditi način na koji sigurnost, jednostavnost korištenja i dostupnost usluge utječu na percipiranu kvalitetu usluge mobilnog bankarstva.

Dodatni ciljevi su, na osnovu analize dosadašnjih istraživanja, identificirati i objasniti ključne determinante kvalitete usluga mobilnog bankarstva i reputacije banaka te se kritički osvrnuti na dosadašnja istraživanja, ukazati na važnost korištenja naprednih informatičkih tehnologija u bankarstvu te ispitati stupanj osviještenosti hrvatskih građana o sigurnosti usluga mobilnog bankarstva.

Postavljene hipoteze su testirane korištenjem metode višestrukih modela složene linearne regresije. Kako bi se ispitale hipoteze, provelo se primarno istraživanje metodom ispitivanja pomoću strukturiranog anketnog upitnika. Način komuniciranja sa ispitanicima je bio putem elektroničke pošte.

Rezultati testiranja hipoteza korištenjem regresijskih modela pokazuju kako su hipoteze postavljene u radu prihvaćene. Doprinos istraživanja očituje se u empirijski potvrđenim spoznajama koja obogaćuju postojeći skup znanja unutar područja poslovne ekonomije koje mogu biti korisne prilikom formiranja tehnoloških strategija banaka u okviru financijske industrije. Na osnovi rezultata istraživanja sukladno prethodno postavljenim ciljevima mogu se ponuditi preporuke za buduće aktivnosti povezanih sa tehnološkim strategijama financijskog tržišta u cilju povećanja konkurentnosti.

Ključne riječi: mobilno bankarstvo, reputacija banaka, kvaliteta usluge mobilnog bankarstva, sigurnost, jednostavnost, dostupnost usluge mobilnog bankarstva

EXTENDED ABSTRACT

The research provides a look at the development of new knowledge of the banking industry, which is based on key determinants of technology role in the financial market of the Republic of Croatia. The key aim is to explore and adequately argue the influence of mobile banking on the reputation of banks in the Republic of Croatia. The purpose of the research is to contribute to the definition of possible areas of implementation of information and communication technologies in mobile banking, which affect the reputation of banks and also to define the aspects of mobile banking (security, ease of use and availability of mobile banking services), which affect the reputation of banks to a large extent.

The basic objectives of the research are to empirically establish the correlation between the perceived quality of mobile banking service and bank reputation, and also to empirically determine the way security, ease of use and availability of services affect the perceived quality of mobile banking services.

Additional objectives, based on analyze of previous researches, are to identify and explain the key determinants of the quality of mobile banking and bank reputation, to highlight the importance of using advanced information technology in banking and to examine the awareness of Croatian citizens on the security of mobile banking services.

The hypotheses have been tested by using multiple modeling methods of complex linear regression. In order to examine the hypothesis, the primary research was carried out using a structured survey questionnaire. The way of communicating with the respondents was via electronic mail.

The results of the testing of hypothesis using regression models show that the hypotheses are confirmed. Based on the results of the research in accordance with the previously set objectives, recommendations can be offered for future activities related to the financial market technology strategies and increase of competitiveness.

Key words: mobile banking, reputation of banks, quality of mobile banking service, security, ease of use and availability of mobile banking services

SADRŽAJ

1 UVOD 1

1.1 Problem istraživanja 6

1.2 Ciljevi istraživanja 7

1.3 Hipoteze istraživanja 9

1.4 Metode znanstvenog istraživanja 14

1.5 Očekivani znanstveni doprinos 15

2 KARAKTERISTIKE BANKARSKOG SEKTORA U REPUBLICI HRVATSKOJ 16

2.1 Specifičnosti bankarskog sektora u Republici Hrvatskoj 16

2.1.1 Vlasnička struktura 17

2.1.2 Koncentracija bankarskog tržišta 20

2.2 Strategije izgradnje konkurentske prednosti bankarskog sektora 37

2.2.1 Strategija niskih troškova kao izvor konkurentske prednosti 59

2.2.2 Strategija diferencijacije kao izvor konkurentske prednosti 62

2.2.3 Strategija fokusiranja kao izvor konkurentske prednosti 66

2.3 Važnost reputacije u poslovanju banaka 74

3 REPUTACIJA KAO BITNA ODREDNICA TRŽIŠNOG USPJEHA U BANKARSKOM SEKTORU 77

3.1 Opće teorije reputacije 78

3.2 Dosadašnja istraživanja reputacije banaka u Republici Hrvatskoj 84

3.3 Interesno-utjecajne skupine procesa izgradnje reputacije u bankarskom sektoru 89

3.4 Izvori korporativne reputacije u bankarskom sektoru 91

3.4.1 Financijski čimbenici 92

3.4.2 Strateška orijentacija 93

3.4.3 Upravljanje ljudskim resursima 95

3.4.4 Društvena odgovornost 101

3.4.5 Inovativnost 104

3.4.6 Kvaliteta proizvoda i usluga 113

4 MOBILNO BANKARSTVO KAO STRATEŠKA ORIJENTACIJA BANAKA 117

4.1 Ključne odrednice mobilnog bankarstva 117

4.2 Distribucija proizvoda i usluga putem mobilnog bankarstva 130
4.3 Upravljanje odnosima s klijentima kroz mobilno bankarstvo 137
4.4 Model mjerenja kvalitete mobilnog bankarstva 141
4.4.1 Sigurnost usluge 142
4.4.2 Jednostavnost korištenja 149
4.4.3 Dostupnost usluge 150
5 EMPRIJSKO ISTRAŽIVANJA POVEZANOSTI KVALITETE MOBILNOG BANKARSTVA I REPUTACIJE BANAKA 153
5.1 Instrument istraživanja 153
5.2 Uzorak istraživanja 158
5.3 Rezultati istraživanja 163
5.4 Diskusija rezultata istraživanja 201
5.5 Ograničenja istraživanja i preporuke za buduća istraživanja 210
6 ZAKLJUČAK 211
POPIS KORIŠTENIH IZVORA 223
POPIS SLIKA 243
POPIS TABLICA 245
ŽIVOTOPIS AUTORICE 247
ŽIVOTOPIS MENTORA 248
PRILOZI 250

1 UVOD

Nositelji posljednje tri industrijske revolucije bili su mehanizacija, elektrifikacija i informacijska tehnologija (Lasi i sur., 2014). Paralelno s razvojem informacijske tehnologije nastavno posljednjoj industrijskoj revoluciji odvija se snažan proces digitalizacije koji podrazumijeva pretvorbu materijala odnosno informacije u digitalni oblik. Digitalizacija je svim sudionicima gospodarstva omogućila smanjenje troškova, porast kapaciteta, online pohranu podataka, napredne analitike i posljedično uzrokovala redefiniranje konkurentskih prednosti. Povećanjem broja sudionika koji prepoznaju njezine koristi, digitalizacija nastavlja transformaciju gospodarstva.

Digitalna tehnologija povećava efikasnost procesa arhiviranja, olakšava pristup podacima, restrukturira distribucijske kanale, omogućava derivaciju informacija koje dosad nisu bile dostupne i posljedično raste kvaliteta usluge krajnjim korisnicima (Milic i sur., 2017). Digitalizacija omogućava personalizaciju usluge i rast kvalitete iskustva korisnika.

Može se reći kako su upravo lakoća u primjeni digitalizacije odnosno tehnološka rješenja postala znak kvalitete poslovanja banaka (Malik, Gulati, 2013). Platforme, uporaba robotike i umjetne inteligencije omogućili su rješavanje zahtjeva klijenata u realnom vremenu odnosno istovremeno promijenili postojeći model bankarstva. Ipak, važno je naglasiti kako digitalizacija nije fenomen koji će jednako osnažiti sve sudionike, a koristi će prvenstveno ostvariti oni koji su prepoznali potencijal inovativnih tehnologija. Posljedično dinamici promjena bankarske industrije potaknute digitalizacijom protekom desetak godina lista 20 najvećih banaka Europe 2017. godine sada uključuju trećinu dosad potpuno nepoznatih imena. Digitalizacija je omogućila ulazak novih konkurenata i nedvojbeno izmijenila strukturu ponude bankarskih usluga koje sada nadilaze domenu financijskog tržišta. Ulaskom novih konkurenata raste kvaliteta usluge, a ukoliko banke žele zadržati vodeću poziciju moraju revitalizirati svoje konkurentske prednosti. Presudno je razmatrati disruptivne tehnologije, a pobjednici će biti one organizacije koje ponude kvalitetu usluge iznad industrijskog standarda. U trci za liderstvo banke imaju na raspolaganju kontrolu operativnih troškova, postojeće baze podataka, partnerstva s nizom financijskih i nefinancijskih organizacija pri čemu je istovremeno neophodno garantirati sigurnost svojih klijenata. Prema Schafer (2018) od svih slučajeva curenja podataka u virtualnom prostoru 8,5 % je bilo u financijskom sektoru uključujući entitete poput banaka, kreditnih unija, kartičnih kompanija, brokera, investicijskih kompanija i mirovinskih fondova između ostalih. Posljedično navedenom može se reći kako se banke nalaze na raskrsnici pri čemu odabiru ulogu unutar dobavnog lanca koju žele zauzeti (WEF, 2017).

Uzimajući u obzir navedeno, oportuna strategija implicira izvor konkurentske prednosti i predstavlja okosnicu reputacije banke.

Reputacija u bankarstvu ima posebnu važnost jer je bankovna usluga uglavnom "neopipljiva" (Fombrun i sur., 1997), a izvršavanje financijskih transakcija temelji se na povjerenju između različitih dionika. Povjerenje je važan mehanizam funkcioniranja bankovnog sustava¸ preduvjet i posljedica poslovnog odnosa između banke i klijenta (Lange i sur., 2011; Weber i sur., 2011). Zbog specifičnosti bankarske usluge, reputacija u bankarstvu ima stratešku važnost. Na bankovnom tržištu nalazi se veliki broj banaka slične tržišne vrijednost te ne postoje nužno izražena razlikovana svojstva, a reputacija može biti ključan element diferencijacije. Kao četiri odrednice korporativne reputacije Fombrun i sur. (1997) navode vjerodostojnost, odgovornost, pouzdanost i povjerenje. Fombrunu i sur. (2012) ističu kako korporativna reputacija nastaje kao rezultat proteklih aktivnosti i rezultata poduzeća koji predstavljaju sposobnost poduzeća da isporuči vrijedne rezultate i buduće planove svojim interesno-utjecajnim skupinama. Interesno-utjecajne skupine, zajedno sa svojim lobijima, zahtijevaju reakcije vezano uz svoja interesna pitanja (Ihlen, 2007). S pozicije interesno-utjecajnih skupina, reputacija je emotivna reakcija na aktivnosti i komunikaciju poduzeća u skladu s njihovim potrebama i očekivanjima (Grgić, 2012). Dakle, kako bi se izgradila dugotrajna i prepoznatljiva reputacija, poduzeće mora uspostaviti snažne odnose sa svima koji su sastavni dio poduzeća (Brickson, 2005; MacMillan i sur., 2005; Helm i sur., 2013). Naglašavaju se tri važna aspekta izgradnje reputacije: ona se zasniva na percepciji, predstavlja kolektivnu procjenu svih interesno-utjecajnih skupina, a istovremeno je međusobno usporediva. Dakle, reputacija poduzeća je kao suma vrijednosti koje interesno-utjecajne skupine pripisuju poduzeću na osnovi svoje percepcije, njegovog ponašanja i slici koju poduzeće šalje prema javnosti. Ona je strateška imovina i predstavlja ekonomsku vrijednost i sposobnost poduzeća (Fombrun i sur., 2001; Akdeniz i sur. (2013).

Korporativna reputacija kao neopipljivi resurs dio je imovine svakog poduzeća (Demartini i sur., 2013). Neopipljiva imovina utječe na buduću dobit, a nema fizički ili financijski oblik koji snižava troškove (Jerman, i sur., 2010). Reputacija je uz intelektualni kapital i organizaciju jedan od najvažnijih elemenata neopipljive imovine koji predstavlja značajan dio vrijednosti poduzeća (Surroca i sur., 2010). Značaj reputacije poduzeća kao neopipljive imovine je porastao otkad je reputacija definirana kao značajna komponenta konkurentnosti poduzeća (Barkemeyer i sur., 2011; Ekatah i sur., 2012). Reputacija predstavlja nematerijalnu imovinu i

posebno je važna u područjima gdje se transakcije baziraju na povjerenju odnosno izvršenju danih obećanja (Gaultier-Gaillard i sru., 2014).

Reputacija omogućava zapošljavanje najboljih kadrova, daje pristup najboljim profesionalnim pružateljima usluga, povećava učinke prodajnog osoblja i oglašavanja, pomaže povećanju vrijednosti organizacije na tržištu dionica (Cable i sur., 2000; Helm, 2013). Obzirom kako reputacija predstavlja percepciju, odnosno sliku javnosti o banci, ona nije pod ničijom izravnom kontrolom te je stoga njome teško manipulirati (Dean, 2003). Rizik reputacije, odnosno vjerojatnost nastupanja okolnosti koje izazivaju gubitak povjerenja, pri čemu banka trpi štetu, iznimno je važan za svaku banku te se mora nadzirati i njime upravljati (Carter i sur., 1992; Casalo i sur., 2007; Dowling i sur. 2012). Upravljanje reputacijom zahtjeva identificiranje područja reputacijskog rizika kojima je poduzeće izloženo i prepoznavanju ključnih interesno-utjecajnih skupina. Pored osnovnih interesno-utjecajnih skupina koje čine korisnici, zaposlenici, investitori i društvena zajednica, ove skupine uključuju i vlast, konkurenciju i javnost (Dalton i Croft, 2003).

Barnettu, Jermieru i Lafferty (2006) prilikom interpretacije korporativne reputacije naglašavaju čimbenik kvalitete. Ennewu i sur. (2014) kažu kako se povjerenje klijenata odnosno reputacija razvija kada usluge prati znanje, stručnost, dosljednost i zajedničke vrijednosti, a bez visoke kvalitete proizvoda i usluga nije moguće graditi dugoročno održivu reputaciju. Tehnološke inovacije donijele su temeljite promjene u području informacijsko-komunikacijske tehnologije (Barrios i sur., 2008), a reputaciju neće biti moguće zadržati bez dosljedne i pravovremene primjene nove tehnologije, pri čemu se poduzeća mogu značajno razlikovati ovisno o brzini uvođenja novih proizvoda i usluga (Houben i sur., 2002; Kim i sur., 2004).

Razvoj Interneta omogućio je pojavu virtualnog bankarstva koje uključuje transakcijsko poslovanje, pružanje usluga korisnicima i trenutno pretraživanje informacija (Meuter i sur., 2000). To je omogućilo brojne pogodnosti u traženju informacija, novih proizvoda i usluga te opći porast kvalitete. Tradicionalno bankarstvo razvija se u smjeru dislocirane komunikacije i direktnih transakcija koje putem udaljenih terminala zadaju sami s klijenti. Razvojem internetskog bankarstva pojavile su se i potpuno virtualne banke koje svoje cjelokupno poslovanje obavljaju putem elektroničke komunikacije (Jayawardhena i sur., 2000; Wu i sur., 2014) .

U globalnom konkurentskom okruženju informatička tehnologija se koristi za pružanje bankarskih usluga zahtjevnim potrošačima (Ganguli i Roy, 2011), a u cilju smanjenja troškova, povećanja lojalnosti te ukupnog zadovoljstvo klijenata, kontinuirani napredak tehnologije primorao je banke na uvođenje novih oblika distribucije proizvoda i usluga (Peevers, 2011). Razvoj alternativnih kanala ostaje važan alat izgradnje reputacije, zadržavanja postojećih klijenata, privlačenja novih te važan faktor uspjeha financijskih institucija (Calisir i Gumussoy, 2008). Razvoj elektroničkih kanala značajno je promijenio poslovanje banaka, a fizička interakcija između djelatnika i klijenta postaje manje važna (Bitner, 2000).

Mobilno bankarstvo počelo se razvijati kao jedan od ključnih oblika virtualnog bankarstva (Lin i sur., 2011) pri čemu se uz pomoć mobilne internetske tehnologije omogućio fleksibilan pristup bankovnim uslugama neovisno radnom vremenu banke (Xie i sur., 2009; Coccorese, 2013). U odnosu na internet bankarstvo mobilna dimenzija tehnologije omogućava stalnu dostupnost, obavljanje transakcije u kratkom roku, jednostavnost korištenja i personalizaciju (Asfour i sur. 2014).

Važno je napomenuti kako uvođenje tehnologije mobilnog bankarstva nije bez rizika. Laukkanen (2017) napominje kako tehnološke inovacije koje zahtijevaju učenje od strane klijenata ili koje prati nedostatak relevantnih informacija obeshrabruju klijente u njihovom usvajanju. Ha i sur. (2012) naglašavaju kako prilikom usvajanja nove tehnologije od strane klijenata treba voditi računa o percipiranom trošku, riziku, koristima te usklađenosti. Također, važan kamen spoticanja ostaje sigurnost. Lallmahamood (2007) sigurnost definira kao percepciju korisnika o kontroli osobnih podataka i zaštite od rizika poslovanja u bežičnom okruženju. Percepcija sigurnosti predstavlja osobno uvjerenje kako pružatelj usluge ima sustav koji omogućava sigurno izvršavanje transakcija i zaštitu osobnih podataka. Prema Jahangir i sur. (2007) percipirana korisnost, jednostavnost korištenja, sigurnost i povjerljivost podataka imaju snažan utjecaj na prihvaćanje usluge elektroničkog bankarstva. Sigurnost internetskog i mobilnog bankarstva može predstavljati ograničenje u korištenju novih tehnologija. Unaprjeđenje i podizanje razine sigurnosti mobilnih plaćanja te primjena suvremenih i naprednih tehnologija ključna je za povećanje broja korisnika usluge mobilnih plaćanja. Zbog zabrinutosti klijenata, industrija kontinuirano razvija nova i kvalitetnija rješenja mobilnog plaćanja za sigurno provođenje transakcija. Kako bi se povećala sigurnost procesa, transakcije koriste EMV standard (globalni standard za odobravanje plaćanja debitnom i kreditnom karticom, a obuhvaća procesiranje plaćanja debitnom i kreditnom karticom koje imaju čip sa

mikroprocesorom) i standardne specifikacije odobravanja plaćanja za autorizaciju kreditnih i debitnih transakcija sa čipom[1]. Posljedično razlikama regulacije, prihvaćanje EMV čipova značajno se razlikuje i unutar sličnih tržišta. Pod pritiskom trgovaca, širenje EMV tehnologije u SAD-u u odnosu na Kanadu dogodilo se značajno sporije. Naim, 2016. godine u SAD-u od ukupnog broja transakcija svega 18,6% transakcija koristi spomenutu tehnologiju, dok je udio istih transakcija u Kanadi bio 90,7% (WEF, 2017). Nadalje, proizvođači mobilnih uređaja kontinuirano unaprjeđuju tehnologiju kako bi uveli nove načine plaćanja: beskontaktno plaćanje, plaćanje NFC[2] tehnologijomili autentifikaciju otiskom prsta. Povećanje razine sigurnosti povezuje se sa unaprjeđenjem servisa mobilnih plaćanja te može povećati povjerenje potrošača u nove tehnologije i njihovo korištenje (Federal Reserve Board, 2015). Strukturalna sigurnost kao komponenta povjerenja prema institucijama ima pozitivan učinak na korištenje mobilnog bankarstva (Morris, 2012).

Stopa korištenja mobilnog bankarstva u stalnom je porastu, a rast uporabe mobilnih telefona kao instrumenta plaćanja na prodajnim mjestima raste još brže. Južna Koreja prednjači u korištenju mobilnog bankarstva pri čemu je 2013. godine imala 115% penetracije korisnika mobilnog bankarstva u odnosu na populaciju odraslih. U SAD-u i Europi posljednjih je godina također zabilježen snažan rast (EFMA, 2014). U SAD-u 87% odrasle populacije koristi mobilni telefon, a 71% mobilnih telefona su pametni uređaji. Od vlasnika mobilnih telefona koji imaju bankovni račun 2014. godine njih 39% koristilo je mobilno bankarstvo. Krajem 2013. godine u Hrvatskoj 1,14 milijuna klijenata imalo je ugovorenu uslugu internetskog bankarstva, dok je 431,5 tisuća imalo uslugu mobilnog bankarstva (HNB, 2014).
Obzirom na stalan rast korisnika mobilnog bankarstva u Hrvatskoj te sve veći značaj koji za banke ima poslovanje sa klijentima putem navedenog kanala, provelo bi se ispitivanje povezanosti mobilnog bankarstva kao strateške odrednice banaka na njihovu reputaciju.

[1] engl. "chip and pin" ili "chip and signature"

[2] akronim od engl. Near Field Communications

1.1 Problem istraživanja

U posljednjih nekoliko godina tradicionalno bankarsko poslovanje se mijenja, suočavajući se sa novim izazovima u poslovanju: snažan porast korištenja mobilnih uređaja promijenio je ponašanje klijenata uvodeći novi bankarski kanal koji bilježi snažan rast, a s druge strane snažan napredak tehnologije koji je promijenio tradicionalan način poslovanja banaka sa klijentima potaknuo je pojavu fleksibilnijih financijskih subjekata na tržištu koji konkuriraju bankama. U takvim uvjetima novi kanali i modeli poslovanja klijenata sa bankom predstavljaju izazov za upravljanje reputacijom banaka.

Dosadašnja istraživanja o mobilnom bankarstvu usmjerena su uglavnom na determinante korištenja mobilnog bankarstva, pretežito u sklopu modela prihvaćanja tehnologija[3]. Do sada nije provedeno istraživanje koje bi ispitalo povezanost mobilnog bankarstva i reputacije banaka. Temeljem analize dosadašnjih istraživanja postavlja se nekoliko istraživačkih pitanja:

(1) Na koji način su sigurnost, dostupnost i jednostavnost korištenja mobilnog bankarstva povezani sa percipiranom kvalitetom usluge mobilnog bankarstva banke?;

(2) Postoji li povezanost između percipirane kvalitete usluge mobilnog bankarstva i reputacije banke?

Navedena pitanja postavljaju se kao istraživačka pitanja ove disertacija kojima se želi postići saznanje o tome utječe li implementacija mobilnog bankarstva kao strateške orijentacije banaka na njihovu reputaciju. Budući da su prethodna istraživanja pokazala kako su korisnicima internetskog bankarstva za njihovu percepciju kvalitete važni sigurnost i jednostavnost korištenja internetskog bankarstva, može se pretpostaviti kako iste determinante utječu na mobilno bankarstvo. U radu se korištenjem primarnog anketnog istraživanja istražuje percepcija ispitanika-korisnika mobilnog bankarstva te mjeri sigurnost, jednostavnog korištenja, dostupnost i percipirana kvaliteta usluga mobilnog bankarstva, kao i reputacija banke. Korištenjem metode višestruke linearne regresije testiraju se istraživačka pitanja rada, formulirana kao hipoteze rada. Cilj rada je teorijski i empirijski utvrditi povezanost mobilnog bankarstva kao strateške orijentacije banaka i njihove reputacije. S obzirom da je unaprjeđenje

[3] engl. Technology Acceptance Model

korištenja informacijsko-komunikacijskih tehnologija u poduzećima jedan od glavnih ciljeva strategije Europe 2020 Europske Unije navedeno ima dodatni značaj i važnost.

1.2 Ciljevi istraživanja

Važnost ciljeva istraživanja rezultat je mogućnosti izrade potencijalnih dugoročno održivih strategija razvoja banaka uvisoko konkurentnoj bankarskoj industriji koji se oslanjanju na relevantne primarne i sekundarne izvore podataka koji su korišteni prilikom izrade doktorske disertacije. Polazeći od teorijskih koncepata, postojećih istraživanja i rezultata primarnog istraživanja može se razmatrati uloga tehnologije i posljedično derivirati složene trehnološke politike razvoja banaka.

Sukladno ciljevima istraživanja dan je pregled karakteristika bankarske industrije i financijskog tržišta. Također kao rezultat ciljeva istraživanja moguće je analizirati utjecaj percepcije jednostavnosti, dostupnosti na kvalitetu poslovanja banaka s naglaskom na mobilno bankarstvo i posljedično na njihovu reputaciju. Na osnovi rezultata istraživanja sukladno prethodno postavljenim ciljevima mogu se ponuditi preporuke za buduće aktivnosti povezanh sa tehnološkim stgrategijama financijskog tržišta.

Ciljevi istraživanja provedeni su kvalitativnim i kvantitativnim testovima u skladu s prethodno postavljenim hipotezama istraživanja. Istraživanje ima za cilj doprinijeti definiranju područja za korištenje informacijsko-komunikacijskih tehnologija u mobilnom bankarstvu koji u najvećoj mjeri utječu na reputaciju banaka. Također je cilj definirati aspekte mobilnog bankarstva (sigurnost, jednostavnost korištenja i dostupnost usluge) koji u najvećoj mjeri utječu na reputaciju banaka. Jedan od najznačajnijih doprinosa rada je unaprjeđenje i poticanje značaja informacijsko-komunikacijskih tehnologija za rast konkurentnosti.

Problem istraživanja, dispozicija rada te istraživačka pitanja čine osnovu za definiranje temeljnih ciljeva istraživanja:

- **C1:** Empirijski utvrditi povezanost percipirane kvalitete usluge mobilnog bankarstva i reputacije banke
- **C2:** Empirijski utvrditi način na koji sigurnost, jednostavnost korištenja i dostupnost usluge utječu na percipiranu kvalitetu usluge mobilnog bankarstva.

Također su definirani i dodatni ciljevi doktorske disertacije, na osnovu analize dosadašnjih istraživanja:

C3: Definirati i konceptualizirati pojam reputacije uz poseban osvrt na analizu mjerenja reputacije, kao i na dosadašnja mjerenja reputacije Hrvatskih banaka.

C4: Identificirati i objasniti ključne determinante kvalitete usluga mobilnog bankarstva;

C5: Prikazati dosadašnja saznanja iz područja determinanti reputacije banaka te se kritički osvrnuti na dosadašnja istraživanja;

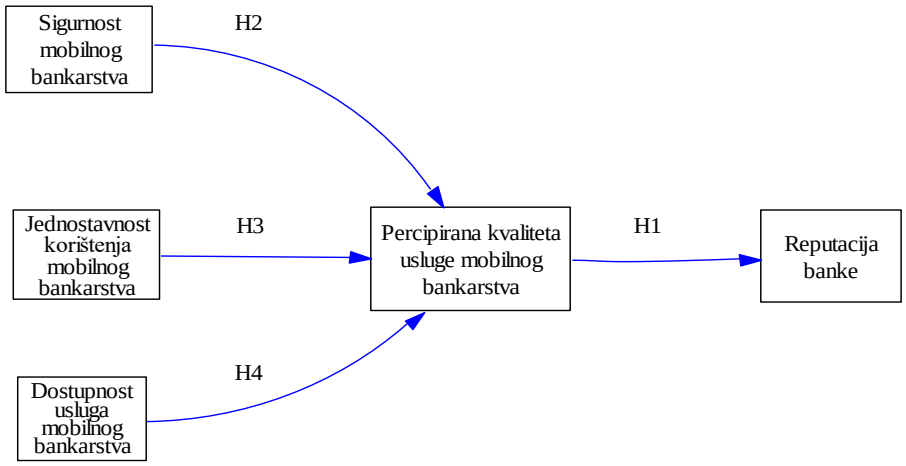
C6: Ispitati povezanost mobilnog bankarstva kao strateške odrednice banaka i reputacije banaka;

C7: Ukazati na važnost korištenja naprednih informatičkih tehnologija u bankarstvu, kao važne odrednice reputacije banaka;

C8: Ispitati stupanj osviještenosti hrvatskih građana o sigurnosti usluga mobilnog bankarstva.

1.3 Hipoteze istraživanja

Kako bi se postigli navedeni ciljevi koncipiran je model kojim se želi istražiti povezanost mobilnog bankarstva kao strateške orijentacije banaka i njihove reputacije, razvijen je model, temeljem teorijske literature, kao i empirijskih istraživanja (Slika 1).



Slika 1. Model istraživanja

Sofisticirani pogled na reputaciju obuhvaća sociološke i kognitivne procese koji unutar dinamičnog okružrenja formiraju organizacijsku reputaciju. Prema Ravasi i sur. (2018) postoji šest perspektiva organizacijske reputacije: pristup terorije igara (ekonomika informacija i signaliziranje), strateški pristup (analiza neopipljive imovine alatima strateškog menadžmenta), makro i mikro kognitivni pristup (kolektivna i individualna sociološko-kognitivna dimenzija), kulturno-sociološki (socio-politički procesi) i komunikacijski (utjecaj interakcije informacija na formaciju reputacije). Pristup teorije igara kaže da sudionici tržišta imaju asimetrične informacije o međusobnoj motivaciji i strateškim pristupima, a reputacija služi kao aproksimacija tih nastojanja te se posljedično namjerim aktivnostima poduzeća nastoje komunicirati one atributi koji su neprimjetni i nematerijalni. Na osnovu tih informacija primatelji nastoje derivirati potencijal stvaranja vrijednosti za korisnika. Strateški pristup podrazumijeva reputaciju kao nematerijalnu imovinu koja odražava višedimenzionalnu komparativnu procjenu od strane interesnih skupina. Kreatori informacija osim poduzeća mogu biti i njihovi konkurenti. Makro pristup podrazumijeva društveno konstruiranu reputaciju kao rezultat prvenstveno trećih strana često institucionalnih sudionika tržišta. Mikro pristup kaže da je reputacija komparativna ocjena analitičkih dimenzija ili globalna ocjena dojmova organizacije. Reputacija nastaje kao rezultat kognitivnih procesa, dojmova i prakse. Informacije

distribuiraju poduzeća, konkurenti i treće organizacije. Kulturno-sociološki pristup podrazumijeva reputaciju kao evaluaciju organizacija prema etičkim, tehničkim i umjetničkim kriterijima. Sociološke konstrukcije te interpretacija događaja formira kolektivnu percepciju interaktivnih okruženja. Kritičari, povijesničari i novinari konkururaju svojim interpretacijama. Komunikacijski pristup definira reputaciju kao opću ocjenu organizacije. Podrazumijeva kontinuiranu evaluaciju reprezentacije putem aktivnosti komunikacije. Izvori informacija su individualni ili institucionalni sudionici pri čemu se kolektivno kreira razumijevanje organizacijskih aktivnosti.

Rast i razvoj upotrebe Interneta predstavljaju jedan od ključnih utjecaja na upravljanje korporativnom reputacijom. Utjecaj društvene dimenzije interneta često nazivanog Web 2.0 nedvojbeno je promijenio način na koji poduzeća komuniciraju s interesnim skupinama i stvaraju dodanu vrijednost brenda. Web kanali imaju potencijala dosegnuti veliki broj korisnika u kratkom vremenu, ali kontekst u kojem se poduzeće spominje ne mora nužno uvijek biti pozitivan (Jones i sur., 2009). Komunikacija informacija o aktivnostima organizacije više nisu isključivo rezultat nastojanja same organizacije ili nekolicine često međusobno povezanih institucionalnih sudionika. Objava teksta, slike ili video materijala putem društvenih mreža od strane pojedinaca koji ne moraju nužno biti utjecajne osobe danas je u potpunosti uobičajena, a može biti naknadno popraćena institucionalnom medijskom intervencijom. Kao posljedica interakcije povećava se heterogenost izvora: njihova ograničenja, motivi i selekcija u odabiru informacija za objavu, dok objave u areni društvenih mreža za razliku od nepristranog objektivnog informiranja institucionlanih medija često prate duhoviti ili emotivni elementi. Nadalje, ako se poduzeće povezuje s nekim incidentom, reputacija brenda može u kratkom roku biti snažno narušena. Koristi i rizici poslovnih odluka moraju biti pažljivo valorizirani, a dvosmjerna komunikacija s interesnim skupinama predstavlja važnu dimeziju koporativne reputacije (Etter i sur., 2019). Kvaliteta usluge predstavlja okosnicu reputacije banaka. Neovisno o tome je li pomak kvalitete usluge bio pozitivan ili negativan društveni aspekt interneta ima tendeciju amplifikacije. Ukoliko postoje poslovne odluke koje su rezultirale kvalitetom usluge koje nije na razini industrijskog standarda, društvena dimenzija interneta će amplificirati njihove efekte na korporativnu reputaciju. Primjerice društveno neodgovorno ponašanje banaka ili sigurnosni incident može značajno narušiti vrijednsot brenda banke. Posljedično tehnološkom napretku i promjeni načina življenja digitalizacija financija postaje standard bankarske industrije. Procjenjuje se kako trenutno jedna trećina ukupne populacije koristi pametni telefon (EFMA, 2017a), a jedna sedmina populacije neki od oblika mobilnog

bankarstva (Multz, 2014). Rastuća upotreba pametnih telefona stvorila je preferenciju klijenata za mobilnošću te istovremeno veliki pritisak na financijske institucije infrastrukture odgođenih transakcija (Parameswar, Dhir, & Dhir, 2017). Digitalno bankarstvo s naglaskom na mobilno bankarstvo pojavljuje se kao jedan od najvažnijih kanala transfera novca putem banaka. Mobilno bankarstvo omogućava trenutni pristup financijskim uslugama, jednostavnost, brzinu i pogodnost uz gotovo zanemarive transakcijske troškove na strani banaka. Razvoj industrije telekomunikacija odnosno masovna upotreba mobitela stvorili su izniman ekonomski potencijal, a banke su prepoznale važnost digitalnog plasmana financijskih usluga. Iako ponuda usluga digitalnog bankarstva podrazumijevajući alternativne načine isporuke financijskih usluga inkorporira tradicionalne financijske proizvode, istovremeno omogućuje pristup proizvodima i tržištima koja dosad nisu bila dio standardnog portfolia banke. Kvaliteta proizvoda predstavlja predispoziciju dugoročnog uspjeha banaka, a digitalno bankarstvo obilježeno fleksibilnošću ne samo da posljedično povećava razinu kvalitete i zadovoljstva klijenata nego omogućuje razvoj odnosno plasman proizvoda izvan tradicionalne lepeze ponude financijskih institucija. Upotreba inovativnih tehnologija poput API (Application programming interface) sustava, Blockchaina, NLP-a (natural language processing), NLG-a (natural language generation), virtualne stvarnosti i umjetne inteligencije čine mobilno bankarstvo jednim od najvažnijih budućih kanala komunikacije klijenata i banaka. Platforme i decentralizirana tehnologija omogućuju dosad nezabilježene kapacitete agregiranja i analize podatka i povećavaju stupanj međusobne povezanosti. Inovacije ojačane novim algoritmima i modernim računarskim procesorima omogućuju dizajniranje proizvoda i usluga skalabilnih kapaciteta. Zahvaljujući novoj infrastrukturi smanjuje se utjecaj posrednika, a time i cijena usluge. Mogućnost digitalnog dokumentiranja transakcija, bolje razumijevanje ponašanja klijenata omogućuje derivaciju novih informacija te istovremeno ostvarivanju prihoda koji su rezultat njihove monetizacije (WEF, 2015). Slijedom navedenog može se reći kako mobilno bankarstvo ima značajan doprinos ukupnoj kvaliteti usluge odnosno ponude organizacija financijskog tržišta.

Povezanost percipirane kvalitete usluge mobilnog bankarstva i reputacije banke

Brojna su istraživanja determinanti kvalitete internetskog bankarstva (npr. Jayawardhena, 2004; Rod i sur., 2009; Ganguli i sur., 2011). Međutim, do sada nisu provedena slična istraživanja vezano uz mobilno bankarstvo, već su do sada istražene samo determinante korištenja mobilnog bankarstva (Zhou, 2012; Akturan i sur., 2012) ili utjecaj mobilnog bankarstva na lojalnost (Sagib, i sur, 2014) i zadovoljstvo (Asfour i sur., 2014). Mobilno bankarstvo imat će sve veću

ulogu, budući da mobilne tehnologije povećavaju svoju primjenu u odnosu na tehnologije temeljene na računalima (Funk, 2005). Fombrun i sur. (2011) ističe kako reputacija u bankarstvu ima veliku važnost, budući da se izvršavanje financijskih transakcija temelji na povjerenju. Grgić (2012) istražuje utjecaj kvalitete usluga banke na njezinu reputaciju, ali pri tome se orijentira na sveukupne usluge banke, pri čemu se ne usredotočuje na pojedine kanale distribucije banaka. Jun i sur. (2001) istražuje utjecaj kvalitete online usluga općenito na reputaciju banke, kao i Cai i sur., (2003). Pri tome, percipiranu kvalitetu usluge mobilnog bankarstva definiramo kao percepciju klijenata banke da je sustav mobilnog bankarstva sposoban pružiti uslugu koja će u visokoj mjeri zadovoljiti njihove potrebe i očekivanja. Ova definicija adaptirana je prema autorima Ennew i Waite (2007). Reputacija banaka definira se kao percepcija klijenata kako je banka vjerodostojna, pouzdana, odgovorna i dostojna njihovog povjerenja (Ponzi, Fombrun, & Gardberg, 2011). Temeljem navedenih istraživanja definirana je prva i glavna hipoteza ovoga rada:

H1: Percipirana kvaliteta usluge mobilnog bankarstva pozitivno utječe na reputaciju banke.

Utjecaj sigurnosti mobilnog bankarstva na percipiranu kvalitetu usluge mobilnog bankarstva

Sigurnost mobilnog bankarstva definiramo kao sposobnost sustava da onemogući neovlašteni pristup informacijama i sredstvima na računima korisnika. Kim i sur. (2009) naglašavaju da relativna korisnost, povjerenje i strukturna jamstva imaju signifikantan utjecaj na inicijalno povjerenje u mobino bankarstvo. Percepcija povjerenja i relativna korisnost usluge su također ključne za namjeru korištenja usluge od strane korisnika. Glavne zapreke korištenju usluge mobilnog bankarstva su preferiranje korištenja ostalih bankovnih kanala za izvršavanje plaćanja i obavljanje bankovnih usluga, ali i zabrinutost zbog sigurnosti mobilnog bankarstva i mobilnih tehnologija za izvršavanje plaćanja (Chen, 2013). Temeljem navedenog istraživanja definirana je druga hipoteza ovoga rada:

H2: Sigurnost mobilnog bankarstva pozitivno utječe na percipiranu kvalitetu usluge mobilnog bankarstva banke.

Utjecaj jednostavnosti korištenja mobilnog bankarstva na percipiranu kvalitetu usluge

Jednostavnost korištenja mobilnog bankarstva omogućava intuitivno korištenje sustava. Ove definicije adaptirane su prema autorima Wang, Lo & Hui (2003), koji su ih definirali za usluge

bankovnog sustava općenito. Temeljem navedenog istraživanja definirana je treća hipoteza ovoga rada:

H3: Jednostavnost mobilnog bankarstva pozitivno utječe na percipiranu kvalitetu usluge mobilnog bankarstva banke.

Utjecaj dostupnosti usluga mobilnog bankarstva na percipiranu kvalitetu usluge

Za mobilno bankarstvo, važna je i dostupnost kao jedna od karakteristika modernih pametnih telefona. Međutim, pri tome je važna paleta usluga koje su dostupne klijentima kroz uslugu mobilnog bankarstva. Mobilno bankarstvo u svom najjednostavnijem obliku može podržavati pružanje potpore provođenju jednostavnih bankovnih transakcija (plaćanje računa), ali u kompleksnijem sustavu mogu biti dostupne usluge kao što su ugovaranje trajnih naloga, ugovaranje oblike štednje i ulaganja, te ugovaranje dodatnih usluga kao što su ugovaranje osiguranja. Najviša razina dostupnosti usluga mobilnog bankarstva je prisutna u onim sustavima koji omogućvaju pružanje personaliziranih usluga, kao i presonaliziranih marketinških poruka. Na temelju navedenog definirana je četvrta hipoteza ovoga rada

H4: Dostupnost usluga mobilnog bankarstva pozitivno utječe na percipiranu kvalitetu usluge mobilnog bankarstva banke.

1.4 Metode znanstvenog istraživanja

Radne hipoteze koje se testiraju u disertaciji definirane su na osnovu proučavanja dosadašnjih istraživanja relevantnih svjetskih i domaćih izvora, a testiraju se korištenjem metode višestrukih modela jednostavne i složene linearne regresije.

Kako bi se ispitale hipoteze ovoga rada, provelo se primarno istraživanje metodom ispitivanja pomoću strukturiranog anketnog upitnika. Način komuniciranja sa ispitanicima je bio putem elektroničke pošte.

Ciljna populacija ovog istraživanja je populacija hrvatskih građana u dobi od 18 do 65 godina, koji koriste usluge mobilnog bankarstva. Navedenim istraživanjem mjeri se ugled i poznatost banke, pozitivna percepcija banke i percipirana kvaliteta usluga.

Uzorak za ovo istraživanje je namjerni, kvotni uzorak, pri čemu su kontrolne varijable dob i spol ispitanika te banka čije usluge mobilnog bankarstva koriste. U uzorku se nalazi ukupno 372 ispitanika, distribuiranih s obzirom na dob i spol prema strukturi populacije Republike Hrvatske dostupne za posljednji popis stanovništva. Uzorkom se obuhvatio podjednak broj ispitanika, klijenata za pet izabranih banaka Republike Hrvatske.

Ovo istraživanje se provelo u dvije faze:

- Prva faza: provelo se preliminarno anketno ispitivanje kojim se željelo testirati razumijevanje anketnog upitnika. U preliminarnom dijelu istraživanju sudjelovao je manji broj ispitanika, a provjerilo se da li su anketna pitanja jednoznačna i da li ih ispitanici razumiju. Temeljem rezultata prve faze istraživanja provelo se prilagođavanje upitnika te izrada konačnog anketnog upitnika za testiranje radnih hipoteza disertacije.
- Druga faza: provelo se zaključno, opisno istraživanje korištenjem strukturiranog anketnog upitnika. Ovaj dio istraživanja se provelo korištenjem on-line upitnika na koji su ispitanici bili pozvani putem elektroničke pošte. Tijekom istraživanja se provjeravalo da li podaci slijede planirani kvotni dizajn uzorka. Nakon što su se podaci prikupili, pristupilo se pripremi i provjeri podataka prikupljenih anketnim ispitivanjem. Navedeno se provodilo testovima koji imaju za cilj ispitati netipične vrijednosti u podacima i ispitati pretpostavke o normalnoj distribuciji manifestnih varijabli. Kako bi se testirale hipoteze rada provela se analiza podataka korištenjem metode višestruke linearne regresije prema modelu prikazanom na Slici 1.

1.5 Očekivani znanstveni doprinos

Znanstvenim doprinosom smatra se sinteza i prikaz recentnih trendova korištenja informacijsko-komunikacijskih tehnologija u bankarstvu s osvrtom na usluge mobilnog bankarstva, koji će se temeljiti na analiziraju podataka prikupljenih primarnim istraživanjem.

Kako bi se utvrdilo na koji način sigurnost, jednostavnost korištenja i dostupnost usluge mobilnog bankarstva banke utječe na kvalitetu mobilnog bankarstva banke, te dodatno na koji način percipirana kvaliteta usluge utječe na reputaciju, koristila se metoda višestrukih modela jednostavne i složene linearne regresije. Primjenom ove metode istražile su se direktne i indirektne determinante reputacije banaka. Znanstvenim doprinosim smatra se i činjenica da se analiza povezanosti po prvi puta istražuje na području Republike Hrvatske, ali i u svjetskoj znanstvenoj literaturi, gdje takvo istraživanje do sada još nije provođeno. Primjenom metode višestrukih modela jednostavne i složene linearne regresije na primarnim podacima dobili su se odgovori na pitanja postavljena u skladu s ciljevima rada te su neke od postavljenih hipoteza i potvrđene.

S naglaskom na primjeni relevantnih aspekata teorije i prakse konceptualizirane su komponente kvalitete usluga mobilnog bankarstva, što omogućava bolji uvid u njihovu povezanost sa reputacijom banaka. Kroz razumijevanje ključnih mjera i pokazatelja kvalitete usluga mobilnog bankarstva ukazuje se na uzročno-posljedične veze koje omogućavaju stvaranje aktivnih praksi povezanosti sa reputacijom banaka kroz poticanje razvoja korištenja informacijsko-komunikacijskih tehnologija. Na taj način dizajnirao se skup aktivnosti koji najbolje odgovara lokalnim uvjetima u kojima banke posluju, te se omogućilo stvaranje konkurentske prednosti banaka.

U procesu izrade rada doprinijelo se identificiranju onih aspekata korištenja mobilnog bankarstva koji u najvećoj mjeri potiču porast reputacije banaka. Rezultati istraživanja je podloga za izradu preporuka za korištenje informacijsko-komunikacijskih tehnologija u području mobilnih komunikacija, kao poticaja rasta reputacije banaka.

2 KARAKTERISTIKE BANKARSKOG SEKTORA U REPUBLICI HRVATSKOJ

U ovom poglavlju detreminirane su specifičnosti bankarskog sektora u Republici Hrvatskoj te je iz perspektive važnosti za konkuretnost opisana reputacija kao iznimno važan čimbenik poslovanja suvremenih institucija.

2.1 Specifičnosti bankarskog sektora u Republici Hrvatskoj

U poglavlju se razrađuje vlasnička struktura i koncentracija bankarskog tržišta u Republici Hrvatskoj.

Kreditne institucije u Republici Hrvatskoj mogu se, prema vlasničkoj strukturi, podijeliti na kreditne institucije u domaćem većinskom privatnom vlasništvu domaćih fizičkih i/ili pravnih osoba sa sjedištem u RH, kreditne institucije u domaćem većinskom državnom vlasništvu te kreditne institucije u većinskom vlasništvu inozemnih fizičkih i/ili pravnih osoba sa sjedištem u inozemstvu. U promatranom periodu 2005. do 2016. godine smanjen je broj kreditnih institucija u većinskom domaćem privatnom vlasništvu te je smanjen i udio njihove imovine. U istome periodu porastao je broj banaka u većinskom stranom vlasništvu te je njihov udio u imovini kreditnih institucija iznosio 89,9%. Na ovaj trend utjecala je i liberalizacija tržišta kapitala Europske Unije te trend prelijevanja kapitala iz razvijenih zemalja sa niskim prinosima na manje razvijene financijske sustave sa višim prinosima na tržištu. S obzirom na prikazane trendove u financijskom sektoru Republike Hrvatske se očekuje daljnje jačanje konkurentnosti te posljedično smanjenje stopa profitabilnosti.

Prema podacima HNB-a u lipnju 2016. godine na tržištu Republike Hrvatske izražena je koncentracija banaka koje čine 98,06% ukupne imovine kreditnih institucija. Tri najveće kreditne institucije u RH upravljaju C_3=58,3% ukupne imovine kreditnih institucija. Na tržištu kreditnih institucija RH dominira deset banaka koje čine 90% ukupne imovine. Republika Hrvatska se u odnosu na zemlje Europske unije prema koeficijentu koncentracije C5 te HH indeksu nalazi na 7./28. i 8./28 mjestu.

U posljednjih nekoliko godina konsolidacija, restrukturiranje i koncentracija su glavna obilježja financijskog tržište Europske unije te se i broj kreditnih institucija u periodu 2008. do 2015.

godine smanjio u cilju smanjenja troškova. Kao rezultat restrukturiranja u 2015. godini dodatno raste efikasnost sustava. U periodu 2005.-2014. pokazatelji koncentracije kreditnih institucija Europske unije su kontinuirano rasli. U cilju revitalizacije financijskog tržišta Europske unije i poticanja dinamike tehnološke revolucije kreirane su dvije regulatorne mjere: PSD1 2007. godine te PSD2 2015. godine. Njima se željelo potaknuti konkurenciju, smanjiti troškove međunarodnih transakcija te potaknuti dijeljenje podataka o financijskim transakcijama na skupnoj razini. Zakonodavni okvir SEPA[4] izjednačava trošak domaćih transakcija sa transakcijama unutar EFTA-e[5], dok IFA[6] regulativa ograničava naknade za pojedine vrste transakcija te zabranjuje selektivan odabir kartičnog plaćanja od strane trgovaca.

Takvu situaciju žele iskoristiti Fintech organizacije koje teže pristupiti bankovnim podacima kako bi uspostavile napredne poslovne modele uz zadržavanje visoke razine sigurnosti podataka i posljedično povjerenja klijenata. Koristeći API (strukturu interakcije raznovrsnih aplikacija) poslovne organizacije mogu implementacijom aplikacija vanjskih partnera stvoriti novu dodanu vrijednost za klijente, te koristeći prednosti digitalizacije pristupiti velikom broju potencijalnih klijenata. S obzirom da API tehnologija stvara ključne promjene unutar raznih industrija, njezina vrijednost značajno raste.

2.1.1 Vlasnička struktura

Struktura vlasništva banaka u Republici Hrvatskoj može se pratiti na osnovi odluke o supervizorskim izvještajima kreditnih institucija (NN, br. 41A/2014., 127/2014. i 67/2015.), odnosno obrazaca PD32 i obrazaca BS2-2 statističkog izvještaja o udjelu imovine prema odluci o statističkom i bonitetnom izvješćivanju (NN, br. 35/2010., 95/2010., 146/2010., 68/2011., 37/2012., 121/2013., 41A/2014., 127/2014. i 67/2015.) Važno je napomenuti kako u sustavu kreditnih institucija Republike Hrvatske imovinom dominiraju banke (98%) te obzirom na veličinu i vlasništvo banaka i stambenih štedionica, regulatora odnosno Hrvatsku narodnu banku izvještavaju na konsolidiranoj osnovi (vidjeti Prilog 2).

[4] akronim od engl. Single Euro Payments Area
[5] akronim od engl. European Free Trade Area
[6] akronim od engl. Interchange Fee Regulation

Od ukupno pet štedionica, njih četiri se nalazi u potpunom vlasništvu jedne od 28 banaka registriranih u RH. Najveća stambena štedionica odnosno Prva stambena štedionica d.d. u apsolutnom je vlasništvu Zagrebačke banke d.d.. Duga po veličina Wüstenrot stambena štedionica d.d. jedina je stambena štedionica koja nije u vlasništvu jedne od 28 hrvatskih banaka već je apsolutni vlasnik Bausparkasse Wustenrot AG, a obuhvaća svega 0,5% ukupne imovine kreditnih institucija. Treća po veličini je PBZ stambena štedionica d.d. te se nalazi u apsolutnom vlasništvu Privredne banke Zagreb d.d, dok su četvrta i peta po veličini stambene štedionice bile Raiffeisen stambena štedionica d.d. i HPB-stambena štedionica d.d. u apsolutnom vlasništvu istoimenih banaka. Ukupna imovina svih stambenih štedionica činila je svega 1,94% ukupne imovine kreditnih institucija (vidjeti tablicu 3, vidjeti prilog 2).

Obzirom na vlasništvo, sve kreditne institucije u Republici Hrvatskoj kategoriziraju se kao kreditne institucije u domaćem privatnom vlasništvu koje imaju većinsko vlasništvo domaćih fizičkih osoba i/ili pravnih osoba sa sjedištem u RH, banke u većinskom domaćem državnom vlasništvu i kreditne institucije u većinskom vlasništvu inozemnih fizičkih osoba i inozemnih pravnih osoba sa sjedištem u inozemstvu. Može se primijeti kako je u razdoblju od VII.2005. do VI. 2016. broj kreditnih institucija u većinskom domaćem privatnom vlasništvu smanjen sa 18 na 10 kreditnih institucija te se njihov udio imovine smanjio sa 5,3% na 4,5% (Kreditna Banka Zagreb d.d, Karlovačka Banka d.d., Imex Banka d.d, VABA d.d. banka Varaždin, Slatinska banka d.d., Partner banka d.d., Štedbanka d.d., Banka Splitsko-Dalmatinska d.d), dok je broj banaka u većinskom inozemnom vlasništvu sa 14 porastao na 16 (Zagrebačka banka d.d, Privredna banka zagreb d.d., Erste&Steiermärkische bank d.d., Raiffeisenbank Austria d.d., Société Générale-Splitska banka d.d., Hypo Alpe-Adria-bank d.d., OTP banka Hrvatska d.d., Sberbank d.d., Podravska banka d.d., Istarska kreditna banka Umag d.d, Kentbank d.d, BKS Bank d.d., Veneto banka d.d., Banka kovanica d.d., Primorska banka d.d., Samoborska banka d.d.), a njihov udio smanjen za 1,1% i obuhvaća 89,9% ukupne imovine kreditnih institucija. U većinskom državnom vlasništvu ostaje Hrvatska poštanska i Croatia banka, dok se udio njihove imovine povećao sa 3,4% na 5,6% (vidjeti tablicu 1, vidjeti prilog 1). Od ukupno 16 banaka koje se nalaze u većinskom stranom vlasništvu, njih 12 pripada u vlasništvo osoba unutar zemalja Europske unije, dok su preostale 4 banke u vlasništvu osoba izvan područja Europske unije. Važno je naglasiti kako udio imovine banaka koje su u vlasništvu osoba izvan područja Europske unije čini svega 0,8% ukupne imovine banaka.

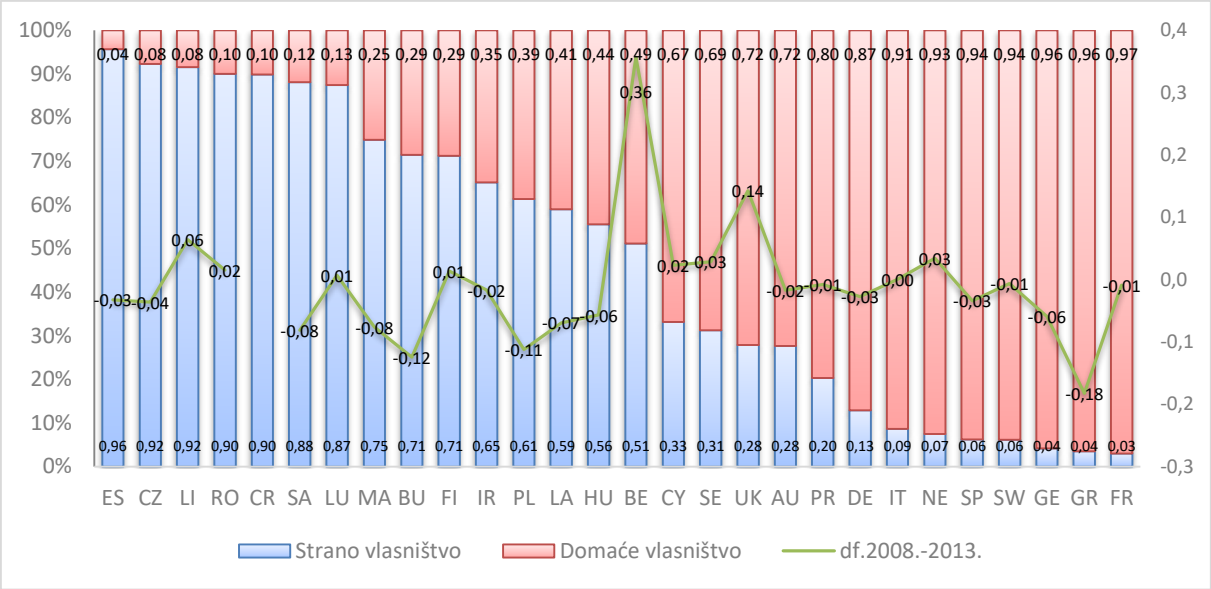
Tablica 1. Vlasnička struktura kreditnih institucija u RH

Godina	2005		2012		2013		2014		VI..2015		VI..2016	
	No	**%**	**No**	**%**	**No**	**%**	**No**	**%**	**No**	**%**	**No**	**%**
Domaće vlasništvo	20	8,7	15	9,9	14	10,3	12	9,9	12	9,8	12	**10,1**
Domaće privatno vlasništvo	18	5,3	13	5,2	12	5,1	10	4,7	10	4,6	10	4,5
Domaće državno vlasništvo	2	3,4	2	4,8	2	5,3	2	5,2	2	5,2	2	5,6
Strano vlasništvo	14	91,3	16	90,1	16	89,7	16	90,1	16	90,2	16	**89,9**
Ukupno	34	100	31	100	30	100	28	100	28	100	28	100,0

No-broj institucija; %-Udio imovine

Izvor:autorica prema HNB 2018b; tablice, Zaključno s 31. prosinca 2013. izvor podataka o vlasničkoj strukturi banaka jesu izvještaji PD32 sastavljeni u skladu s Odlukom o nadzornim izvještajima kreditnih institucija (NN, br. 35/2010., 81/2010., 146/2010., 68/2011., 147/2011., 37/2012., 67/2013., 121/2013. i 157/2013.). U idućim razdobljima izvor podataka jesu izvještaji PD32 (na dan 31. prosinca 2014.) odnosno izvještaji PD33 (od 31. prosinca 2015.) sastavljeni u skladu s Odlukom o supervizorskim izvještajima kreditnih institucija (NN, br. 41A/2014., 127/2014., 67/2015. i 119/2015.). Izvor podataka o iznosu imovine banaka jesu obrasci BS3-2 iz statističkog izvješća, koji se temelje na podacima dostavljenima u skladu s Odlukom o statističkom i bonitetnom izvješćivanju (NN, br. 35/2010., 95/2010., 146/2010., 68/2011., 37/2012., 121/2013., 41A/2014., 127/2014., 67/2015., 119/2015. i 54/2016.)

Za potrebe razumijevanja strukture vlasništva kreditnih institucija RH važno je uzeti u obzir liberalizaciju kretanja kapitala zajedničkog tržišta Europske unije i trendove u sustavu kreditnih institucija odnosno vlasničku strukturu na razini pojedinih zemalja članica Europske unije. Udio stranog vlasništva kreditnih institucija na razini zemalja članica Europske unije izrazito je heterogen i kreće se u rasponu od 96% do 0,03%. Najveći udio stranog vlasništva prisutan je u Estoniji (96%), Češkoj (92%), Litvi (92%), Rumunjskoj (90%), Hrvatskoj (90%), te Slovačkoj (88%), dok je najmanji udio stranog vlasništva bio u Francuskoj (3%), Grčkoj (4%), Njemačkoj (4%), Švedskoj (6%) i Španjolskoj (6%). Može se reći kako strano vlasništvo dominira u manje razvijenim zemljama, a zemlje s najvećim udjelom domaćeg vlasništva su neke od razvijenijih zemalja EU. Iznimke su Luksemburg (87%), Finska (87%), Irska (65%) i Cipar (33%). Može se reći kako se sa liberalizacijom tržišta suficit kapitala razvijenih financijskih sustava zemalja niskih prinosa kretao u manje razvijene financijske sustave zemalja gdje su povrati na ulaganja bili relativno visoki.



Slika 2. Vlasništvo imovine kreditnih institucija prema zemljama članicama Europske unije
Izvor: ECB – Europan Central Bank, 2017d

Sukladno navedenom može se zaključiti kako trendovi sektora kreditnih institucija Europske unije predstavljaju dobar pokazatelj promjena koje se mogu očekivati u sektoru kreditnih institucija manje razvijenih zemalja i Republike Hrvatske. Poslovni modeli kreditnih institucija koji su se pokazali uspješnima u najrazvijenijim zemljama, transferiraju se u ostale zemlje Europske unije. Obzirom na dominaciju stranog vlasništva imovine banaka odnosno kapitala zemalja Europske unije u sektoru kreditnih institucija RH očekuje se jačanje konkurencije i smanjenje stopa profitabilnosti.

2.1.2 Koncentracija bankarskog tržišta

Iako postoje razlike između pojedinih zemalja članica Europske unije, zadnjih desetak godina tržište kreditnih institucija Europske unije obilježeno je konsolidacijom i rastom koncentracije. Primjerice, u Velikoj Britaniji tradicionalno su dominirale svega četri banke (RBS, Barclays, HSBC i Lloyds) koje zajedno upravljaju 77% osobnih i 85% poslovnih računa. Istraživanje je pokazalo da klijent u prosjeku ostaje u istoj banci 17 godina, a njih 37% više od 20 godina. Vodeći se navedenom dinamikom i bez klijenta koji zahtjeva inovacije bilo je teško očekivati aktivni angažman menadžmenta u rizičnoj provedbi radikalnih promjena unutar financijskog sektora (Wilkinson, 2017). Kao što je citirano u Dumičić, Pavković, & Akalović Antić (2012) Dumičić, Pavković i Palić navode kako se prema istraživanju provedenom na zemljama srednje i istočne Europe pokazalo kako postoji jaka konkurencija bankovnih grupacija: UniCredito,

Raiffeisen Group, Hypo Alpe Adria, Intesa SaoPaolo i Erste banke te kako je koncentracija bankarskog sektora još veća u manje razvijenim zemljama kao što su Albanija i Kosovo.

U svrhu smanjenja troškova, financijske poluge i restrukturiranja, broj kreditnih institucija se s 6.767 2008. godine smanjio na 5.614 2015. godine. Kao rezultat restrukturiranja u 2015. godini u odnosu na 2014. godinu smanjuje se aktivnost spajanja i preuzimanja te dodatno raste efikasnost sustava. U 2015. godini napori su usmjereni na konsolidaciju unutar EU te geografsku distribuciju rizika ulaskom na tržište zemalja izvan Eurozone i Europske unije (ECB, 2016).

Prema Zakonu o kreditnim institucijama Republike Hrvatske kreditna institucija u Republici Hrvatskoj može se osnovati pod nazivom banka, štedna banka i stambena štedionica. Kreditnom institucijom smatra se svaka pravna osoba koja je primila odobrenje za rad odnosno primanje depozita ili drugih povratnih sredstava od široke javnosti te odobravanje kredita u svrhu ostvarenja poslovnog rezultata (HNB, 2013).

Prema podacima HNB-a u lipnju 2016. godine od ukupno 33 kreditne institucije u Republici Hrvatskoj bilo je 27 komercijalnih banaka, 1 štedna banka i 5 stambenih štedionica. Istovremeno ukupna imovina banaka iznosila je HRK 382,176 milijarde, dok je udio ukupne imovine kreditnih institucija bio HRK 389,833 milijarde. Na tržištu Republike Hrvatske očigledna je koncentracija banaka koje čine 98,06% ukupne imovine kreditnih institucija. Od ukupno 28 banaka, zbog pokrenutog stečaja Splitsko-Dalmatinske banke, sanacijskog postupka Jadranske banke i mjera supervizije nad Tesla štednom bankom koje se provode zbog nezadovoljavanja zakonskih odredbi adekvatnosti kapitala, može se reći kako u Republici Hrvatskoj efektivno posluje svega 25 banaka.

Prema veličini imovine najveća kreditna institucija u Republici Hrvatskoj bila je Zagrebačka banka d.d. s udjelom od 26,2% ukupne imovine, zatim Privredna Banka Zagreb d.d. (17,7%), Erste & Steiermärkische bank d.d. (14,5%), Raiffeisenbank Austria d.d. (7,6%), Société Générale-Splitska Banka d.d. (6,70%), Hypo Alpe-Adria-Bank d.d (Addiko Bank d.d.) (6,0%), Hrvatska Poštanska Banka d.d (4,7%), OTP Banka Hrvatska d.d (3,9%), Sberbank d.d. (2,5%) i Kreditna Banka Zagreb d.d. (0,9%). Prema koeficijentima koncentracije tri najveće kreditne institucije u RH upravljaju C_3=58,3% ukupne imovine, pet najvećih upravlja $C_{5=}$74,9% ukupne imovine, odnosno deset najvećih upravlja $C_{10=}$90,7% ukupne imovine kreditnih institucija.

Koeficijenti koncentracije kreditnih institucija Republike Hrvatske usporedivi su na razini Europske unije odnosno pojedinih zemalja članica. Pokazatelji koncentracije kreditnih institucija Europske unije u razdoblju 2005.-2014. kontinuirano su rasli, a razlozi su prvenstveno bili u restrukturiranju pojedinih zemalja kao što je Grčka, Španjolska, Malta i Cipar. Koeficijenti koncentracije stabilizirani su 2014. godine dok je HH nastavio rasti (ECB, 2015). Načelno, velike zemlje imaju snažno razvijen i fragmentiran financijski sustav, dok su manje zemlje izuzev Austrije i Luksemburga imale snažniju konsolidaciju i koncentraciju. Najveći stupanj koncentracije kreditnih institucija bio je prisutan u Grčkoj pri čemu je koeficijent koncentracije C_5 iznosio 95,2%. Nakon Grčke najveća koncentracija kreditnih institucija bila je u Estoniji 88,6%, zatim Litvi 86,8%, Nizozemskoj 84,6% i Malta 81,3%. Republika Hrvatska se prema rangu koeficijenata koncentracije nalazi iznad medijana te zauzima čak 7. mjesto (72,6%). Najmanja koncentracija kreditnih institucija bila je u Njemačkoj (30,6%), zatim Luksemburgu (31,3%), Austriji (35,8%), Velika Britanija (36,8%) Italija (41,1%). Najveća promjena koncentracije u periodu 2011.-2015. dogodila se u Grčkoj i Španjolskoj. Promjena koncentracije posljedica je dužničke krize pri čemu je za potrebe sanacije utrošeno više od €240 mlrd u Grčkoj i €53 mlrd u Španjolskoj (ECB, 2015). Kao rezultat krize te unatoč sanaciji nad jednim dijelom kreditnih institucija pokrenut je stečaj te se koncentracija u Grčkoj povećala za 12%, a u Španjolskoj za 23,2% (vidjeti tablicu 2).

Osim navedenih koeficijenata, kao pokazatelj koncentracije kreditnih institucija koristi se Herfindahl-Hirschmanov indeks koji je krajem 2016. godine iznosio 0,14 (HHI*=0,11) i predstavlja povijesno najveću vrijednost zabilježenu zadnjih 20 godina. (Vidjeti tablicu 2). Prema podacima u Kundid, Škrabić i Ercegovac (2011) u razdoblju od 2003.-2008. indeks je konstantno rastao te od 0,1270 dosegnuo 0,1308. Prema teorijskoj distribuciji stupanj koncentracije manji od 0,01 smatra se savršenom konkurencijom, između 0,01 i 0,15 niskom koncentracijom, 0,15-0,25 umjerenom koncentracijom, te iznad 0,25 visokim stupnjem koncentracije. Na osnovu teorijske distribucije moglo bi se reći kako u RH postoji niska koncentracija kreditnih institucija, a u odnosu na 28 zemalja članica Europske unije RH zauzima 8. mjesto, dok su najveći stupanj koncentracije imale Finska 0,273, Estonija 0,2409, Grčka 0,2254, Nizozemska 0,2104 i Litva 0,1939. Najmanja koncentracija bila je u Njemačkoj (0,0273), Luksemburgu (0,0321), Austriji (0,0397), Velika Britanija (0,0432) te Italiji (0,0435). Kao što su prethodno pokazali koeficijenti koncentracije konsolidacija je bila najveća u Grčkoj (rast HHI-a 76,4%) i Španjolskoj (rast HHI-a 50,3%) te Cipru (rast HHI-a 40,1%) i Malti (rast HHI-a 34,7%).

Tablica 2. Koncentracija kreditnih institucija u pojedinim zemljama članicama Europske unije, 2011-2015, C_5, HHI

	Zemlja	C_5	df C_5		Zemlja	HHI	df HHI
1	Grčka	95,2	**23,2**	1	Finska	0,2730	-26,2
2	Estonija	88,6	-2	2	Estonija	0,2409	-7,8
3	Litva	86,8	2,1	3	Grčka	0,2254	**76,4**
4	Nizozemska	84,6	1	4	Nizozemska	0,2104	1,8
5	Malta	81,3	**9,3**	5	Litva	0,1939	3,6
6	Finska	75,0	-5,9	6	Malta	0,1621	**34,7**
7	**Hrvatska***	72,7	1,2	7	Cipar	0,1443	**40,1**
8	Slovačka	72,3	0,1	8	**Hrvatsia***	0,1396	0,9
9	Portugal	69,6	-1,2	9	Slovačka	0,1250	-1,4
10	Danska	67,8	1,5	10	Danska	0,1180	-1
11	Cipar	67,6	**6,9**	11	Portugal	0,1159	-3,9
12	Belgija	65,5	-5,3	12	Slovenija	0,1077	-5,7
13	Latvija	64,5	4,9	13	Latvija	0,1033	11,2
14	Češka	63,3	1,5	14	Belgija	0,0998	-22,9
15	Španjolska	60,2	**12,1**	15	Češka	0,0987	-2,7
16	Slovenija	59,2	-0,1	16	Bugarska	0,0919	20
17	Švedska	57,8	0	17	Španjolska	0,0896	**50,3**
18	Bugarska	57,6	5	18	Mađarska	0,0878	3,5
19	Rumunjska	57,4	2,8	19	Švedska	0,0866	0,3
20	Mađarska	53,3	-1,3	20	Rumunjskaa	0,0860	-2,1
21	Poljska	48,6	4,9	21	Irska	0,0679	4,9
22	Francuska	47,2	-1,1	22	Poljska	0,0670	19
23	Irska	46,0	-0,7	23	Francuska	0,0589	-1,8
24	Italy	41,1	1,6	24	Italy	0,0435	6,9
25	V Britanija	36,8	-6,7	25	V Britanija	0,0432	-16,8
26	Austrija	35,8	-2,6	26	Austrija	0,0397	-6,1
27	Luxembourg	31,3	0,1	27	Luxembourg	0,0321	-7,2
28	Njemačka	30,6	-2,9	28	Njemačka	0,0273	-13,9

Izvor: ECB – Europan Central Bank, 2017b.

U odnosu na prethodnu godinu u RH pet najvećih kreditnih institucija bilježi pad udjela imovine u rasponu od 1,12%-3,97% pri čemu je najveća promjena bila za Raiffeisen banku. Kent banka koja se prema udjelu imovine i profitabilnosti nalazi na 18./28. mjesta imala je najveću dvoznamenkastu stopu rasta od 27,5%, zatim Primorska banka (21,23%) koja se prema udjelu imovine i profitabilnosti nalazila na 25. i 11. mjestu te Vaba banka Varaždin (12,41%.) koja je prema udjelu imovine i profitabilnosti zauzela 16. i 27.

Također, udio iznosa plasiranih kredita Zagrebačke i Privredne banke iznosio je 44,8%, a zajedno s Erste & Steiermärkische, Raiffeisen i Société Générale-Splitskom bankom pet najvećih banaka zaslužno je za plasman 75,3% ukupnih kredita, a deset najvećih banaka 93,8% kreditnih plasmana RH. Udio koncentracije depozita odgovara strukturi plasmana kredita pri

čemu su dvije najveće banke (Zagrebačka i Privredna) prikupile 43,3% depozita, pet najvećih banaka 73,7% depozita (Zagrebačka, Privredna, Erste & Steiermärkische, Raiffeisen i Société Générale-Splitska banka) i deset najvećih banaka 92,5% depozita (Zagrebačka, Privredna, Erste & Steiermärkische, Raiffeiseni i Société Générale-Splitska banka, Hypo Alpe-Adria, Hrvatska-poštanska, OTP, SBER i Kreditna banka) (HNB, 2018).

Ukupna dobit banaka u razdoblju 1. siječnja 2016. - 30. lipnja 2016. godine iznosila je 3.546,4HRK milijuna, a dobit stambenih štedionica u istom razdoblju bila je svega 29,2HRK milijuna. nKoncentracija dobiti banaka neznatno se razlikuje od koncentracije udjela imovine, kredita i depozita. Prvih devet najvećih institucija ostvarilo je 99,5% ukupne dobiti, dok je Podravska banka s udjelom imovine na 12. mjestu prema udjelu dobiti bila na 10. mjestu, a Kreditna banka s udjelom imovine na 10. mjestu prema udjelu dobiti bila na 19. mjestu.

Iako se veličina kreditne institucije ogleda prvenstveno u vrijednosti imovine važno je naglasiti da se dio poslovanja bilježi izvan bilance. Izvanbilančne stavke uključuju garancije, akreditivi, mjenice, okvirni krediti i obveze financiranja, rizične klasične izvanbilančne stavke, ročnice (futures), opcije, swapove, terminski poslove (forwards), ostale derivate, a kod podružnica stranih banaka dodatno se bilježi jamstveni kapital, stopa adekvatnosti kapitala i prosječan broj zaposlenih. Ponderirani prosječan udio izvanbilaničnih aktivnosti banaka RH iznosio je 15,1% ukupne imovine, dok je Raiffeisenbank Austria d.d. imala najveći udio 24,9%, zatim Société Générale-Splitska banka d.d. (21,1%), Zagrebačka banka d.d. (18,0%), Privredna Banka Zagreb d.d. (17,9%), i Podravska Banka d.d. (12,3%).

Tablica 3. Kreditne institucije u Republici Hrvatskoj, 30.6.2016.

R1	*R2*	*Naziv kreditne institucija*	*Udio imovine*	*Cr*	*R*	*IBS*	*Dobit*	*ROA*	*ROE*
		Naziv banke							
1	**7**	ZAGREBAČKA BANKA d.d.	26,19	26,19	-3,68	18,04	953.814	0,93	6,61
2	**2**	PRIVREDNA BANKA ZAGREB d.d.	17,69	43,88	-1,12	17,93	860.760	1,25	7,88
3	**6**	ERSTE&STEIERMÄRKISCHE BANK d.d.	14,47	58,35	-4,42	10,21	556.253	0,99	9,36
4	**1**	RAIFFEISENBANK AUSTRIA d.d.	7,63	65,98	-4,68	24,95	438.174	1,47	11,85
5	**4**	SOCIÉTÉ GÉNÉRALE-SPLITSKA BANKA d.d.	6,67	72,65	-3,97	21,17	304.511	1,17	9,47
6	**8**	HYPO ALPE-ADRIA-BANK d.d.	6,05	78,70	-7,64	8,33	207.990	0,88	8,83
7	**13**	HRVATSKA POŠTANSKA BANKA d.d.	4,71	83,41	3,74	12,28	88.840	0,48	5,75
8	**10**	OTP BANKA HRVATSKA d.d.	3,92	87,33	-3,88	7,16	104.494	0,68	6,70
9	**14**	SBERBANK d.d.	2,50	89,83	0,22	7,94	45.004	0,46	4,14
10	**19**	KREDITNA BANKA ZAGREB d.d.	0,89	90,72	0,17	7,21	2.090	0,06	0,83
11	**20**	CROATIA BANKA d.d.	0,82	91,54	2,68	5,55	1.986	0,06	1,13
12	**5**	PODRAVSKA BANKA d.d.	0,82	92,36	0,73	12,39	34.381	1,08	10,38
13	**15**	ISTARSKA KREDITNA BANKA UMAG d.d.	0,78	93,14	-1,96	5,74	10.709	0,35	4,23
14	**21**	KARLOVAČKA BANKA d.d.	0,54	93,68	4,1	12,06	862	0,04	0,64
15	**24**	IMEX BANKA d.d.	0,51	94,19	-3,06	5,36	-9.028	-0,46	-6,53
16	**27**	VABA d.d. BANKA VARAŽDIN	0,48	94,67	**12,41**	4,62	-60.411	-3,26	-35,01
17	**16**	JADRANSKA BANKA d.d.[3]	0,45	95,12	-3,49	8,62	6.171	0,35	-2,03
18	**18**	KENTBANK d.d.	0,44	95,56	**27,59**	4,41	2.330	0,13	1,17
19	**9**	BKS BANK d.d.	0,41	95,97	2,39	6,14	12.272	0,78	6,08
20	**23**	SLATINSKA BANKA d.d.	0,40	96,37	1,29	5,24	40	0	0,03
21	**17**	PARTNER BANKA d.d.	0,39	96,76	1,84	9,51	2.115	0,14	1,36
22	**26**	VENETO BANKA d.d.	0,39	97,15	-6,98	6,8	-28.057	-1,87	-20,87
23	**22**	BANKA KOVANICA d.d.	0,32	97,47	4,62	1,77	284	0,02	0,28
24	**3**	ŠTEDBANKA d.d.	0,22	97,69	-16,62	8,92	10.189	1,18	3,03
25	**11**	PRIMORSKA BANKA d.d.	0,14	97,83	**21,23**	3,45	3.667	0,68	8,11
26	**12**	SAMOBORSKA BANKA d.d.	0,12	97,95	0,44	6,19	2.471	0,52	3,39
27	**25**	BANKA SPLITSKO-DALMATINSKA d.d.	0,11	98,06	-8,91	0,58	-2.961	-0,71	-25,09
28	**28**	TESLA ŠTEDNA BANKA d.d.	0,00	**98,06**	-30,82	0	-2.550	-0,40	-122,08
		Naziv štedionice							
1	**1**	PRVA STAMBENA ŠTEDIONICA d.d.	0,64	98,70	-3,78	0,43	18.025	0,72	7,18
2	**5**	WÜSTENROT STAMBENA ŠTEDIONICA d.d.	0,50	99,20	-0,73	0,66	982	0,05	0,97
3	**4**	PBZ STAMBENA ŠTEDIONICA d.d.	0,42	99,62	2,32	0,10	1.709	0,10	0,76
4	**3**	RAIFFEISEN STAMBENA ŠTEDIONICA d.d.	0,32	99,94	-4,91	0,43	6.983	0,56	10,16
5	**2**	HPB-STAMBENA ŠTEDIONICA d.d.	0,08	100	8,70	0,52	2.120	0,67	5,40
		Herfindahl-Hirschman Index	**0,14**						
		Normaliziran Herfindahl-Hirschman Index	**0,11**						

Ib-vrijednost imovine/ukupna imovina kreditnih institucija
R1-rang institucije prema veličini imovine
R2-rang institucije prema profitabilnosti imovine
Cr-koeficijenti koncentracije
R-stopa rasta imovine
IBS-udio izvanbilančne imovine u ukupnoj imovini
ROA=dobit/imovina
$\mu_{ROA=}$0,92%
Herfindahl-Hirschman Indeks koncentracije

$$HHI = \sum_{i=1}^{n} p_i^2$$

H ispod 0,01 savršena konkurencija, H ispod 0,15 niska koncentracija, H 0,15-0,25 umjerena koncentracija, H >0,25 visoka koncentracija.
H*=(H-1/N)/(1-1/N) - normaliziran HHI (Raspon 0 - 1)
Godina/HHI: 2003/1270; **2004**/1363; **2005**/1357; **2006**/1296; **2007**/1277; **2008**/1308 (Kundid, Škrabić, & Ercegovac, 2011)
1) Banco Popolare Croatia d.d., Zagreb, pripojena je 1. prosinca 2014. OTP banci Hrvatska d.d., Zadar.
2) Dana 30. rujna 2013. otvoren je stečajni postupak nad Centar bankom d.d., Zagreb.
3) Banka Brod d.d., Slavonski Brod, promijenila je 6. srpnja 2012. ime u KentBank d.d., Zagreb.
4) Dana 1. prosinca 2014. otvoren je stečajni postupak nad Nava bankom d.d., Zagreb.
5) Dana 1. prosinca 2012. Međimurska banka d.d., Čakovec, pripojena je Privrednoj banci Zagreb d.d., Zagreb.
6) Volksbank d.d., Zagreb, promijenila je 18. siječnja 2013. ime u Sberbank d.d., Zagreb.
7) 1. srpnja 2016. otvoren je stečajni postupak za Splitsko-Dalmatinsku banku
8) 11. srpnja 2016. banka Hypo Alpe-Adria-Bank d.d je promijenila ime u Addiko Bank d.d.
9) 9. listopada 2015. otvoren je sanacijski postupak nad Jadranskom bankom d.d.
10) Zbog neudovoljavanja zakonskim odredbama o adekvatnosti kapitala u tijeku je poduzimanje supervizorskih mjera nad Tesla d.d. bankom
Izvor: autorica prema HNB, 2018

Prema Kundid, Škrabić i Ercegovac (2011) smatraju kako se zaokret u razvoju kreditnih institucija Republike Hrvatske dogodio 2003. godine. Prethodno tome sustav kreditnih

institucija RH smatrao se nerazvijenim i nestabilnim. Nakon 2003. godine dogodila se privatizacija i liberalizacija tržišta, a posljedično s povećanjem stabilnosti sustava i rast koncentracije. Trenutno u sustavu kreditnih institucija RH dominira relativno malen broj banaka. Svega deset banaka čini 90% ukupne imovine. U odnosu na zemlje Europske unije, vodeći se koeficijentom koncentracije C5 te HH indeksom RH se nalazi respektivno na 7./28. i 8./28 mjestu. Prve tri najveće banke obuhvaćaju 58% tržišta kreditnih institucije te svojom veličinom i kvalitetom usluge dominiraju bankarskim sustavom. Visoka efikasnost poslovanja, široka lepeza tehnološki naprednih te raznovrsnih osnovnih i dodatnih usluga omogućavaju privlačenje i zadržavanje velikog broj korisnika te čine izvor konkurentske prednosti koje značajno otežavaju penetraciju tržišta novih i ostalih kreditnih institucija. Može se pretpostaviti kako postoji negativan utjecaj visoke koncentracije banaka na tržišnu konkurenciju financijskog sektora Europske unije. Smatrajući kako su postojeće barijere ulaska u industriju visoke te je gotovo nemoguće konkurirati nekolicini velikih banaka, regulatorna tijela Europske unije nastoje prilagoditi zakonski okvir industrije kako bi potaknuli dinamiku tehnološke revolucije. U želji da se financijsko tržište revitalizira kreirane su dvije važne regulatorne mjere: jedna 2007. godine (PSD1), a druga 2015. godine (PSD2). Namjera je povećati konkurenciju, smanjiti troškove međunarodnih transakcija i promovirati dijeljenje podataka financijskih transakcija klijenata banaka na skupnoj razini. Fintech organizacije nastoje pristupiti podacima banaka kako bi uspostavile nove poslovne modele, a od banaka se očekuje da istim podacima upravljaju te ih osiguraju. Sigurnost podataka je presudna za stvaranje i održavanje povjerenja klijenata. S jedne strane regulativa PSD1 ima zadaću integrirati tržište financijskih transakcija odnosno omogućava pružanje financijskih usluga organizacijama koje nisu banke i ne podliježu regulaciji kreditnih institucija (Western Union, WorldPay, PayPal), a s druge strane regulator ima zadaću nadzirati rizik hakiranja podatka koji su predmetom dijeljenja, voditi računa o tome jesu li klijenti svijesni da se podaci prikupljaju i koliko kontrole nad procesom imaju te kako banke koriste dodatno prikupljene podatke (WEF, 2017).

Nadalje, legislativni okvir pod nazivom SEPA (Single Euro Payments Area) izjednačava trošak domaćih transakcija sa svim transakcijama unutar EFTA-e (European Free Trade Area). Također, donešena je IFA (Interchange fee regulation) regulativa koja ograničava naknade za pojedine vrste transakcija i zabranjuje se selektivan odabir kartičnog plaćanja od strane trgovaca čime se pogoduje kartičnim kućama s nižim provizijama. Obzirom na tendencije smanjenja nakanada za pojedine usluge klijenti mogu očekivati niske troškove svih usluga unutar financijskog tržišta (WEF, 2017). Očekivanja su kako će PSD1 povećati konkurenciju na

tržištu financijskih usluga, a regulativa PSD2 ide korak dalje te zainteresiranim organizacijama na siguran način omogućava pristup podacima o svim financijskim transakcijama. To će biti moguće putem API-a (Application Programming Interfaces (struktura interakcije raznovrsnih aplikacija)) odnosno regulative („XS2A“) „Access to Accounts“ (Wilkinson, 2017). Očekuje se kako će zahvaljujući novoj regulativi najviše koristi ostvariti trgovci, zatim klijenti, a najmanje posrednici. Trgovci će nastojati proširiti svoje online sustave plaćanja i putem API-a osvojiti dio tržišta kartičnog plaćanja. Iako broj korisnika i broj aplikacija trgovaca za plaćanje raste, iznos transakcija kartičnog plaćanja na internetu nije u padu, a još uvijek nije moguće identificirati dominantnog pružatelja usluge. Obzirom da sve veći broj klijenata koristi direktna rješenja, smanjuju se naknade za bezgotovinsko kartično plaćanje. Također, jedan od najvažnijih izvora prihoda za izdavatelje kartica (revolving kreditiranje) ostaje otvoreno zainteresiranim organizacijama, a očekuje se pojačana fragmentacija financijskog tržišta. U uvjetima fragmentacije potrošnja klijenata postaje manje transparentna kategorija, a banke zadržavaju monopol pristupa podacima o ukupnoj potrošnji (WEF, 2017).

Neovisno industrijama i organizacijama API reflektira vrijednost koje pruža digitalizacija, omogućava pristup velikom broju potencijalnih klijenata i stvara disruptivne promjene unutar mnogih ustanovljenih industrija. Koristeći API (strukturu interakcije raznovrsnih aplikacija) modularnost organizacije odnosno poduzeća implementiraju aplikacije trećih strana i stvaraju novu dodanu vrijednost za klijente. Upotreba API sustava ima zadaću redom: povećati kvalitetu iskustva korisnika, povećati dinamiku dizjaniranja novih proizvoda, smanjenje vremena potrebnog za plasman istih na tržište, nove prihode, stvoriti veću fleksibilnost, operacijsku efikasnost i konačno osigurati pristup dodatnim informacijama. Krajem 2016. godine bilo je preko 140.000 API protokola (WEF, 2017). Većina banaka zasad koriste prvenstveno interne API sustave, jedan dio banaka partnerske, a manji dio otvorene API sustave. Interni API sustavi pospješuju informacijske tokove unutar organizacije, dok otvoreni API sustavi stvaraju dodatne uvide u ponašanje klijenata i nove prihode. Otvoreni API sustavi podrazumijevaju dijenje podataka s organizacijama koje nisu u formalnom odnosu s bankom te predsatvljaju sigurnosni rizik. Unatoč rizicima procjenjuje se kako će API ekonomija do 2018. dosegnuti vrijednosst $2,2 milijarde (Wilkinson, 2017).

Posljedično PSD2 direktivi klijenti će pristupiti svojim računima koristeći različite pružatelje usluga. Očekuje se pojava organizacija koje će putem AISP (Account Information Service Provider) odnosno lako razumljivog sučelja agregirati informacije istog klijenta nekoliko

banaka ili drugih pružatelja usluga te će klijent imati bolji uvid u svoje financije i donositi efikasnije odluke. Nije isključivo kako će koristeći postojeću reputaciju, raznovrsan porfolio proizvoda, prisutnost na webu i brojnim fizičkim lokacijama te bazu podataka deriviranu kao rezultat velikog broja transkacija plaćanja i različitih programa lojalnosti, upravo maloprodajni lanci postati pružatelji AISP usluge. Nadalje, postavljanjem OBS-a (Open Banking Standard) omogućen je transfer računa klijenata u roku od 7 dana, dok je prethodno za isto bilo potrebno 30 dana. Posljedično, je 2,8 milijuna klijenata u Velikoj Britaniji iskoristilo spomenutu uslugu. Buduća konkurencija unutar financijskog tržišta mogla bi se podijeliti u tri glavna segmenta: nove banke, srednje banke i velike banke. Nove banke koje nisu opterećene tradicionalnom strukturom iskoristiti će novu regulaciju da ponude potpunu digitalizaciju proizvoda i usluga. Nadalje, važno je napomenuti da iste ne moraju nužno imati dovoljno reputacije i kapitala da privuku prosječnog korisnika, ali će se orijentirati na tehnološki osviještene klijente. Zabrinuti za sigurnost i oni koji nisu skloni tehnološkim inovacijama vjerojatno će zadržati dosadašnje pružatelje usluga. Neke od banka će eventualno pokušati same postati API platforme te će na tržištu financijskih proizvoda i usluga nastupiti kao distributeri, a jedna od mogućih strategija spomenute kategorije banaka može biti i prodaja usluga nekoj od velikih banaka. Segment srednjih banaka manje je opterećen tradicionalnom strukturom, a ima dovoljno kapitala i fleksibilnosti kako bi putem API-a otvorio svoje interne sustave da iskoristi novu regulaciju. Koristeći svoju reputaciju na tržištu i pružajući uslugu veće kvalitete u odnosu na lidere, srednje banke mogu privući one klijente koji žele istražiti digitalne mogućnosti. Brzom reakcijom, većom kvalitetom usluge i nižom cijenom mogu povećati svoj udio na tržištu, a snažnijim ulaganjem u tehnologiju u odnosu na nove banke zadržati vodeću tehnološku poziciju. Ciljani segment tržišta srednjih banaka bit će pod pritiskom visoke razine inovacija novih banaka i snažne reputacije velikih banaka koje provode digitalizaciju svojeg poslovanja. Kako bi ojačale svoju poziciju, banke srednje veličine mogu razmatrati konsolidaciju unutar svog segmenta, kupnju neke od novih banaka ili prodaju svojih usluga velikim bankama. Konačno, velike banke će morati uložiti značajne resurse kako bi se prilagodili novoj regulaciji. U takvim sustavima proces odlučivanja je složen i dugotrajan, a uprava je manje sklona rizicima. To svakako ne znači da se velike banke neće digitalizirati, ali će isto provesti konzervativnije vjerojatno uz suradnju s trećim stranama odnosno partnerima upravo kao što predviđa OBS (Open Banking Standard). Otvaranje sustava banke prema platformi može osigurati testiranje novih proizvoda i usluga uz puno manje rizika nego da se isti omoguće putem tradicionalnih kanala. Isti ne moraju biti razvijeni unutar banke već mogu biti kupljeni od partnera. Cjelokupni razvoj neke ideje do konačnog proizvoda zahtjeva alokaciju odnosno realokaciju ljudskih resursa koji u

banci imaju prethodna zaduženja i ulaganje ostalih resursa pri čemu banke u postojećoj strukturi mogu biti manje efikasne za razliku od Fintech organizacija ili drugih partnera. Fintech organizacije predstavljaju tehnološki osnažena poduzeća koja ulaze ili pokušavaju ući na financijsko tržište (WEF, 2017).

Banke profitiraju jer ne moraju same razvijati određena tehnološka rješenja, a stvarni pružatelji usluge profitiraju koristeći reputacije banke. Sigurno je kako će mnogi klijenti imati više povjerenja u inovativne financijske proizvode ako iza njih stoji renomirana banka. Obzirom da su različite Fintech organizacije ipak dizajneri tih inovativnih proizvoda može se očekivati kako će banke podrazumijevati njihovu odgovornost za sigurnost klijenata s očekivanjem da mogućnost prijevare da bude minimlana. Posljedično financijskoj snazi Fintech organizacije koja se ne može uspoređivati s bankama, ugovor između banke i Fintech organizacije neće biti relevantan za stvarenje adekvatne razine povjerenje od strane klijenata. Iako su Fintech organizacije odgovorne za svoje proizvode prema banci, banke će prema klijentima osigurati direktna jamstva. Nadalje, API sustavi koje integriraju financijsko tržište mogu rezultirati višestrukim koristima. Klijenti dobivaju veću kvalitetu iskustva upotrebe usluge i proizvoda (više inovacija), a banke pristup novim informacijama. Na temelju pristupa dodatnim informacijama (sve transakcije klijenata koje su dosada bile izvan dosega) banke će imati mogućnost bolje procijeniti kreditne sposobnosti klijenata odnosno smanjiti teret otpisanih dugova. Fintech organizacije kao tehnološki eksperti u financijsko okruženje donose nove vještine, iskustvo i metode izvan tradicionalnog pristupa banaka stvarajući inovacije, a zauzvrat uzimaju dio financijskog tržišta (Wilkinson, 2017). Fintech organizacije pokazale su da klijent u bankarstvu može doživjeti tehnološki osnaženo iskustvo kvalitete nalik onome što se očekuje od poduzeća kao što su Google-a i Apple. S jedne strane na tržištima gdje nije postojala visoka koncetracija ustanovljenih pružatelja financijskih usluga ili su neki segementi klijenata bili nezadovoljeni, Fintech organizacije zauzele su nezanemarive tržišne udjele. S druge strane, zbog nedostatka financijskog poticaja spremnost klijenata da promjene pružatelja usluge bila je precijenjena te se pokazalo kako su Fintech organizacije bile uspješnije prilikom unaprijeđenja postojećih sustava nego izgradnje alernativne infrastrukture. Iako je pojava Fintech organizacija stvorila tržište inovacija te omogućila trgovinu talentima, dinamika promjene predstavlja prijetnju nedovoljno fleksibilnim strategijama banke (WEF, 2017).

Konkurencija unutar financijskog tržišta više se ne događa samo u segmentu transakcija plaćanja, nego obuhvaća 30 različitih segmenata financijskog tržišta redom prema vjerojatnosti ulaska uključujuči (EFMA, 2017d):

a) Transakcije (digitalni novčanici, mobilna plaćanja, kartice, procesuiranje transakcija)
b) Korporativno i masovno bankarstvo (upravljanje novcem, digitalizacija pozajmica, štednja)
c) SME (upravljanje digitalnim novcem, P2P korporativno financiranje)
d) Upravljanje imovinom (robotsko savjetovanje, sociološko osjetljivo investiranje, grupno financiranje, savjetovanje)
e) Kapitalna tržišta (posredovanje i analiza trgovine vrijednosnim papirima, upravljanje kolateralima)
f) Devizno tržište
g) Osiguranje (digitalna prevencija, telematika)

Ekspanzija djelovanja Fintech organizacije uključuje operacije, ali i infrastrukturu. Fintech organizacije koriste tehnologiju DLT/Blockchain, AI (umjetne inteligencije), RPA (robotic process automation), GPS-a (Global positioning system), VA (verbal assistance), VR/AR (virtual reality/augmented reality) i API (application programming interface). Nadalje, Fintech organizacije koriste CC (cloud computing) i alate za napredne analitike. Također, često nude inovativne usluge, primjerice financiranje uz savjetovanje i umrežavanje za potrebe razvoja karijera te nove kanale distribucije odnosno integraciju višestrukih kanala komunikacije.

Tehnologije kao DLT, AI, RPA, GPS, VA, VR/AR i API već se godinama testiraju unutar različitih industrija uključujući bankarstvo. DLT (distributed ledger technology) tehnologija je do kraja 2016. godine privukla $1,4 milijarde kapitala, a kao rezultat razvoje tehnologije uloženo preko dvije i pol tisuće patenata. U bankarstvu se koristi za potrebe digitalnog identiteta (glatka prijava u sustav, AML (anti money laundering), KYC (know your customers)), povećanje sigurnosti i obrade čekova, pametne ugovore (autonomna ekzekucija ugovora, nije potrebno prethodno povjerenje partnera, povijesni tijek upisa tražbine na ime kolaterala, AML), provedbu međunarodnih transakcija (smanjenje troškova, mikroplaćanja) i regulatorno usklađivanje (automatizacija procesa, transparentnost, smanjenje troškova). Iako DLT nudi mogućnost provedbe platnih transakcija u gotovo realnom vremenu uz niže troškove provedbe transakcija (2016. godine prosječni trošak transkacije tradicionalnog globalnog sustava plaćanja iznosio je 7,68%, a vrijednost tržišta $601 milijardi), razina usvajanja tehnologije u

konkretnu svrhu trenutno je gotovo zanemariva. Nadalje, neovisno o tome jesu li informacije zapisane uz pomoć DLT tehnologije javne ili je pristup ograničen samo na sudionike s ključem, jednom unesen zapis ostaje nepromijenjiv, a novokreirane transkacije ne mogu promijeniti zapis prethodno provedenih te se istovremeno smanjuje asimetrija informacija, a nepromijenjivost isključuje potrebu za mirenjem. Također, identificirano je pet najizglednijih područja buduće primjene DLT tehnologije: dijeljeni repozitorij kao informacijska platforma za evidenciju imovine i njihovih vlasnika kojem mogu pristupati interni ili eksterni sudionici, višestruki sudionici s pravnom upisa u dijeljeni repozitorij (sustav plaćanja upravljan je od strane manjeg broja banaka, a tisuće klijenata obavlja transakcije s pojedinom bankom), transakcije koje zahtjevaju povjerenje (robna naplata koja čini tržište $18 bilijuna), aktivnostima gdje pouzdani posrednici garantiraju za ispunjenje obveza (provedba transakcija trgovanja, globalna plaćanja), transakcijska zavisnost gdje se provjera ciljane transakcije povezuje s prethodnim transkacijama (WEF, 2016b).

Obzirom da je za usvajanje tehnologije potrebna suradnja etabliranih institucija, inovatora i regulatora trenutno postoji niska razina usvajanja iste, a važno je napomenuti kako DLT ima tendenciju decentralitzacije odnosno smanjuje važnost posrednika u pružanja financijskih usluga. Očekuje se nekoliko divergentnih scenarija razvoja i upotrebe DLT tehnologije. Prvi scenarij podrazumijeva da banke zadržavaju postojeću infrastrukturu, a DLT tehnologija postaje konkurencija prvenstveno u transakcijama plaćanja alternativnih kanala Fintech i ostalih nefinancijskih organizacija. Drugi scenarij podrazumijeva kako će banke tehnologiju uključiti u svoje kanale komunikacije vodeći računa o rizicima i prilagođavajući se regulativnim mjerama. U namjeri da poveća efikasnost svojih procesa potpuno digitalna banka Fidor već korsiti Ripple (DLT protokol) za interno poravnavanje računa. Treći scenarij podrazumijeva kako će banka neovisne tehnologije Bitcoina stvoriti mrežu financijskih institucija koje će imati bolje karakteristike međuinstitucijske komunikacije odnosno transfera vrijednosti (WEF, 2015).

Umjetna inteligencija koristi se u računalnim programima za poticanje razgovara s klijentima, simulaciju prirodnog govora, preporuke klijentima, stvaranja većeg stupnja personalizacije, za trgovinu vrijednosnicama i devizama na osnovi algoritama i alatima za sprječavanja prevare (EFMA, 2017d). Japanska banka Jibun dizajnirala je AI baziranu aplikaciju koja predviđa kretanje tečaja, a njezina točnost u testiranom periodu iznosila je 80% pri čemu je dnevno provedeno deset tisuća transakcija od strane 1500 jedinstvenih korisnika (Ein Presswire, 2017).

Deutshe Banka (DB) dizajnirala je robo-savjetnika pod komercijalnim nazivom ROBIN koji prema afinitetima klijenta ima zadaću kreirati ETF (Exchange traded funds) porfolio (Deutsche Bank, 2017). Proizvod se temelji na informacijama koji su dostupne glavnom investicijskom direktoru DB-a i naprednim algoritmima. Unatoč naprednim analitikama sugestije ROBIN-a nisu bez nadzora financijskih eksperata. Dosad najpopularniji robo-savjetnik koji upravlja najvećim udjelom imovine Vanguard Personal Advisor obuhvaća vrijednost $47 milijardi. Charles Schwab također je lansirao robo-savjetnika za tržište stanovništva i najbogatijih klijenata s minimumom ulaganja od pet tisuća dolara. Imovina kojom upravlja CS (Charles Schwab) dosegnula je $12,3 milijarde te čini drugi najveći investicijskih portfolio upravljan na osnovi robo savjetnika. Ciljana konkurencija Charlesa Schwaba je Fintech organizacija pod imenom Wealthfront čiji imovina obuhvaća $4,4 milijarde, dok se na trećem mjestu robosavjetnika nalazi Betterment sa 6,7$ milijarde imovine. Pored ETF naknada, CS nema skrivenih troškova i nudi 24/7 pristup profesionalnim investicijskim savjetnicima (WEF, 2017). Neke od brokerskih kuća poput Robinhood (2018) ili N26 (2018) ponudile su trgovanje vrijednosnim papirima uz nulte troškove transakcija.

Od financijske krize 2008. godine investicijsko savjetovanje obilježeno je visokom razinom dinamike. Obnova povjerenja u financijski sustav i stabilizacija tržišta popraćeni su razvojem inovativne tehnologije koja mijenja strukturu tržišta. Gotovo svaki proces koji je dosad smatran ključnim kompetencijama tradicionalnog investicijskog menadžmenta (investicijskih ili klasičnih banaka) posljedično razvoju tehnologije može biti eksternaliziran: prikupljanje podataka, analiza, strategije trgovanja i provedba, nadzor, procjena rizika i usklađivanje s regulativom. Veličina institucije investicijskog menadžmenta više nije direktno povezana s kvalitetom. Fintech Kensho osnovan 2013. godine kao rezultat suradnje Harvarda i MIT-a, imenovan je najperspektivnijim privatnim AI poduzećem, specijaliziran je za računarsku analizu podatka i posjeduje analitičke algoritme nove generacije koji mogu provoditi masovno-pararelne statističko računarske operacije, gotovo neograničene infrastrukture razmjera i korisnički pristupačnog sučelja kojima uz visoku razinu točnosti u kratkom vremenskom periodu modelira tržišne trendove na razini kvalitete najvećih investicijskih institucija (Kensho, 2018). Upotrebom poluge tehnologije gotovo svako investicijsko poduzeće može producirati najmodernije kvantitativne analize uz minimalan angažman kvantitativnih eksperata. Postoje platforme otvorenog tipa koje nude besplatnu uslugu upravljanja rizikom, a financiraju se od naknada za podršku, edukaciju i trening zaposlenika čija je zadaća implementirati spomenute kapacitete u svrhu prilagođenih potreba pojedinih organizacija. Ekternalizacija, konsolidacija i

komunalizacija izjednačili su prilike za sve institucionalne investitore neovisno o veličini, a diferencijacija ostaje rezultat osobnog kontakta. Prethodno spomenuta visoka razina kvalitete investicijskog savjetovanja donedavno je bila dostupna samo najvećim investitorima, a većina klijenata ostvarivala je prinose prvenstvno na razini pasivnih kamatnih stopa koje su često bile niže od stope inflacije (što je rezultiralo negativnim realnim prinosom). Može se reći kako je upotreba AI tehnologije revolucionizirala segment investicijskog bankarstva (WEF, 2015).

RPA se prvenstveno koristi za obavijesti i upozorenja, pozicioniranje za povećanje sigurnosti kartičnog plaćanja, VA provođenje transakcija, VR/AR u segmentu nekretnina, dok API omogućuje suradnju s netradicionalnim pružateljima usluga. Tehnologija VA razvija se prvenstveno izvan bankarstva. Neke od najpoznatijih primjena spomenute tehnologije su danas Apple Siri, Microsoft Cortana, Samsung Bixby/Viv, Google Assistant/Now i Amazon Alexa pri čemu se orijentacija na mobilne telefone mijenja u smjeru platformi za potrebe stanovanja. Unutar financijskog tržišta najpoznatija su poduzeća Nuance i Personetics čija je tehnologija sadržana unutar aplikacija banaka kao što je Santander Bank, USAA, Ally. Putem Paypal-a, Square Cash-a i Venmo-a Apple Siri također ima mogućnost P2P plaćanja. P2P plaćanja putem Siri asistencije omogućile su europske banke Monzo (2018), RBC (Royal Bank of Canada) (2017) i N26 (2018). Nadalje, 2012. godine koristeći VR/AR tehnologiju u segmentu nekretnina po uzoru na Commonwealth banku Australije iz 2010. godine, Halifax dizajnira aplikaciju koja omogućava klijentima da na fizičkoj lokaciji učitaju informacije o nekretninama koje su trenutno na prodaju. Podružnica Lloyds Banking grupe udružena s findaproperty.com nudi mogućnost pretraživanja nekretnina diljem UK. Klijenti mogu držati svoje pametne mobitele na lokaciji kojoj se nalaze pristupajući svim nekretnimama na prodaju uz popratne informacije o rangiranju škola, infrastrukture transporta i slično, uključujući slike interijera i tlocrtnih planova odnosno mogućnosti financiranja (WEF, 2015).

Tehnologija „Cloud computing"-a koristi se za prikupljanje i pohranu velikih količina podataka o dnevnim transakcijama, ponašanju klijenata (koje kanale komunikacije koriste, geolokaciju, njihove stavove) te informacija s eksternih izvora kao što su društveni mediji. Prelazak na Cloud tehnologiju odvija se u etapama, a ima zadaću zamijeniti manje efikasne sustave i smanjiti troškove obrade podataka. Nadalje, Cloudcomputing ima zadaću koordinacije internog i eksternog toka podataka, njihovog prikupljanja i analize. Nastavno, agregiranju i označavanju, najvažniji korak u procesu upravljanja podacima predstavlja njihovu transformaciju u razumljive izvještaje koji se koriste za daljnju segmentaciju tržišta, razvoj novih proizvoda,

praćenje kvalitete iskustva korisnika i praćenje uspjeha poslovanja. Odabrani podaci koji će pritjecati u realnom vremenu trebaju biti pristupačni, pohranjeni i analizirani, a vrijednost rezultata primjene AI tehnologije bit će direktna posljedica kvalitete prikupljenih podataka. Tradicionalna analitika podrazumijeva pogled unazad, dok alati napredne analitike pokušavaju predvidjeti prilike. Ipak valja napomenuti kako primjena AI/ML-a *per se* ne mora nužno garantirati tržišni uspjeh. Napredni tehnološki alati zasigurno omogućuju brže izlazne informacije, ali ako su ulazni podaci nerelevantni te ostatak procesa organizacije nije adekvatno usklađen rezultat neće biti zadovoljavajući. Upotreba algoritama na osnovi AI (umjetne inteligencije) posebice za potrebe trgovanja koristi se od 1970-ih godina, dok su potpuno automatizirane radnje provođene već početkom 1990-ih godina. Trgovina koja se bazira na algoritamima nove generacije primarno je orijentirana na predviđanje cijene i izvršavanja naloga visokofrekventnog trgovanja koje je doživilo svoj vrhunac 2009. godine. Danas je značaj te vrste trgovanja nešto manji zbog nižeg stupnja volatilnosti, veće likvidnosti, povećanih troškova infrastrukture i ograničavajućih regulatornih mjera. Važno je napomenuti da spomenuta tehnologija upotrebom odnosno metodom pokušaja i pogrešaka te samokorekcije evoluira, a očekuje se kako će njezina kvaliteta u budućnsoti značajno rasti. Za razliku od generacije algoritama koji predviđaju buduće kretanje cijena vodeći se povijesnim podacima, novi algoritmi dizajnirani su s namjerom interpretacije vijesti u realnom vremenu odnosno stvarnih događaja [7] te će na osnovi bihevioralne analitike derivirati predviđeno kretanja cijene imovine. Postoje specijalizirani servisi (Dataminr i SNTMNT) koji u kombinaciji s društvenim medijima, bihevioralnim tržišnim pokazateljima i alatima analize u realnom vremenu brže od konkurencije omogućuju pristup informacijama o događajima koje mogu uzrokovati šokove na tržištu (izvanredne vijesti, špekulacije o preuzimanjima i spajanjima). Postoji teza kako će s protekom vremena strojnog učenja i rastom kvalitete raznovrsnih algoritama koji se baziraju na kombinaciji povijesnih podataka i stvarnih događaja doći do njihove konvergencije i singularnog pogleda na tržište, ali istovremeno i svojevrsnog fenomena crne kutije [8], a regulatori će svakako biti zainteresirani za rizike koji se mogu povezati sa stabilnošću financijskog sustava. Valja napomenuti kako spomenuti alati nisu bez rizika odnosno imaju svoje nedostake. U travnju 2013. godine objavljena je vijest o eksploziji unutar Bijele kuće te se posljedično automatskoj trgovini u nekoliko sekundi tržište urušilo za $136 milijardi. Iako

[7] engl. machine readable news

[8] eng. Black box

se oporavak dogodio unutar tri minute nakon što je objavaljen ispravak lažne vijesti mnogi eksperti su zaključili kako se isti šok ne bi mogao dogoditi kao rezutlat ljudskog djelovanja(WEF, 2015).

Od spomenutih tehnnologija, prema njihovoj važnosti odnosno postojećoj razini ulaganja unutar bankarske industrije ističu se sustavi sigurnosti, napredne analitike, API, „cloud computing“, AI, ML, dok su AR/VR, Blockchain i RPA bili manje značajni. Fintech organizacije neopterećene su tradicionalnom strukturom i regulacijom, ali zbog nedovoljnog poznavanja regulacije i nedostatka baze klijenata za postizanje ekonomije obujma često formiraju partnerske odnose s bankama. Istovremeno to su organizacije koje efikasno prikupljaju podatke, analiziraju te koristeći napredne tehnologije stvaraju nove vrijednosti za klijenta čime predstavljaju i njihovu konkurenciju. Smatra se kako će upravo u sferi transakcija plaćanja i stvaranja digitalnih novčanika te eventualno alokacije viškova financijskih sredstava Fintech organizacije biti najveći konkurenti banaka (EFMA, 2017d). Može se očekivati kako će odnosi unutar financijskog tržišta putem API-a između banaka i Fintech organizacija poprimiti visok stupanj složenosti, dok će spomenute organizacije u nekim segmentima biti konkurenti, a u nekim segementima i vremenskim periodima partneri. Banke za svoju osobnu upotrebu mogu samostalno razvijati određene API-e, koristiti API-e razvijene od trećih strana, a treće strane mogu iskoristiti API-e koji su razvijeni u bankama. Zahvaljujući svojem iskustvu kao rezultat milijuna provedenih transakcija plaćanja i povrata novca, Amazon je lansirao „Amazon Payments“. Usluga je dio API tržišta, a omogućuje trgovcima da unutar svojih web mjesta Fefmaintegriraju siguran sustav plaćanja koji je svoju reputaciju stekao u okviru Amazona (EFMA, 2017d). Naglasak je na kreiranju iskustva neprimjetnog bezgotovinskog plaćanja popraćenog pozadinskim procesima dokumentacije detalja provedenih transakcija (WEF, 2017). Amazon je također uložio značajne napore u izradu vlastitog sustava ocjene kreditne sposobnosti vlastitih aktivnih trgovaca. Na temelju obujma i opsega prodaje svojih trgovaca Amazon je dosad odobrio više od 3 milijarde dolara kredita. Na istom principu AMP (Advanced Merchant Payment) koji pruža uslugu plaćanja mikro, malim i srednjim trgovcima u Singapuru, Velikoj Britaniji, Hong Kongu i Filipinima odobrava kredite svojim klijentima direktno ili na osnovi dostupnih podataka u suradnji s bankama povećava kvalitetu ocjene boniteta manjih trgovaca (Bloomberg, n.d.). Iako Fintech organizacije imaju svojevrsne prednosti u odobravanju kredita u odnosu na etablirane banke ista nisu bez ograničenja. Pristup izvorima financiranja svakako je relativno otežan u odnosu na klasične ili digitalne banke. Banke se oslanjaju na depozite kao relativno jefitin izvor kapitala, dok se tehnološka poduzeća

moraju okrenuti privatnim investitorima s većim profitnim očekivanjama koja se mogu povezati s reputacijom manje etablirane organizacije. U želji da osiguraju pristup depozitima neke su od spomenutih organizacija (Sofi, Zopa) istraživale i mogućnost dobivanja bankovne licence, a neke su se udružile u strateška partnerstva s bankama (LendingClub i UnionBank) (WEF, 2017).

Koristeći API tehnologiju poduzeće Raisin kreira platformu koje omogućava pristup najboljim ponudama kamatnih stopa diljem Europe. Prethodno Raisin tehnologije klijent je morao zaobilaziti administrativne barijere, prolaziti proces otvaranja računa u banci što je često zahtjevalo i fizičku prisutnost. Prva u potpunosti digitalna banka Europe sa svim pravima klasične banke, N26, preuzela je Raisin rješenje te isto integrirala u svoju online bankovnu platformu (EFMA, 2017d). Slično, može se očekivati da će banke i samostalno razvijati API-e koristeći ekspertizu autentifikacije korisnika i provedbe transakcija. Nadalje, banke moraju strateški upravljati API sustavima te periodično razmatrati do koje će se mjere eksterni sustavi integrirati u sustav banke i obrnuto. Ukoliko neke od API-a razvijenih od jedne Fintech organizacije koriste i drugi sudionici banka mora razmatrati raspoložive kapacitete, a ograničenja uključiti u svoje razvojne planove. Također, banke koje samostalno razvijaju svoje API-e moraju odlučiti o stupnju otvorenosti istih kao predizspozcije za budući razvoj od stane Fintech organizacija. Analogija otvorenosti API-a nalikuje operativnim sustavima mobilnih uređaja. Primjerice, iako je iOS sustav otvoren vanjskim programerima, stupanj otvorenosti ne može se mjeriti s operativnim sustavom Androida (Wilkinson, 2017).

Nadalje, monetizacija API-a kao posljedice otvaranja financijskog sektora trećim stranama i suradnje s Fintech organizacijama može biti provedena odabirom jednog ili kombinacije sljedeća tri pristupa. Prvi pristup podrazumijeva plaćanje po usluzi pri čemu pružatelj usluge omogućava dizajneru pristup podacima o transakcijma klijenta kako bi zauzvrat dobio komparaciju cijena ili analizu ponašanja. Drugi pristup podrazumijeva plaćanje pretplate prema dogovorenom iznosu u vremenu neovisno količini korištenja usluge. Konačno, treći pristup podrazumijeva podjelu prihoda koji su rezultat prodaje proizvoda od strane pružatelja usluge krajnjem korisniku pri čemu dizajner API-a istovremeno ostvaruje svoj udio (Wilkinson, 2017).

2.2 Strategije izgradnje konkurentske prednosti bankarskog sektora

Može se reći kako znanstveno izučavanje strategije polazi od paradigme koja je nastala početkom 1980.-ih godina od strane Michaela Portera. Jedna perspektiva Porterove strategije nalaže kako će poduzeće napraviti one radnje koje će ga činiti zaštićenim od konkurencije, a druga perspektiva podrazumijeva pristup koji nalaže strateški sukob. Dva pristupa nisu odvojena niti isključiva, ali drugi naglašava aspekte nesavršenosti tržišta i njihovu međusobnu interakciju. Strateški sukob podrazumijeva alate teorije igara, a konkurentsku prednost smatra derivacijom sposobnosti poduzeća da kroz ulaganja, cjenovnu strategiju i kontrolu informacija, svoje konkurente zadrži izvan ravnoteže. Ipak, oba pristupa jasno ističu kako je prinos na imovinu poduzeća upravo rezultat povlaštenog tržišnog položaja. Treća perspektiva Porterove strategije naglašava kako se konkurentska prednost stvara prvenstveno povećanjem efikasnosti odnosno kako suština strategije leži u tehnološkim i organizacijskim promjenama poduzeća (Teece, 1997).

Nastavljajući se na poznatog japanskog stratega Kenichi Ohmaea koji je rekao kako bez konkurencije nema potrebe za strategijom, Tipuric (2014) ističe kako je najbolja ona strategija koja ne poznaje konkurenciju. Također, navodeći kako je govorio Porter, autor napominje da se suština strateškog promišljanja zapravo ne svodi na pitanje odabira onoga što će se raditi, nego na pitanje onoga što se neće raditi.

Od početka devedesetih pa sve do kraja prvog desetljeća 21. stoljeća sektor bankarstva karakterizira dominacija difuzne i nasumične poslovne strategije. Poslovanje banaka obilježeno je niskom averzijom prema riziku, širokim rasponom poslovnih plasmana, minimalnom kontrolom troškova i nepostojanjem napora da se uspostavi strateška diferencija koja će banke razlikovati od konkurencije. Nakon financijske krize 2008. godine dogodio se zaokret u poslovanju banaka. Prestaje dominacija strategije rasta, a prevladavaju modeli čija je zadaća osigurati preživljavanje. Bankarski sektor je restrukturiran, odnosno banke su revalorizirale svoje plasmane te kako bi udovoljile novoj regulaciji adekvatnosti kapitala i smanjenja poluge banke su promijenile strukturu svojih izvora imovine. Nadalje, iako je nakon krize zadnjih nekoliko godina većina banaka bila orijentirana na smanjenje troškova, racionalizaciju poslovne mreže i rast efikasnosti smanjuju se prosječne stope profitabilnosti. Prethodno financijskoj krizi, 2001.-2006. globalni bankarski prosjek povrata na kapital iznosio je 16,9%, nakon krize 2009.-2014., 10,6%, a 2014. godine negativan trend se nastavlja. Iako su negativni

trendovi u sektoru bankarstva rezultat gospodarskog ciklusa odnosno kontrakcije, nisu sve banke ostvarile jednak neuspjeh ili uspjeh. Očigledan je porast heterogenosti unutar bankarskog sektora, pri čemu je prosječno odstupanje od prosjeka u razdoblju 1993.-2003. bilo svega 5%, dok je za razdoblje 2003.-2013. isti pokazatelj dosegnuo 9%. Trend pada profitabilnosti odnosno rasta diferencijacije upućuju na potrebu da banke revidiraju odnosno redizajniraju svoje strategije rasta i razvoja. Smanjenje profitabilnosti banaka rezultat je kreditne kontrakcije odnosno tendencije smanjenja zaduživanja stanovništava i poduzeća te jačanje konkurencije koja je smanjila raspon kamatnih stopa te prihode od naknada za usluge. Kao rezultat napretka tehnike pojavili su se digitalni konkurenti, solidarno kreditiranje i mogućnost pružanja prekogranične usluge platnih transakcija, a banke se nikako ne žele naći s pogrešne strane tehnološke revolucije. Kratkoročni izraz strategije mnogih banaka dosada je bio definiran kvartalnim razinama profita, a neostvarenje tih ciljeva podrazumijevalo je odricanja za buduće koristi, dok jasno određena strategija banke uključuje odabir tržišta, portfolio usluga i troškovno vodstvo (Hadley i sur., 2015).

Kao što je citirano u Kundid, Skrabic i Ercegovac (2011), Rose napominje kako su za uspjeh banke važni: rizik, udio financijske poluge, veličina banke, cijena usluga, kontrola troškova, produktivnost zaposlenika, upravljanje likvidnošću, struktura depozita i vlasništva. Spomenute varijable predstavljaju mikroekonomsko okruženje, a dijelom makroekonomskog okruženja smatraju se: inflacija, kamatna stopa, tečaj, nezaposlenost, kapitalizacija na tržištu vrijednosnica i stopa rasta BDP-a. Pored toga važne odrednice industrije predstavljaju koncentracija, raspon kamatnih stopa i regulacija.

Šireći se u čitav niz različitih zemalja jedan dio globalnih banaka preslikavao je postojeće poslovne modele i proizvode na tržišta raznovrsnih karakteristika. Zahvaljujući performansama rastućih ekonomija i pozitivnih ekonomskih trendova, ekonomije opsega i obujma nisu nikada u potpunosti empirijski potvrđene, a kompleksnost te izazovi kontrole daleko su nadmašeni prilikama na tržištu odabranih zemalja. Smanjenje zamaha rasta ekonomija u razvoju, jačanjem domaće konkurencije i regulatornih promjena, javlja se potreba za revizijom strategije banaka (Hadley i sur., 2015).

Za banke je važno zauzeti poziciju na tržištu digitalnih komunikacija odnosno banke se trebaju potruditi da preusmjere promet na svoje digitalne kapacitete kako bi mogle nastaviti dominirati u pružajnu široke lepeze financijskih usluga. Strategija mora uzeti u obzir potrebe korisnika,

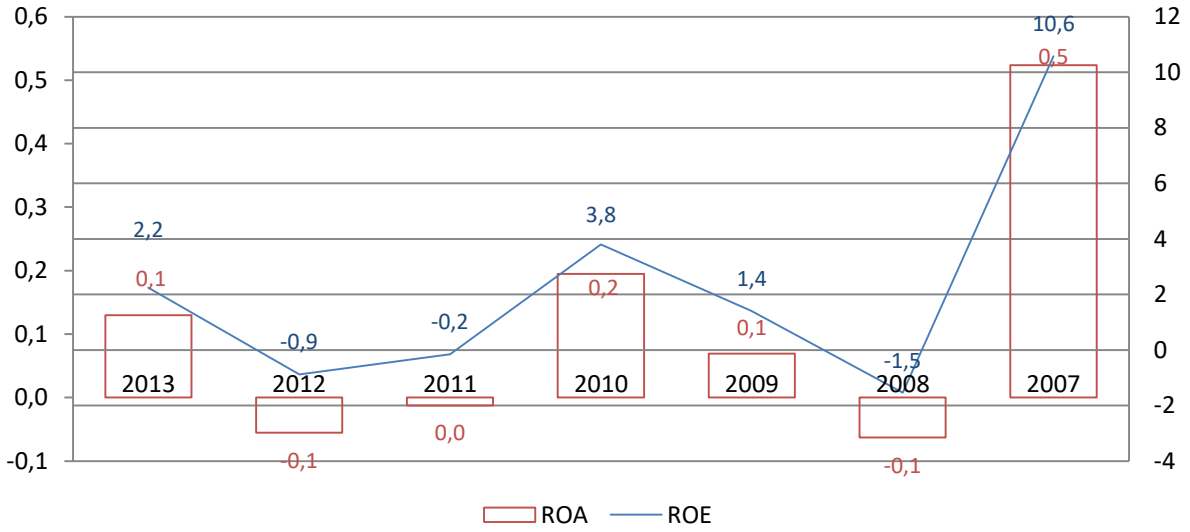
tehnička i regulatorna ograničenja, a banka će postaviti kriterije preuzimanja rizika te uzeti u obzir odstupanja koji su rezultat ekonomskih ciklusa. Povezano, može se razmatrati osjetljivost strategije na sistemski rizik. Posljedično, financijskoj krizi 2008. godine koja se smatra najvećom krizom nakon 1930.-ih godina cjelokupni financijski sustav pretrpio je velike gubitke, a neke od banaka su propale. Kao rezultat ekonomskih ciklusa i odgovarajućeg spleta okolnosti, kreditna ekspanzija hipotekarnih kredita koja je doživjela vrhunac 2007. godine dovela je do propasti nekih od najvećih imena financijskog tržišta. Poznati su primjeri Lehman Brothersa, Washington Mutuala, Fannie Mae-a, Freddie Mac-a te AIG-a (Ivashina i Scharfstein, 2010). Posljedično dugoročnom trendu ekonomskog rasta i razvoja financijskog tržišta banke su odobrile relativno velik udio nenaplativih stambenih kredita koji su preprodani na sekundarnom financijskom tržištu. Najveći relativan porast udjela nenaplativih plasmana započeo je 1996. godine, a smatra se da je zaslužno procesu sekuritizacije potvrđena negativna korelacija prihoda i kreditne ekspanzije (Mian i Sufi, 2009). Vrijednost nekretnina i reputacija velikih imena financijskog tržišta predstavljali su garanciju za naplatu spomenutih potraživanja, a menadžeri su potaknuti željom da ostvare godišnje premije spremno otkupili i kapitalom velikih financijskih institucija stvarali rejting vrijednosnica koje su izdane na osnovi nenaplativih potraživanja (Hadley i sur., 2015).

Kriza koja se dogodila 2008. godine utjecala je na adaptaciju strategije banaka rastućih ekonomija. Na strani izvora imovine banke su smanjile ovisnost prema veleprodajnom tržištu, a fokusiraju se na privlačenje depozita. Na strani plasmana usporava aktivnost kreditiranja te se banke orijentiraju na manje rizične plasmane i kupovinu državnih obveznica. Skraćenjem dospijeća plasmana, povećava se likvidnost imovine, smanjuje aktivnost na međubankarskom tržištu i povećava opseg transakcija s centralnom bankom (Mihaljek, 2014)

Kao što je citirano u Vojvodić Rosenzweig, Volarević, Varović (2013), prema Kosak i Čok, Bulletin Banks (HNB, 2011), Kundid, Skrabić i Ercegovac, Chortareas, Girardone i Ventouri, Cernohorska i Cernohorsky, Siddiqui, najvažniji pokazatelji profitabilnosti banke su raspon kamatnih stopa i omjer profitabilnosti imovine i kapitala ROA/ROAE/ROE/ROAE (Return of asset (Povrat na imovinu) = Profit nakon poreza / Vrijednost (prosječne) imovine), a raspon kamatnih stopa čini omjer vagane sredine kamatnog prinosa i vagane sredine troška kapitala, a profitabilnost imovine odnosno kapitala omjer profita i aritmetičke sredina tekuće i prethodne godine prosječne imovine ili kapitala. Kako bi mjera profitabilnost banke bila reprezentativna odnosno usporediva važno je kvantificirati mjeru rizika. Često korišteni pokazatelji rizika su:

omjer nepodmirenih potraživanja banke uvećanih za rezervacije i ukupnih plasmana uvećanih za potencijalne izvanbilančne obveze banke, omjer kapitala banke i ukupnih depozita, omjer kapitala i ukupne imovine banaka, omjer gotovine i obveza prema klijentima te omjer kreditnih plasmana i depozita.

Dinamička analiza na podacima promjenjive kompozicije zemalja Europske unije u periodu 1.1.2007.-1.1.2013. (vidjeti sliku 3) pored očigledno padajućeg trenda pokazuje sinusoidu prinosa kreditnih institucija. Godine 2007. profitabilnost kapitala iznosila je nenadmašenih ROE=10,6% (ROA=0,5%) nakon čega se 2008. godine razina profitabilnosti smanjuje te iznosi negativnih ROE=-1,5% (ROA=-0,1%). Nastavno, 2009. i 2010 godine prinosi rastu te iznose 1,4% i 3,8%, a ponovni pad dogodio se 2011. i 2012. godine (0,2%;-0,9%), dok je 01.01.2013. stopa profitabilnosti bila pozitivna te iznosila ROE=2,2%. (ROA=0,1%).

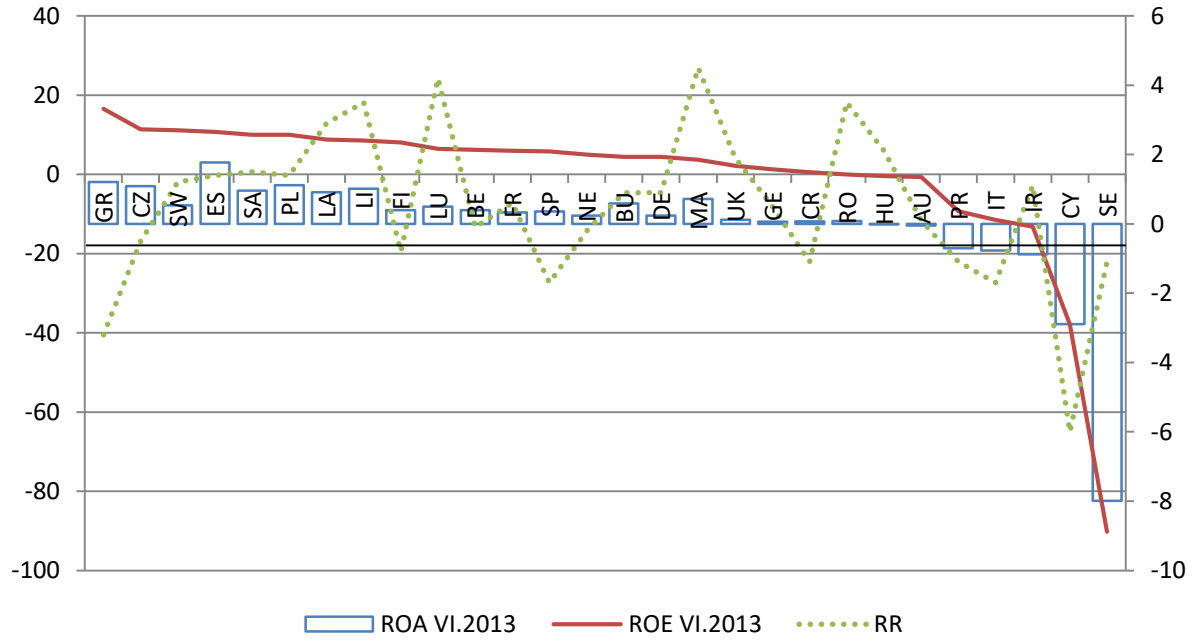


Slika 3. Stope profitabilnosti prema promjenjivoj kompoziciji Europske unije u periodu 2007.-2013.

Izvor: ECB, 2017a

Na razini zemalja Europske unije podaci su dostupni za drugi kvartal 2013. godine. Profitabilnost kapitala kreditnih institucija Republike Hrvatske te godine iznosila je ROE=0,56%, a profitabilnost imovine ROA=0,07%. Niža razina profitabilnosti kapitala u odnosu na kreditne institucije Republike Hrvatske ostvarena je u Rumunjskoj (0,01%), Mađarskoj (-0,42), Austriji (-0,68%), Portugalu (-9,34%), Italiji (-11,51%), Irskoj (-13,15), Cipru (-37,86) i Sloveniji (-90,25). Najuspješnije su bile Grčka (16,52%), Češka (11,36%),

Švedska (11,11%), Estonija (10,74%) i Španjolska (10,01%). Važno je naglasiti kako profitabilnost kapitala kreditnih institucija zemalja Europske unije nije visoko korelirana s realnim stopama rasta bruto domaćeg proizvoda te implicira kako uspjeh kreditnih institucija nije preslika gospodarskih ciklusa zemlje. Primjerice, Grčka, Češka, Finska, Belgija, Španjolska, Danska i Hrvatska imale su negativne stope rasta 2013. godine dok je profitabilnost imovine bila pozitivna, a kreditne institucije nekih od prethodno spomenutih zemalja pripadaju skupini zemalja najvećeg omjera profita i kapitala (Grčka, Češka i Finska).



Slika 4. Profitabilnost kapitala te imovine banaka na razini zemalja Europske unije, ROE, ROA

Izvor: ECB, 2017e

ROE-lijevo, ROA-desno, RR(stopa realnog rasta-desno), GR-Grčka, CZ-Češka, SW-Švedska, ES-Estonija, SA-Slovačka, PL-Poljska, LA-Latvija, LI-Litva, FI-Finska, LU-Luksemburg, BE-Belgija, FR-Francuska, SP-Španjolska, NE-Nizozemska, BU-Bugarska, DE-Danska, MA-Malta, UK-Ujedinjeno Kraljevstvo, GE-Njemačka, CR-Hrvatska, RO-Rumunjska, HU-Mađarska, AU-Austrija, PR-Portugal, IT-Italija, IR-Irska, CY-Cipar, SE-Slovenija. ROE i RR –lijeva os; ROA – desna os

Komparativno na razini zemalja Europske unije rast pokazatelja profitabilnosti dogodio se u relativno malim sustavima, primjerice Portugalu, Sloveniji, Austriji i Malti, dok se u razvijenim financijskim sustavima primjerice Njemačkoj omjer profita i vrijednosti imovine smanjuje. Generalno govoreći, kreditni sustavi niskog rasta i niskih kamatnih stopa teško održavaju postojeće razine i stope profitabilnosti (ECB, 2016).

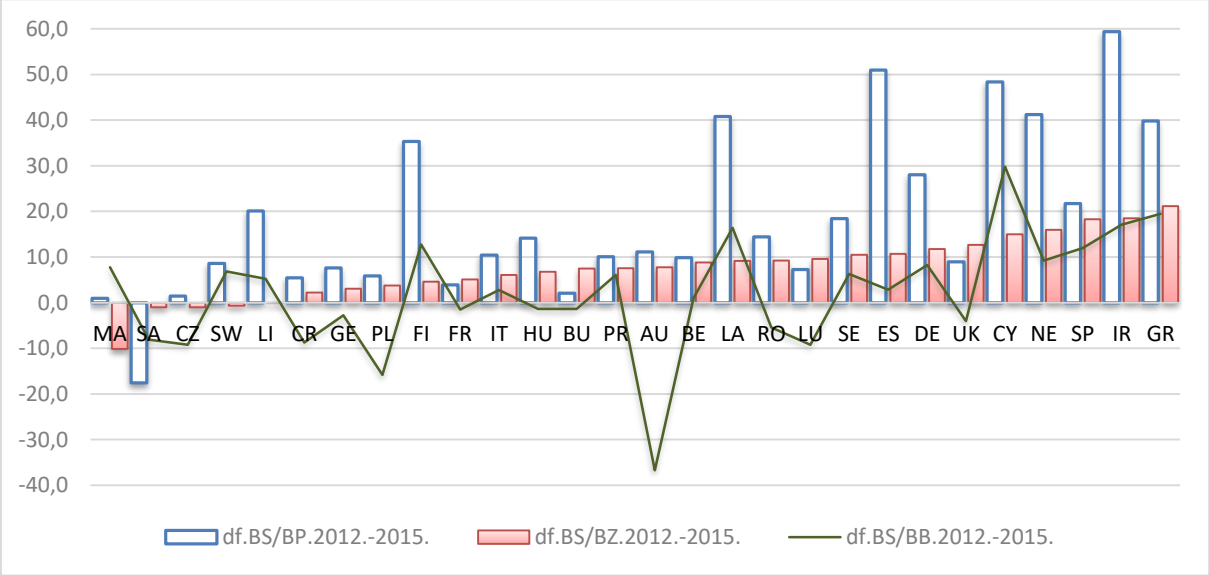
U Republici Hrvatskoj u 2015. godine izostaje kreditna ekspanzija, a kao posljedica razduživanja prema stranim vjerovnicima veličina imovine banaka smanjena je za 0,5%. Dodatno, kao rezultat zaduživanja u inozemstvu i plasmana kredita s valutnom klauzulom te značajne promjene tečaja švicarskog franka otpisan je dio nenaplativih potraživanja. Kao rezultat propisa o konverziji kredita napravljene su rezervacije u iznosu 6,8HRK mlrd., a poslovni gubitak 2015. godine iznosio je –5.032,2HRK mlrd. Profitabilnost prosječne imovine ROAA iznosila je –1,3%, a profitabilnost prosječnoga kapitala ROAE=–8,8%. Negativni poslovni rezultat na agregatnoj razini banaka prethodno tome dogodio se prvi put 1998. godine odnosno prije 16 godina (HNB, 2016). Tako je 2015. godine od ukupno 28 banaka čak njih 15, uključujući sve najveće banke osim Privredne Banke Zagreb iskazalo gubitke. Značajno veće gubitke iskazali su Hypo-Alpe Adria (22,6%) i Erste Steiermarkische banka (19,1%) (FINA, 2016).

Nastavno, 2016. godine dogodio se oporavak sektora kreditnih institucija. Prosječna profitabilnost imovine prvih šest mjeseci 2016. godine iznosila je ROA=0,92%, a prosječna ponderirana profitabilnosti kapitala ROE=7,23%. Najuspješnije su bile Raiffeisenbank Austria d.d. (ROA=1,47%; ROE=11,85%), zatim Podravska Banka d.d. (ROA=1,08%; ROE=10,38%), Société Générale-Splitska banka d.d. (ROA=1,17%; ROE=9,47%), Privredna Banka Zagreb d.d. (ROA=1,25%; ROE=7,88%), Štedbanka d.d. (ROA=1,18%; ROE=3,03%), Iako su Štedbanka d.d. i Podravska Banka d.d. prema profitabilnosti kapitala među pet najuspješnijih kreditnih institucija, prema apsolutnoj vrijednosti ukupne dobiti nalaze se na 13. i 10., te je njihov utjecaj na tržištu kreditnih institucija Republike Hrvatske manje značajan (vidjeti tablicu 3).

Početkom 2016. godine prepoznat je trend rasta depozitnog izvora financiranja kako trgovačkih društava tako stanovništva. Rast depozita trgovačkih društava rezultat je izvanrednih događaja malog broja subjekata, dok je rast depozita stanovništva rezultat rasta depozita na transakcijskim računima. Smanjena je ukupna kreditna aktivnost banaka, osim u sektoru poljoprivrede i turizma kao dviju komplementarno-perspektivnih djelatnosti. Kreditiranje stanovništva smanjuje se kontinuirano sedam godina zaredom te je prisutno valutno restrukturiranje izvora financiranja. Osim što je napravljena konverzija kredita švicarskog franka u euro kao rezultat negativnih posljedica promjene tečaja raste udio nenamjenskih i stambenih krediti u domaćoj valuti (ibid.).

Na području Europske unije koncentracija populacije na jednog zaposlenika kreditne institucije u periodu 2008.-2014. godine porasla je s 122 na 128 građana odnosno 4,91%, dok je broj građana na jedan bankomat s 1035 na 1078 rastao gotovo istom brzinom 4,15% (ECB, 2016).

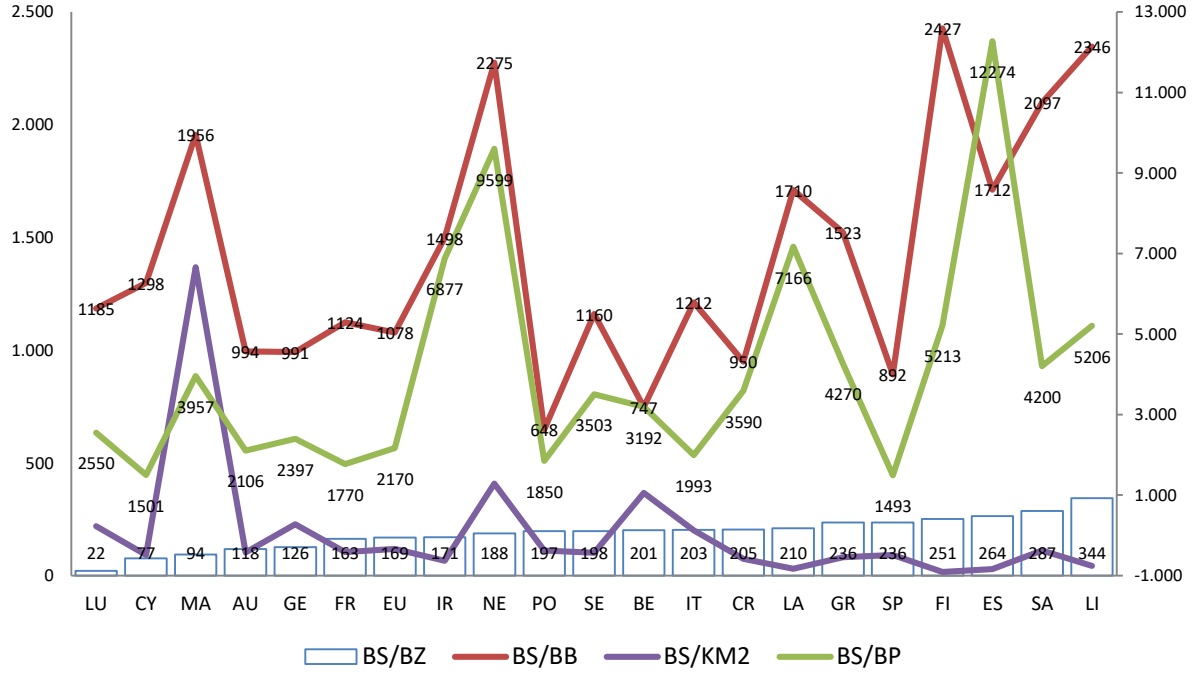
Podaci o koncentraciji poslovnih jedinca kreditnih institucija u Republici Hrvatskoj dostupni su na razini županija. Prema podacima za razdoblje 2012.-2015. godine može se vidjeti kako se udio koncentracije poslovanja banaka odnosno broja poslovnih jedinica prema županijama nije značajno promijenio. Najveća koncentracija poslovnica bila je na području Zagrebačke županije (23,1%), zatim Splitsko-dalmatinska županije (12,1%), Primorsko goranske županije (8,54%) te Istarske županije (8,79%) pri čemu ¼ ukupnog broja županija obuhvaća 56,9% svih poslovnica.



Slika 5. Stopa promjene koncentracije broja stanovnika na jednu poslovnicu kreditne institucije, jednog zaposlenika i jedan bankomat zemalja Europske unije
df.BS.BP-postotna promjena broja stanovnika na jednu poslovnicu
df.BS.BZ-postotna promjena broja stanovnika na jednog zaposlenika
df.BS.BB-postotna promjena broja stanovnika na jedan bankomat
GR-Grčka, CZ-Češka, SW-Švedska, ES-Estonija, SA-Slovačka, PL-Poljska, LA-Latvija, LI-Litva, FI-Finska, LU-Luksemburg, BE-Belgija, FR-Francuska, SP-Španjolska, NE-Nizozemska, BU-Bugarska, DE-Danska, MA-Malta, UK-Ujedinjeno Kraljevstvo, GE-Njemačka, CR-Hrvatska, RO-Rumunjska, HU-Mađarska, AU-Austrija, PR-Portugal, IT-Italija, IR-Irska, CY-Cipar, SE-Slovenija.
Izvor: autorica prema ECB, 2017b; autorica prema HNB, 2018

U nastavku na slici 6 može se vidjeti komparativna analiza koncentracije poslovnih jedinica, zaposlenika i broja bankomata prema zemljama Europske unije 2015. godine. Podaci su sortirani prema broju stanovnika na jednog zaposlenika, a povezanost između koncentracije stanovnika na zaposlenika banke i broja poslovnica, broja bankomata i gustoće naseljenosti nije

vidljiva. Može se zaključiti kako se poslovnice banaka prema svojoj veličini odnosno broju zaposlenika razlikuju unutar zemalja Europske unije te je broj stanovnika na jednog zaposlenika bolji pokazatelj strukture komunikacije banaka odnosno njihove digitalizacije. Također, mreža bankomata nije direktna posljedica koncentracije klijenata na zaposlenika banke nego predstavlja alternativni kanal komunikacije banke i klijenata. Najveća koncentracija stanovnika na zaposlenika banke bila je u Litvi (344), zatim Slovačkoj (287), Estoniji (264), Finskoj (251), Španjolskoj (236) i Grčkoj (236), a najmanja u Luksemburgu (22), Cipru (77), Malti (94), Austriji (118) i Njemačkoj (126).



Slika 6. Koncentracija poslovnih jedinica, zaposlenika i broja bankomata prema zemljama Europe, 2015

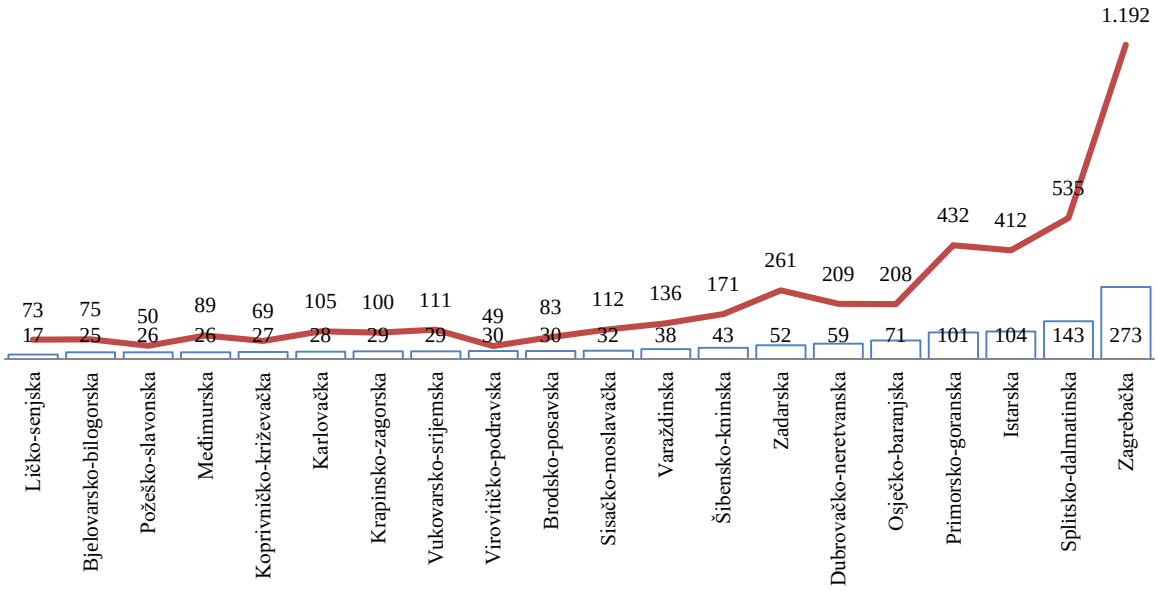
BS/BZ- broj stanovnika/broj zaposlenih, primarna os
BS/BB- broj stanovnika/broj bankomata, sekundardna os
BS/BP-broj stanovnika/broj poslovnica, sekundarna os
GR-Grčka, CZ-Češka, ES-Estonija, SA-Slovačka, PL-Poljska, LA-Latvija, LI-Litva, FI-Finska, LU-Luksemburg, BE-Belgija, FR-Francuska, SP-Španjolska, NE-Nizozemska, BU-Bugarska, DE-Danska, MA-Malta, UK-Ujedinjeno Kraljevstvo, GE-Njemačka, CR-Hrvatska, RO-Rumunjska, HU-Mađarska, AU-Austrija, PR-Portugal, IT-Italija, IR-Irska, CY-Cipar, SE-Slovenija, DE-Danska, SW-Švedska.
Izvor: autorica prema ECD, 2015; autorica prema HNB 2018: autorica prema ECB, 2017b

Koncentracija stanovnika na broj zaposlenika banke ne može se povezati sa stupnjem razvoja financijskih sustava te se može zaključiti kako razvijenost financijskog sustava i digitalizacija ne podrazumijevaju manji broj zaposlenika na jednog stanovnika banke. Nadalje, infrastruktura bankomata odnosno alternativni kanal komunikacije bio je najrazvijeniji u Sloveniji (116), Latviji (171), Portugalu (648), Belgiji (747), Španjolskoj (892) i Hrvatskoj (950), a najmanje

razvijen u Švedskoj (2968) Finskoj (2427), Litvi (2346), Nizozemskoj (2275), Slovačkoj (2097) i Malti (1956). Broj stanovnika na jedan bankomat također se ne može povezati s razvijenošću financijskog sustava zemlje odnosno može se pretpostaviti kako je posljedica povijesno-kulturoloških razlika unutar zemalja Europe.

Uspostavljanje mreže bankomata može biti u svrhu stvaranja dodatnih kanala distribucije ili kao dio strategije osvajanja novih tržišta kada nije moguće povećavati broj poslovnica. Nadalje, iako se bankomatima jedne banke najčešće isključivo ili uz nulte troškove služe samo klijenti te banke broj bankomata može povećati vidljivost te banke na tržištu (Parameswar, Dhir, Dhir, 2017). Povijesno gledano može se reći da su banke povećavale mrežu svojih poslovnica da bi osnažile reputaciju banke, povećale stopu rasta novih klijenta i stopu rasta depozita. S pojavom poslovnica na svakom koraku rastao je utjecaj na potencijalne klijente koji su istraživajući tržište hodali od poslovnice do poslovnice i skljupljali promotivne brošure. Danas većina klijenata financijsko tržište istražuje putem računala ili mobitela, a obzirom na rast upotrebe i prihvaćanje digitalne tehnologije od strane klijenata, očekuje se kako će za potrebe istraživanja financijskog tržišta odnosno ugovaranja financijskih proizvoda i usluga u budućnosti biti dovoljno izreći nekoliko glasovnih naredbi. Iskustvo kupovine u Internet trgovinama promjenilo je toleranciju klijenata prema određenim aspektima poslovanja banaka. Odlazak na fizičku lokaciju banke kako bi se otvorio račun, predstavlja manjak podgodnosti odnosno može odbiti potencijalne klijente. Naime, klijent želi smanjiti ili izbjeći trošenje vremena potrebnog za istraživanje tržišta ili odlazak u banku, a pokazalo se kako prethodno odabiru pružatelja financijskih usluga klijent u prosjeku razmatra svega dvije organizacije (EFMA, 2017d). Prema istraživanju 2017. godine koje provodi Novantas (Omni-channel Shopper Study) većina klijenata u SAD-a ili ne koriste ili ne pridaju važnost broju poslovnica svoje banke. Zainteresirani su za personalizaciju usluge i rast kvalitete iskustva kao rezultat upotrebe digitalizacije. Uspjeh financijskih organizacija u budućnosti svakako će dobrim dijelom ovisiti o sposobnosti prilagodbe klijentima na mikro razini. Iako je pogodnost ostala jedan od prioriteta inicijalnog odabira banaka, broj i udaljenost poslovnica više nije parametar pogodnosti, a isto je sada prvenstveno rezultat digitalnih kapaciteta organizacije. Može se reći kako su banke dosad orijentirane na centralno računalo, efikasnost osobne obrade klijenata, bankomata, komunikacije telefonom i kartičnog plaćanja pod utjecajem digitalizacije reorganizirale svoje poslovanje i transakcije prvenstveno izvan poslovnica banaka na mobilne uređaja te uz pomoć napredne analitike ponašanja korisnika počele isporučivati visoko personaliziranu uslugu. Uporaba robotike, umjetne inteligencije i platformi omogućili su zadovoljavanje potreba klijenata u realnom vremenu te istovremeno promjenili strukturu bankarstva. Spomenute

promjene prvenstveno su pogodovale bankama koje su prepoznale potencijal inovatinih tehnologija, a one banke čija tehnološka rješenja ne prate trendove neće moći zadržati svoju poziciju (Cognizant, 2018).

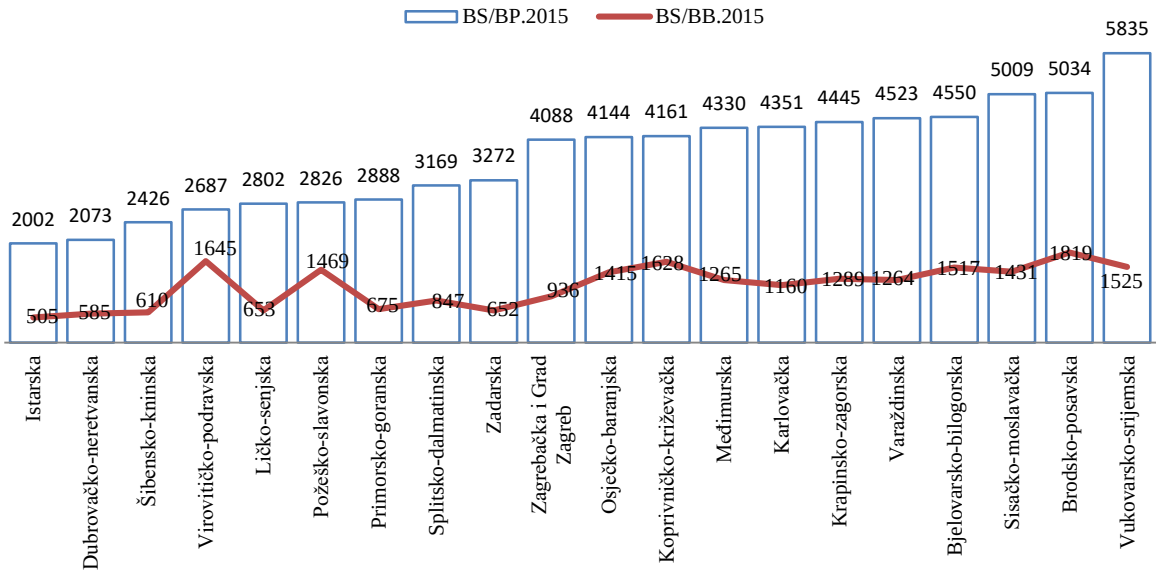


Slika 7. Udio poslovnih jedinica i bankomata kreditnih institucija prema županijama RH, 2015
Linijski grafikon – udio bankomata
Stupčasti grafikon – udio poslovnih jedinica
Izvor: autorica prema HNB, 2018

Promatrajući udio poslovnih jedinica i bankomata kreditnih institucija prema županijama unutar Hrvatske može se reći kako postoji korelacija između broja poslovnica i broja bankomata te se može zaključiti kako je koncentracija istih rezultat broja stanovnika i financijske razvijenosti pojedine regije odnosno županije. Najveći broj poslovnica i bankomata imala je Zagrebačka županija (BP:273, BB:1192), zatim Splitsko-dalmatinska (BP:143, BB:535), Istarska (BP:104, BB:412), Primorsko-goranska (BP:101,BB:432 i Osječko-baranjska (BP:71, BB:208), a najmanji Ličko-senjska (BP:17, BB:73), zatim Bjelovarsko-bilogorska (BP:25, BB:75) i Požeško-slavonska (BP:26, BB:50) (vidjeti sliku 7).

Kada se uzme u obzir broj stanovnika pojedine županije (vidjeti sliku 8) tada se koncentracija broj stanovnika na zaposlenika banke i jedan bankomat slično kao u Europskoj uniji ne može povezati s razvijenoštću pojedine regije. Najveća koncentracija stanovika na zaposlenika banke bila je u Vukovarsko-srijemskoj županiji (5835), Brodsko-posavskoj (5034), Sisačko-moslavačkoj (5009), Bjelovarsko-bilogorskoj (4550), Varaždinskoj (1264), a najmanja u Istarskoj (2002), Dubrovačko-neretvanskoj (2073), Šibensko-kninskoj (2426), Virovitičko-

podravskoj (2687), Ličko-senjskoj (2802). Nadalje, koncentracija stanovnika na jedan bankomat bila je najveća u Brodsko-posavskoj županiji (1819), Virovitičko-podravskoj (1645), Koprivničko-križevačkoj (1628), Bjelogorsko-bilogorskoj (1517) i Požeško-slavonskoj županiji (1649), a najmanja koncentracija bila je u Istarkoj (505), Dubrovačko-neretvanskoj (585), Šibensko-kninskoj (610), Zadarskoj (652) i Ličko-senjskoj (653) (vidjeti sliku 8). Također, u periodu 2012.-2015. godine, 12 županija imalo je porast, a 7 županija pad koncentracije broja stanovnika na broj zaposlenika banaka. Najveći porast dogodio se na području Koprivničko-križevačke županije (19,6%), Međimurske (14,4%), Zadarske (11%), a najveći pad na području Virovitičko-podravske (13,4%), Požeško-slavonske (-7,8%) i Bjelovarsko-bilogorske (-3,7%) (vidjeti sliku 9). Iako je u većini županija koncetracija stanovnika na broj zasposlenika banke rasla, koncetracija broja stanovnika na broj banomata u istom periodu smanjuje se u svim županijama. Najveća promjena koncentracije bankomata dogodila se na području Ličko-senjske (26,8%), Šibensko-kninske (18,4%) i Istarske (16,6%) (vidjeti sliku 10). Zaključno, može se poretpostaviti kako su razlike u koncetraciji stanovnika rezultat povijesno-kulturoloških razloga, a ne razvijenosti financijskog sustava te kako raste važnost automatizacije poslovanja banaka.



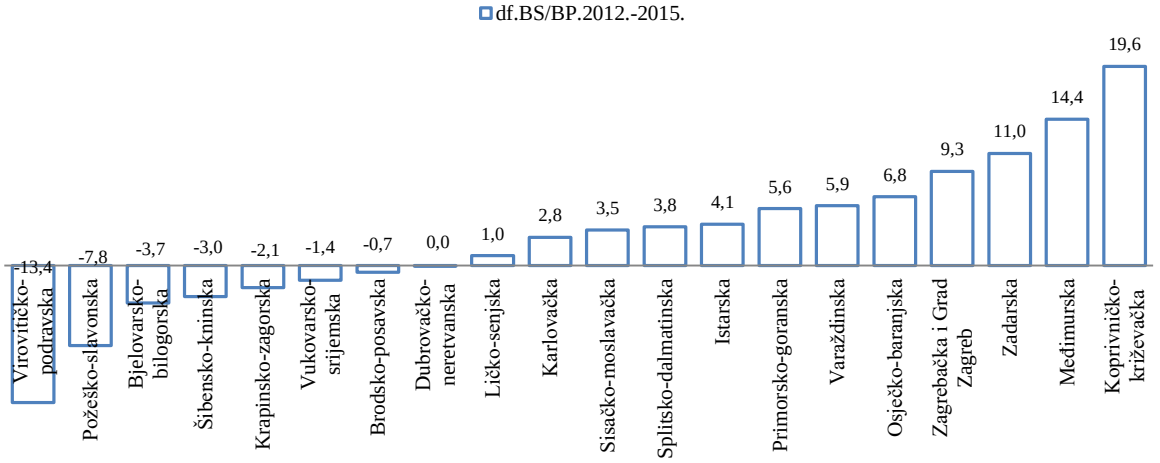
Slika 8. Koncentracija poslovnih jedinica banke i bankomata prema županijama RH, sortirano prema broju stanovnika na jednu poslovnicu banke, 2015

BS/BP - broj stanovnika na jednu poslovnicu

BS/BB –broj stanovnika na jedan bankomat

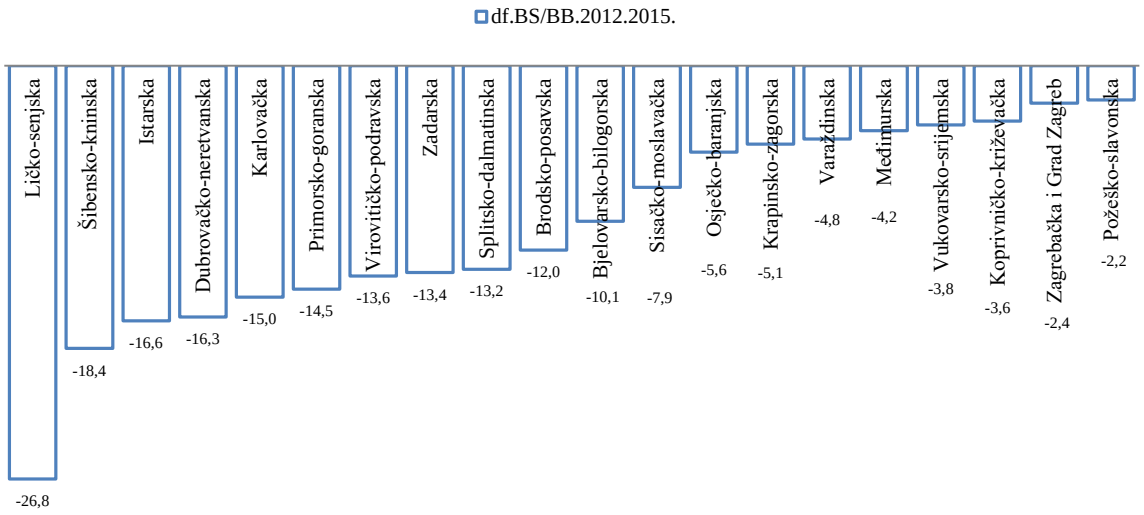
**Grad Zagreb i Zagrebačka županija su prikazani kao jedna županija*

Izvor: autorica prema HNB 2018; autorica prema DZS, 2016



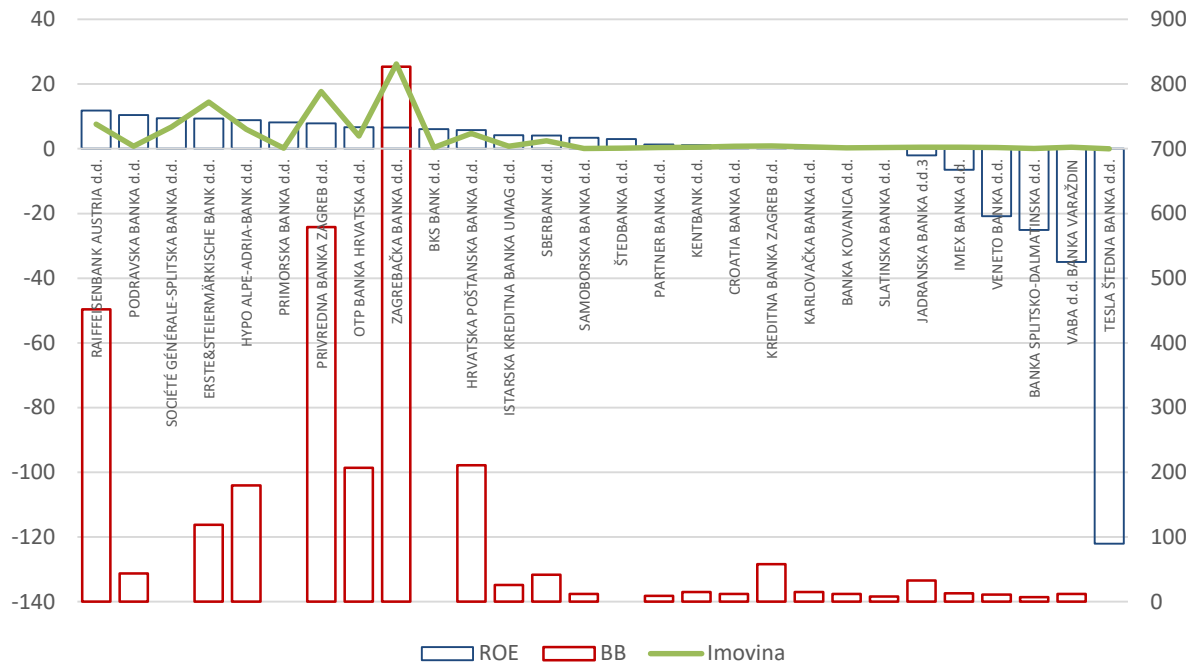
Slika 9. Stopa promjene koncentracije stanovnika na jednu poslovnicu banke u periodu 2012.-2015.

Izvor: autorica prema HNB, 2018; autorica prema DZS, 2016



Slika 10. Stopa promjene koncentracije stanovnika na jedan bankomat u razdoblju 2012.-2015.
Izvor: autorica prema HNB, 2018; autorica prema DZS, 2016

U nastavku se istražuje povezanost najvažnijeg pokazatelja profitabilnosti banke ROE (povrat na kapital) veličine banke i broja bankomata kao pokazatelja automatizacije banke. Banke su sortirane prema pokazatelju profitabilnosti (Slika 11). Može se primijetiti kako je veličina banke korelirana s brojem bankomata iz čega proizlaze dva zaključka: velike banke povećavaju stupanj automatizacije i veličina banke podrazumijeva dovoljno kapaciteta za implementaciju nove infrastrukture. Ipak, treba napomenuti kako profitabilnost banke nije isključivo rezultat njezine veličine. Najprofitabilnija banka u drugom kvartalu 2016. godine bila je Raiffeisen banka (ROE:11,85%) 4 po veličini, zatim Podravska banka (ROE:10,38%) 12. po veličini, SocieteGenerale-Splitska banka (ROE:9,47%) 5. po veličini, Erste i Steirmarkische banka (ROE:9,36%) 3. po veličini, Hypo alpe Adria banka (ROE:8,83%) 6. po veličini i Primorska banka (ROE:8,11%) 25. po veličini. Od ukupno 28 banaka, 6 banaka je imalo negativan poslovni rezultat: Tesla banka (ROE:122,08%), VABA (ROE:35,01%), Banka-Splitsko Dalmatinska (ROE:25,09%), Veneto-banka (ROE:20,87%), Imex Banka (ROE:6,53%) i Jadranska banka (ROE:2,03%).



Slika 11. ROE, veličina banke, broj bankomata

Izvor: VI.2016, ROE-Return on Investment, BB-broj bankomata, Imovina, Imovina (%), autorica prema HNB 2018

Kako bi se dobio uvid osnovno poslovanje i strategiju banaka na tržištu Republike Hrvatske može se promatrati konsolidirana bilanca. Konsolidirana bilanca daje prikaz strukture imovine odnosno izvora imovine u kapitalu i obvezama. Nadalje, dan je prikaz računa dobiti i gubitka, i rizičnosti kreditnih plasmana. Promatrajući strukturu konsolidirane imovine banaka na tržištu Republike Hrvatske može vidjeti kako su banke tradicionalno prvenstveno depozitno kreditne institucije pri čemu je 62,4% ukupne imovine usmjerene u kredite. Vrijednost odnosno udio fizičke imovine iznosio je svega 1,1% ukupne imovine banke, a to je bilo skoro upola manje od imovine koja je rezultat naknada i kamata (1,8%) (vidjeti tablicu 4). U strukturi izvora imovine dominiraju obveze (86,4%) od čega su dvije najvažnije stavke bile oročeni depoziti 48,1% i transakcijski računi (21,7%), dok je prosječna kapitaliziranost banaka iznosila 13,6% ukupne imovine. Udio transakcijskih računa raste te se u periodu 2012.-2016. godine povećao za 9,81%, a oročeni depoziti su smanjeni za 3,69% (vidjeti tablicu 5).

Tablica 4. Struktura imovine banaka, XII. 2012 - VI. 2016. mil. HRK

	XII. 2012.		*VI. 2016.*		
	Iznos	**Udio**	**Iznos**	**Udio**	**Promjena**
Gotovina i depoziti kod središnje banke	51.169,4	12,8	48.450,2	**12,7**	-0,12
Gotovina	6.438,9	1,6	8.050,8	**2,1**	0,50
Depoziti kod središnje banke	44.730,5	11,2	40.399,4	**10,6**	**-0,61**
Depoziti kod financijskih institucija	23.846,9	6,0	27.153,9	7,1	1,14
Trezorski zapisi MF-a i blagajnički zapisi SB	10.701,6	2,7	9.618,5	2,5	-0,16
Vrijednosni papiri	32.095,1	8,0	39.235,9	**10,3**	2,24
Derivatna financijska imovina	910,6	0,2	2.474,4	0,6	0,42
Krediti[a]	267.965,1	67,0	238.486,0	**62,4**	**-4,60**
Krediti financijskim institucijama	5.007,8	1,3	5.195,8	1,4	0,11
Krediti ostalim komitentima	262.957,3	65,8	233.290,2	61,0	-4,71
Ulaganja u podružnice, pridružena društva i zajedničke pothvate	3.120,0	0,8	4.225,5	1,1	0,33
Preuzeta imovina	1.268,5	0,3	1.473,9	0,4	0,07
Materijalna imovina (minus amortizacija)	4.320,1	1,1	4.280,1	1,1	0,04
Kamate, naknade i ostala imovina	7.411,5	1,9	6.778,0	1,8	-0,08
Ispravak vrijednosti za gubitke na skupnoj osnovi[b]	2.888,9	0,7	-	-	-
UKUPNO IMOVINA	**399.919,8**	**100,0**	**382.176,4**	**100,0**	**-0,04**

Bonitetni podaci o poslovanju kreditnih institucija, tablice, Izvor podataka o iznosu imovine banaka jesu obrasci BS3-2 iz statističkog izvješća, koji se temelje na podacima dostavljenima u skladu s Odlukom o statističkom i bonitetnom izvješćivanju (NN, br. 35/2010., 95/2010., 146/2010., 68/2011., 37/2012., 121/2013., 41A/2014., 127/2014., 67/2015., 119/2015. i 54/2016.), [pristupljeno 03.9.2017.]
Izvor: autorica prema HNB, 2018

Tablica 5. Struktura obveza i kapitala banaka, XII. 2012. - VI. 2015. mil. HRK

	XII. 2012.		*VI. 2016.*		
	Iznos	**Udio**	**Iznos**	**Udio**	**Promjena**
Krediti od financijskih institucija	1.455,1	0,4	971,5	0,3	-0,11
Kratkoročni krediti	1.315,4	0,3	249,5	0,1	-0,26
Dugoročni krediti	139,7	0,0	722,0	0,2	0,15
Depoziti	275.844,0	69,0	288.561,4	**75,5**	**6,53**
Transakcijski računi	47.466,3	11,9	82.864,1	**21,7**	**9,81**
Štedni depoziti	21.229,8	5,3	21.851,6	5,7	0,41
Oročeni depoziti	207.147,9	51,8	183.845,7	**48,1**	**-3,69**
Ostali krediti	45.947,0	11,5	20.301,6	5,3	-6,18
Kratkoročni krediti	6.627,5	1,7	2.180,3	0,6	-1,09
Dugoročni krediti	39.319,5	9,8	18.121,3	4,7	-5,09
Derivatne financijske obveze i ostale financijske obveze kojima se trguje	1.752,3	0,4	2.208,9	0,6	0,14
Izdani dužnički vrijednosni papiri	300,0	0,1	300,0	0,1	0,00
Kratkoročni izdani dužnički vrijednosni papiri	0,0	0,0	0,0	0,0	0,00
Dugoročni izdani dužnički vrijednosni papiri	300,0	0,1	300,0	0,1	0,00
Izdani podređeni instrumenti	1.391,0	0,3	2.682,0	0,7	0,35
Izdani hibridni instrumenti	3.243,0	0,8	2.200,4	0,6	-0,24
Kamate, naknade i ostale obveze[a]	12.611,7	3,2	12.837,6	3,4	0,21
UKUPNO OBVEZE	**342.544,1**	**85,7**	**330.063,4**	**86,4**	**-0,04**
Dionički kapital	34.231,0	8,6	33.990,5	8,9	0,33
Dobit (gubitak) tekuće godine	2.687,6	0,7	2.862,4	0,7	0,08
Zadržana dobit (gubitak)	15.706,9	3,9	11.228,9	2,9	-0,99
Zakonske rezerve	1.081,1	0,3	1.047,1	0,3	0,00
Statutarne i ostale kapitalne rezerve	3.292,4	0,8	2.981,0	0,8	-0,04
Revalorizacijske rezerve	427,0	0,1	644,3	0,2	0,06
Dobit (gubitak) prethodne godine	-50,1	0,0	-641,3	-0,2	-0,16
UKUPNO KAPITAL	**57.375,7**	**14,3**	**52.113,0**	**13,6**	**-0,09**
UKUPNO OBVEZE I KAPITAL	**399.919,8**	**100,0**	**382.176,4**	**100,0**	**-0,04**

Izvor podataka o iznosu imovine banaka jesu obrasci BS3-2 iz statističkog izvješća, koji se temelje na podacima dostavljenima u skladu s Odlukom o statističkom i bonitetnom izvješćivanju (NN, br. 35/2010., 95/2010., 146/2010., 68/2011., 37/2012., 121/2013., 41A/2014., 127/2014., 67/2015., 119/2015. i 54/2016.)
Izvor: autorica prema HNB, 2018

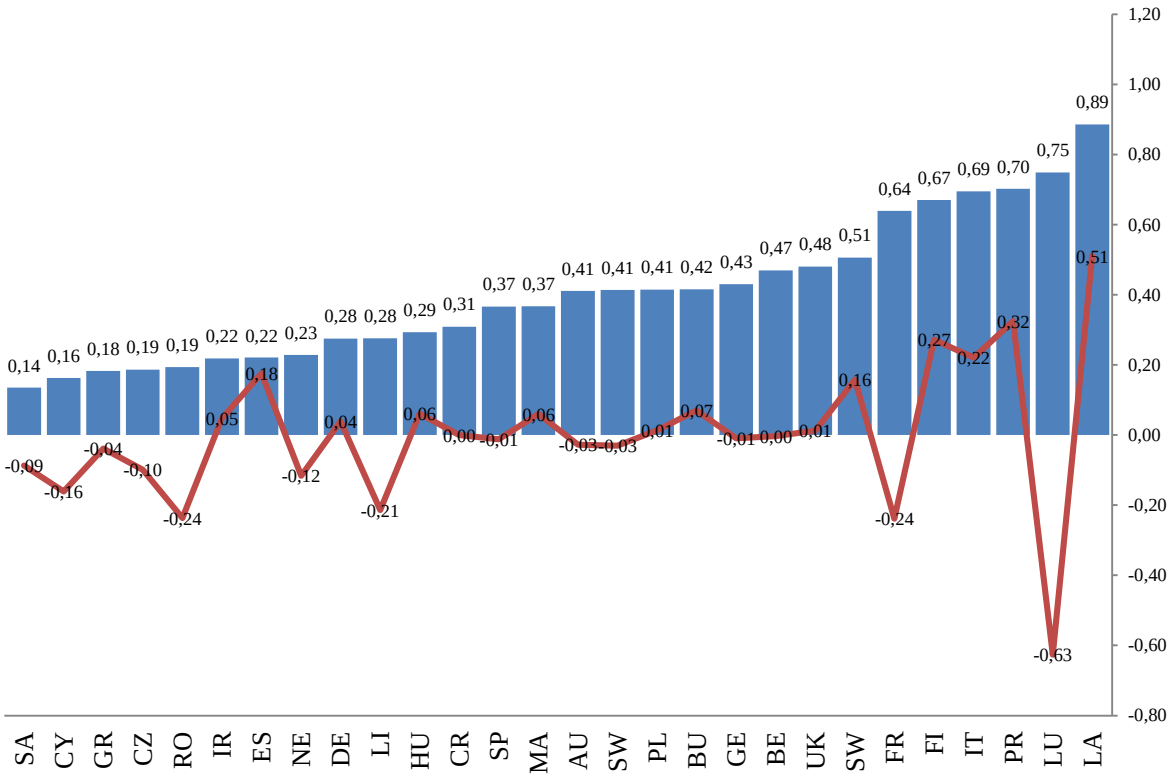
Prema računu dobiti i gubitka može se zaključiti kako je osnova poslovnog rezultata banaka u Republici Hrvatskoj neto kamatni prihod, a čini 76,45% ukupnih operativnih prihoda. Osim neto kamatnih prihoda, operativne prihode činile su još dvije stavke: neto prihodi od provizija i naknada s 21,51% udjela i neto ostali nekamatni prihod koji čini svega 2,04% ukupnog udjela. Također, valja napomenuti kako u zadnjih godinu dana rastao i neto kamatni i neto prihod od provizija i naknada 2,7% i 3,1% (vidjeti tablicu 6).

Tablica 6. Račun dobiti i gubitka banaka, mil. HRK

	Iznos		***Promjena***
	I. – VI. 2015.	**I. – VI. 2016.**	***I. – VI. 2015. I. – VI. 2016.***
Kamatni prihod	9.287,00	8.488,00	-8,6
Kamatni troškovi	3.982,50	3.041,20	-23,6
Neto kamatni prihod	5.304,50	**5.446,80**	**2,7**
Prihod od provizija i naknada	2.108,70	2.097,40	-0,5
Troškovi provizija i naknada	612,3	554,7	-9,4
Neto prihod od provizija i naknada	1.496,40	**1.542,60**	**3,1**
Prihod od vlasničkih ulaganja	187,5	201,2	7,3
Dobici (gubici)	202,3	903,2	346,5
Ostali operativni prihodi	265,2	250,2	-5,7
Ostali operativni troškovi	514,9	685,5	33,1
Neto ostali nekamatni prihod	140,1	669,1	377,5
Ukupno operativni prihod	6.941,00	7.658,50	10,3
Opći administrativni troškovi i amortizacija	3.642,90	3.603,40	-1,1
Neto prihod iz poslovanja prije rezerviranja za gubitke	3.298,00	4.055,00	23
Troškovi ispravaka vrijednosti i rezerviranja	1.893,10	508,6	-73,1
Ostali dobici (gubici)	-1,2	0	-
Dobit (gubitak) iz poslovanja koje će se nastaviti, prije poreza	1.403,80	3.546,40	152,6
Porez na dobit od poslovanja koje će se nastaviti	180,1	685,7	280,7
Dobit (gubitak) iz poslovanja koje će se nastaviti, nakon poreza	1.223,70	2.860,70	133,8

Izvor podataka o računu dobiti i gubitka banaka jesu izvještaji RN (Odluka o supervizorskim izvještajima kreditnih institucija, NN, br. 41A/2014., 127/2014., 67/2015. i 119/2015.)
Izvor: autorica prema HNB, 2018

U nastavku na slici 12 prikazan je omjer neto kamatnih prihoda i neto prihoda od provizija i naknada konsolidiranih financijskih izvještaja banaka zemalja EU u periodu 2008.-2013. godine. Najveći omjer imale su Latvija (0,89), Luksemburg (0,75), Portugal (0,70), Italija (0,69) i Finska 0,67), a najmanji Slovenija (0,14), Cipar (0,16), Grčka (0,18), Češka (0,19) i Rumunjska (0,19). Ako se uzme u obzir dinamika promjene pri čemu se u periodu 2008.-2013. dogodio značajan rast nekamatnih prihoda u Latviji (0,51) može se reći kako postoji korelacija između razvijenosti financijskog sustava i udjela neto nekamatnog prihoda u neto kamatnim prihodima što upućuje na važnost usluge u poslovanju banaka.



Slika 12. Omjer neto kamatnih prihoda i neto prihoda od provizija i naknada prema zemljama EU, 2008.-2013.
Izvor:ECB, 2017c

Obzirom da su kamatni prihodi banaka osnova poslovanja i najvažniji izvor profitabilnosti razmatra se struktura rizičnosti kreditnih plasmana. Na konsolidiranoj osnovi može se vidjeti kako je 2016. godine od ukupnih kreditnih plasmana 13,8% bilo djelomično ili potpuno nenadoknadivih kredita. Najveći udio pripada u sektor nefinancijskih društava, koji je od 7,47% 2008. godine, 2016. godine dosegao 28,3%. Udio djelomično ili potpuno nenadoknadivih kredita u sektora stanovništva 2008. godine bio je 3,97%, a 2016. godine iznosi 10,33% (vidjeti tablicu 7).

Tablica 7. Rizik u plasmanima banaka, VI. 2012.-2016., u 000 HRK

KREDITI / DJELOMIČNO NADOKNADIVI I POTPUNO NENADOKNADIVI KREDITI	**31. 12. 2008.**	**31. 12. 2010.**	**31. 12. 2016.**	%	%	%
Ukupno	**252.682.170**	**267.415.497**	**261.221.608**	**4,94**	**11,23**	**13,80**
Opća država	**21.509.832**	**36.286.786**	**50.994.655**	**0,31**	**0,20**	**0,01**
Nefinancijska društva	**96.827.650**	**100.460.805**	**83.403.375**	**7,47**	**19,55**	**28,30**
Poljoprivreda, šumarstvo i ribarstvo	N/A	3.600.777	4.986.295	N/A	14,44	13,14
bRudarstvo i vađenje	N/A	656.918	405.520	N/A	29,97	17,84
Prerađivačka industrija	N/A	27.829.156	19.245.013	N/A	14,22	25,02
Građevinarstvo	N/A	15.102.039	9.945.019	N/A	29,47	65,70
Trgovina na veliko i na malo; popravak motornih vozila i motocikala	N/A	22.020.311	16.364.169	N/A	20,40	28,39
Prijevoz i skladištenje	N/A	3.182.854	3.057.083	N/A	18,19	11,06
Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	N/A	6.396.711	8.539.006	N/A	21,62	15,61
Informacije i komunikacije	N/A	2.025.836	1.768.939	N/A	38,12	52,33
Poslovanje nekretninama	N/A	5.574.152	6.009.827	N/A	15,25	35,84
Stručne, znanstvene i tehničke djelatnosti	N/A	5.871.548	4.865.845	N/A	24,56	27,10
Ostale djelatnosti	N/A	8.200.503	8.216.660	N/A	11,62	9,87
Stanovništvo	**125.922.607**	**124.551.794**	**113.246.010**	**3,97**	**7,81**	**10,33**
Stambeni krediti	52.317.495	55.769.874	48.236.040	1,70	4,46	8,17
Hipotekarni krediti	3.130.145	3.279.841	2.206.976	9,71	22,45	30,09
Krediti za kupnju automobila	9.645.990	6.508.063	988.822	2,88	4,13	5,64
Krediti po kreditnim karticama	5.529.724	4.524.909	3.607.864	1,86	3,98	3,23
Prekoračenja po transakcijskim računima	N/A	8.194.403	7.422.137	N/A	14,69	9,99
Gotovinski nenamjenski krediti	N/A	31.771.973	40.734.670	N/A	7,90	7,52
Ostali krediti stanovništvu	55.299.253	14.502.731	10.049.501	6,19	17,11	31,02
Ostali sektori	**8.422.080**	**6.116.112**	**13.577.568**	**2,11**	**9,76**	**5,53**

Podaci o kreditima iskazani su na bruto načelu, a odnose se na glavnicu (kamate isključene). Od 31. ožujka 2010. krediti isključivo podrazumijevaju kredite razvrstane u portfelj kredita i potraživanja. Od 31. prosinca 2013. iznos kredita umanjuje se za iznos naplaćenih naknada (prije iskazivane kao odgođeni prihod u obvezama).
Izvor: autorica prema HNB, 2018

Nakon privatizacije banaka u Republici Hrvatskoj posljedično razlikama u stupnju razvijenosti financijskog sektora starih i novih europskih zemalja dogodio se značajan priljev inozemnog kapitala. Niži stupanj konkurencije unutar financijskih tržišta novih zemalja Europske unije uključujući Republiku Hrvatsku omogućio je relativno veće aktivne kamatne stope banaka te zbog inicijalno niskog stupnja zaduženja, rasta zaposlenosti, procvata tržišta nekretnina i optimističnih očekivanja dogodila se ekspanzija kreditne aktivnosti banaka. Stopa rasta kredita stanovništvu i poduzećima od 2001. do 2008. iznosila je prosječno 25% i 20% što je nadmašilo stopu rasta dohotka u istom periodu. Većina kreditne aktivnosti bila je usmjerena na domaću potrošnju, a manje na investicije. Iako je monetarna vlast provodila restriktivnu monetarnu politiku usmjerenu na smanjenje zaduživanja, rast kredita stanovništvu bio je prisutan sve do 2008. godine, dok je rast kredita poduzećima neovisno izostanku gospodarskog rasta, iako značajno manji (2%) bio pozitivan sve do kraja 2012. godine. Od 2008. do 2015. godine dolazi

do primjene dinamike zaduživanja pri čemu se smanjuje zaduženost privatnog sektora odnosno stanovništva i poduzeća. Obzirom kako je spomenuti proces zaduživanja privatnog sektora bio temeljen na izvorima financiranja hrvatskih banaka od strane matičnih velikih europskih banaka, kreditna ekspanzija obilježena je rastom prvenstveno inozemne aktive (Dumičić, Ljubaj, 2017).

Početkom 2011. godine udio kunskog financiranja banaka iznosio je 31,3%, dok je najveći udio inozemne aktive bio euro te iznosio 58,3% (švicarski franak: 6,2%; američki dolar: 4,01%). 2016. godine udio kunskog financiranja raste na 36,3%, eura se smanjuje na 57,6%, švicarskog franka na 1,06% te američki dolar blago raste na 4,9%. Također, promatrajući udjele izvora financiranja i pripadajuće troškove može se primijetiti kako je u periodu 2010.-2016. godine udio kunskog financiranja rastao 5%, dok su troškovi s 29,7% pali na 10,8%. Usporedno, također važan izvor financiranja u eurima u istom periodu smanjuje se sa 58,3% na 57,6%, dok troškovi tih izvora rastu sa 60,8% na 68,8% (vidjeti tablicu 8).

Navedeno upućuje na rast važnosti kunskih izvora financiranja. Valja naglasiti da je zaslužno krizi od 2008. godine do 2013. godine udio kunskih izvora padao, ali nakon toga njihov udio kontinuirano raste te iznosi 32% ukupnih izvora monetarnih institucija. Spomenute promjene valutnih udjela prvenstveno su bile rezultat rasta sredstava na kunskim transakcijskim računima, dok se valutna struktura oročenih i štednih depozita nije značajno promijenila (dominira euro). Može se zaključiti kako je padom kamatnih stopa (vidjeti sliku 13 ZIBOR) porasla sklonost klijenata prema držanju većeg udjela likvidne imovine. Sukladno izvorima mijenja se i struktura kreditnih plasmana, a smatra se kako je rast kunskog kreditiranja rezultat nekoliko faktora: promjene u strukturi financiranja pri čemu je porastao udio kunskih depozita na transakcijskim računima, ekspanzivna monetarna politika HNB-a, smanjenje troškova kamata kunskih kredita, povećane potražnje kao rezultat negativnog iskustva s valutnim klauzulama, rast svijesti o valutnom riziku stanovništva, jačanje konkurencije unutar bankarskog tržišta i slabiji rast domaće kreditne aktivnosti u odnosu na inozemstvo. Također, nakon donošenja novog zakona koji je stupio na snagu 1. srpnja 2015. godine, banke su postale obvezne da na adekvatan način uz devizne kredite ponude i kunsku alternativu. Ako ipak banka u koju se potrošač došao informirati nema kunski proizvod, ponuda mora sadržavati informacije o drugim bankama gdje će potrošač moći dobiti kredit u kunama odnosno bez valutne klauzule. Prema preporuci Europskog odbora za sistemske rizike iz rujna 2011. regulatorna tijela financijskog sustava dobila su naputak da trebaju poticati komercijalne banke na ponudu kredita

u domaćoj valuti bez valutne klauzule. Slično, iako odredba Direktive 2014/17 Europskog parlamenta i Vijeća 4. veljače 2014. koja se odnosi na stambene kredite ne zabranjuje devizne plasmana domaćem stanovništvu kaže kako će za kredite odobrene nakon njezinog stupanja na snagu svaki klijent imati pravo na konverziju bez dodatnih troškova (Ljubaj i Petrović, 2016). Iako posljednja odredba trenutno nije dio nacionalnog zakonodavstva banke će nastojati privlačiti najjeftinije izvore financiranja te ih istovremeno usklađivati s postojećim odrednicama domaće potražnje.

Tablica 8. Troškovi izvora financiranja banaka prema valutama, Udio u ukupnim izvorima i troškovima

	HRK	*EUR*	*CHF*	*USD*	*Ukupno*
Izvori					
31. 12. 2011.	0,3134	0,5839	0,0626	0,0401	1
31. 12. 2016.	0,3634	0,5764	0,0106	0,0497	1
Troškovi					
31. 12. 2011.	0,297	0,6088	0,0535	0,0407	1
31. 12. 2016.	0,1081	0,6881	0,0055	0,0357	1

** Glavni izvori sredstava u pasivi kreditnih institucija jesu transakcijski računi, depoziti, primljeni krediti i izdane dužničke vrijednosnice. Fizičke osobe uključuju i nerezidente. Nefinancijski sektori uključuju pravne osobe, rezidente i nerezidente, koji ne pripadaju nekom od financijskih sektora. Kamatni troškovi za obuhvate "Fizičke osobe" i "Fizičke osobe i nefinancijski sektori" odnose se samo na transakcijske račune i depozite koji nisu maržni, hibridni ili podređeni. Kamatni troškovi za obuhvat "Sve fizičke i pravne osobe" odnose se na sve fizičke i pravne osobe (uključujući i one iz financijskih sektora), kao i na sve glavne izvore sredstava banaka (uključujući i maržne depozite, hibridne i podređene instrumente te primljene kredite i izdane dužničke vrijednosnice). "EUR", "CHF" i "USD" uključuju kamatne troškove na izvore sredstava u istoimenim valutama, kao i na kunske izvore sredstava indeksirane u tim valutama. "HRK" ne uključuje kamatne troškove na izvore sredstava indeksirane uz stranu valutu.*

Izvor: autorica prema HNB, 2018

Posljedično inozemnim izvorima financiranja i regulatornih zahtjeva za valutnom usklađenosti banaka, promjena tečaja nametnula se kao važan činitelj kreditnog rizika odobrenih plasmana. Nakon 1993. godine kada je donesen zakon o izloženosti banaka valutnom riziku te je zbog stabilnosti sustava bilo zabranjeno odobravati kunske plasmane koji nadilaze devizne obveze u iznosu većem od 30% jamstvenog kapitala. U trenutku donošenja zakona o valutnoj izloženosti banke, neto devizna imovina bila je 6 puta veća od propisane gornje granice. Posljedično, najveći porast kredita koji su se plasirani uz valutnu klauzulu dogodio se u sektoru stanovništva čija su primanja dominantno bila denominirana u domaćoj valuti te su građani sami ostali izloženi valutnom riziku. Tako su banke kao specijalisti za procjenu rizika bili zaštićeni zakonom, a građani su ostali izloženi deviznom riziku. Također, devizni rizik velikog broja građana je istovremeno predstavljao potencijalni valutno-inducirani kreditni rizik, a posljedično i sistemski rizik za regulatora(Jankov, 2000).

Krajem 2011. godine od ukupno plasiranih kredita stanovništvu 23,6% bili su kunski plasmani, a 76,4% devizni, dok se udio kunskih plasmana krajem 2016. godine povećao na 40,3%, a deviznih smanjio na 59,7%. Isti trend dogodio su u sektoru poduzeća pri čemu je udio kunskih plasmana krajem 2011. godine iznosio 29,5%, a krajem 2016. godine 41,2%, a udio deviznih plasmana 70,5% 2011 i 58,8% 2016. godine. Dok su kreditni plasmani stanovništvu u kunama rasli od 2013. godine i kumulativno dosegnuli 19,6 mlrd. kuna, udio deviznih plasmana smanjen je za 22,7 mlrd. kuna. U istom periodu kunski plasmani poduzeća povećani su za 6,8 mlrd. kuna, a devizni smanjeni za 8.8 mlrd kuna (Ljubaj i Petrović, 2016).

Tablica 9. Kvaliteta kredita po valutama

KREDITI/DJELOMIČNO NADOKNADIVI I POTPUNO NENADOKNADIVI KREDITI	***31. 12. 2010.***	***31. 12. 2016.***	*%*	*%*
UKUPNO	**274.949.617**	**261.221.608**	**11,23**	**13,80**
Kuna (bez valutne klauzule)	71.158.485	90.083.446	15,90	13,08
Nefinancijska društva	28.245.146	30.516.413	26,06	26,53
Stanovništvo	32.722.461	48.053.014	11,87	7,57
Stambeni krediti	4.652.928	9.684.452	6,18	4,56
Ostali krediti stanovništvu	28.069.533	38.368.562	12,81	8,33
Ostali sektori	10.190.878	11.514.020	0,65	0,45
Euro	165.457.986	163.904.407	9,85	13,20
Nefinancijska društva	68.331.485	51.096.522	16,98	27,95
Stanovništvo	63.588.868	63.472.581	6,58	11,01
Stambeni krediti	27.839.302	37.085.980	3,01	6,96
Ostali krediti stanovništvu	35.749.565	26.386.601	9,35	16,69
Ostali sektori	33.537.633	49.335.304	1,53	0,74
Švicarski franak	35.484.904	2.584.285	8,82	66,31
Nefinancijska društva	4.105.548	780.599	27,18	77,16
Stanovništvo	30.780.118	1.607.599	6,05	66,72
Stambeni krediti	25.453.427	1.415.204	5,73	64,95
Ostali krediti stanovništvu	5.326.690	192.395	7,61	79,77
Ostali sektori	599.239	196.087	25,18	19,74
Ostale valute	2.848.242	4.649.470	4,90	19,93

Za odabrane valute, sektore i vrste kredita stanovništvu prikazani su iznosi kredita te iznosi djelomično nadoknadivih i potpuno nenadoknadivih kredita. Krediti u stranim valutama uključuju kunske kredite s valutnom klauzulom. Krediti isključivo podrazumijevaju kredite razvrstane u portfelj kredita i potraživanja, iskazani su na bruto načelu, a odnose se na glavnicu (kamate isključene). Stanovništvo obuhvaća kućanstva i neprofitne ustanove koje služe kućanstvima, a Ostali sektori ukupnu državu, financijska društva i inozemstvo.

Izvor: *autorica prema HNB 2018*

Sukladno valutnoj strukturi može se promatrati poslovni rizik komercijalnih banaka. Obzirom kako je valutna neusklađenost banke od strane regulatora nedozvoljena, inozemna imovina u strukturi kreditnih plasmana banaka predstavljala je kreditni rizik klijenata. Naime, prema podacima HNB-a, za 2010. i 2016. godinu troškovi djelomično nadoknadivih i potpuno nenadoknadivih kredita porasli su 2,5% (vidjeti konsolidiranu bilancu banaka u Tablici 9) te se može primijetiti kako je kreditni rizik bio značajno veći za odabrane valute. Udio djelomično i potpuno nenadoknadivih kredita neovisno njihovoj valuti, 2010. i 2016. godine iznosio je

11,23% i 13,80%. Općenito govoreći, poslovni sektor izuzev financijskih institucija imao je veće udjele djelomično i potpuno nenadoknadivih kredita u svim valutama kreditnih plasmana banka. Udio loših plasmana za poslovni sektor izuzev financijskih institucija u kunama iznosio je 26,5%, dok je udio istih kredita u sektoru stanovništva bio svega 7,5%. U eurima je iznos istih kredita za poslovni sektor bio 27,9%, a stanovništvo 11%, dok je u francima udio loših plasmana iznosio čak 77,3% i 66,7%. Također, može se primijetiti kako je udio loših plasmana i rizik poslovanja u sektoru stanovništva bio veći izvan stambenih kredita, primjerice u kunama 8,3% (stambeni: 4,5%), eurima 16,6% (stambeni: 6,9%) i francima 79,7% (stambeni: 64,9%).

Kada postoji visok stupanj konkurencije, osim raspona kamatne stope (osnovne djelatnosti banke) i nekamatnih prihoda (naknade i provizije), uspjeh banke biti će rezultat mogućnosti upotrebe ekonomije obujma i diversifikacije ponude, a ekonomija obujma može se povezivati s razvojem tehnike i padajućom funkcijom prosječnih fiksnih troškova masovnog bankarstva. Dodatno, na uspjeh banke mogu utjecati stavke izvan bilance (koje su 2015. godine činile 54,8HRK milijarde obuhvaćajući prvenstveno revolving plasmane, kreditne linije i garancije, od čega je 58,3% plasirano sektoru poduzeća, a 36,2% sektoru stanovništva) (HNB, 2016), racionalizacija općih troškova poslovanja, sposobnost procjene i upravljanja kreditnim rizikom i kvaliteta zaposlenika.

2.2.1 Strategija niskih troškova kao izvor konkurentske prednosti

Strategija niskih troškova odnosi se prvenstveno na konkurenciju cijenama. Niski troškovi omogućavaju da se u konačnici za uslugu iste ili veće kvalitete ponudi niža cijena koja će privući klijenta. Cijena usluge podrazumijeva monetarni izraz vrijednosti koji uključuje primjerice u bankarstvu kamatnu stopu i provizije odnosno nemonetarni dio koji predstavlja utrošeno vrijeme i rad. Polovica korisnika koja je promijenila banku navodi kako je razlog upravo visina naknada. Naknade se prvenstveno odnose na troškove podizanja gotovine na bankomatima drugih banaka, proviziju kreditnih kartica i kamate na prekoračenja bankovnih računa (EFMA, 2017a).Vrijeme i rad obuhvaćaju traženje, čekanje i neizvjesnost, a prethode korištenju bankovnih usluga. Rast konkurencije i liberalizacija tržišta rezultirali su ujednačenjem monetarnog dijela cijena te se smatra kako će nemonetarni elementi biti okosnica diferencijacije i ostvarenja konkurentske prednosti u budućem poslovanju banaka (Pisnik, Dlačić, Milfelner, 2016).

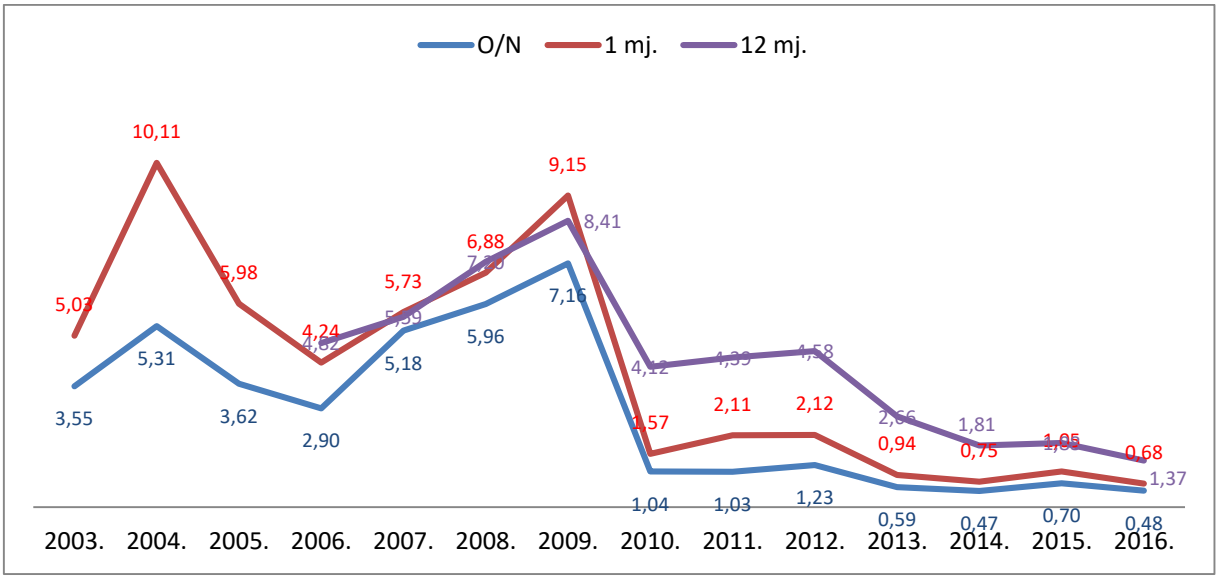
Može se primijetiti kako je osnovna struktura izvora financiranja svih kreditnih institucija temeljena na depozitima od čega je najvažniji sektor stanovništva 60,9%, zatim trgovačka društva 15,5%, nerezidenti 13,5% i financijske institucije 6,2%. Obzirom kako je poslovni rezultat banke prvenstveno rezultat razlike u kamatnim stopama, a prosječni povrat na dionički kapital predstavlja relativno skup izvor financiranja (7,23%) privlačenje depozita postaje važno strateško pitanje poslovanja banaka (vidjeti tablicu 10).

Tablica 10. Struktura depozita banaka prema sektorima

	Depoziti transakcijskih računa	*Štedni depoziti*	*Oročeni depoziti*	*Ukupni depoziti*
Financijske institucije	7,3	5,9	5,9	6,2
Trgovačka društva	38,3	11,9	7,6	15,5
Stanovništvo	39,3	68,8	67,9	60,9
Nerezidenti	5,0	7,9	17,0	13,5
Ostalo	10,0	5,5	1,6	3,9

Izvor: autorica prema HNB, 2018

Ponuđena kvaliteta usluge odnosno pogodnost i niski troškovi upravljanja sredstava na računima stanovništva, trgovačkih društava važan su faktor privlačenja depozita i strategije banaka. Prosječni kamatni prihodi i troškovi banaka u RH u prvoj polovici 2015. godine iznosili su 5% i 2,4%. Očigledno je kako ponderirani prosječni trošak kapitala nadilazi prosječne aktivne kamatne stope banaka. Također, u periodu 2009.-2016. godine može se vidjeti trend smanjenja kamatnih stopa. Primjerice, 2009. godine ZIBOR (Zagreb Interbank Offered Rate) iznosi 8,41%, a 2016. godine 1,37%. S padom kamatnih stopa smanjuje se i važnost neto kamatnog prinosa banaka (vidjeti sliku 13).



Slika 13. Kamatne stope na međubankarskom tržištu (ZIBOR)
Izvor: autorica prema HNB, 2017b

Operativni troškovi važan su preduvjet liderstva standardne tržišne utakmice unutar financijskog tržišta, ali nisu nužno dovoljni da poniše utjecaj disruptivnih tehnologija i poslovnih modela koji redefiniraju okvir tržišne utakmice. Također, nefokusiran i neodmjeren pristup koji podrazumijeva strategiju sveobuhvatne integracije tehnoloških inovacija neće biti realan neovisno veličini poduzeća. Strategija svih organizacija financijskog tržišta uključujući banke mora pomiriti operativnu efikasnost i fleksibilnost organizacije kako bi se nesmetano odvijao inovacijski proces.

Nadalje, može se očekivati kako će banke na osnovi ekonomije dijeljenja, eksternalizacije i automatizacije u budućnosti gotovo u potpunosti harmonizirati svoje operativne troškove, a izvore konkurentske prednosti tražiti kroz diferencijaciju. Velike banke predvode stvaranje nacionalnih platformi koje će anulirati dupliciranje poslova. Primjerice, ugledne banke Singapura kreiraju nacionalnu platformu KYC (poznaj svoj klijenta) koja će smanjiti troškove prikupljanja informacija o karaktersitikama i ponašanju klijenta. Nadalje, banke eksternalizacijom povećavaju udio tradicionalno internih aktivnosti (portfolio menadžment, analiza rizika, alate za regulatornu usklađenost institucionalne investitora, upravljanje imovinom za stanovništvo) koje se alociraju trećim stranama kao što su Fintech organizacije. Konačno, automatizacija ima zadaću implementirati alate koji će smanjiti interne troškove poslovanja (plasman kredita, udovoljavanja računovodstvenim standardima i sl.). Dijeljenje troškova će devertikalizirati dobavni lanac i smanjiti barijere ulaska novih organizacija unutar financijskog tržišta. Banke će morati promatrati partnerstva kao dio šireg strateškog fokusa,

dok će procjena sigurnosnog rizika i prednosi dijeljenja informacija biti razmatrani od projekta do projekta. Potpuno digitalna banka s neusporedivo nižim operativnim troškova u odnosu na tradicionalne banke pod nazivom Simple nudi osnovne financijske usluge s naglaskom na kvalitetu štednje, budžetiranja i kontrole potrošnje. Kako bi unaprijedila kvalitetu svojih usluga banka se udružila s nekoliko etabliranih i rastućih financijskih organizacija: Venmo za mobilna plaćanja, Visa u svrhu provedbe debitnih transkacija,, Bankcorp i CBW u svrhu investicija štednje u FDIC osigurane proizvode i Allpoint za besplatan pristup mreži bankomata (WEF, 2015).

Obzirom da bi velik dio dosada internih procesa financijskih organizacija mogao biti eksternaliziran, diferencijacija će biti rezultat prvenstveno procesa koji su direktno vidljivi klijentima. Posljedično rastu udjela eksternih aktivnosti banke će nadzirati svoju izloženost prema trećim stranama, a regulator će morati proširiti parametre ocjene sistemskog rizik. Očekuje se i promjena strukture dobavnih lanaca. Sudionici postojećih dobavnih lanaca će nastojati izbjeći tradicionalne posrednike te se udružiti s onim organizacijama koje direktno nastupaju prema klijetima. Tehnologija će dozvoliti kretanje klijenata između različitih dobavnih lanaca te se očekuje rekonstrukcija ustanovljenih udjela profita financijskog tržišta, a posljedično razvoju novih tehnologija uloga onih poduzeća koja su dosada imala zadaći povezivati različite organizacije biti će preispitana (WEF, 2017).

2.2.2 Strategija diferencijacije kao izvor konkurentske prednosti

Na temelju istraživanja koje su proveli na uzorku 25 tisuća američkih poduzeća Raynor i Ahmed (2013) zaključuju da je kvaliteta osnova dugoročno uspješnog poslovanja. Navode tri elementarna pravila:

1. Kvaliteta je važnija od niske cijene - preporuča se strategija diferencijacije
2. Povećanje prihoda nadilazi važnost smanjenja troškova
3. Nema drugih pravila koja su važnija od prva dva pravila - treba učiniti sve što je moguće da prvo i drugo pravila budu zadovoljeni

Napori usmjereni na rast kvalitete promijenili su standarde svih industrija, proizvoda i usluga. Polazeći od potreba klijenata usluga i koristeći najnoviju tehnologiju banke nastoje ispuniti i/ili

nadmašiti očekivanja klijenata. Primarni izazov bankarske industrije polazi od identifikacije faktora koji su predispozicija lojalnosti klijenata. Umjesto smanjenja cijena u sektoru usluga preporuča se periodična revizija ponude, holistički i sustavan pristup s namjerom povećanja koristi za klijente. Svakako, važno je napomenuti kako cijena ne smije biti značajno veća od konkurencije. Posebice u maloprodaji, cijena usluge u bankarstvu nadilazi važnost kvalitete usluge koju isporučuje banka (Pisnik, Dlačić, Milfelner, 2016). Može se reći kako lojalnost povezuje kvalitetu i cijenu. Rowley (2005) navodi kako su lojalni klijenti manje cjenovno osjetljivi, smanjuju troškove privlačenja novih klijenata i povećavaju profitabilnost.

Većina istraživanja o kvaliteti usluga u bankarstvu u Europskoj uniji provedena je u Njemačkoj i Grčkoj, dok je svega nekoliko studija od kojih su neke bile komparativnog karaktera provedeno na uzorku zemalja u razvoju (Pisnik, Dlačić, Milfelner, 2016). Kolar (2006) napominje kako su banke u zemljama CEE značajno manje marketinški orijentirane u odnosu na tržište razvijenih zemalja Europske unije. Smatra se kako su donedavno banke u zemljama CEE bile prvenstveno orijentirane na restrukturiranje osnovnog poslovanja, dok je razvoj strategije koja polazi od diferencijacije imao manji značaj. Naravno, obzirom da je bankarski sustav u Republici Hrvatskoj nakon 90.-ih godina privatiziran te se velika većina ukupne imovine nalazi u rukama velikih financijskih konglomerata, formiranje strategije čini okosnicu budućeg poslovanja.

Specifično za bankarstvo može se reći kako je razina kvalitete usluge u velikoj mjeri određena vremenom čekanja i kvalitetom komunikacije između zaposlenika i klijenata (ljubaznost, točnost i jasnoća) (Severović, Žajdala, Cvetković Šoštarić, 2009) te uključuje niz subjektivnih elemenata koji su rezultat emocija, a nisu nužno povezani s financijskim stavkama ponude (Pisnik, Dlačić, Milfelner, 2016). Uz pomoć tehnologije moguće je prikupljati podatke o vremenu čekanja i vrsti usluga koje klijent koristi (Kunac, 2012). Kvalitetu usluge moguće je unaprijediti prostornom i vremenskom realokacijom zaposlenika te unaprjeđenjem komunikacije s klijentima. Osim vremena koje klijent provodi u čekanju i komunikacije sa zaposlenicima, kvalitetu usluge odražava sigurnost i privatnost transakcija koje klijent obavi s bankom. Sustavi komunikacije banke i klijenta često su izloženi pokušajima zloupotrebe od čega su za neke odgovorne banke, a za neke klijenti. Rizici koji se mogu povezati s niskom kvalitetom usluge su zagušenje, pogrešna informacija, nedostatak fleksibilnosti i nepotrebni troškovi. Vrsta usluga koju banka nudi na pojedinim tržištima može se značajno razlikovati ovisno o socioekonomskim specifičnostima odnosno preferencijama klijenata, dok se razlike

unutar pojedinog tržišta smatraju segmentima ili stratifikacijom klijenata banke. Načelno govoreći, unutar segmentiranog tržišta, banke nude velik broj usluga i proizvoda te nastoje utvrditi važnost pojedinih klijenata. Neke skupine klijenata su važne za održavanje likvidnosti banke, neke skupine u smislu podrške razvoja i testiranje novih usluga i proizvoda koje će osigurati nove prihode banke, a neki kao važni klijenti u smislu veličine depozita i društvenog statusa (Severović, Žajdala, Cvetković Šoštarić, 2009). Neke od usluga i segmenata klijenata banke mogu imati sinergijski učinak, ali i nadilaziti postojeće kapacitete. Razvoj tehnologije značajno je utjecao na kapacitete banaka. Primjerice, upotreba ekspertnih sustava danas omogućava rješavanje problema na kojima su dosad radili timovi stručnjaka, a one banke koje ne primjene adekvatnu tehnologiju neće moći parirati u pružanju usluga s tehnološkim liderima industrije (Kunac, 2012). U visoko-dinamičnom poslovnom okruženju samo će one banke koje implementiraju i integriraju najbolje tehnološke inovacije steći povjerenje klijenata i rezultirali transparentnim, sigurnim, efikasnim i pomirenim sustavima upravljanja novcem. Razvoj sustava koji će imati spomenute karakteristike ima zadaću omogućiti održivost i profitabilnost. Ipak, uvođenje najnovijih tehnoloških rješenja *per se* ne može bezuvjetno osigurati koristi za organizaciju te će kvaliteta tehnološkog menadžmenta biti presudna za uspjeh (Gold, 2012).

Nadalje, većina tradicionalnih banaka koje nude uslugu mobilnog bankarstva orijentirane su na osnovne proizvode (provjera računa, transkacije, lokacijske usluge, obavijesti), a manji broj banaka se uspio značajno diferencirati. Neovisno različitim strategijama banaka odnosi s klijentima su homogeni. Naime, kada banke uspostave svoju dominaciju kao pružatelji financijskih usluga tada se mogu orijentirati na stvaranje dodane vrijednosti. Dodana vrijednost može biti rezultat povećanja kreditnih kapaciteta klijenata, obavijesti o limitima koje pomažu upravljati financijama klijenata, pomoć u ostvarenju ciljeva štednje, odabiru u kupnji automobila i/ili rješavanju stambenog pitanja (pronalaženje odgovorajuće nekretnine), registracija poduzeća, vođenje knjigovodstva te izdavanje računa. Mreža mobilne komunikacije, skeniranje obrazaca kamerama visoke kvalitete, geolokacija, glasovne naredbe, čitači biometrijskih podataka, NFC čipovi zajedno osiguravaju jedinstvene prilike za kreiranje i ponudu diferenciranih usluga koje svojom razinom kvalitetom nadilaze postojeće servise. Primjerice, banke putem mobilnog bankarstva mogu ponuditi putno osiguranje obzirom na geolokaciju, specijalne ponude lokalnih trgovaca za inozemne posjetitelje, integraciju financija unutar društvenih medija, pomoć prilikom odabira nekretnine (skeniranje dijelova grada unutar ojačane virtualne stvarnosti kako bi se vidjelo koje su nekretnine za najam ili prodaju, povijest prethodnih prodaja, cijene različitih renovacija, maksimalni iznos potencijalnog hipotekarnog

kredita), odraditi promociju putem obavijesti na mobilnom uređaju koje šalje aplikacija, detektirati kriminalne radnje obzirom na udaljenost lokacije transakcije i mobitela i sl. Zahvaljujući inovativnim sustavima kao što je „iMessage“ i „Siri“ moguće je putem telefonskog imenika ili adrese elektroničke pošte glasovnim naredbama izvršiti transfer novca ili zatražiti novac bez da se dodirne telefon. Ukoiliko su oba sudionika unutar zajednice (banke) transfer će se dogoditi u realnom vremenu, a ukoliko jedna od sudionika pripada drugoj banci od njega će se putem elektroničke pošte ili SMS-a zatražiti njegovi bankovni podaci. Osim ponude različitih inovativnih usluga u svrhu povećanja kvalitete usluge, banke također nastoje povećati stupanj personalizacije. Klijenti se često mogu osjetiti preplavljeni ponudama koje ne korespondiraju s njihovim potrebama. Prikupljanje i obrada podataka o karakteristikama klijenata mogu pomoći da se osim prilagodbe izgleda aplikacije mobilnog bankarstva plasiraju one usluge i proizvodi za koje će klijenti tek shvatiti da ih trebaju. Takav pristup nadilazi uobičajeno pružanje financijskih usluga i proizvoda odnosno popraćeno jednostavnom aktivacijom u nekoliko koraka stvara dojam visoke razine kvalitete financijskog savjetovanja i partnera koji smiono prati klijenta u njegovim životnim ambicijama (EFMA, 2017a).

Strategija podrazumijeva kako će banka kreirati portfolio usluga koje će nuditi svojim klijentima te ukoliko nije moguće osigurati adekvatnu razinu usluge svim potencijalnim klijentima, a biti dobar nije dovoljno, diferencijacija ili dezinvesticija mogu biti očekivane strateške odluke (Hadley i sur., 2015). Za svaki od proizvoda neovisno jesu li oni vlastiti, zajednički ili proizvodi treće strane, banka ima svoje izvore i distribucijske kanale te može odlučiti hoće li te aktivnosti zadržati unutar poduzeća ili provesti eksternalizaciju. Obzirom kako svaki proizvod i usluga zahtjeva pripadajuću tehniku i znanje kadrova odnosno ima svoje troškove i vrijeme implementacije strategija podrazumijeva dugoročno poslovno planiranje u rasponu minimalno 3-5 godina, a definiranjem spomenutih parametara može se postaviti jasna strategija banke. Nadalje, uspjeh banke mjeri se profitabilnošću imovine, udjelom i rastom tržišta te lojalnošću klijenata. Neki dosad potvrđeni modeli strategije baziraju se na inovacijama proizvoda, efikasnosti te opetovanom spajanju i preuzimanju. Iako navedene strategije nisu međusobno isključive one podrazumijevaju različitu strukturu imovinu i kompetencije (Hadley i sur., 2015).

2.2.3 Strategija fokusiranja kao izvor konkurentske prednosti

Polazeći od strategije diferencijacije koja se ne bazira isključivo na troškovnoj konkurentnosti, već aktivnostima koje banku mogu razlikovati od uobičajene ponude, strategija fokusiranja dodatno naglašava segmentaciju klijenata i odabir željene kombinacije profitabilnosti, kreditnog rizika i likvidnosti. Spomenuti kriteriji predstavljaju svojevrsni kompromis, pri čemu nije moguće istovremeno postići optimizaciju sva tri kriterija, već se nastoji riješiti pitanje profitne optimizacije uz odabir prihvatljive i regulacijom dopuštene razine rizika (Vojvodić Rosenzweig, Volarević, Varović, 2013) .

Iako strategija diferencijacije podrazumijeva kreiranje palete proizvoda ili usluga koji će kreditnu instituciju diferencirati od konkurencije, strategija može dodatno uključivati i segmentaciju klijenata, ali je važno naglasiti kako Republika Hrvatska veličinom svojeg tržišta ne predstavlja izazov kapacitetima financijskih konglomerata Europske unije. Može se očekivati da će razlika strategije pojedinih banaka prvenstveno biti rezultat prilagodbe nacionalnim specifičnostima, a ne odraz ograničenja financijskih kapaciteta.

Kao što je citirano u Podrug, Rašić Bakarić, Slijepčević (2007), Keren-Ofer napominje da su banke u tranzicijskim zemljama (u Republici Hrvatskoj do 2000. godine) bile u državnom vlasništvu, odabir klijenata bio je rezultat naloga države, a za iste nije provođena objektivna procjena rizika. Posljedično, velik dio kredita odobren na inicijativu države nikada nije vraćen. Krediti su u konačnici otpisani, a sanacija provedena na teret proračuna. Može se reći kako je prethodno privatizaciji, kreditna aktivnost banaka bila prvenstveno usmjerena na poduzeća, a sektor stanovništva dominirao je na strani izvora financiranja. Kako su troškovi sanacije posrnulih kreditnih institucija dosegnuli neumjerene iznose (vidjeti poglavlje 2.3) čime je narušena njihova reputacija donesena je odluka kako će bankarski sustav u konačnici biti privatiziran. Obzirom kako je prethodno privatizaciji, stanovništvo bilo prvenstveno izvor štednje, banke do tada nisu kreirale proizvode i usluge koji će adresirati njihove potrebe, dok u sustavu tržišne alokacije resursa, sektor stanovništva ostaje važan izvor štednje i financiranja. Potpomognuto razvojem tehnologije segment stanovništva postao je ravnopravan segmenta bankarskog poslovanja. Neke od banaka napravile su dodatni korak u segmentaciji tržišta te razlikuju poslovne korisnike (brzina i kvaliteta), „tehnološku generaciju“, studente, umirovljenike, radnike u inozemstvu, ruralno stanovništvo i slično. Ako nije moguće dominirati svim segmentima industrije banke se mogu orijenitrati na pojedine segmente poslovanja

(Arrawatia i Misra, 2014). Unutar segmenta stanovništva 2007. godine 13 banaka ponudilo je proizvode i usluge specifično dizajnirane za potrebe više od 128 tisuća studenata, a dvije su banke ponudile pakete za mlade osobe. Proizvodi su obuhvaćali tekuće račune, kredite za školovanje i edukaciju, kredite za kupnju informatičke opreme, gotovinske kredite, kreditne kartice i različite pakete usluga. Upravo je populacija studenata svojim karakteristikama (financijskom snagom) važan segment maloprodajnog bankarstva. Zadržavanje postojećih klijenata u gotovo svim industrijama, a tako i u financijskom sektoru zahtijeva niža ulaganja od privlačenja novih klijenata, neovisno o tome jesu li oni do tada bili usluženi od konkurencije. Kao što je citirano u Podrug, Rašić Bakarić, Slijepčević (2007), Lewis napominje da velik udio studenata i nakon školovanja ostaju lojalni korisnici bankovnih usluga odnosno klijenti banke.

Moderno bankarstvo počiva na principima tržišne konkurencije, a banke istraživanjem tržišta nastoje prikupljati važne informacije koje će omogućiti stvaranje prihoda od naknada za prodane usluge, a razvoj tehnologije višestruko kriterijsku analizu ponašanja i potreba klijenata. Istraživanje tržišta podrazumijeva informacije o tržišnim udjelima financijskih institucija, udjelima korisnika koji koriste postojeće financijske usluge, zadovoljstvu korisnika te imidža banke (Kunac, 2012).

Konkurencija na financijskom tržištu više nije posljedica isključivo međusobne interakcije banaka. Na tržištu financijskih usluga sve su više prisutna poduzeća kao pružatelji telekomunikacijskih usluga (prepaid računi) (Mas, Rosenberg, 2009), trgovački lanci i druga poduzeća maloprodaje (kartična plaćanja, aplikacije za plaćanje, namjensko kreditiranje), web komparativna mjesta (gocompare.com, moneysupermarket.com) (Wilkinson, 2017) i Fintech (Steiner, 2017) organizacije bazirane na inovativnm tehnološkim rješenjima (kriptovalute, platforme za P2P/B2B transfer vrijednosti odnosno kreditiranje i crowdfunding) (EFMA, 2017a). Tradicionlano su kreditiranje i prikupljanje kapitala bili funkcija isključivo specijaliziranih financijskih institucija koji su koristeći ekspertizu procjene rizika odobravali investicije ili potrošnju, dok su pristup investicijskom dijelu u okviru spomenutih financijskih institucija imali pojedinici visoke vrijednosti imovine te institucionalni investitori. U prilikama digitalne demokratizacije i velikog interesa prema novo osnovanih poduzeća javlja se mogućnost alternativnog financiranja putem crowdfunding platforme. P2P/B2B kreditiranje i Crowdfunding povećavaju mogućnost financiranja dosad isključenih društvenih skupina, idejnih projekata (seed stage poduzeća), malih i rizičnih poduzeća, a imaju mnogućnost postati izvor financiranja tražitelja visokog boniteta (privatnih osoba, srednjih i veliki poduzeća).

Razvoj B2B platformi podrazumijeva i povećanje kvalitete OTC tržišta (Over the counter). Imovina kojom se ne može trgovati na burzi može biti predmetom OTC tržišta. Posljedično regulatornim ograničenjima nastavno financijskoj krizi 2008. godine te nasljednim ograničenjamima OTC tržišta koji su rezultat veličine mreže posrednika, ograničene likvidnosti, nedostatka vidljivosti, ograničenog pristupa, poteškoća u vrednovanju i ručne obrade platforme imaju mogućnost unaprijediti OTC trgovinu. Pojava platformi može povećati značaj malih i srednjih posrednika ili međusobnim povezivanjem velikih organizacija učvrstiti njihovu poziciju ili otvoriti ulazak na OTC tržište individualnim investitorima. Osim prilika za tražitelje kapitala, crowdfunding predstavljaju nove investicijske prilike za štediše koji sada imaju direktnu kontrolu nad alokacijom investicija odnosno odabirom projekata. Iako raste interes prema P2P/B2B platformama i Crowdingu nije vjerojatno da će iste eliminirati etablirane financijske institucije. P2P kreditiranje razvija se prvenstveno unutar lokalne zajednice, a crowding platforme privlače rizičnije plasmane (seed stage poduzeća) i nisko-profitne projekte (u svrhu lokalnog razvoja i alternativnih energetskih projekta). Tražitelji financiranja (ponekad srednja i velika poduzeća) u odnosu na klasično financiranje putem crowding platforme zadržavaju veću kontrolu poslovanja, proces traje kraće i anulira se provizija posrednika. U okviru klasičnog financiranja struktura je unaprijed definirana od strane posrednika, a crowdfunding djeluje prvenstveno kao tržište. Investitori mogu biti rezultat baze potencijalnih korisnika proizvoda ili usluge novog podzeća koje traži financiranje. Iako su banke orijentirane prvenstveno na tražitelje snažnijeg boniteta može se reći da prilike financiranja korisnika crowding patformi nadilaze popratne rizike te predstavljaju mogućnost diverzifikacije portfolia etabliranih financijskih institucija. Informacije koje dosada nisu bile dostupne (društvene mreže, geolokacija, volumen online prodaje) omogućile su unaprjeđenje procesa ocjene boniteta i povećali vjerojatnost kreditiranja klijenata koji su dosad bili isključeni odnosno nisu imali dovoljno povijesti s bankom ili ne pripadaju u prvoklasne dužnike (WEF, 2015). CreditEase kineska P2P platforma kreirana 2006. godine počela je svoj rad alocirajući viškove urbanih pojedinaca prema ruralnoj populaciji. Zahvaljujući velikom uspjehu unutar segmenta P2P kreditiranja CreditEase nudi i uslugu upravljanja imovinom za imućne klijente (CreditEase, 2018). Britanska P2P platforma Zopa osnovna 2005. godine od samih početaka orijentirana je na prvoklasne dužnike u sektoru stanovništva, a zahvaljujući inovativnim metodama ocjene boniteta nadmašila je tradicionalne banke ostvarivši stopu defaulta od 0,38% (Zopa, 2018). Slično vrijedi za sektor malih i srednjih poduzeća, a osim proširenja baze klijenata povećana je efikasnost procesa. Također, pojavljuju se platforme sa zadaćom B2B kreditiranja, a tehnološki specijalisti zaduženi su za pružanje platformske usluge. Za

odobravanje kredita nekada je bilo potrebno više dana, a sada se proces odvija u svega nekoliko minuta. Stope odobravanja kredita malim i srednjim poduzećima bile su najmanje u velikim bankama 23,7%, zatim kreditnim unijama 41,4% i malim bankama 48,8%, dok su najveće bile kod alternativnih pružatelja financijskih usluga odnosno institucionalnih investitora, respektivno 59,2% i 63,3% (WEF, 2017). S pojavom crowdfunding platforme prvi puta se na strani ponude pojavljuju neakreditirani investitori. Posljedično velikom broju Startup-ova, posebice tehnoloških baziranih poduzeća na strani potražnje i velikog broja privatnih investitora na strani ponude u potrazi za alternativom rizičnog kapitala koji je prvenstveno orijentiran na investicije veće od $1 milijarde pokazao se velik interes za crowdfunding platforme. Putem britanske platforme SEEDRS koja omogućava participaciju privatnih investitora (individualni ulog mogao je biti najmanje £10) izlistana poduzeća su 2016. godine prikupila £85 milijuna pri čemu je 45 tisuća pojedinaca financirano 159 projekta od čega je svaki investitor u prosjeku sudjelovao u 9 projekta. Kako bi se zaštitio interes pojedinaca, financiranje projekata odobrava se kada ponuda dosegne unaprijed postavljenu razinu praga. Ako je interes bio nedovoljan, sudionicima su vraćeni njihovi ulozi. U odnosu na 2015. godinu akumulacija kapitala porasla je za 33%. Regulator nastoji ublažiti uvjete privatnog crowdfunding kako za investitore tako za poduzeća, ali nepostojanje regulacije svakako nije rješenje. Uobičajena praksa je da investitor ne smije ulagati više od 10% svoje neto imovine odnosno da poduzeća koja traže do $1 milijun dolara moraju objaviti financijske izvještaje, dok je granica za objavu financijskih izvještaju UK £5 milijuna. Ponekad je unutar platformi gdje djeluju akreditirani investitori dozvoljen pristup privatnim investitorima. Posljedično, pokazalo se kako privatni investitori značajnije podižu cijene u prvim krugovima ulaganja, a odluke su često povezane s osobnim preferencijama prema određenom brendu. Kako bi se izbjegao navedeni problem, SyndicateRoom je osmislio model ulaganja pri čemu isključivo profesionalni investitori ulažu u prvim rundama, a ostali mogu kasnije sudjelovati prema istim uvjetima. Ipak, važno je naglasiti kako još uvijek postoji manjak znanja na strani privatne ponude kapitala i kako je dionički crowdfunding zbog manjka institucionalnog sudjelovanja izgubio dinamiku inicijalnog momenta i ostao izdvojen od šireg financijskog sustava (WEF, 2017).

Plasman disruptivnih tehnologija očekuje se prvenstveno od strane ustanovljenih tehnoloških poduzeća (Google-a, Appple-a, Facebook-a i Amazona), zatim nebankovnih financijskih organizacija (Fintech-ova), novih banaka izazivača na tržištu, tradicionalnih srednjih i velikih banaka, maloprodaje, telekomunikacijska poduzeća i osiguravajućih društava. Smatra se kako su napredne analitike, umjetna inteligencija i „cloud computing“ tri aspekta koja mogu osigurati

diferencijaciju financijskih organizacija, a spomenuti tehnološki divovi (GAFA) lideri u tom segmentu tržišta. AWS (Amazon Web Services) ugovora svoje usluge s organizacijama kao što su JP Morgan (financijski konglomerat), Bankinter (banka), Aon (društvo za posredovanje u rizicima, osiguranju i reosiguranju), Capital One (financijski konglomerat), Nasdaq (burza vrijednosnih papira), Stripe (online sustav za provedbu transakacija plaćanja za Internet poslovanje) i Pacific Life (financijski konglomerat). Capital One, American Express i USAA (poduzeće koje nudi financijske proizvode i usluge specijalizirano za vojno osoblje i njihove obitelji) dizajnirali su glasovno upravljano tehnološko rješenje osobne asistencije pozanto pod komercijalnim nazivom „Alexa“. S jedne strane tehnološki specijalisti mogu odabrati segmente financijskog tržišta u kojem žele konkurirati, iskoristiti pristup bazi podataka, jake brendove i učiniti velike financijske organizacije svojim dugoročnim partnerima. S druge strane financijske organizacije u želji da zadrže neovisnost mogu izbjegavati partnerstvo s tehnološkim ekspertima, ali istovremeno riskiraju rast cijene talenata i gubitak tržišne utakmice u smislu kvalitete usluge koje isporučuju. Može se očekivati kako će većina financijskih organizacija tražiti modele suradnje koji će sačuvati centralne vrijednosti i omogućiti ponudu prvoklasne usluge. Promjene financijskog ekosustava ovisiti će o tehnološkim kapacitetima, karakteristikama klijenata i regulatornim prioritetima koji se geografski mogu razlikovati. Također, ovisno spomenutim specifičnostima može se očekivati i svojevrsna regionalizacija financijskog tržišta. U tom slučaju Fintech organizacije teško će istovremeno ostvarivati globalnu prepoznatljivost te će se nastojati udružiti s etabliranim financijskim organizacijama, dok će iste razvijati regionalno prilagođene strategije (EFMA, 2017d).

Prema izvještaju WEF-a (World Economic Forum) ističe se osam dimenizija koje će utjecati na dizajn financijskih proizvoda (WEF, 2017):

a) Financijska regionalizacija (divergentni regulatorni prioriteti i potrebe klijenata rezultirati će prilagođenim regionalnim modelima pružanja financijskih usluga)
b) Sistemski važna tehnološka poduzeća (tehnološki eksperti na koje se olanja velik broj financijskih institucija)
c) Bionics tehnologije (supstitucija radne snage koja se bazira na tehnologijama umjetne inteligencije, NLP-a i NLG-a
d) Monetizacija podatka (prema uzoru na ostala poduzeća u tehnološkoj areni financijske organizacije počinju shvaćati vrijednost velikih baza podataka)
e) Platforme (višestruki pružatelji platformi za distribciju i trgovanje)

f) Vlasništvo iskustva klijenata (distributeri kontroliraju paletu proizvoda i usluga, razvijaju brend, prikupljaju podatke i postaju vlasnici iskustva klijenata, a tehnološki eksperti visoko specijalizirani postižući ekonomiju obujma i opsega)
g) Redistribucija profita (pojavom važnih tehnoloških inovacija mijenja se distribucija profita)
h) Nestanak troškovne diferencijacije (implementacijom novih tehnologija troškovni aspekti diferencijacije gube na važnosti)

Ulaskom novih konkurenata, raste i kvaliteta iskustva klijenta, a ukoliko banke žele zadržati vodeću poziciju unutar financijskog tržišta one će morati redefinirati svoje poslovne modele. Banke se moraju orijentirati na disruptivne tehnologije, a pobjednici će biti one organizacije koje iskoriste digitalizaciju za kreiranje iskustva klijenata koje će nadilaziti industrijski standard. Ako žele ostati konkurentne, banke moraju iskoristiti postojeće baze podataka, kontrolirati ili smanjiti operativne troškove, uspostaviti partnerstva s nizom financijskih i nefinancijskih organizacija te istovremeno garantirati sigurnost svojih klijenata. Banke moraju odlučiti koju ulogu unutar dobavnog lanca žele preuzeti: ulogu distributera ili ulogu upravitelja platforme. Velike banke imaju mogućnost pozicionirati se na mjestu distributera financijskih proizvoda, a ovisno uspjehu one će zadržati ili smanjivati svoj udio u distribuciji profita financijskog tržišta. Rastom konkurencije i naglaskom na klijenta najviše profitiraju korisnici usluga, dok isti često preplavljeni ponudom ostaju zbunjeni, a fintech organizacije zaobilaze problem nedovoljnog obujma i opsega odnosno putem platforme pristupaju velikom broju korisnika (WEF, 2017) (EFMA, 2017d).

Načelno, banke mogu odabrati jedan od četri osnovna pristupa stvaranja dodane vrijednosti za svoje klijente. Polazeći od tri podvrste inovacija: inkrementalne, evolucijske i revolucijske, mogu se derivirati četri osnovne inovacijske strategije. Prvi pristup podrazumijeva zadržavanje postojeće tržišne pozicije inkrementalnim unaprijeđenjem ponude prema postojećoj bazi klijenata. Drugi pristup podrazumijeva evoluciju postojeće ponude uvođenjem novih proizvoda koji će se plasirati bazi postojećih klijenta. Treći pristup podrazumijeva prilagodbu postojeće ponude kako bi se osvajalo nove segemente tržišta ili potpuno nova tržišta. Konačno, četvrti pristup podrazumijeva revoluciju poslovanja pri čemu se mijenja sustav vrijednosti odnosno nastaje nova ponude za nove klijente.

Očekuje se kako će velike ustanovljene organizacije biti primarno orijentirane na inkrementalne inovacije, a mlade tehnološki osnažene organizacije na inovacije revolucionarnog karaktera. Obzirom na organizacijsku kulturu i odabranu strategiju ulaganja u inovacije malo je vjerojatno kako će se revolucionarne inovacije događati unutar ustanovljenih poduzeća, osim ako su iste predmetom akivizicija. Navedeni pristupi rezultat je razmatranja može li u visoko dinamičnom okruženju optimizacija postojećeg poslovnog modela omogućiti opstanak ili barem prolongirati postojeću poziciju organizacije. Također, omjer broja koncipiranih inovacija i onih koje su dokraja razvijene za upotrebu krajnih korisnika odraz je upravljanja sustavom kvalitete (EFMA, 2017d).

Prema Kunac (2012) u budućnosti može se očekivati personaliziran pristup klijentima i reorijentacija od strategije transakcijskog bankarstva prema institucijama savjetodavnog karaktera. Iako je primjena informatičke tehnologije imperativ modernog bankarstva tek će način njezine primjene moći diferencirati uspješne od neuspješnih banaka. Upotrebom dostupne tehnologije banke će nuditi spektar prilagodljivih i cjenovno konkurentnih usluga. Poznato je kako su prvotno ciljano tržište za aplikacije mobilnog bankarstva bili korisnici bankovnih usluga razvijenih zemalja, a mobilno bankarstvo dizajnirano je kao komplementarni proizvod pametnih kartica, čekova, sustava bankomata, sučelja za glasovne poruke, POS-uređaja te Internet resursa u svrhu ne-gotovinskog upravljanja novcem (Karjaluoto, 2002), dok je usluga mobilnog bankarstva u zemljama u razvoju umjesto dostupnosti i pogodnosti prvenstveno bila atraktivna zbog pristupačnosti (Cracknell, 2004). Obzirom kako je u zemljama u razvoju proporcija korisnika mobilnih uređaja često veća od proporcije imatelja bankovnih računa postoje različite inicijative koje upravo putem mobilnog bankarstva nastoje moderirati financijsku isključenost. Financijske institucije koja dosada nisu mogle profitabilno pružati svoje usluge najsiromašnijim klijentima, koriste mobilno bankarstvo kao oblik poslovanja koji ne zahtjeva povećanje broja poslovnica (Ivatury i Mas, 2008; Onsongo i Schot, 2017). Takve inicijative podrazumijevaju usluge pod različitim nazivima (uključujući doznake velikih udaljenosti, mikro-plaćanja, neformalane barter sheme) mobilno bankarstvo, mobilni transferi i mobilna plaćanja. Uzimajući u obzir široku dostupnost i popularnost tih usluga u Južnoj Africi (Donner i Tellez, 2008), Keniji (Onsongo i Schot, 2017) i Filipinima (Chiu, Bool i Chiu, 2017) ne može se više govoriti isključivo o pilot projektima nego značajnom utjecaju mobilnog bankarstva na smanjenje socijalne isključenosti te najsiromašnijim slojevima društva kao jednog od ciljanih segmenata korisnika.

Upravo je razvoj tehnologije omogućio dinamičniju tržišnu utakmicu u sektoru bankarstva. Ograničenost kapaciteta koji su dosad bili prepreka pružanju financijskih usluga stanovništvu. malim i srednjim poduzetnicima odnosno poslovanju malih i srednjih banaka, razvojem digitalizacije smanjuju važnost jednog od najvažnijih izvora konkurentske prednosti velikih banaka. U budućnosti se očekuje kako će male i srednje banke u skladu sa svojom strategijom pomno odabirati tržišne segmente, a digitalizacija će stvarati nove prilike za prodaju proizvoda i plasman usluga na istoj razini kvalitete ili u nekim aspektima iznad kvalitete proizvoda i usluga velikih banaka. Inovacije u svijetu financijskih usluga nisu rezultat slučajnosti. Može se očekivati kako će nova poduzeća (Fintech organizacije) ciljano biti orijentirane na segmente tržišta gdje postoji određeno nezadovoljstvo ili nezadovoljena potreba klijenta, posebice ako su isti mogu povezati s visokim iznosima naknada i provizija. Na listi 20 najvećih banaka Europe 2017. godine u odnosu na prije deset godina nalazi se jedna trećina potpuno novih imena. Uvođenje digitalizacije u pozadinske procese poslovanja banaka označilo je početak digitalne revolucije. Digitalne organizacije danas kvalitetom svoje usluge postaju lideri industrije, a brzina promjene prijeti onima koji se oslanjaju na povijesnu reputaciju ili samo ubrazno slijede lidere. Promjene su rezultat očekivanja klijenata i pojave tehnoloških eksperata na tržištu financijskih usluga. Uloga bankarstva u suštini ostaje gotovo nepromijenjena, ali je način distribucije financijskih proizvoda značajno izmjijenjen. Navedeno dovodi u pitanje ulogu banaka i mogu li se tehnološki osnažena poduzeća kao GAFA pozicionirati u liderskoj ulozi distributera bankovnih usluga i proizvoda (EFMA, 2017d).

2.3 Važnost reputacije u poslovanju banaka

Specifičnost poslovanja banaka u Republici Hrvatskoj dobrim je dijelom rezultat povijesnog naslijeđa. Razvoj bankarskog sustava RH može se podijeliti u tri karakteristične faze. Prva faza odnosi se na razdoblje 1980.-1991. godine. Iako se u tom periodu ipak provodio svojevrstan nadzor poslovanja banaka on je bio usmjeren prvenstveno na postizanje ciljeva monetarne i devizne politike odnosno kontrolu selektivnog kreditiranja iz primarne emisije novca, obračun obvezne rezerve i održavanje likvidnosti te je posljedično prema izvještaju Hrvatske narodne banke do 1991. godine od ukupno 29 banaka njih 13 proglašeno insolventnima. Sanacija insolventnih banaka provedena je kroz emisiju državnih obveznica koje su poklonjene poljoprivrednim kombinatima, brodogradilištima te izvoznicima koji su u to vrijeme bili usmjereni na klirinško tržište odnosno korisnicima selektivnog kreditiranja iz primarne emisije novca. Nakon osamostaljenja 1991. broj banaka se u Republici Hrvatskoj udvostručio te su osnovane 34 nove banke i 35 štedionica, a model nadzora u primjeni i strategija poslovanja banaka sve do 1997. godine ostaju više manje nepromijenjeni. Istovremeno se razvija nova vrsta supervizije banaka koja će biti usmjerena na bonitetnu kontrolu i regulirati maksimalnu izloženost banaka, adekvatnost kapitala i rezervacije za loše plasmane banaka (HNB, 2002).

Iako su početkom 1980.-ih godina banke pretvorene u dionička društva i započet je razvoj sustava supervizije banaka, kao posljedica poslovanja do 1998. godine odnosno financiranja diskrecijske potrošnje i moralnog hazarda, računajući troškove rješavanja problema stare devizne štednje, izdavanja „velikih obveznica“ za sanaciju insolventnih banaka do 1991., poslovanje u razdoblju 1991.-1996. i 1998.-1999., trošak sanacije bankarskog sustava Republike Hrvatske, dosegnuo je 30% ukupnog društvenog proizvoda čime je RH uspjela nadmašiti svega nekoliko tranzicijskih zemalja svijeta: Argentinu (55%), Kuvajt (42%), Čile (41%) i Urugvaj (31%) (Prga, 2002).

Predvođene sanacijom nekoliko pojedinačnih banaka, nakon 1991. godine u Republici Hrvatskoj dogodile su se dvije velike bankovne krize. Prva 1996. godine s propašću Splitske, Privredne i Riječke banke, a druga 1998. godine s propašću Riječke banke. Nakon Riječke banke, 1998. i 1999. propalo je još nekoliko malih i srednjih banaka. Smatra se kako su male i srednje banke natprosječno visokim kamatnim stopama financirale neopravdano rizične plasmane, dok su u Splitska, Privredna, Riječka i Dubrovačka banka propale zbog političkih pritisaka da se odobre neosigurani i nenaplativi krediti. Posljedično nesigurnosti koja je nastala

s propašću spomenutih banaka te zbog nedostatka bonitetnih informacija koje su bile dostupne sa šest mjeseci zakašnjenja, 1998. godine došlo je do sloma međubankarskog tržišta novca (Jankov, 2000).

Kao posljedica spomenutih događaja većina je banaka u državnom vlasništvu do 2000. godine prodana stranim investitorima odnosno velikim bankarskim konglomeratima u inozemstvu, a preostali dio banaka koji je ostao u državnom vlasništvu, Hrvatska-Poštanska banka i Croatia banka danas čine samo 5,53% ukupne imovine kreditnih institucija.

Iako sanacija nije provedena u svim bankama jednakom dinamikom, a štedišama je bio onemogućen pristup njihovim depozitima, spomenuti događaji imali su ograničen utjecaj na reputaciju budućeg poslovanja spomenutih banaka. Iako je institut osiguranja štednih uloga i sanacije banaka (DAB) osnovan 1994. godine, Republika Hrvatska je sanaciju banaka koje su propale u razdoblju prethodno formalizaciji DAB-a (Državne agencije za osiguranje štednih uloga i sanaciju banaka) provela na teret proračuna.

Iako znatno manjih razmjera, 2002. godine dogodila se još jedna kriza bankarskog sustava Republike Hrvatske, a bila je rezultat propasti Riječke banke. Riječka banka je propala kao posljedica ilegalnih transakcija riječkog deviznog dilera pri čemu je banka tim transakcijama oštećena za 100 milijuna dolara (Vidaković, 2014).

Poslovanje banaka u RH dodatno je obilježeno hiperinflacijom koja se dogodila u razdoblju 1992.-1994. pri čemu je stopa rasta cijena na mjesečnoj razini dosegnula 25% (Vidaković, 2014). Program stabilizacije cijena proveden je 1994. odnosno početkom 1995. godine pri čemu je inflacija uspješno zaustavljena, ali zbog financiranja diskrecijske potrošnje primarnom emisijom novca povjerenje u domaću valutu nikada u potpunosti nije obnovljeno, a gospodarstvo je zadržalo visok stupanj eurizacije.

Za razliku od povjerenja u domaću valutu te obzirom kako je većina štednje u kreditnim institucijama danas osigurana od strane države, a većina banaka do 2003. godine privatizirana, važnost prethodnih događaja obzirom na reputaciju banaka značajno je umanjena nakon njihove privatizacije i ulaska stranog kapitala.

Strane banke koje su u tijeku privatizacije ušle u Republiku Hrvatsku svoju reputaciju temelje na modelima poslovanja i rezultatima koje su postigli unutar matičnih tržišta. Smatra se kako strane banke nisu opterećene lošom aktivom naslijeđenom iz starog sustava državno-upravljanih banaka te kako će primijeniti efikasnije organizacijske strukture. Također, strane banke privlače kvalitetniji kadar, koriste najnoviju tehniku te na domaćem tržištu nude inovativne proizvode i usluge već razvijene u inozemstvu. Slično, zahvaljujući jeftinijim izvorima financiranja smatra se da strane banke mogu ponuditi niže kamatne stope od svojih konkurenata u domaćem vlasništvu. Nadalje, zadržavanje imena svojih matičnih banaka u inozemstvu nije samo simbolički, već gotovo sve strane banke koje su ušle na tržište Republike Hrvatske u svojim upravama i/ili nadzornim odborima imaju članove matičnih organizacija, te svojim financijskim potencijalom jamče ugled svojih podružnica. U slučaju krize, podružnice mogu pozajmljivati od matičnih banaka, a neke od matičnih banaka su se i različitim jamstvima ugovorno obvezale svojim podružnicama.

3 REPUTACIJA KAO BITNA ODREDNICA TRŽIŠNOG USPJEHA U BANKARSKOM SEKTORU

Kao što je citirano u Nicolò (2015), Bensman, Boabacar i Foster te Knaup i Piazza napominju da neovisno vremenu i mjestu, velik udio novoosnovanih poduzeća ne uspijeva preživjeti pritisak konkurencije dulje od godinu dana. Iako će preživljavanje novih poduzeća ovisiti o višestrukim utjecajima iz okoline, smatra se kako su novi poduzetnici posebno osjetljivi na nedostatak reputacije i teško stječu povjerenje dobavljača, distributera i kupaca. Reputacija između ostalog predstavlja sposobnost poduzeća da zadovolji potrebe svojih kupaca i ostalih interesno utjecajnih skupina te ukoliko poduzeće u ranim fazama razvoja potroši većinu svojih resursa, a nisu uspostavljene snažne veze s dobavljačima, distributerima i kupcima poduzeće neće moći preživjeti. Ukoliko poduzeće ipak uspije osvojiti povjerenje jedne interesno utjecajne skupine ili partnera unutar industrije, raste povjerenje i ostalih sudionika i sve više partnera smatra kako postoje temelji za probitačnu suradnju. Nicolo (2015) dodatno napominje kako u malim obiteljskim poduzećima gdje iako postoji značajna reputacija, ako se ona bazira na njihovim osnivačima, nakon smjene generacija ista se preispituje, a partneri nastoje utvrditi hoće li novi vlasnici odnosno upravitelji jednako ispunjavati očekivanja svojih interesno utjecajnih skupina.

3.1 Opće teorije reputacije

Fombrun i Riel (1997) prvi pokušavaju sistematizirati nomenklaturu korporativne reputacije. Polazeći od korporativnog indentiteta i imidža, Fombrun i Riel (1997) predlažu definiciju koporativne reputacije. S jedne strane korporativni identitet predstavlja odraz percepcije poduzeća od strane zaposlenika i menadžera te obuhvaća ključne karakteristike koje poduzeće razlikuje od konkurencije, a kontinuirano povezuju prošle, sadašnje i buduće rezultate. S druge strane korporativni imidž predstavlja odraz percepcije interesno-utjecajnih skupina izvan poduzeća, a smatra se posljedicom odnosa s javnošću, marketinga i drugih organizacijskih procesa koji oblikuju percepiju ljudi o poduzeću (imidž). Poduzeće može nastojati moderirati svoj korporativni imidž, ali konačan rezultat bit će pod utjecajem publiciteta, regulacije, industrijskih karakteristika i drugih eksternih čimbenika. Prema Fombrun (2001) koristi se nova sveobuhvatna i dorađena definicja reputacije pri čemu se navodi kako ista obuhvaća ekonomsku vrijednost (reputacijski kapital), imidž (reprezentaciju) i procjenu kvalitete poduzeća.

Tablica 11. Atributi reputacije

Autor	*Opis*	*Atribut*
Mahon, 2002; Fombrun, 1996	Dosadašnje aktivnosti poduzeća i potencijal stvaranja budućih koristi za svoje dionike.	Nematerijalna imovina
Schultz i sur., 2006; Yang i Grunig,, 2005; Gruning i Hung, 2002; Rinova i Fombrun, 1999	Raspon međusobno kompleksno povezanih aktivnosti poduzeća koje formiraju reputaciju.	Velik broj različitih aktivnosti poduzeća
Shultz i sur., 2006; Fombrun i van Riel, 2004; Shapiro, 1983	Nema univerzalnog okvira reputacije. Reputacija se razlikuje ovisno karakteristikama poduzeća i njihovih dionika.	Koncept reputacije je neodvojiv od konteksta konkurentske ponude
Zabala i sur., 2005; Golin, 2003; Stigler, 1962;	Povjerenje kao sociološki konstrukt i temelj dugoročnog uspjeha. Povjerenje predstavlja temelj konkurentske prednosti, a konkurentska prednost izvor reputacije.	Reputacija predstavlja mehanizam putem kojeg dionici često nedovoljno upoznati s ukupnim aktivnostima poduzeća odlučuju o povjerenju poduzeću.
Doorley i Garcia, 2006; Philips, 2006; Jones, 1995	Aktivnosti poduzeća i njihova komunikacija u svrhu stvaranja odnosa.	Komunikacija i relacijski kapital
Brown i sur., 2006; Corley i sur., 2006; Fombrun, 1996	Reputacijom je teško manipulirati od strane poduzeća. Ona je rezultat velikog broja čimbenika koji se temelje na percepciji.	Društveni konstrukt kao rezultat percepcije
Flanagam i O'Shaugnessy, 2005; Fombrun, 1996	Rezultat percepcije svih dionika, internih i eksternih.	Zajednička percepcija svih dionika
Wartick, 2002; Brown & Longsdon, 1997; Fombrun, 1996	Poduzeća se mogu komparirati na osnovu svoje reputacije. Moguće je napraviti longitudinalnu komparaciju te izračunati prosjek industrije ili sektora.	Usporediv konstrukt
Rhee i Haunschild, 2006; Brown i sur., 2006	Konačna reputacija poduzeća kao rezultat povijesnih aktivnosti. Ona je relativna i usporediva, a može biti pozitivna i negativna.	Reputacija je binarnog karaktera: pozitivna ili negativna
Roberts i Downing, 2002; Gray i Balmer, 1998; Rindova, 1997	Reputacija predstavlja dugoročnu percepciju poduzeća i odraz temeljnih vrijednosti.	Reputacija nije volatilna

Izvor: prilagođeno prema: Grgić, D. (2012). Indeks reputacije poduzeća: empirijsko istraživanje u bankovnom sektoru. Market-Tržište, 24(1), 5.

Barnett, Jermier i Lafferty (2006) pretražuju literaturu kako bi dali pregled definicija korporativne reputacije, a na osnovu analize 47 izjava definiraju tri osnovne skupine definicija korporativne reputacije: reputaciju kao prepoznatljivost, reputaciju kao procjenu poduzeća i reputaciju kao ekonomsku vrijednost. Prepoznatljivost podrazumijeva upotrebu jezika koji simbolizira kako je poduzeće prepoznato u interesno utjecajnim skupinama, ali bez izravne pozitivne ili negativne ocjene. Definicije koje spadaju u skupinu procjene definiraju status poduzeća kao ocjenu pri čemu se podrazumijeva svojevrsna atraktivnost poduzeća. Konačno,

definicija reputacije kao imovine odnosi se na neopipljivu odnosno ekonomsku vrijednost poduzeća pri čemu se posljednja skupina definicija bavi prvenstveno implikacijama reputacije.

U svom istraživanju reputacije banaka u Republici Hrvatskoj Grgić (2012) navodi ključne atribute reputacije. Obzirom kako je riječ o društvenom konstruktu koji je podložan percepciji, a postoje i unutar sektorske razlike i specifičnosti, reputacija se ne može jednoznačno definirati, ali može se reći kako predstavlja važnu komponentu nematerijalne imovine te je blisko povezana s uspjehom poduzeća.

Tablica 12. Lista najutjecajnijih časopisa te pripadajućih rang lista poduzeća prema njihovoj reputaciji

Manager Magazine (MM)	od 1987. godine objavljuje 100 najvećih njemačkih proizvodnih i uslužnih poduzeća
Management Today (MT)	od 1991. godine objavljuje pandan Fortunea za najprestižnija Britanska poduzeća
Asian Busines (AB)	od 1992. godine objavljuje pandan Fortunea za najprestižnija Azijska poduzeća
Faar Eastern Economics Review (FEER)	od 1993. godine objavljuje listu vodećih Azijskih poduzeća (ALC)
Financial Times (FT)	od 1994. godine objavljuje listu najprestižnija Europskih poduzeća. Lista kasnije postaje globalna
Industry Week (IW)	od 1997. godine objavljuje listu najbolje vođenih poduzeća kao rezultat glasanja i višestrukih nominacija
Fortune GMAC	od 1997. godine objavljuje listu najprestižnijih poduzeća globalne razine

Grgić (2008) navodi kako literaturom dominiraju tri metode mjerenja reputacije poduzeća: procjenom specijaliziranih časopisa, kvocijentom reputacije i putem „Skale osobnosti poduzeća“ (Corporate Personality Scale). Prvi specijalizirani časopis koji je mjerio reputaciju poduzeća 1983. godine bio je „Fortune“ i njegova ljestvica AMAC (America's most admired companies). Osim Fortune-ove AMAC ljestvice ostali specijalizirani časopisi koji su mjerili reputaciju poduzeća prikazani su u Tablici 12.

Kao što je citirano u Grgić (2012), prema Fombrun rang reputacijske liste razlikovao se ovisno kriterijima ocjenjivanja, ali su to prvenstveno bili: financijski pokazatelji, kvaliteta proizvoda i usluga, odnos za zaposlenicima, uloga unutar društvene zajednice, očuvanje okoliša i etika poslovanja. U namjeri da se proširi obuhvat interesno utjecajnih skupina poduzeća izvan uprave i vrhovnog menadžmenta u odnosu na Fortune AMAC, 1999. Reputation Institute (2018) i Harris Interactive (2018) konstruirali su kvocijent reputacije koji obuhvaća kupce robe i usluga

poduzeća, zaposlenike te investitore, a instrument je testiran na 300 tisuća ispitanika u Australiji, SAD-u i Europi. Skala osobnosti[9] kao metoda mjerenja reputacije također naglašava ulogu kupaca i zaposlenika te obuhvaća sedam dimenzija: udobnost, poduzetnost, stručnost, eleganciju, obzirnost, maskulinitet i opuštenost (Davies i sur., 2003). Kao najvažnija dimenzija ističe se udobnost, a odražava povjerenje i društvenu odgovornost poduzeća kao ključnu dimenziju osobnosti.

Divergentno ponašanje poduzeća i društvena očekivanja predstavljaju osnovni izvor rizika reputacije poduzeća. Kao što je citirano u Grgić (2012), Dowling i Neef navode četiri osnove kategorije relacijske reputacije: upravljanje poduzećem, zaštita okoliša, prava zaposlenika i sigurnost proizvoda. Lee i Carter (2009) smatraju kako su navedene kategorije posebno važne za ona poduzeća koja se povezuju s društveno odgovornim poslovanjem čime se omogućuje stvaranje i održavanje povjerenja s interesno utjecajnim skupinama, a u konačnici utječe na privlačenje kapitala, stvaranje mreže poslovnih partnera i povećanja prodaje.

Orlitzky, Schmidt, Rynes (2003) na uzorku 52 znanstvena rada i 33.878 opservacija testiraju povezanost društvenih indikatora poslovanja i financijskih performansi poduzeća. Rezultati njihovog istraživanja pokazuju kako društvena odgovornost poduzeća (ekološka dimenzija u nešto manjoj mjeri) ima značajan utjecaj na financijske performanse poduzeća. Također, važno je napomenuti kako društveno odgovorno ponašanje ima veći utjecaj na računovodstvene pokazatelje poslovanje, a manje na tržišne pokazatelje poslovanja. Također, u smjeru financijskih performansi poduzeća, autori su kao najznačajniji element društvenih indikatora prepoznali upravo reputaciju poduzeća. S druge strane, McWilliams & Siegel (2001) u svom radu navode kao je društveno odgovorno poslovanje korporacije odraz njezine veličine, stupnja diversifikacije, ulaganja u I&R i promociju, suradnje s javnim sektorom, razine prihoda, uvjeta na tržištu rada i pozicije u životnom ciklusu industrije. Zaključuju kako postoji idealna razina društveno odgovornog poslovanja koja se može odrediti omjerom koristi i troškova te posljedično neutralna veza između društvene odgovornosti i financijskih performansi. Dodatno, polazeći od teorije markiranja, kao začetnici područja korporativne reputacije, Fombrun & Shanley (1990) u svom radu razlikuju dvije vrste reputacije: CA (Korporativna sposobnost u proizvodnji) & CSR (Društveno odgovorno poslovanje). Prema rezultatima istraživanja

[9] engl. Corporate Personality Scale

napominju kako reputacija poduzeća ima utjecaj na percepciju kvalitete novih i postojećih proizvoda, CA & CSR mogu imati različite utjecaje, a proizvodi čija poduzeća imaju problem reputacije ne moraju nužno imati negativan odziv.

Jedno od najnovijih istraživanja u području korporativne reputacije, kao što je primjerice, Saeidi i sur. (2015), u svom radu napominju kako dosadašnje proučavanje direktne veze između društveno odgovornog poslovanja (DOP-a) i financijskih pokazatelja ostaje nedovoljno potvrđeno i neprecizno. Uzrok tome smatra čitav niz medijacijskih efekata između DOP-a i financijskih pokazatelja poduzeća pri čemu navodi: održivu konkurentsku prednost, reputaciju poduzeća i zadovoljstvo klijenata. Na uzorku 205 poduzeća potvrdili su posredničku ulogu DOP-a i financijskih pokazatelja u slučaju reputacije i konkurentske prednosti, dok se zadovoljstvo klijenata pokazalo samo kao dodatni rezultat prethodno spomenutih medijatora.

Ioannou & Serafeim (2015) pročavali su utjecaj korporativne reputacije na investicijske preporuke analitičara te se pokazalo kako je početkom 1990-ih godina visok stupanj DOP-a imao negativan utjecaj na ocjenu budućih financijskih pokazatelja poduzeća, ali se s vremenom taj utjecaj promijenio i danas podrazumijeva optimističniju prognozu.

Smatrajući reputaciju poduzeća važnom nematerijalnom imovinom Dijkmans, Kerkhof i Beukeboom (2015), a ističući kako je posljedično razvoju moderne komunikacijske tehnologije odnosno Interneta teško kontrolirati dijalog interesno utjecajnih skupina, autori razmatraju u kojim uvjetima Internet aktivnosti poduzeća mogu unaprijediti njegovu reputaciju. Na uzroku 3.531 ispitanika pokazali su kako postoji pozitivna veza između intenziteta korištenja društvenih medija i praćenja medijskih aktivnosti avio-prijevozničkih poduzeća. Također, pokazalo se kako medijske aktivnosti avio-prijevoznika mogu imati pozitivan utjecaj na njihovu reputaciju.

Chernev & Blair (2015) u svom radu potvrđuju kako DOP iako nepovezan s osnovnim poslovanjem poduzeća može imati pozitivan utjecaj na percepciju kvalitete njegovih proizvoda. To se događa čak i kada potrošači mogu neposredno promotriti i iskusiti proizvod poduzeća.

Nadalje, meta analiza koju proveli Ali i sur., (2015) u svom istraživanju nakon analize ukupno 101 kvantitativne studije, napominju kako zbog utjecaja geografske lokacije (zemlje), različitih utjecajnih skupina unutar kojih se mjeri reputacija i odabranih pokazatelja reputacije rezultati

mogu biti značajno različiti. Ukoliko praktičari žele razvijati ili unaprijediti reputaciju poduzeća, prilikom svoje namjere oslanjajući se na rezultate znanstvenika moraju oprezno razmotriti korporativne specifičnosti kao predispozicije i posljedice korporativne reputacije.

Može se zaključiti kako je korporativna reputacija važna neopipljiva imovina poduzeća koja se može povezati s najvažnijim financijskim pokazateljima i dugoročno održivom konkurentskom prednosti poduzeća. Također, kao jedan od najviše istraživanih faktora korporativne reputacije upravo je društveno odgovorno poslovanje, a rezultati istraživanja upućuju kako DOP može i treba biti važan instrument strateškog menadžmenta u razvoju i unaprjeđenju reputacije poduzeća.

3.2 Dosadašnja istraživanja reputacije banaka u Republici Hrvatskoj

Zahvaljujući turbulentnoj povijesti poslovanja bankarskog sektora u Republici Hrvatskoj, kako zbog nacionalnih kriza tako zbog međunarodne financijske krize 2008. godine narušena je reputacija banaka. Kao što se navodi u pod-poglavlju 2.3., brojne su kritike upućene na poslovanje banaka Republike Hrvatske. Do 1991. godine poslovanje bankarskog sektora obilježeno je kreditiranjem diskrecijski odabranih klijenata, a posljedično tome od ukupno 29 banaka njih 13 je proglašeno insolventnima. Iako je velik broj banaka zbog svoje nesolventnosti zatvoren, a sanacija provedena na teret proračuna, poslovanje banaka nakon toga nije se bitno promijenilo. Stopa inflacije kao posljedica diskrecijske potrošnje koja se financirala primarnom emisijom novca na mjesečnoj razini 1994. godine dosegnula je 25%. Stabilizacijski program proveden je 1995. godine nakon čega su cijene više od 20 godina ostale stabilne, ali je gospodarstvo posljedično inicijalnom sidru tečaja i nedostatku povjerenja u domaću valutu sve do danas zadržalo visok stupanj eurizacije.

Također, poslovanje banaka u Republici Hrvatskoj obilježeno je brojnim problemima od kojih su neki završili i na sudu (povezano kreditiranje, prikrivanje stvarnog boniteta klijenata, manipulacije na financijskim tržištima, agresivno preuzimanja rizika i oduzimanje nekretnina). Banke su tužene zbog ugovora za koje klijenti smatraju kako sadrže elemente štetnih financijskih proizvoda odnosno predatorske prirode. U mnogim srednjoeuropskim zemljama opće je poznat problem dugoročnih kredita s valutnom klauzulom pri čemu je specifično u Republici Hrvatskoj upravo švicarski franak imao najveću negativnu reputaciju. Naime, privučeni nižim kamatnim stopama na kredite u švicarskom franku u odnosu na eure, klijenti su s bankom sklapali dugoročne ugovore čija je protuvrijednost anuiteta posljedično visokoj volatilnosti švicarskog franka značajno rasla.

Grgić (2012) napominje kako u uvjetima snažne konkurencije banaka nije graditi održivu konkurentsku prednost, a orijentacija prema kratkoročnoj optimizaciji profita stavlja naglasak na taktičke odluke. Osim uobičajenih kompetencija, banka bi trebala razvijati reputaciju koju nije moguće replicirati u kratkom roku od strane konkurenata. Tako stvaranje i održavanje reputacije postaje važan element strategije banke pri čemu za klijente veću vrijednost ima usluga koju pruža banka s većom reputacijom. Kako se poduzeće razvija, njegova tržišna vrijednost se transformira od početne vrijednosti koja se bazira na materijalnoj imovini prema vrijednosti kojom dominira nematerijalna imovina (društvena očekivanja, povjerenju i

odnosima). Polazeći od empirijski potvrđenog koncepta mjerenja reputacije „kvocijentom reputacije“ (RQ) i kritike Warticka (2002) koji kaže kako je reputacija navedenog instrumenta prvenstveno rezultat percepcije opće javnosti koja nije nužno povezana s poslovanjem banke, Grgić (2012) proširuje model za odnose poduzeća sa interesno utjecajnim skupinama koji predstavljaju klijente banke te obuhvaća ukupno 24 atributa i sedam dimenzija. Sedam dimenzija čine: emocionalni doživljaj, odnose s klijentima, kvalitetu proizvoda i usluga, viziju i vodstvu, kvalitetu radnog okruženja, financijsku izvedbu i društvene odgovornosti. Istraživanje na uzorku najvećih hrvatskih banaka pokazalo je kako su navedene dimenzije značajne za reputaciju banke te u konačnici imaju pozitivan utjecaj na percipiranu konkurentsku prednost, osim aspekta vizije i vodstva koji nije imao značajan utjecaj na reputacija i konkurentnost. Navedenim varijablama objašnjeno je 95% reputacije i 79% percipirane konkurentnosti. Može se reći kako reputacija podrazumijeva neopipljivu imovinu poduzeća i predstavlja temelj konkurentske prednosti.

Sićenica (2001) navodi kako je reputacija banke odraz tržišnih principa poslovanja, a dugoročno održivi pristup neophodna sastavnica strategije modernog poslovanja banaka. Korisnik kao dugoročni partner mora imati mogućnost utjecaja na oblikovanje proizvoda, cijenu i distribuciju pri čemu se informativna i otvorena komunikacija javlja kao alat za uspostavljanje povjerenja. Također, Andaleeb i Anwar (1996) napominju kako će u manje razvijenim gospodarstvima povjerenje korisnika u bankarske proizvode i usluge biti odraz povjerenja u organizaciju te nije povezano s razinom znanja samog korisnika (Andaleeb & Anwar, 1996).

Također, iako ne postoji konsenzus o prirodi njihovog odnosa, povjerenje u banku može se povezivati s aspektom društveno odgovornog poslovanja. Neka istraživanja (Kundid, Rogošić, 2011; Ivić, Grubišić, 2013; Wu, Shen, 2013) pokazuju kako postoji pozitivna korelacija društveno odgovornog poslovanja i profitabilnosti, ali Balabanis i sur. (1998) napominju kako svi aspekti društvenog odgovornog poslovanja nemaju jednak utjecaj na profitabilnost banke te da se odluke usmjerene na zaštitu okoliša mogu negativno odraziti na poslovni rezultat. Ipak, ukoliko posljedično visokom stupnju konkurencije postoji visok stupanj homogenosti proizvoda i usluga banaka na tržištu, društvena odgovornost poslovanja može biti važan faktor odabira banke neovisno o tome je li riječ o depozitnim ili kreditnim poslovima. Rogošić i Kundid (2012) napominju kako veće banke u odnosu na srednje i male banke u RH objavljuju više informacija o DOP-u. Također, velike banke u Republici Hrvatskoj objavljuju manje

informacija o društveno odgovornom poslovanju u odnosu na svoje matične bake u inozemstvu. U Republici Hrvatskoj su to prvenstveno informacije o posebnim proizvodima namijenjenim razvoju lokalne zajednice, novim proizvodima, donacijama na području umjetnosti i kulture, zdravstvenih i sportskih projekata i posebnim uslugama koje nude klijentima. S druge strane utvrđen je deficit informacija o sigurnosti i zaštiti na radu, osvojenim nagradama za proizvode i ulaganjima u ekološke projekte (primjerice povoljniji uvjeti kreditiranja). Od ukupno šest područja izvještavanja o društveno odgovornom poslovanju banke najčešće objavljuju aktivnosti u domeni participacije u lokalnoj zajednici.

Za potrebe istraživanja reputacije i društveno odgovornog poslovanja Kundid (2012) predlaže sistematizaciju mjerenja DOP-a odnosno upotrebu indeksa koji obuhvaća: etički kodeks, zajednica (filantropske aktivnosti, sponzorstva, stipendiranja), izvještavanje o društvenoj odgovornosti, aspekte zaštite okoliša, financijsku uključenost i suradnju s institucijama koje promoviraju društveno odgovorno poslovanje te svojim istraživanjem obuhvaća Zagrebačku banku, Privrednu, Erste, Raiffeisen, Hypo Alpe Adria Bank, Societe Generale Splitsku banku, Hrvatsku poštansku banku, OTP i Sberbanku. Rezultati su pokazali kako raste važnost izvještavanja o društveno odgovornom poslovanju, a navedene banke su u prosjeku objavljivale informacije za više od polovice aktivnosti koje sačinjavaju indeks.

Za potrebe ovog rada temeljem javno dostupnih podataka istražila se društveno odgovorna praksa nekih hrvatskih banaka poput Erste Steirmerkische i Hrvatske poštanske banke. Promatrane su interne i eksterne dimenzije društveno odgovornog poslovanja odabranih banaka. Erste banka ima dugu tradiciju društveno odgovornog poslovanja obilježenog donacijama u smjeru kulturnih, sportskih, obrazovnih i humanitarnih manifestacija širom zemlje uzimajući u obzir regionalne i lokalne specifičnosti. U okviru interne dimenzije ističu se nastojanja da se osigura kvaliteta radne okoline, sredstava za edukaciju zaposlenika i korištenje preventivnih medicinskih usluga na račun banke. Nadalje, Erste banka poznata je po svom projektu korporativnog volontiranja koji je od 2011. postao dio programa za razvoj rukovoditelja, a omogućuje zaposlenicima da se kroz vlastiti rad angažiraju u pomoći najpotrebitijima. Također, 2015. godine organizirana je akcija pod nazivom Erste pomagalica pri čemu je banka za svaki crtež djeteta zaposlenika do 12 godina učinila donaciju u dobrotvorne svrhe. U okviru eksterne dimenzije, banka nudi mogućnost sniženih cijena proizvoda za ciljane skupine, mikro-financiranje za najbolje poduzetničke ideje, investicijske kredite za zapošljavanje i edukaciju za svoje klijente te posebnu pažnju pridaje uređenju svojih poslovnica

za klijente s posebnim potrebama. Također, banka je organizirala i/ili sudjelovala u nizu donacija i sponzorstava: SOS dječje selo Hrvatska, Klinika za dječje bolesti Zagreb, Psihijatrijska bolnica Rab, Udruga „crveni nosovi“, Centar za rehabilitaciju Zagreb, nekoliko sportskih klubova i kulturnih događaja, Projekt PET te Korak u život. U smjeru zaštite okoliša, banka je ponudila eko-kredite za ekološke projekte svojih klijenata te u svojem poslovanju pridaje visoku važnost reciklaži papira, ekološkim načelima u dizajnu rasvjete i sustava klimatizacije.

Hrvatska poštanska banka također je svjesna svojeg djelovanja unutar zajednice, a društveno odgovorno poslovanje razvija putem nekoliko segmenata: brigom za okoliša, ulaganjem u obrazovanje i razvoj zaposlenika, donacijama i sponzorstvima. Njihove aktivnosti društvenog odgovornog poslovanje prelaze propisane zakonske okvire, a namjera je stvoriti imidž banke koja doprinosi općoj dobrobiti društva. Od 2007. godine HPB je postala članica UN Global Compact inicijative te svake godine izvještava o svom napretku u segmentu društveno odgovornog poslovanja s naglaskom na antikorupcijska načela, ljudska prava, uvjete rada i zaštitu okoliša. Interna dimenzija društveno odgovornog poslovanja prepoznata je kroz akciju zaposlenika koji su samoinicijativno odgovorili na poziv za pomoć doma za nezbrinutu djecu Vugrovca. Također, HPB usvojila je preporuke UN koje se odnose na smanjenje otpada, recikliranje i racionalno korištenje uredskog materijala i energije. Eksterna dimenzija društveno odgovornog poslovanja HPB očigledna je u nastojanjima da se podupru projekti obrazovnog i znanstvenog karaktera (HPB kombinacija diploma, Stipendije Vukovarskih studenata, donacije Nacionalnoj zakladi za potporu učeničkom i studentskom standardu), zdravstvene, sportske i kulturne institucije te humanitarne organizacije. Neki od poznatih projekata bili su: Zaklada vaša pošta koja je pružala novčanu potporu nezbrinutoj djeci, financijska potpora organizacije Sinjske alke, Kupujmo hrvatsko, Bijenale slikarstva, Modni ormar te projekti edukacije građana i poduzetnika.

Može se pretpostaviti kako će u budućnosti s rastom svijesti klijenata banke posebice u uvjetima dugoročne krize i iznadprosječne profitabilnosti banaka rasti i praksa društveno odgovornog poslovanja (Kundid i Rogošić, 2012).

Kao što je citirano u Sičenica (2001), Ardrey i Pecotich napominju kako su istraživanja pokazala da se dugoročno pozitivnim publicitetom može stvoriti kredibilitet i povjerenje u financijske institucije i banke.

3.3 Interesno-utjecajne skupine procesa izgradnje reputacije u bankarskom sektoru

Reputacija banke podrazumijeva njezin imidž u širokom krugu dionika. To uključuje dobavljače, konkurente, medije, klijente, vladu, društvo, ostale financijske institucije, nevladine organizacije, zaposlenike, upravu i dioničare (Saraiva & Serrasqueiro, 2007). Potreba upravljanja reputacijom banke posljedica je rasta konkurencije u bankarskom sektoru. Ponuda mnogih banaka već je duže vrijeme gotovo unificirana, a pojavljaju se i druge organizacije koje svojim supstitutima i komplementarnim uslugama konkuriraju u financijskom sektoru (Kunac, 2012). Nadalje, određivanje konkurentske pozicije banke više nije isključivo rezultat tradicionalnih mjera kao što su financijski pokazatelji (ROA, ROE, EBITDA) ili/i tržišni udio, već i kvalitativne mjere koje se mogu povezati s neopipljivom imovinom. Zadovoljstvo i lojalnost klijenata banke postaju važna odrednica reputacije te osnova dugoročno održive konkurentske prednosti (Szwajca, 2016).

Banke otvaraju odjele za odnose s javnošću čija je zadaća upravljati reputacijom banke. Društveno odgovorno poslovanje i odnos s klijentima koji se temelji na opetovanim i obostrano interesnim transakcijama osnova su pozitivnog imidža. Stvarajući sliku društveno odgovornog poslovanja, odjel za odnose s javnošću upravlja transferima banke, a isto nastoji komunicirati u široku javnost. Prethodno transferima, odjel za odnose s javnošću istražuje koja su važna društvena pitanja i polazeći od budžeta na raspolaganju transferima banke nastoji postići pozitivan utjecaj na imidž banke (Kunac, 2012).

Polazeći od fenomena društvenog kretanja (Social movement theory), Gomez-Carrasco & Michelon (2017) istražuju utjecaj aktivizma putem društvenih medija na tržišne indikatore poslovanja banaka. Promatrali su utjecaj dviju specifičnih interesno-utjecajnih skupina: udruge potrošača i sindikate te napominju kako isti putem društvenih medija kao mehanizma mobilizacije nezadovoljnih interesno-utjecajnih skupina mogu narušiti korporativnu reputaciju banaka te posljedično izazvati reakcije tržišta kapitala.

Stvaranje marketinškog modela banke započinje odabirom ciljanog tržišta i ciljeva te se isto usklađuje s kapacitetima banke. Nadalje, kreira se promotivna kampanja i prate se postignuti rezultati. Sadržaj promocije mora biti istinit i jednostavan, iscrpan, ali ne pretjerano opsežan, a vrijeme i oblik komunikacije prilagođen preferencijama korisnika. Banke trenutno od medija prvenstveno koriste televiziju, zatim dnevne novine i časopise, radio i povremeno vanjsko

oglašavanje. Prilikom ugovaranja oglašavanja banke razmatraju karakteristike pojedinih medija, a obzirom na ciljanu skupinu klijenta nastoji se postići visok stupanj učinkovitosti (Kunac, 2012). Novi kanali komunikacije, kao Internet, omogućuju veći stupanj interakcije i kreativnosti. Interaktivna komunikacija podrazumijeva razvoj participativnog bankarstva odnosno kreiranje i prilagodbu konačnog proizvoda pri čemu raste percepcija dodane vrijednost (Dabholkar, 1994). Takav oblik interakcije omogućava element personalizacije i ekskluzive. Element interakcije nije prisutan samo prilikom prodaje već se nastavlja nakon sklapanja ugovora, a omogućuje kontinuirano praćenje zadovoljstva klijenata (Kunac, 2012).

Važno je naglasiti da konačno realizacija društveno odgovornog poslovanja banaka neće biti odraz samo zakonske regulative i korporativne politike nego i zatečenog stanja pravne države, stupnja gospodarskog razvitka te institucionalne uređenosti neke zemlje (Williams & Seguí-Mas, 2010).

3.4 Izvori korporativne reputacije u bankarskom sektoru

Na korporativnu reputaciju banaka utječu brojni čimbenici. Neki od najznačajnijih su financijski indikatori, strateška orijentacija, upravljanje ljudskim resursima, društvena odgovornost, inovativnost i kvaliteta proizvoda i usluga. Financijski indikatori i profitabilnost poslovanja imaju značajan utjecaj i povezanost sa ostalim pokazateljima uspješnosti poslovanja te se mogu povezati s društveno odgovornim poslovanjem i reputacijom banke.

Tržište financijskih usluga još uvijek je suočeno s negativnim efektima posljednje financijske krize, a mnogo je napora uloženo u prilagodbu novoj regulaciji, stabilizaciju bankovnih plasmana i obnovu povjerenja klijenata. Banke su svjesne evolucije društva i posljedičnog utjecaja na bankarstvo, a ponudu financijskih usluga i svoju organizaciju pokušavaju prilagoditi novim očekivanjima koja su potaknuta digitalizacijom. Mobilno bankarstvo obilježeno jednostavnošću, dostupnošću, transparentnošću, personalizacijom i autonomijom predstavlja budućnost bankarstva, a posebice maloprodajnog. Budući razvoj mobilnog bankarstva biti će deriviran kroz šest dimenzija: sigurnost i regulaciju, koncentraciju tržišta, segmentaciju, operativni model i ljudske resurse, kvalitetu iskustva klijenata i profitabilnost (EFMA, 2017a).

U dijelu upravljanja ljudskim resursima banke poseban naglasak stavljaju na osobni kontakt u pružanju financijskih usluga posebice klijentima sa značajnijim iznosom imovine u portfelju. Nova tehnologija omogućava i savjetovanje klijenta na daljinu, dok bankar uz autorizaciju klijenta može za njega obavljati transakcije kao da se klijent nalazi u poslovnici. Time se optimiziraju troškovi, ali se i omogućava uska specijalizacija u pojedinim područjima investicijskog savjetovanja.

Europska komisija definira društveno odgovorno poslovanje kao utjecaj poslovanja poduzeća na društvo, a društveno odgovorno poslovanje financijskog sektora odnosno kreditnih institucija zbog svog snažnog utjecaja ima važne socioekonomske posljedice na društvo. Interes prema društveno odgovornom poslovanju raste s pojavom nadogradnje tradicionalnog financijskog izvještavanja inicijativom koja adresira problematiku održivost poslovanja. Društveno odgovorno poslovanje smatra se važnom odrednicom reputacije, a reputacija preduvjetom financijskih performansi.

Inovacija ima snažan utjecaj na reputaciju banaka na suvremenim financijskim tržištima. Od 2000. godine na bankarskom tržištu niz značajnih inovacija omogućile su efikasnije procesuiranje i razmjenu informacija: bankomati, kartično poslovanje, internetsko i mobilno bankarstvo te digitalno bankarstvo.

Jedno od ključnih aspekata poslovanja banaka također je i kvaliteta usluge koju isporučuju klijentima. Kvaliteta proizvoda i usluga je ključna predispozicija zadovoljstva klijenata, lojalnosti i rasta profitabilnosti poslovanja.

3.4.1 Financijski čimbenici

Zemel (2018) istražuje informacijski paket sadržan unutar kreditne ekspanzije banke. Pronalazi pozitivnu vezu između cijene dionica banke i rasta kreditnog porfolia u visoko profitabilnim bankama. Također, postoji negativna povezanost cijene dionica i rasta kreditnog portfolia nisko profitabilnih banaka. Može se pretpostaviti kako će rast kreditne aktivnosti imati različita očekivanja na financijske pokazatelje banaka ovisno njihovoj reputaciji. Rast komercijalne kreditne aktivnosti prvenstvno malih visoko profitabilnih banaka povećava njihovu cijenu dionica. Ukoliko promjena cijene dionica predstavlja informaciju o vrijednosti banke tada je rast kreditne aktivnosti prediktor budućih financijskih pokazatelja banke. Nadalje, Aras, Tezcan i Furtuna (2018) napominju kako izvrsnost u pojedinim aspektima poslovanja banke ima pozitivan utjecaj na rangiranje i poziciju banke, ali unaprijeđenje višestrukih aspekata poslovanja može imati sinergijske efekte. Primjerice, Laguir, Marais, El Baz i Stekelorum, (2018) ističu kako financijske institucije iznadprosječnih financijskih pokazatelja imaju veću vjerojatnost ulaganja u društveno odgovorno poslovanje te su CFP[10] i CEP[11] međusobno povezani implicirajući dvosmjernu vezu. Wu, Shen i Chen (2017) istraživali su utjecaj DOP-a na financijske performanse banaka te obzirom na heterogenost njegove primjene primijenili su višerazinski sustav kategorizacije. Prethodno višerazinskom sustavu kategorizacije, utjecaj DOP-a na financijske performanse bio je zanemariv, a nakon modifikacije pristupa potvrđena je snažna pozitivna veza. S druge, strane, Fijalkowska, Zyznarska-Dworczak i Garsztka (2018) istražuju povezanost društveno odgovornog poslovanja i financijskih pokazatelja banaka zemalja CEE (Centralne i Istočne Europe) u periodu 2012.-2106. godine. Rezultati nisu

[10] akronim od engls. corporate financial performace
[11] akronim od engl. corporate environemntal performance

potvrdili značajnu vezu, ali se pokazalo kako banke s boljim financijskim pokazateljima imaju veću efikasnost društveno odgovornog poslovanja te da bi se potvrdio utjecaj na financijske pokazatelje poslovanja banaka mora se povećati kvaliteta procesa donošenja odluka o društveno odgovornim aktivnostima. Naime, Beccalli, Casu i Girardone (2006) napominju kako se dinamika cijene dionica banaka jednim dijelom može objasniti promjenama operativne efikasnosti odnsono da efikasnije banke imaju veći rast.

Gorondutse, Ahmad i Nasidi (2014) napominju kako je reputacija refleksivan konstrukt te ima pozitivan utjecaj na performanse banaka. Diferencirajući organizacijski legitimitet i organizacijsku reputaciju od čega su oboje društveni konstrukti i posljedice, Deephouse i Carter (2005) pručavali su izvore reputacije komercijalnih banaka SAD-a. Organizacijski legitimit podrazumijeva društveno odobravanje kao rezultat pridržavanja društvenih konvencija i normi, a reputacija naglašava organizacijsku komparaciju. Izomorfizam povećava ligitimit, ali je utjecaj na reputaciju ovisan o aktivnostima organizacije. Reprezentativniji financijski pokazatelji povećavaju reputaciju, ali ne povećavaju legitimitet visoko profitnih banaka.

Može se reći kako su financijski indikatori povezani s ostalim pokazateljima uspješnosti poslovanja. Također, financijski indikatori mogu se povezati s društveno odgovornim poslovanjem i reputacijom banke.

3.4.2 Strateška orijentacija

Kao što navodi Sičenica (2001) nedovoljna financijska efikasnost, višak neadekvatnih i nedostatak kvalitetnih kadrova bili su odraz poslovanja banaka koje se baziralo na principima tradicionalnog bankarstva. Smatra kako je upravo visok udio kamatnih prihoda odraz neefikasnog poslovanja banaka te istovremeno izvor sanacije visokih operativnih troškova. Navodi kako su banke u RH donedavno zaostajale s ponudom u odnosu na svjetske trendove razvoja financijskih proizvoda. Na osnovi komparativne analize bankarskog sektora napominje kako je cijena usluge bila rezultat izračuna, potrošač neistražen, distribucija u razvoju, a informiranost niska, dok bankarstvo koje podrazumijeva tržišne principe polazi od zadane cijene, visoke segmentiranosti klijenata, poznavanja njihovih potreba, višestruke kanale distribucije i visoku razinu informiranosti. Primjerice, do 2001. godine suvremenim sredstvima komunikacije koristilo se svega 24 od ukupno 47 banaka, a ti su napori prvenstveno bili uloženi

u opće marketinške strategije u svrhu privlačenja ili zadržavanja postojećih klijenata. Izuzev 6 banaka koje su tada nudile neki oblik elektroničkog poslovanja sve ostale banke su putem Interneta objavljivale samo osnovne informacije. Kako domaće tako i strane banke su do tada imale razvijen prvenstveno regionalni imidž, dok su samo dvije od svih banaka promovirale nacionalnu pokrivenost.

Može se reći kako su banke, dosad prvenstveno u državnom vlasništvu, od nacionalnog financiranja diskrecijske potrošnje i poduzeća od posebne važnosti, postale prvenstveno privatne banke, orijentirane na masovno bankarstvo, sekuritizaciju i namjensko kreditiranje. Kao što je citirano u Sičenica (2001), Kotler napominje kako bi moderni marketing bankarskog sektora trebao biti alat kontrole potražnje te da bi se isti realizirao potrebno je postaviti organizacijsku koncepciju marketinga u čijem se centru nalazi klijent kao dugoročni partner, a pri čemu se reputacija banke prvenstveno stvara kao rezultat percepcije koristi koju ostvaruje klijent. Povjerenje između banke i klijenta može biti rezultat ugovora ili reputacije banke, a nadograđuje se komunikacijom o preferencijama i percepciji korisnika, od čega se posljednje dvoje ne mora u potpunosti podudarati. Kao što je citirano u Sičenica (2001), Kahn napominje kako moderni marketing ima zadaću zadovoljiti potrebe klijenata pri čemu se istovremeno pretpostavlja da klijent zna što želi. Polazeći od toga da klijent inicijalno ne zna koji proizvod će biti najbolje rješenje njegovog problema on traži informacije, interpretira priloženo te nerijetko dolazi do informacijskog preopterećenja pri čemu se od naočigled jednakih proizvoda klijent odlučuje za onaj proizvod ili proizvode koji ima prosječene karakteristike. Na taj način smanjuje se vjerojatnost troškova koji mogu biti posljedica pogrešne interpretacije dobivenih informacija. Kao rezultat opisane pristranosti čini se kako marketing banke nije usmjeren na osiguranje idealnog rješenja za individualnog korisnika te zadaća banke ostaje upravljati odnosima na način da se može upravljati zadovoljstvom na osobnoj razini klijenta. Financijski savjetnik dobiva zadaću edukacije, a korisnika pretvara u dugoročnog partnera.

Više nego ikada osim prilagodbe cikličkim kretanjima i učenja u kratkom roku metodom pokušaja i pogrešaka ako žele zadržati svoju poziciju banke će morati osmisliti dugoročno održivu strategiju na tržištu financijskih proizvoda. Kako bi strategija bila ispravno formulirana važno je odgovoriti na pitanja: 1. koje su tehnologije potencijalno disruptivne za organizaciju, 2. kako će iste utjecati na prihode, konkurentnost i operativu, 3. što će organizacija učiniti da zaštiti osnovno poslovanje, kako iskoristiti nove prilike, kreira višetruke opcije, smanji razinu rizika i odabere nekoliko dugoročnih projekata. Osnovno poslovanje podrazumijeva poteze koji

stvaraju dodanu vrijednost za organizaciju, a nose minimalan rizik. Opcije i hedging podrazumijevaju zaštitu od nastanka značajnih negativnih trendova, a istovremeno omogućuju participaciju u pozitivnim trendovima. S druge strane dugoročni projekti nose veći rizik, ali imaju zadaću osigurati kontinuitet organizacije. Čekati i gledati što će se dogoditi na tržištu nije preporučen pristup za lidere. Uprava banaka mora tražiti i prepoznavati prilike te upravljati rizicima koji prate odabrane projekte. Istraživanje provedeno 2016. godine pokazuje kako je u odnosu na 2009. godinu udio banaka koje su definirale svoju inovacijsku strategiju porastao sa 37% na 74%. Najveći porast investicija u inovacije kod mikro i malih financijskih organizacija, 2017. godine u odnosu na 2016. godinu dogodio se u segmentu distribucije respektivno 74% i 80%, a srednje velikih i velikih organizacija u segmentu kvalitete iskustva korisnika 89% i 82%. Najmanje zastupljeni, neovisno veličini organizacije bili su marketing i prodaja (58%, 61%, 58%, 55%), zatim proizvodi i procesi (64%, 65%, 73%, 68% i 58%, 69%, 68, 70%). Ipak, financiranje je ocijenjeno tek kao četvrta najvažnija prepreka inovacijskog procesa. Veću važnost imali su problemi povezani s integracijom inovacija, postojeći tehnološki okvir, potrebno vrijeme[12], a prepreke koje su imale manju važnost od finaciranja bili su kultura, određivanje prioriteta, nedostatak znanja, praćenje informacije koje dolaze s tržišta, usvajanje inovacija od strane tržišta i podrška uprave (EFMA, 2017d).

3.4.3 Upravljanje ljudskim resursima

Tehnološka revolucija promijenila je način poslovanja, a banke su prepoznale važnost digitalizacije. Ulaganjem u razvoj i implementaciju tehnologije raste kvaliteta operative i djelotvornost sigurnosnih mjera. Digitalizacija dokumentacije povećava efikasnost procesa arhiviranja i olakšava pristupu podacima. Konačno, tehnologija povećava efikasnost isporuke usluge korisnicima pružajući potporu distribucijskim kanalima i procesu donošenja ključnih odluka banke (Milic i sur., 2017).

Razvojem informacijsko komunikacijske tehnologije javljaju se novi često paralelni kanali distribucije proizvoda i usluga te zajedno s kvalitetom verbalnih i neverbalnih vještina zaposlenih čine okosnicu prodajnog procesa. Interakcija između zaposlenika banke i klijenata kreće se u rasponu od potpuno automatizirane standardne transakcije do više-kriterijskog

[12] Vremenski okvir za procjenu uspjeha ulaganja u inovacije kreće se u rasponu 1 do 3 godine.

opetovanog savjetovanja. Iako su mnoge banke unatoč rizicima iskoristile razvoj tehnologije odnosno digitalnu infrastrukturu, a neke od njih su osnovane kao potpuno virtualne institucije, može se reći kako postoji razmjerna nesigurnost i staromodnost klijenata koja se veže uz osobni kontakt. Razvoj informatičke infrastrukture ima zadaću smanjiti koncentraciju klijenata na zaposlenika banke, ali osobni kontak, osobni bankar ili osobni savjetnik ostaje važan dio komunikacije s bankom za mnoge klijente (WEF, 2017). Banke su svjesne važnosti osobnog kontakt u pružanju financijskih usluga, a ključna stavka odnosa klijenta s bankom je bankar. Obzirom da se uz pomoć tehnologije sada može savjetovati klijenta na daljinu, a bankar nakon autorizacije u ime i za račun klijenta može obavljati gotovo sve transakcije kao da se klijent nalazi u poslovnici, banka može optimizirati troškove smanjujući broj poslovnica. Razvojem informacijsko komunikacijske tehnologije dio osobnog kontakta klijenta i banke postao je virtualan, ali zbog održavanja određene kvalitete odnosa banke i klijenata, radikalno smanjivanje dostupnosti bankovnih službenika predstavlja visok rizik reputacije banke. (Milic i sur., 2017). Nadzor poslovnica putem Interneta omogućuio je reorganizaciju radnog vremenu. Kada klijenti čekaju predugo ili dio radnog vremena broj zaposlenika premašuje potrebe klijenata koji dolaze, isti se mogu alocirati na druge poslovne aktivnosti. Praćenje vrste i učestalosti pojedinih transakcija omogućuje uvid u strukturu i potrebe klijenata, a prilagodbom organizacije banka može povećava kvalitetu usluge. Iako se preferencije klijenata kreću u smjeru digitalne komunikacije mnogi klijenti osjećaju kako se neke od njihovih složenijih potreba mogu riješiti samo putem osobnog kontakta (dnevni transfer za kupovinu nekretnice) ili jednostavno preferiraju osobni kontakt. Slično, isključivo digitalne banke ili Fintech organizacije često su odabrani kao sekundarni pružatelji financijskih usluga (prvenstveno kao rezultat nižih troškova), a pritom ostvaruju samo manji dio profita. Etablirane financijske organizacije nastoje zadržati najprofitabilnije klijente i kada se pojave organizacije koje ugrožavaju navedeni segment iste brzo slijede ponudu konkurentnih organizacija (WEF, 2017). U segmentu osobne komunikacije zaposlenika banke s klijentom, banka nastoji stvarati visoko personaliziran odnos. Na temelju informacija koje dobiva na licu mjesta zaposlenik banke radi procjenu klijenta i nastoji odabrati pristup koji će unaprijediti reputaciju banke, dok s druge strane neadekvatna procjena može uzrokovati nezadovoljstvo ili odlazak klijenata.

Obzirom na složenost procesa može se reći kako je konačan utisak na klijenata rezultat motivacije i kreativnosti zaposlenika. Kvaliteta zaposlenika važna je u rješavanju problema povezanih s tekućim poslovanje i razvoja novih proizvoda i usluga te konačno u ostvarenju poslovnih ciljeva banke. Važno je napomenuti kako s razvojem tehnologije raste asimetrija

informacija i složenost ponude proizvoda i usluga, a vještine zaposlenika imaju važan utjecaj na kvalitetu prezentacije istih prema klijentima. Sukladno, raste važnost odabira kadrova te banke ulažu značajne resurse u analizu njihove motivacije odnosno individualnih ciljeva, kognitivnih sposobnosti, verbalnih i neverbalnih vještina komunikacije, emocionalne stabilnosti, etičnosti, inteligencije, vizualne i audio percepcije te čak i psihomotoričkih sposobnosti (Kunac, 2012). Upravljanje ljudskim resursima nedvojbeno ostaje važna zadaća upravljanja organizacijom (Foster, 2014). Kao što je citirano u Bratton i Gold (2017), Cappelli napominje kako obzirom na složenost ciljeva poduzeća, odjel ljudskih resursa ne mora se nužno slagati s upravom poduzeća oko odluka u odabiru zaposlenika. Ponekad uprava želi zapošljavati neovisno preporukama odjela za ljudske resurse, a odjel za ljudske resurse smatra kako je njihova procjena objektivnija te uzima u obzir više kriterija. Nadalje, čini se kako je u uvjetima preokreta, krize i niske proizvodnosti odjel za ljudske resurse važan partner, dok se u uvjetima prosperiteta često propituje njihov doprinos.

Zadovoljstvo klijenata direktna je posljedica tehničke infrastrukture i kvalitete zaposlenika, a zadržavanja postojećih i privlačenje novih klijenata osnovna mjera uspjeha banke. Razvoj Interneta i minijaturizacija tehnike promijenili su kanale prikupljanja i distribucije novca, a istovremeno je provedeno tehnološko, organizacijsko i kadrovsko restrukturiranje banaka. Koristeći Internet, kartice (EFTPOS) i mrežu automatskih terminala (ATM) banke su omogućile svojim klijentima obavljanje gotovo svih transakcija 24-sata dnevno bez dolaska u banku. Korisnicima je omogućeno da minimiziraju rizike korištenja gotovinom, a banka je istovremeno dobila uvid u sve transakcije korisnika koje su dosad obavljane gotovinom. Upotrebom i napretkom RPA (robot process automation) tehnologije neka će radna mjesta biti smanjena brojem, a neka u potpunosti eliminirana struktura kadrova banke se mijenja. Razvojem nove tehnologije kao što je umjetna inteligencija mijenja se definicija talenata. Jedna od vodećih banaka SAD-a (Bank of America) koristi AI tehnologiju (Erica) u aktivnostima prednjeg ureda. Računala i ljudski talenti mogu imati sinergijske efekte, a kadroviranje postaje menadžemnt kvalilifikacija (WEF, 2017). Nadalje, upotreba AI može imati negativne efekte na broj zaposlenih. Posljedično promjeni regulative Ujedinjenog Kraljevstva (The Retail Distribution Review) 2013. godine samo jedna banka (Royal Bank of Scotland) otpustila je 550 svojih zaposlenika. Investicijsko savjetovanje postalo je neisplativo za klijente ispod £250 tisuća (prethodno £100 tisuća), a spomenuta tehnologija omogućila je pružanje iste usluge uz zanemarive jedinične troškove (Davies, 2016). Ipak, osobni kontakt ostaje alat diferencijacije proizvoda, posebice za VIP klijente, ali se uloga savjetnika umjesto na odabir proizvoda

orijentira na uključenost klijenta, emocionalnu inteligenciju i potporu odlučivanju (WEF, 2017). Udružujući se s drugim organizacijama kao tehnološkim partnerima koji eliminiraju ručno procesuiranje (čitanje i verifikaciju osobnih dokumenata, provode digitalizaciju birokracije, kreiraju prilagođene promotivne programe) banke svojim promptnim reakcijama povećavaju razinu zadovoljstva klijenata.

Promjenom tehničke infrastrukture procesa mijenja se uloga zaposlenika banke. Zaposlenici trebaju razvijati vještine slušanja, ekonomsku ekspertizu te interes za inovativnim tehnologijama koje se kontinuirano integriraju u nove proizvode i usluge. Osim tradicionalnih poslovnih vještina i ekonomskih znanja kadroviranje sada obuhvaća i privlačenje kanditata za ekspertizom u odražavanju sustava umjetne inteligencije (EFMA, 2017b). Accenture provodi istraživanje na 33 tisuća ispitanika i napominje kako su klijenti otvoreni prema potpuno automatiziranoj digitalnoj usluzi prvenstveno za kupovino osiguranja, otvaranje računa i mirovinskog plana. Kao razloge navode nepristranost, brzinu i cijenu (Accenture Insurance, 2017). Smanjenjem vremena čekanja novi kanali komunikacije povećali su kvalitetu usluga i omogućili izravnu i sofisticiranu promociju istih, smanjili jedinične troškove obrade transakcija i pritisak na poslovnice, a spomenute promjene potaknule su banke da se snažno orijentiraju na maloprodajni segment odnosno poslovanje s građanima, obrtnicima i malim poduzećima. Iako se razvojem Interneta i upotrebom računala (mobitela) obavlja sve veći dio standardnih transakcija koje čine redovno poslovanje klijenata, kada se donose važne odluke o stambenom kreditiranju, financijskim ulaganja i oročavanju relativno velikih iznosa ili se ugovara inovativna usluga i proizvod većina klijenata preferira osobnu komunikaciju. S jedne strane većina informacija je sada klijentima dostupna na zahtjev te je moguća brza komparacija ponude različitih banaka, a s druge strane s razvojem novih instrumenata raste složenost upravljanja financijama te će konačna odluka biti rezultat ekonomskih argumenata i kvalitete osobne komunikacije klijenta i zaposlenika banke (Kunac, 2012).

Otpor prema tehnološkoj revoluciji bankarskog poslovanja javlja se kao odraz nedostatka informatičkih znanja klijenata te zaštite privatnosti, rizika otuđenja imovine, izostanka osobnog kontakta, visokih troškova infrastrukturnih ulaganja, snažne dinamike upravljanja tehnološkim rješenjima i otpora zaposlenih. Kao rezultat snažne tehnološke promjene, dinamika edukacije zaposlenika nadilazi klasične kanale komunikacije. Uprava prema poslovnicama i poslovnice međusobno sve više komuniciraju u realnom vremenu, od čega je dio komunikacije selektivan te se upućuje direktno zainteresiranim korisnicima, a edukacija se osim putem klasičnih

radionica i treninga događa uz pomoć elektroničkih kanala (e-učenja). Primjerice, ruska Sberbnaka ponudila je e-learning programe edukacije koji omogućuju personaliziran pristup zaposlenicma u području prodaje, tehnologije i/ili organizacije, smanjuju potrebno vrijeme za edukaciju, angažman edukatora i štede financijskih resurse banke te omogućavaju pravovremenu edukaciju bez redudancije. Rezultati kratkih tečajeva brzo su dostupni edukatorima i nadređenima te ukoliko je potrebno edukacija se može ponoviti. U programu edukacije 2017. godine je sudjelovalo više od 6075 zaposlenika koji su mogli odabrati između 12 tisuća kratkih treninga (Sberbank, 2018a). Također prema istraživanju Delloite 2016. godine pokazalo se kako 76% zaposlenika smatra važnim da njihovo poduzeće bude tehnološki lider i/ili ojačajno digitalizacijom, a kombinirajući iskustvo tehnološki entuzijastičnih zaposlenika i digitalizacije može se postići sinergijski efekt na kvalitetu iskustva korisnika (Andrus, Kejriwal, Wadhwani, 2016).

Unatoč razvoju informatičke tehnologije koji omogućava pristup klijentima na daljinu, kvaliteta komunikacije zaposlenika banke i klijenta snažno se razvija te banke organiziraju edukaciju svojih prodajnih predstavnika koja se temelji na najnovijim znanjima psihologije. Polazeći od objektivnog razmišljanja o sebi i drugima, spomenute radionice imaju zadaću jačati percepciju zaposlenika o pravilnostima psihologije uzročno-posljedičnog ponašanja i sociološke interakcije. U trenutku prvotnog istraživanja tržišta, klijenti su otvoreniji prema promotivnim porukama, a visoka razina poslovnosti zaposlenika i blaga sugestija stvaraju osjećaj dobrog odabira. Važno je naglasiti kako upotreba znanja psihologije odnosno metoda komunikacije u svrhu manipulacije može osigurati prednost i ostvariti značajne koristi za pojedinca i organizaciju te se istovremeno nameće pitanje etički odgovornog ponašanja i prihvatljivih metoda koje neka organizacije želi primijeniti (Kunac, 2012).

Prodajne sposobnosti zaposlenika rezultat su vještine slušanja klijenata, emotivne empatije i neverbalne komunikacije, kapaciteta percepcije potreba klijenata i načina komunikacije prednosti koje donose ponuđeni proizvodi i/ili usluge. Kako bi zaposlenik mogao uspješno prezentirati iste, osim prodajnih vještina mora poznavati klijenta, sve proizvode i usluge banke i ponudu konkurencije. Klijenti banke imaju različite potrebe, očekivanja i sustave vrijednosti, a zaposlenici banke koristeći direktna, indirektna, vodeća pitanja, otvorena, zatvorena, alternativna i protupitanja, retorička i kontrolna vode klijenta prema idealnom rješenju njegovog problema. Trening zaposlenika banke često uključuje metode kontrole stresa. Stres zaposlenika može biti rezultat kriznih situacija koje mogu nastati kao posljedica kriminalnih

radnji ili obrade velikog broj klijenata pri čemu neki od njih mogu biti krajnje neugodni. Konačno, valja naglasiti kako je postupak razvoja vrhunskih zaposlenika u modernom okruženju banke složen, kontinuiran i dugotrajan proces. Obzirom kako je ostvarenje prodajnih ciljeva koreliran s kvalitetom zaposlenika banke su zainteresirane za provedbu kontinuirane edukaciju kako bi unaprijedili prodajne vještine svojih zaposlenika. (Kunac, 2012). Odabirom i razvojem kadrova prema kriteriju izvrsnosti rezultira napuštanjem klasične organizacije posla. Zaposlenike koje karakterizira izvrsnost odnosno posjeduju jedinstvene vještine realocira se unutar poduzeća na osnovi kriterija najvećeg doprinosa te isti često napuštaju unarpijed dodijeljene pozicije i postaju suradnici na različitm projektima gdje najviše doprinose stvaranju dodane vrijednosti organizacije. Također, ne samo da se zaposlenici realociraju prema potrebama projekata unutar organizacije nego banke nastoje razvijati otvoreni sustav inovacija kako bi u suradnji s drugim organizacijama privukli najveće talente. Kompetencije su tada usmjerene na interne izazove i/ili razvoj ideja koje mogu unaprijediti komercijalnih aktivnosti banaka. Voditelj inovacijskog procesa jedne od najprogresivnijih banaka SAD-a (U.S. Bank), Dominic Venturo napominje kako je isto rezultirato razvojem višestrukih proizvoda i usluga koje se trenutno nalaze u njihovj lepezi ponude ili se prirema njihova komercijalizacija (EFMA, 2017d). Poh, Kilicman i Ibrahim (2018) potvrđuju kako postoji značajna povezanost intelektualnog kapitala i financijskih pokazatelja banke.

Kada banka privuče adekvatne talente vodi računa o stvaranju i održavanju radnog okruženja koje će smanjiti fluktuaciju radne snage. Mansor i Idris (2015) istraživali su predispozicije minimalne fluktuacije radne snage i pritom testirali utjecaj pet različitih pogodnosti: fleksibilno radno vrijeme, dijeljenje radnog mjesta, fleksibilno vrijeme odlaska s radnog mjesta, fleksibilne karijere i fleksibilnost lokacije radnog mjesta u odnosu na fluktuaciju radnika. Rezultati su pokazali kako isključivo fleksibilno radno vrijeme ima nedvojbeno pozitivan utjecaj (u skladu s prethodnim istraživanjima), dok je utjecaj ostalih elemenata nestabilan i ovisan o kontekstu.

Nova tehnologija unutar poslovnica omogućila je direktan nadzor i prikupljane podatka o vremenu čekanja klijenata i broju obavljenih i/ili traženih transakcija. Također, agenti banke koje nije moguće razlikovati od stvarnih korisnika obavljaju različite transakcije te mogu objektivno analizirati procese interakcije s klijentima. Na temelju prikupljenih podataka koji su odraz unutarnjeg i vanjskog okruženja poslovnice može se prilagođavati njezina organizacija prostora i funkcionalnost. Važan aspekt unapređenja usluge nadilazi isključivo prikupljanje podatka unutar poslovnice te se dodatno izvan poslovnice provodi istraživanje tržišta.

Istraživanje tržišta uključuje: tržišne udjele različitih financijskih institucija, njihovu reputaciju, prikupljanje povratnih informacija koje su rezultat oglašavanja, analizu vrste korištenih i traženih usluga, njihovu optimizaciju i segmentaciju klijenata koje osim financijskih institucija mogu provoditi neovisna i specijalizirana poduzeća (Kunac, 2012). Obzirom na postojeće trendove može se očekivati sve manja interakcija klijenta sa zapolenicma te kako će stupanj digitalizacije rasti, a sve veći broj transakcija će se obavljati putem interaktivnog sučelja na daljinu. Ipak, unatoč digitalizaciji poslovanja ljudski faktor ostaje poželjan od strane klijenata. Dobro osmišljena strategija mora pronaći ravnotežu između ljudske interakcije i računarske inteligencije.

3.4.4 Društvena odgovornost

Iako regulativa društveno odgovornog poslovanja postoji u SAD još od 1977. pri čemu se prvi puta spominje Zakon o reinvestiraju u zajednicu, Europska unija 2014. unosi dopune zakona o računovodstvenom izvještavanju te obvezuje poduzeća sa više od 500 zaposlenih, društva na burzi i društva koja nacionalna regulativa proglasi od javnog značaja poput banaka i osiguravajućih društava da izvijeste svoje interesno utjecajne skupine o čitavom nizu aspekata društveno odgovornog poslovanja (Kundid, Novokmet, Bilić, 2016):

a) podatke o učinku poslovanja na okoliš,
b) tretman zaposlenika,
c) zaštita ljudskih prava,
d) nadzor korupcije u poslovanju,
e) adekvatnu strukturu uprave.

Može se reći taj kako trend nije prisutan samo u zemljama Europske unije i SAD-a, nego postoje globalne inicijative: WBCSD (World Business Council for Sustainable Development), ISO 26000, (UNEP-FI) United Nations Environemnt Programme Finance Initiative, UN Global Compacta i Global initiative reporting agencija. Iako se koncept društveno odgovornog poslovanja banaka ojačan u vremenima krize razvio kao rezultat nejednakosti unutar društva i financijske isključenosti današnji smisao te riječi nadilazi ideju profitno orijentiranih banaka usklađenih s regulacijom. Kao što je citirano u Kundid Novokmet & Bilić (2016), San Jose i Retaloza navode kako se društveno odgovorno poslovanje banaka najbolje može pratiti kroz njihovu politiku prikupljanja izvora financiranja i plasmana imovine. Smatra se kako banke prilikom alokacije resursa moraju voditi računa ne samo o financijskom riziku i prinosima nego

i društvenim učincima poslovnih aktivnosti svojih klijenata. Banke bi trebale privlačiti one klijente čije aktivnosti podupiru održivi razvoj: ekološka poljoprivreda, razvoj lokalne zajednice, smanjenje nezaposlenosti, razumno gospodarenje otpadom, smanjenje nejednakosti te izbjegavati one klijente koji svojim aktivnostima pridonose zagađenju okoliša, nepoštivanju ljudskih prava ili plasiraju proizvode dvojbene kvalitete. Sukladno prethodno iznesenom, postavlja se pitanje motivacije banaka da se angažiraju u aktivnostima koje potencijalno mogu smanjiti profitabilnost ili da propuste plasmane imovine u najprofitabilnije segmente gospodarstva ukoliko ih smatraju dvojbenim u smislu društveno odgovornog poslovanja.

Rogosic (2014) napominje kako je svega 10% i 6% banaka respektivno u Republici Hrvatskoj odnosno Bosni i Hercegovini na svojim stranicama objavilo samostalni izvještaj društveno odgovornog poslovanja, dok u Crnog Gori nije bilo takve prakse.

Ipak, pod pritiskom konkurencije banke su postale svjesne rizika društveno neodgovornog poslovanja koje se može povezati s financiranjem projekata dubioznih društvenih posljedica. Poznati su primjeri banaka koje pored uobičajene kreditne analize uzimaju u obzir društvene posljedice investicija svojih klijenata. Društveno odgovorno poslovanje kreditnih institucija danas svakako nadilazi uobičajene izjave misije i vizije pojedine banke, a može se realizirati kroz različite programe sponzoriranja odabranih skupina poduzetnika, znanstvenika, marginalnih društvenih skupina, projekata umjetnosti i kulture. Osim poslovanja svojih klijenata, banke mogu prakticirati društveno odgovorno poslovanja politikama koje obuhvaćaju interne procese, a mogu zahtijevati i od svojih dobavljača da izbjegavaju prakse koje imaju negativan utjecaj na okoliš (Ivanišević Hernaus, 2016).

Kao što je citirano u Forcadell i Aracil (2017), Goyal i sur. napominju da je provedeno mnogo istraživanja koja povezuju društveno odgovorno poslovanje, reputaciju i financijske pokazatelje poduzeća, ali su ista nedovoljno zastupljena u sektoru bankarstva.

Istraživanje koje su proveli Del Brio i Lizarzaburu (2017) upravo na primjeru bankarskog sustava zemlje u razvoju pokazuje da postoji strateški potencijal kao posljedica povezanosti društveno odgovornog poslovanja i korporativne reputacije banaka. Rezultati su pokazali kako društveno odgovorno poslovanje utječe na stvaranje povjerenja prema bankama te može poslužiti u svrhu izgradnje reputacije banke i posljedično rast ekonomskih kategorija. Odabirom svojih klijenata banke mogu unaprijediti svoju reputaciju, a posljedično rastu

reputacije pospješiti svoje performanse te istovremeno podržati veću održivost gospodarstva (Forcadell, Aracil, 2017). Ipak, vodeći se istraživanjem koje su proveli Jo, Kim i Park (2015) na uzorku 29 zemalja, treba napomenuti kako utjecaj DOP-a može imati odgođene efekte (do 2 godine) na financijske pokazatelje banke, ali da je poček u slučaju razvijenih financijskih tržišta kraći. Također, društvo odgovorno poslovanje, može povećati reputaciju banke i popraviti financijske pokazatelje, ali veza nije neovisna o gospodarskim ciklusima te u uvjetima krize ona postaje negativna, osim ako je kriza izazvana štetnim financijskim proizvodima. Tada će klijenti banke značajno preferirati one banke čija reputacija smanjuje rizik upotrebe štetnih financijskih proizvoda. Jo, Kim i Park (2015) napominju kako banke iako se ne nalaze u sektoru prerađivačke industrije imaju dovoljno razloga uključiti društveno odgovorno poslovanje u svoje strateške planove.

Sustavan pristup analizi društvenog odgovornog poslovanja potaknut je i smjernicama računovodstvenog izvještavanja (GRI) koje u tu svrhu obuhvaća šest cjelina: pokazatelje ekonomskih učinaka, pokazatelje učinaka na okoliš, pokazatelje učinka radnih odnosa i dostojnog rada, pokazatelje učinka ljudskih prava, pokazatelje društvenih učinka i pokazatelje odgovornosti za proizvode i usluge. Ekonomski učinci uključuju visinu novo ostvarene dodane vrijednosti, njezinu raspodjelu, financijske posljedice djelatnosti organizacije na klimatske promjene, sustav mirovinskog osiguranja zaposlenika, visinu subvencija primljenih od vlade, omjer standardne početne i minimalne plaće, zapošljavanje domaće radne snage i njihov udio u menadžmentu, utjecaj infrastrukturnih ulaganja i usluga u svrhu koristi komercijalnih, nenovčanih i nenaplaćenih djelatnosti, opis neizravnih ekonomskih utjecaja i udio potrošnje na domaće proizvode i usluge. Pokazatelji učinka na okoliš obuhvaćaju obujam i opsege upotrijebljenih materijala, potrošnju energije i vode, utjecaj na biološku raznolikost, emisiju otpadnih voda, preuzimanje prodanih proizvoda i ambalaže, pridržavanje propisa o zaštiti okoliša, prijevoza radnika i distribucija proizvoda, izdaci u zaštitu okoliša, procjenu dobavljača prema njihovom utjecaju na okoliš i mehanizme rješavanja sporova. Pokazatelji učinka radnog odnosa obuhvaćaju strategiju zapošljavanja, odnos nadređenih i podređenih, zdravlje i sigurnost na radu, ulaganja u edukaciju zaposlenika, raznolikost i jednakost mogućnosti i procjena dobavljača prema njihovim radnim odnosima. Pokazatelji učinka na ljudskih prava sastoje se od ulaganja u projekte koji su povezani s ljudskim pravim, poštivanje ljudskih prava od strane dobavljača, broja diskriminacija i način rješavanje sporova, mogućnost kolektivnog pregovaranja, dječji i obvezni rad, sigurnosne prakse, poštivanje domicilnog autohtonog stanovništava, procjena dobavljača, rješavanje sporova, Pokazatelje društvenog učinka

obuhvaćaju utjecaj na zajednicu, borbu protiv korupcije, javne politike, monopol, pridržavanje propisa, procjena dobavljača i mehanizme rješavanja sporova. Konačno, pokazatelji društvenog učinka obuhvaćaju zdravlje potrošača, informacije na proizvodima, promotivnu komunikaciju, privatnost potrošača i pridržavanje propisa iz navedene domene (Rogošić, Bekavac, 2015).

Odnos između aktivnosti banke, njezine reputacije i ekonomskih efekata ostaje važan element strategije banke. Prema istraživanju koje su proveli Dell'Atti, Trotta, Iannuzzi i Demaria (2017) u periodu nakon financijske krize (2008-2012.) na uzroku 75 međunarodnih banaka pokazalo se kako je reputacija pozitivno korelirana s financijskim pokazateljima, a negativno korelirana s polugom i rizikom. Također, potvrdili su pozitivnu vezu između reputacije i društveno odgovornog ponašanja, dok je odnos reputacije i ekoloških pokazatelja bio negativan.

3.4.5 Inovativnost

Zadnjih nekoliko desetaka godina, posljedično, utjecaju razvoja i trendova IT tehnologije, sustavima poslovne inteligencije (Business Intelligence) te inovativnih strategija upravljanja rizicima, poslovanje banaka značajno je promijenjeno (Sushil, 2013). Osim primjene novih tehnoloških rješenja, prilagodba banaka mora obuhvatiti redefiniranje odnosa s klijentima, iskoristiti inovacije i osigurati adekvatne prinose. Tehnologija kao nositelj inovacije, omogućava nove distribucijske kanale, kreiranje novih proizvoda, osvajanje tržišta i povećanju kvalitete usluge, a upotreba tehnologije ima pozitivan utjecaj na performanse uslužnih poduzeća (Kumar Behera, Nayak, Das, Mohapatra, 2015).

Naime, može se reći kako se početkom 21. stoljeća unutar industrije bankarstva dogodilo nekoliko radikalnih međusobno isprepletenih inovacija koje su omogućile efikasnije procesuiranje i razmjenu informacija. Kao neke od najvažnijih mogu se izdvojiti bankomati[13], kartično poslovanje i Internet bankarstvo (Murali, 2016).

Bankomati kao inovacija bankarske industrije pojavili su se prvi puta prije pedesetak godina. Početkom 1967. godine pojava prvog bankomata označila je početak digitalizacije

[13] engl. Automated teller machines

maloprodajnog bankarstva. Kao odgovor na rast troškova radne snage te u namjeri da se omogući distrbucija gotovine izvan radnog vremena banke, najopsežnija implementacija bankomata dogodila se u Europi. Iako su prvi bankomati svojom funkcionalnošću bili ograničeni omogućvali su podizanje gotovine izvan radnog vremena poslovnice banke. Klijent se prethodno isplati gotovine identificirao putem papirnatih ili plastičnih žetona. Žetoni su se vraćali klijentima nakon što je njihov račun bio terećen u banci za iznos podignutih sredstava. Bankomati prve generacije često su ostajali zaglavljeni, bez proizvoda ili greškom izbacivali više novčanica bez znanja banke. Obzirom na nedostatak njihove fleksibilnosti trebalo je nekoliko desetaka godina da bankomati postanu dio svakodnevice potrošača. Bankomati su se pojavili u trenutku kada je gotovina bili preferencijalni izbor za novčane transakcije odnosno prije nego su debitne i kreditne kartice postale popularne. Uz iznimku SAD-a i Francuske čak su i osobni čekovi bili privilegija za bogate. U početku je zbog namjenskih telefonskih linija lokacija bankomata bila ograničena isključivo na poslovnice banaka i visokofrekventna mjesta, a s razvojem digitalne telekomunikacije i ugradnjom Windows operativnog ustava omogućena je daljinska dijagnostika, integracija unutar mreže kartičnog kliringa te konačno odabir lokacije nevisno fizičkih telefonskih linija. Danas je više od 3 milijuna bankomata postavljeno na različitim lokacijama od visoko-frekventnih mjesta pa sve do ponekad najudaljenihh mikrolokacija te omogućuju provjeru stanja računa, uplate, čekovni kliring, isplate, transakcije između računa te nadoplatu računa telekomunikacijskih usluga i cestarine. Iako je funkcionalnost bankomata napredovala, tehnologija nije ostala bez izazova. Izazovi su povezani s troškovima prilagodbe regulativi, troškovima nadogradnje, pritiskom interesnih skupina za smanjenje ili eliminaciju provizija, sofisticiranim pokušajima hakiranja, krađom podataka s kartice (skimming) (godišnje uzrokuje štetu u vrijednsoti 2 milijarde dolara), fizičkim napadima koji rezultiraju uništenjem imovine, rastom bezgotovinskog broja transakcija i rastom interesa za stvaranjem bezgotovinskog društva. Unatoč preprekama više od 80% eksperata smatra kako će upotreba i broj bankomata nastaviti rasti.

Snižavanjem troškova upotreba bankomata trebala je povećati efikasnost banaka. Ipak, vodeći se teorijom produktivnosti poduzeća i strukturom određenih performansi na uzorku banaka Indije u periodu 2007-2012, Sathye i Sathye (2017) su izračunali kako postoji negativna veza između ulaganja u bankomate i efikasnosti banaka. Autori smatraju kako je razlog tome nedovoljna upotreba alterantivnih kanala te su banke uz postojeća ulganja u tehnologiju bila primorana zadržati klasične oblike distribucije gotovine, a Jones i sur. (2012) generaliziraju

kako je paradoks produktivnsoti posljedica pogešnog mjerenja, pogrešnog menadžmenta ili nedostatka ekonomije obujama.

Inovacija kartičnog plaćanja potječe iz 1946. godine kada je od strane Biggins banke izdana prva debitna kartica. Klijent banke mogao je platiti račun trgovca karticom nakon čega je banka u određenom roku refundirala puni iznos. Kupnje su mogle biti samo lokalnog karaktera, a vlasnici kartice isključivo klijenti banke. Nedugo nakon toga izdane su prve kvazi-kreditne kartice: Diners kartica 1950. godine i American Express 1958. godine. Kvazi-kreditne kartice podrazumijevale su kako naplata iznosa ne mora podrazumijevati postojanje dovoljnog iznosa novca na računu klijenta u trenutku kupnje nego je dospijeće plaćanja krajem mjeseca. Do kraja 1951. godine Diners karticu je koristilo 20 tisuća korisnika, a pet godina nakon izdavanja American Expressa bilo je više od milijun korisnika koji su mogli karticom plaćati na 85 tisuća različitih lokacija (unutar i izvan zemlje). Vrlo brzo nakon toga neke od banaka ponudile su mogućnost kreditiranja te su izdane kreditne kartice u punom smislu riječi koje se danas nose naziv revolving kartice. Nešto kasnije, početkom 1966. godine pojavile su se udruženja banaka koja su izdavala svoje kartice danas poznate pod imenom Visa i Mastercard. Jedna od značajnih inovacija u kartičnom poslovanju za potrebe verifikacije korisnika 60-ih godina 20.stoljeća bio je izum magnetske trake. Nedugo nakon toga pojavila se tehnologija identifikacije radio frekvencijom (RFID) te je omogućena beskontaktna autentifikacija. Ipak, zbog izazova povezanih sa sigurnošću, danas se umjesto magnetnih traka i RFID tehnologije koristi EMV kompjuterski čip razvijen kao rezultat suradnje Europaya, Mastercarda i Vise. EMV čip je daleko sigurniji od magnetne traka zato što je ona u osnovi statične prirode. Jednom kad se podaci s magnetne trake kopiraju ona se bez ograničenja može umnožavati i pretvoriti u gotovinu. Za razliku od magnetne trake prilikom svake kupnje EMV čip stvara jedinstveni kod koji se ne može višestruku iskoristiti. Ukoliko bi takav kod bio ukraden u tijeku jedne kupnje ne bi ga bilo moguće iskoristiti za novu kupnju, a kartica bi bila odbijena (Kossman, 2017). Kartično plaćanje smanjilo je troškove klijenata i trgovaca povezane s nošenjem gotovine (odlazak u banku, oportunitetne troškove prinosa na depozite), povećalo efikasnost upravljanja sustavom pružanja financijskih uslugama, transparentnost i sigurnost of fizičke krađe imovine odnosno gotovine. Novi sustav plaćanja ima relativno visok stupanj sigurnosti, a najveći nedostatak bila je njegova neodvojivost od nošenja fizičke kartice i broj koraka koji su potrebni za provedbu transakcije.

Razvojem digitalnog novčanika i prateće infrastrukture nestaje potreba za nošenjem materijaliziranih kartica. Iste su pohranjene unutar digitalnog novčanika koji se nalazi u jednom od mobilnih uređaja, prvenstveno mobilnom telefonu. Nadalje, obzirom da se proces plaćanja karticama u odnosu na gotovinu odvija u nekoliko koraka klijenti su manje iznose skloniji podmirivati gotovinom, a posljedično postoji tendencija pružatelja usluge kartičnog plaćanja da smanjuje broj koraka potrebnih za manje iznose transakcija. S manjim brojem koraka anulira se jedan dio autentifikacije klijenata, a time raste i rizik zloupotrebe (manje transkacije provode se bez autentifikacije PIN-a) (WEF, 2015). Iako rizik zloupotrebe nije u potpunosti nestao, u zemljama razvijenih financijskih sustava, savjesni korisnik kartice ne snosi gotovo nikakvu odgovornost za troškove koje mogu nastati zloupotrebom (MacDonald i Tompkins, 2017). Upotreba kartičnog plaćanja ograničena je prihvaćanjem trgovaca zbog troškova infrastrukture, financijske isključenosti i mogućnosti digitalnih malverzacija.

Kako bi kartično plaćanje funkcioniralo mora biti uspostavljena mreža sudionika koja uključuje izdavatelja kartice i procesni centar (Acquirer) (autorizacija, namira, pozivni centar, programi lojalnosti, izdavanje i slanje računa), trgovca, posrednike koji angažiraju trgovca i posrednike procesuiranja (ponekad ista pravna osoba kao i posrednik koji angažira trgovca: autorizacija prethodno ulasku u mrežu plaćanja, prijenos i sigurnost podatka te namira), mrežu plaćanja te imatelja kartice, a veličina tržišta navedenih sudionika procjenjuje se na $900 milijardi. Izdavatelj kartice distribuira iste, šalje račune i naplaćuje potrošeni iznos. Specifični posrednici koji angažiraju trgovca zaduženi su za njihovo regrutiranje (prihvaćanje izdanih kartica) te osiguravaju hardver za procesuiranje transakcije koja se registrira kod izdavatelja. Nadalje, hardver naplate (Point of Sales uređaje) te infrastrukturu za ulazak u mrežu plaćanja proizvode specijalizirana poduzeća. Neki od najvećih posrednika koji angažiraju trgovca trenutno su Chase (19%), BAMS (13%), Vantiv (12%), Global Payments (7%), Wells Fargo (6%), Evalon(6%) i Frist Dana (6%), a neki od najvećih posrednika procesuranja su First Dana (34%), Chase Commerce (20%), Vantiv (12%) i Evalon (6%). Mrežu plaćanja čine podzeća koja povezuju izdavatelja kartice i posrednika koji angažiraju trgovce, a neki od najvećih su: Visa, MasterCard, American Express, Discover/PULSE, Interlink, NYCE, Accel, UnionPay, Interac i Star. Autorizacija se događa na mjestu prodaje provlačenjem ili umetanjem kartice ili putem online obrazaca ručno upisujući podatke ukoliko korisnik kartice nije fizički prisutan. Neke transakcije i dalje zahtijevaju telefonsku autorizaciju od strane pozivnog centra koja se događa nakon što je isti zaprimio podatke o trgovcu, podatke s kartice te iznos transakcije. Nakon zaprimanja spomenutih podataka traži se autorizacija od strane banke koja je izdala karticu.

Nakon zaprimanja zahtjeva banka provjerava vjerodostojnost transakcije te ukoliko postoji pokriće ili otvorena kreditna linija banka može odobriti ili odbiti autorizaciju.

Posrednik koji je angažirao trgovca zaprima odgovor te isti prosljeđuju na mjesto kupnje, a cjelokupni proces traje svega nekoliko sekundi (DeGennaro, 2006). Posljedično daljnjem razvoju tehnologije kako bi se povećala razina fleksibilnosti nastoji se provesti konsolidacija pružatelja POS infrastrukture, procesnog centra (Acquirer) i mreže plaćanja (Payment Network). Spomenuto podrazumijeva suradnju od strane izdavatelja kartica, trgovaca i klijenata. Također, kreira se infrastruktura koja će biti pristupačna većem broju trgovaca, a ima zadaću komplementirati i/ili zamijeniti upotrebu POS uređaja (mobilna plaćanja, integrirane aplikacije, automatska plaćanja (streamlined payment solutions)) (WEF, 2015). Debitne i kreditne kartice su prihvaćene kao plastični ekvivalent novca, a mnogi iste smatraju i preferencijalnim načinom kupovine i plaćanja (Premalatha, Suresh, Kumar, & Venkatram, 2017).

Ne računajući predujmove na kreditnim karticama i dizanje gotovine s debitnih kartica opeg kartičnog plaćanja 2016. godine u odnosu na prethodnu porastao je 5,8%, a iznosio je 20 trilijuna dolara godišnje (20% svjetskog GDP-a). Visa, UnionPay, MasterCard, JCB, DinersClub/Discover i American Express karticama 2016. godine provedeno je 257 milijardi trgovačkih transakcija s godišnjim rastom od 13,3%. Spomenuti broj transakcija uključuju debit, kredit i prethodne uplate (prepaid). Najćešće korištenom karticom (Visa) plaćeno je 54% ukupne vrijednosti kartičnog plaćanja, od čega je 34% išlo u korist debitnih kartica, a19% u korist kreditnih. Ukupan broj kartica u cirkulaciji krajem 2016. godine porastao je 9,4% te je iznosio je 11,15 milijardi, od čega je 77,4% kartica bilo debitno, a 22,6% kreditno (Mobile Payments Today, 2017).

Zadnjih deset godina dogodio se izniman rast popularnosti Interneta i mobilnih telefona, a banke su inovacijom Internet bankarstva iskoristile spomenuti fenomen. Digitalno bankarstvo putem pametnih telefona omogućilo je pružanje bankovnih usluga gotovo neovisno lokaciji i radnom vremenu banke, a popraćen je visokim stupnjem kvalitete i minimalnim operativnim odnosno varijabilnim troškovima poslovanja.

U namjeri da očuvaju svoj status mnoga već uspješna poduzeća započela su digitanu transformaciju. Iako digitalna transformacija nije zamišljena kao odredište sama po sebi, ona

ima zadaću iskoristiti digitalne kapacitete kako bi tradicionalno poduzeće pripremilo za tržište unutar digitalne ekonomije. Na primjeru četiri banke: Danske Bank, mBank, BBVA i ING, Weill i Woerner (2018) deriviraju četiri elementa strategije za opstanak unutar digitalne ekonomije: standardizaciju, povećanje kvalitete iskustva korisnika, alternirajuća orijentacija između kvalitete iskustva korisnika i optimizacije operacionalizacije procesa, izgradnju novog poduzeća (otežana transformacija organizacijske kulture pri čemu nije moguća pravovremena prilagodba). Menadžemnt mora odlučiti koje poteze napraviti i kojom brzinom izvršiti transformaciju. Weill i Woerner (2018) navode kako je poečetkom 2000. godine uprava jedne od promatranih banaka prepoznala da postojeća kvaliteta iskustva klijenata banke nije adekvanta. To je potaknulo banku na uvođenje inovacija kao što su: uspotavljanje pozivnog centra, ponudu Internet usluga i novih proizvoda. U nemogućnosti da se prilagodi postojeća platforma te kako će se problemi intenzivirati banka je u periodu 26 mjeseci dizajnirala platformu koja će imati nove mogućnosti: mobilno plaćanje, integraciju s društvenim mrežama, odobravanje zajmova u 30 sekundi, video komunikaciju, međusobno umrežavanje klijenata i beskartično isplate na bankomatu (inovacija mobilnog bankarstva: aplikacija na mobitelu generira jednokratni kod koji omogućava podizanje gotovine (The Financial Brand, 2017). Nova platforma imala je zadaću povećati efikasnost obrade podataka. Svaka transakcija ili promjena koja se napravi unutar mobilne aplikacije istovremeno je trebala biti dostupna unutar distribucijskog kanala i bankaru zaduženom za klijenata. Nova platforma dizajnirana na principu otvorenosti također omogućavaju ponudu usluga klijentima putem partnerskih odnosa s drugim poduzećima unutar drugih tržišta i nekonkurentskih banaka kako u zemlji tako u inozemstvu.

Nadalje, slično kao što je kartično poslovanje predstavilo inkrementalni tehnološki pomak početkom 1950-ih, mobilno se bankarstvo kao tehnološka revolucija javlja tek početkom 2000. godine i to u svom vrlo primitivnom obliku pri čemu su se prve transakcije obavljale putem tekstualnih poruku (SMS-a). Naime, razvoj tehnologije mobilnih telefona diljem svijeta stvorio je izuzetnu tehnološku infrastrukturu za razvoj čitavog niza novih usluga putem različitih programskih rješenja unutar spomenute mreže. Cijenom pristupačne kartice na bonove i pretplatu te cijenom dostupni uređaji, zadnjih deset godina stvorili su milijune novih korisnika mobilne telekomunikacije i potencijalno tržište mobilnog bankarstva, a slanje poruka, glasovni pozivi i upotreba mobilnih aplikacija postali su sastavni dio svakodnevice zapadne kulture. Mobilno bankarstvo danas pod različitim nazivima: m-financiranje, m-plaćanja, m-bankarstvo i m-transferi podrazumijeva skup aplikacija koje omogućuju da se putem mobilnog telefona upravlja sredstvima računa: obavlja plaćanja, investicijske, štedne i kreditne poslove te pristupa

proizvodima povezanih poduzeća: osiguranja i telekomunikacija. Mobilno bankarstvo ima zadaću osigurati komplementarni kanal komunikacije s bankom koji će uz čekove, bankomate, pametne kartice i POS-uređaje omogućiti bezgotovinsko upravljanje sredstvima korisnika (Donner, Tellez, 2008).

Kao preduvjet digitalnog bankarstva važno je ramotriti koncept identiteta. Potvrda identiteta nameće se kao ključna pretpostavka modernog bankarstva. Identitet je osnova poslovanja financijskih institucija čija se aktivnost povezuje s transakcijama koje podrazumijevaju određenu razinu rizika i zahtjevaju sigurnost provedbe, a financijske institucije istovremeno snose teret nedostatka efikasnosti sustava identifikacije. Postoji čitav niz problema koji se može povezati s utvrđivanjem identita: nedostatak efikasnosti i visoka cijena ugovoranja usluge, dugotrajnost procesa ručne obrade, manjak efikasnosti i cijena analize klijenata, nedostatka vidljivosti financijske povijesti klijenta, različite procjene klijenta, poteškoće u odabiru ponude adekvatne usluge, poteškoće utvrđivanja izvora imovine i vlasništva, poteškoće u evidenciji tražbine kolaterala, poteškoće identifikacije sudionika transkacije, poteškoće utvrđivanja osobnog identita korporativnih klijenata, teškoće regulatornog usklađivanja upravljanja podacima i privatnošću klijenta, teškoće utvrđivanja povezanosti pravnih osoba i ukupne razine izloženosti i kriminalne radnje (2015. godine regulator je Barclays banku kaznio sa £72 milijuna funti za neadekvatnu zaštitu od rizike financijskog kriminala). Neki od spomenutih problema mogu se ublažiti ili rješiti razvojem tehnologije odnosno kreiranjem adekvatnog sustava digitalnog identita. Digitalni identitet treba povećati privatnost i sigurnost klijenata, ostvariti prihode za pružatelja usluge, olakšati regulatorno usklađivanje i povećati kvalitetu pružanja drugih javnih usluga. Digitalni identitet može se pohraniti, transferirati i koristiti uz pomoć naprednih sigurnosnih protokola koji gotovo u potpunosti onemogućavaju neautorizirani pristup, modifikaciju, gubitak i krađu, omogućava korisniku kontrolirano dijeljenje informacija, kontinuitet različitih procesa koji zahtjevaju potvrdu identitata bez ručnog unosa podatka i mogućnosti ljudske pogreške i ažurirati novim atributima koji su nastali tijekom vremena (WWF, 2016a).

Inovativna AIDC tehnologija omogućila je otvaranje računa bez posjeta banke. Idnow (KOFAX, 2017) aplikacija uz pomoć AIDC[14] tehnologije omogućava identifikaciju isprava kao

[14] akronim od engl. Automatic Identification & Data Capture

što je osobna karta ili putovnica, verifikaciju integriteta isprave: validaciju kvalitete slike, verifikaciju kontrolnih točaka i strojnih zona[15] i ekstrahiranje podatka putem OCR-a[16] za komparaciju s podacima unesenim od strane klijenta (u kombinaciji s državnim biometrijskim repozitorijem putem API sustava za komunikaciju privatnih institucija sa državnim bazama). Ipak, valja naglasiti kako potvrda identiteta na osnovi fizičkih isprava ne zahtjeva uvijek povezivanje klijenta i samih isprava dok posljedično korisnik ne mora nužno biti ista osoba, a fizičke isprave također mogu biti falsificirane ili izmjenejne (WWF, 2016a).

U potpuno digitalnoj indijskoj banci Digibank koja je započela svoj rad 2016. godine moguće je otvoriti račun za 90 sekundi, dok je u nekim Europskim zemljama za isto potrebno 8 minuta. Posljedično četvrtoj direktivi Europske unije eIDAS[17] koja se odnosi na sprječavanje pranja novca određeno je da potvrda identiteta elektroničkim putem mora biti ekvivalent odlaska u banku. Primjerice, nakon potvrde zaprimanja inicijalne elektroničke pošte i unošenja osnovnih podataka potencijalni klijent mora uputiti video poziv agentu banke koji će ga zatražiti prezentaciju minimalno dokumenta koji su potrebni za otvaranje računa (EFMA, 2017d). Procjenjuje se da će u SAD-u 2020. godine samo 20% računa biti otvoreno putem tradicionalnih kanala odnosno u poslovnici, a 46% putem Interneta i 36% putem mobilnih uređaja. Obzirom na prirodu procesa otvaranja računa, banka želi procijeniti rizik klijenta za banku (kriminalitet, solventnost). Sustav procjene uzima u obzir podatke koje klijent unosi sam (ručno ili uz pomoć ADR-a[18] i RT-a[19]) te podataka koji o klijentu postoje u Središnjoj banci, bazama lokalnih vlasti, bankarskoj mreži, listama politički izloženih osoba te podatke o geolokaciji i vremenu komunikacije. S jedne strane ukoliko postoji sumnja da klijent ugrožava reputaciju banke proces može biti zaustavljen, a s druge strane kada rizik nije visok kako se pretjeranim zahtjevima ne bi obeshrabrilo potencijalne klijente procjena može biti provedena naknadno, a do konačne potvrde prebivališta račun klijenta može imati ograničenu funkcionalnost (EFMA, 2017a). Dosada je klijent morao fizički otići u banku ili je predstavnik banke morao doći na lokaciju klijenta, a prilikom odlaska u banku ponekad duže vrijeme čekati u banci. Osim smanjenja prepreka, upotreba Interneta omogućila je niz drugih prilika. Komunikacija putem

[15] engl. Machine Readable Zones
[16] akronim od engl. Optical Character Recognition
[17] akronim od engl. Electronic Identification and Trust Services
[18] akronim od engl. Automatic Document Recognition
[19] akronim od engl. Reading technologies

računala ili mobitela pokazala se kao efikasan marketinški kanal, a moguće je plasirati personalizirane promotivne sadržaje (Parameswar, Dhir, Dhir, 2017).

Kao posljedica nedostatka osobnog kontakta za potrebe mobilnog bankarstva dizajniraju se interaktivni upitnici koji u kombinaciji sa situacijskim simulacijama i praktičnim pitanjima mogu derivirati prilagođene ponude za svakog klijenta. Prikupljene informacije mogu unaprijediti profil korisnika te identificirati komercijalne prilike ili detektirati anomalije funkcioniranja računa. Ukoliko su pitanja dobro dizajnirana mogu dati uvid u potrebe i očekivanja klijenta. Proces može biti neinvazivan i zabavan, a klijent dobiva osjećaj personaliziranog kontakta nalik onome odlasku u poslovnicu (EFMA, 2017a). Proces kreiranja digitalnog identiteta sastoji se od nekoliko dimenzija: osiguranje efikasnosti i kontinuitet u pružanju usluge, kategorizacija identiteta prema ovlastima (autorizacija), osiguranje razmjene atributa između sudionika (sigurnost i privatnost), povezivanje sudionika s atributima (snažna autentifikacija), prikupljanje i pohrana atributa (dovoljna količina i točnost atributa), izrada standarda upravljanja operacijama (adekvatna razina koordinacije). Ukoliko banke ne iskoriste benefite koji donosi tehnologija, Fintech organizacije zasigurno hoće. Za one koji se profiliraju kao dominantni pružatelji usluge digitalnog identiteta povećavaju svoju reputacije posljedično pozicioniranju unutar digitalnog tržišta i osiguravaju pristup dijelu profita financijskog tržišta. Obzirom na postojeću poziciju odnosno povjerenje klijenata koje uživaju banke u okviru regulatornih ograničenja postoji značajan potencijal monetizacije sustava identiteta klijenata.

Kako bi se smanjile barijere ulaska u industriju i povećala konkurentnost odnosno omogućila promjena institucija sustavi identifikcije moraju biti bazirani na otvorenim tehnološkim i podatkovnim standardima. U Švedskoj postoji sustav digitalnog identita (eID) koji omogućava pristup više od 300 javnih i privatnih usluga. Identiteti su izdani od strane nekoliko privatnih institucija, uključujući velike banke i pružatelje telekomunikacijskih usluga. Javni sektor izdavatelju plaća za uslugu validacije identiteta spomenutog sustava. Potpisivanjem ugovora privatni pružatelji usluga također se mogu se pridružiti sustavu identifikacije banke, a spomenuto rješenje zasad koristi 9 milijuna građana. Banke također mogu odabrati model udruženog nastupa u svrhu pružanja digitalnog identiteta. TUPAS predstavlja udruženje financijskih institucija Finske koji su pružatelji usluge digitalnog identiteta. Korisnik ima uvid u zahtjev tražitelja identifikacije i može ili ne mora dati odobrenje za dijeljenje podatka. Kao što banke imaju mogućnost biti pružatelji usluge digitalnog identiteta tako će i Fintech organizacije koje već ionako prikupljaju informacije o klijentima za potrebe osnovnog

poslovanja biti potaknute potencijalnom monetizacijom sustava identiteta. Clarient Entity Hub, DTCC je privatna organizacija koja upravlja podacima i brine o ispunjavanju regulatornih zahtjeva sudionika financijskih transakcija. Povećava transparentnost financijskog tržišta i svoje uluge naplaćuje drugim organizacijama. Važno je napomenuti kako stvaranje digitalnog identiteta ima višestruke i različite implikacije za sve interesne skupine odnosno sudionike procesa te istovremeno predstavlja kulturni fenomen tako da nije realno očekivati kako će jedan model biti idealan za sva prilike (WWF, 2016a).

Obzirom kako se razvoj tehnike dosada događao relativno brzo, unutarnji procesi nisu uvijek adekvatno popratili njihovu upotrebu, a banke će biti primorane odvagnuti između nagrada i rizika koji su generirani novim okruženjem (Campanella i sur. 2013, Campanella, Peruta, Giudice, 2017). Dinamično okruženje obilježeno inovacijom i tehnološkim napretkom suočava poduzeća ne samo s problemom asimetrije informacija nego asimetrije znanja. Fenomen predstavlja kočnice inovacije, rasta, restrukturiranja poduzeća i evolucije poslovnih sustava. Kako bi proces evolucije ipak bio moguć, biti će neophodno odabrati one transformacije društvenih koncepata, poslovne i organizacijske strategije koje mogu podnijeti rizike financiranja i inovacije (Baravelli, 2017). Campanella, Peruta, Giudice (2017) napominju kako utjecaj tehnološkog napretka i složenosti inovativnih tehnologija na strukturne i društvene elemente podrazumijeva ograničenja u strateškim opcijama razvoja banaka (Campanella, Peruta, Giudice, 2017).

3.4.6 Kvaliteta proizvoda i usluga

Na temelju rezultata istraživanja koje su proveli na uzorku 25 tisuća američkih poduzeća Raynor i Ahmed (2013) naglašavaju da je kvaliteta osnova dugoročnog uspjeha poduzeća. Uspoređujući troškovnu efikasnost koja također predstavlja aspekt poslovne strategije, autori smatraju kako će kvaliteta proizvoda i usluga unutar industrije ipak biti presudna odrednica dugoročnog uspjeha poduzeća. Kao što je napisano u Parameswar, Dhir i Dhir, (2017), u želji da ostvare konkurentsku prednost banke se fokusiraju na one poslovne aktivnosti koje mogu osigurati veću vrijednost za njihove klijente. U želji da se izgradi dugoročno održiva konkurentsku prednost, napuštajući orijentaciju isključivo na cjenovne čimbenike, banke inovativnim tehnološkim rješenjima unaprjeđuju svoje analitičke procese (Kimble, Milolidakis,

2015), komunikaciju izvan i unutar banke te uz pomoć novih distribucijskih kanala stvaraju dodanu vrijednost za svoje klijente. (Thrassou, Philip, 2008). Osnaženo digalizacijom, prikupljanje velike količine informacija o svojim klijentima i napredna analitika omogućili su bankama da dobro upoznaju svoje klijente te ponude rješenja prije nego su njihovi klijenti svijesni da imaju problem, a orijentiranost na klijenta te kvaliteta njihovog iskustva postali su osnova modernog bankarskog poslovanja (EFMA, 2017d).

Razvoj infrastrukture i programskih rješenja postali su važan aspekt transformacije poslovnog okruženja. Razvoj računarstva, Internet i mobilne aplikacije samo su neke od široko prihvaćenih inovacije koje su promijenile poslovanje mnogih poduzeća, a tako i bankarstva. Inovacija mobilnog bankarstva pojavila se kao važan distributivni kanal bankarske industrije te su mnoga istraživanja posvećena upravo njegovu usvajanju (Shaikh, Karjalouto, 2015). Programske aplikacije na pametnim telefonima i tabletima omogućili su poduzećima pružanje financijskih usluga uz veću fleksibilnost klijenata te istovremeno ponudu novih funkcionalnosti. Napredak tehnike promijenio je karakter pružanja usluge, uključujući i njezinu kvalitetu. Prema istraživanju koje su uz pomoć SERQUAL instrumenata proveli Treen i sur. (2017), klijenti smatraju da je kvaliteta usluge banaka putem programskih aplikacija veća u odnosu na klasične kanale komunikacije s bankom te ih ocjenjuju u rangu s uslugom elektroničkog bankarstva uz pomoć preglednika. Kao što je citirano u Roy (2017), Klaus i Maklan naglašavaju da je kreiranje superiornog iskustva klijenta osnova zadovoljstva i lojalnosti. Iskustvo je rezultat interakcije klijenta i pružatelja usluge, a zbog njegove neopipljive prirode često podcijenjena kategorija (Vargo, Lusch, 2008). Rezultati pregleda literature ukazuju na to kako je područje istraživanja o usvajanju mobilnog bankarstva fragmentirano, ali se dominantno oslanja na modele prihvaćanja tehnologije i njezine modifikacije (Shaikh, Karjalouto, 2015).

Polazeći od niza prethodnih istraživanja kvalitete usluga u periodu od 1984.-2003., koristeći Fuzzy AHP[20] i TOPSIS[21], Özdağoğlu i Güler (2016) kreirali su ekstenzivan model mjerenja kvalitete usluga elektroničkog bankarstva. U odnosu na simultanu komparaciju kriterija, AHP omogućuje sukcesivnu validaciju parova koja omogućuje primjenu jednostavne hijerarhijske strukture za rješavanje složenih problema, a čiji rezultat daje rang mogućih kriterija (Saaty, 2008), a TOPSIS metoda podrazumijeva odabir kriterija koji ima najmanju i najveću udaljenost

[20] Analitički hijerarhijski proces
[21] akronim od engl. The Technique for Order of Preference by Similarity to Ideal Solution

od respektivno idealnog i najmanje idealnog rješenja (Agarwal, Fallah Tehrani, Hüllermeier, 2015). Kao pet glavnih elemenata Özdağoğlu i Güler (2016) navode:

1. Učinkovitost/dostupnost sustava,
2. Vjerodostojnost/isporuka,
3. Privatnost,
4. Brzinu odgovora,
5. Dizajn aplikacije.

Od čega se svaki od navedenih sastoji od nekoliko podkategorija. Učinkovistost sustava uključuje: učinkovitost preglednika, dostupnost web mjesta, pogodnost transakcije te interaktivnost komunikacije. Vjerodostojnost obuhvaća: povjerenje, reputaciju, pravovremenu reakciju i adekvatan odgovor banke. Kriterij privatnosti se odnosi na: autentifikaciju i sigurnost i osiguranje. Brzina odgovora podrazumijeva: dostupnost, izravnost i brzinu veze te brzu pomoć. Konačno, kvaliteta dizajna aplikacije rezultat je: estetike, strukture i popratnih informacija. Prema istraživanju koje su proveli spomenuti autori najveću važnost imao je kriteriji sigurnosti, zatim brzine transakcije i pogodnost, dok je najmanje važan kriterij bio dizajn aplikacije.

Također, prema istraživanju koje su proveli, Singh i Srivastava (2018), redoslijedom prema važnosti potvrđeni su sljedeći čimbenici usvajanja mobilnog bankarstva: sigurnost, efikasnost, lakoća upotrebe i percipirani trošak. Slično, Kumar, Kumar i Shareef (2017) izdvajaju šest faktora: sigurnost, privatnost, povjerenje, pristupačnost, jednostavnost, kvalitetu usluge te se može zaključiti da su sigurnost i jednostavnost kriteriji usvajanja mobilnog bankarstva koji se ponavljaju. Korišteni su mjerni instrumenti višestruko potvrđeni za različite aspekte tehnološke promjene: GAM[22], TAM[23], teorija difuzije inovacija, UTAUT[24] uključujući mjerenje percepcije i namjere usvajanja elektroničkih i mobilnih sustava.

Tehnološka infrastruktura čini preduvjet pružanja visoke kvalitete usluge mobilnog odnosno digitalnog bankarstva. Uz odgovarajajuću strategiju i alokaciju resursa od strane menadžmenta infrastruktura zahtjeva izgradnju sigurne i otvorene digitalne platforme adekvatnih kapaciteta

[22] akronim od engl. Generalized Additive Model
[23] akronim od engl. Technology Acceptance Model
[24] akronim od engl. Unified Theory of Acceptance and Use of Technology

isporuke proizvoda i usluga u realnom vremenu. Platforma mora integrirati međusobno povezane komponente koje uključuju: upisivanje u sustav, napredno upravljanje i arhiviranje dokumentacije, elektronski potpis, autentifikaciju, robotiku, umjetnu inteligenciju, virtualnu asistenciju, analitiku u relanom vremenu (alate za analizu alternativnih rješenja), procesni i proizvodni menadžemnt dostupni putem različitih kanala za upravljanje odnosima s klijentima (EFMA, 2017b).

Naime kako bi kreditne institucije osvajale i preusmjeravale tokove novca u svoje distribucijske kanale morati će zadovoljiti nekoliko ključnih prinicipa: diferencijaciju, personalizaciju, jednostavnost i dostupnost. Trenutno postoji mala razlika u ponudi proizvoda i usluga različitih banaka, 63% klijenata traži prilagodbe standardizirane ponude, a jednostavnost i dostupnost usluga (mogućnost korištenja svih usluga u bilo kojem trenutku nadohvat ruke klijenta) imperativ ponude (EFMA, 2017a). Očekuje se veća dinamika u procesima digitalizacije s integracijom OBS-a[25] temeljenog na API[26] sustavima, AI-a[27], Blockchaina, robotike, NLP-a[28], NLG-a[29], „Cloud computing"-a, VR[30] i ostalih tehnoloških inovacija (EFMA, 2017d). Rastuće platforme i decentralizirana tehnologija omogućili su nove načine agregiranja i analize informacija, povećali stupanj povezanosti, smanjili trošak pristupa informacijama i sudjelovanja u financijskim transakcijama. Inovacije ojačane novim algoritmima i modernim računarskim procesorima zamijenjuju nekad ručno odrađivane aktivnosti nudeći pristupačnije i brže skalom neograničene proizvode i usluge. Istovremeno, posljedičnoj izgradnji nove infrastrukture smanjuje se važnost uloge posrednika, a time i cijena usluge. Mogućnost prikupljanja vrste i količine podataka koji dosad nisu bili dostupni (veći broj dokumentiranih transakcija, bolje razumijevanje ponašanja i preferencija klijenata na osnovi informacija s društvenih mreža) stvara prilike za inovacije i prihode koji su rezultat njihove monetizacije (WEF, 2015). Inteligentna upotreba informacija i ponuda rješenja u realnom vremenu od strane financijskih i nefinancijska organizacija (poput Amazon, Baldu, Alibaba/Allpay, Tencent, Tesco) redefinira strukturu bankarstva (EFMA, 2017d).

[25] akronim od engl. Open Banking Standard
[26] akronim od engl. Application Programming Interface
[27] umjetna inteligencija
[28] akronim od engl. Natural Language Processing
[29] akronim od engl. Natural Language Generation
[30] virtualna stvarnost

4 MOBILNO BANKARSTVO KAO STRATEŠKA ORIJENTACIJA BANAKA

Posljedično tehnološkom napretku, demografskim promjenama i promjenama životnog stila korisnika, smanjuje se utjecaj tradicionalnog bankarstva putem poslovnica i raste utjecaj digitalnog bankarstva s posebnim naglaskom na mobilno bankarstvo (m-bankarstvo). Razvoj industrije telekomunikacija i prihvaćanje pametnih telefona stvorili su izniman ekonomski potencijal, a banke su prepoznale važnost novonastalog kanala komunikacije za plasman financijskih usluga.

4.1 Ključne odrednice mobilnog bankarstva

Prva usluga Internet bankarstva u svijetu ponuđena je 1983. godine unutar Velike Britanije od strane NBS-a[31], dok je isto zahvaljujući Stanton Federal Credit Union unutar SAD-a dostupno te 1994. godine. Godinu dana kasnije osnovana je prva isključivo Internet banka SAD-a. Sredinom 2007. Apple Inc. proizvođač pametnih telefona prvi je ponudio uslugu mobilnog bankarstva (Milic i sur., 2017). Krajem 2016. godine pametni telefon je posjedovalo 2,15 milijardi ljudi, a očekuje se kako će 2018. godine biti 2,56 milijardi korisnika. U Njemačkoj 65% populacije koristi pametni telefon, SAD-u 70%, Velikoj Britaniji 75%, Australiji 81%, Južnoj Koreji 82%, a Singapuru 92% (EFMA, 2017a). Očekuje se kako će 2018. godine biti više od milijardu korisnika mobilnog bankarstva (Multz, 2014).

Rastuća upotreba pametnih telefona stvorila je preferenciju klijenata za mobilnošću, a istovremeno se događa veliki pritisak na financijske institucije koje se oslanjaju na infrastrukturu odgođenih transakcija (Parameswar, Dhir, Dhir, 2017). Uz tradicionalne kanale financijskih transakcija te inovacije koje su obilježile razvoj postojećeg sustava transfera novca (nošenje gotovine uz pomoć osobne mreže poznanika, sredstva na računima prijevoznih poduzeća i pošte, zalagaonice) i kanala sive ekonomije (mreža podružnica koja omogućava korisnicima da uplaćuju sredstva na jednom mjestu, a isplatu obavljaju na drugoj fizički udaljenoj lokaciji) (Maurer, 2008), mobilno bankarstvo pojavljuje se kao jedan od najvažnijih kanala transfera novca putem banaka. Mobilno bankarstvo omogućiva trenutni pristup financijskim uslugama, jednostavnost, brzinu i pogodnost i niske cijene. Pružatelji usluge novčanih transkacija načelno nisu ovlašteni za provedbu međuanodnih transakcija, a s druge

[31] akronim za engl. Nottingham Building Society

strane raste važnost mobilnog plaćanja koje pruža više mogućnosti. U nerazvijenim zemljama mobilno bankarstvo često se koristi za pružanje usluge onima koji su dosad bili isključeni (M-Pesa usluga za mobilno plaćanja u Keniji) i za međunarodni transfer novca radnika u inozemstvu. Prethodno spomenuti M-Pensa na mnoge načine je revolucionalizirala mobilne transakcije, inicijalno u Keniji gdje je izbačena na tržište 2007. godine od strane Safaricoma, onda u ostatku istočne Afrike i recentno u zapadnoj Africi. Samo u tri mjeseca 2018. putem ove mobilne aplikacije M-Pensa je samo za svojih 23 milijuna pretplatnika u Keniji procesuriala 581 milijun transakcija ukupne vrijednosti 14,5 milijardi US$ ili 162 milijuna US$ svaki dan (Shapshak, 2018). Nakon što su prepoznali potencijal tržišta dva najveća telekom operatera u Africi Orange i MTN su zajednički razvili i početkom 2019. će izbaciti na tržište aplikaciju Mowali koja želi prikupiti preko 100 milijuna korinika na 22 tržišta na kojima ovi operateri djeluju (Camner, 2018).

Prema procjeni Svjetske banke 2018. godine bilo je 1,7 milijarde odraslih osoba koje nemaju bankovni račun ili pristup bankovnoj usluzi za obavljanje financijskih transakcija, a 2/3 istih posjeduje mobilni telefon (Felsenthal i Hahn, 2018). U razvijenim zemljama postoji kapacitet brzog usvajanja novih tehnologija plaćanja, a usvajanje mobilnog bankarstva potaknuto je razvojem online trgovine. Valja naglasiti kako mobilno bankarstvo podrazumijeva pristup financijskim uslugama banke (pregled stanja računa, plaćanje komunalija, mjenjačnica, štednja i slično) putem mobitela, dok mobilno plaćanje podrazumijeva plaćanje roba (POS uređaji ili elektronički automati) i usluga (aviokarte, javni prijevoz, novine, igre, glazba) bez upotrebe gotovine ili kartica. Za potonje se često koristi izraz digitalni/mobilni novčanik ili digitalni/mobilni novac.

Aplikacije poput Paypal-a, Google Pay Send-a, Alipay-a i Apple Wallet-a dali su značajan doprinos u razvoju koncepta digitalnog novčanika. Putem računa elektroničke pošte i telefonskih brojeva omogućeno je plaćanje u trgovinama, plaćanje unutar aplikacija, plaćanje na webu, upotreba nagradnih kupona, plaćanje prijevoza, slanje i primanje zahtjeva za novcem te uplate između fizičkih osoba bez naknada i postojanja bankovnih računa (ukoliko se želi podići gotovina servise je potrebno povezati s bankovnim računom). Pojava ove vrste usluge stvorila je snažan pritisak na pad cijena u segmentu financijskih transakcija.

Nadalje, mobilna plaćanja ne podrazumijevaju nužno udaljenu transakciju. Udaljena plaćanja podrazumijevaju indirektnu interakciju platitelja i POS sustava trgovca, a transakcija se događa

putem 4G mreže, Interneta i GSM-a (Leng i sur., 2018). Većina tehnologija koje podržavaju udaljene transakcije inkorporiraju neke od sljedećih tehnologija: UICC[32], IVR[33], USSD[34], WAP[35] i SMS[36] (ISACA, 2011). Transakcije na licu mjesta podrazumijevaju direktnu interakciju platitelja s POS uređajem trgovca beskontaknim plaćanjem (fizičke trgovine ili elektronički automati). Transakcije su ovisne o infrastrutkuri petlje plaćanja ili infrastrukturi financijskih institucija: NFC-u[37], QR ili barkodovima. Shen i Yazdanifard (2015) također navode vrste mobilnog plaćanja: WAP (mobile network payment), SMS, telekomunikacijski račun i NFC. Transakcije koje se događaju između korisnika usluge i trgovca (C2B/B2C) oslanjaju se na posredništvo banke ili telekomunikacijskog operatera, a P2P mobilne transakcije podrazumijevaju transfer sredstava između dva korisnika (Leng i sur., 2018).

Može se reći da se mobilno bankarstvo dosada prvenstveno razmatralo kroz tri aspekta. Prvi aspekt odnosi se na razumijevanje i predviđanje stope prihvaćanja mobilnost bankarstva, drugi aspekt obuhvaća procjenu utjecaja na korisnike i gospodarstvo, a treći aspekt razmatra upotrebu sustava mobilnog bankarstva u kontekstu društvenog, ekonomskog i kulturnog konteksta. Posljednji aspekt podrazumijeva elemente kao što su: prihvaćanje elektroničkog novca *per se,* dostupnost opcija i socijalni kontekst transakcija (Donner, Tellez, 2008).

Usluge mobilnog bankarstva mogu se klasificirati u četiri kategorije: SMS bankarstvo, programski orijentirane aplikacije, mobilno bankarstvo putem Internet preglednika i mobilnih aplikacija, a najčešće vrste aktivnosti korisnika mobilnog bankarstva su provjera stanja računa, pružanje periodičnih sažetih izvještaja, prijenos sredstava i plaćanje računa (Bhatt 2016). Ipak, unatoč njegovom potencijalu, stopa prihvaćanja i upotrebe inovativne tehnologije mobilnog bankarstva još uvijek ostaje relativno niska. Iako se volumen i broj transakcija 2012. godine udvostručio, prema istraživanju koje u Indiji provodi Bhatt (2016), 64/80 banaka je ishodilo licencu za uslugu mobilnog bankarstvo, a postoji svega 22 milijuna aktivnih korisnika (73% od ukupnog broja pretplatnika) odnosno 5% ukupnog broja bankovnih računa. Iako je brzina prihvaćanja mobilnog bankarstva veća u odnosu na ostale kanale komunikacije s bankom isti se prvenstveno koristi za osnovne funkcionalnosti. U prve četri godine inovacije, proporcija

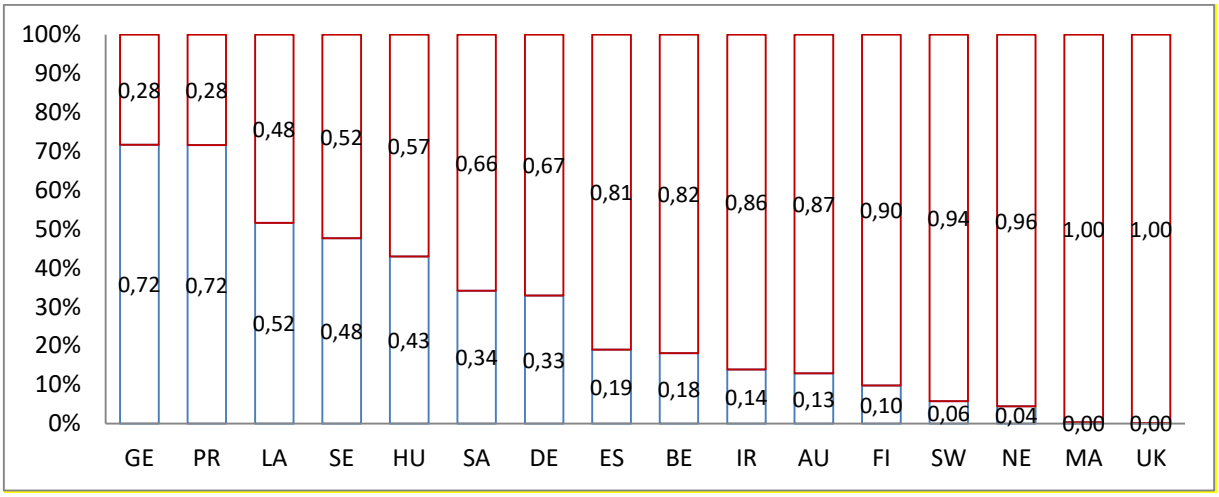
[32] associated general Purpose Integreated Service Circuit
[33] akronim od engl. Interactive Voice Response
[34] akronim od engl. Unstructured Suplementary Services Data
[35] akronim od engl. Wireless Application Protocol
[36] akronim od engl. Short Message Service
[37] akronim od engl. Near Field Communication

korisnika mobilnog bankarstva bila je veća od 20%, manja od proporcije korisnika društvenih mreža te veća od proporcije korisnika Internet bankarstva i korisnika bankomata. U prosjeku Europskih zemalja trenutno je proporcija korisnika mobilnog bankarstva dosegnula 47%. Zadnjih šest mjeseci 97% Francuza koristilo je mobilno bankarstvo za provjeru stanja računa, 58% za transakcije, a 9% za upravljanje i kategorizaciju potrošnje. Slično, upotreba mobilnog bankarstva u SAD-u prvenstveno je rezultat pogodnosti, a manje inovativnih funkcionalnosti (63% ispitanika koristi mobilno bankarstvo jer zahtjeva manje vremena, a 62% navodi kako mobilno bankarstvo omogućava pristup računima bez posjeta banci). Inovativne funkcionalnosti koristi samo 10% klijenata (EFMA, 2017a). Kao što je citirano u Bhatt (2016), Suoranto napominje da je upotreba mobilnog bankarstva primarno motivirana pogodnošću: neograničenim pristupom usluzi (dostupno 24 sata svaki dan u tjednu neovisno lokaciji korisnika), uštedama vremena i ostalih resursa i privatnošću.

Prema opisu pretplatnika može se reći kako je prosječni klijent mobilnog bankarstva mlađa osoba visoke razine tehničkog znanja koji pripadaju srednjem razredu platežne moći. Prema istraživanju jedne od največih banaka SAD-a (Bank of America) 2015. godine taj segment tržišta pod nazivom „Millenials“ nadmašio je „Baby Boomers“ generaciju, pri čemu 47% spomenutih potencijalnih klijenta smatra kako ne mogu živjeti bez mobitela, 39% svog vremena provode koristeći mobitel, a 72% s bankom komunicira prvenstveno putem mobilne aplikacije, predstavlja najveći tržišni segment banaka (80 milijuna potencijalnih korisnika samo u SAD-u). Iako su oni prema svojim karakteristikama primarna ciljana skupina mobilnog bankarstva, oni očekuju visoku kvalitetu korisničkog iskustva odnosno kvalitetu aplikacije te imaju dvostroko veću vjerojatnost promjene banke u odnosu na klijente klasičnog bankarstva ukoliko navedena očekivanja nisu ispunjena. Nadalje, osim navedenog, ciljana skupina mobilnog bankarstva su malo i srednje poduzetništvo te ostali poduzetnici. Skloni su tehnološkim inovacijama, a nemaju vremena odlaziti u banku kako bi iskoritili klasične kanale komunikacije. Dodatno, 240 milijuna osoba koje žive i rade izvan zemlje rođenja ili često putuju također su potencijalni korisnici mobilnog bankarstva jer žele imati pristup digitaliziranim financijskim uslugama koje mogu pristupati neovisno lokaciji gdje se nalaze. Nadalje, iako starije osobe nisu primarno ciljano tržište mobilnog bankarstva pokazalo se kako 18% spomenutih klijenata koristi mobilnu aplikaciju i digitalne novčanike da bi plaćali svoje komunalne usluge.

S druge strane, pretpostavka imanja pametnih mobilnih uređaja i njihova kvaliteta (veličina ekrana, brzina komunikacije), nedostatak poznavanja usluge, složenost procesa postavljanja, kreiranje tajnih brojeva povezanih s ulaskom u sustav, registracija telefonskih brojeva, percepcija nesigurnosti i tehničko znanje smatraju se kočnicama širenja usluge mobilnog bankarstva. Weisbaum (2015) kaže da 86% Amerikanaca koji ne koriste mobilno navode da je razlog što su njihove potrebe zadovoljne, a skoro 2/3 ljudi ne koristi mobilno bankarstvo jer smatraju kako nije sigurno zbog mogućnosti presretanja komunikacije, hakiranja mobitela i gubitka uređaja. Sigurnost, povjerenje, dostupnost, jednostavnost dizajna te kvaliteta ukupnog iskustva najvažniji su faktori utjecaja na formiranje negativne ili pozitivne percepcije korisnika tehnologijom osnažene usluge (Kumar, Kumar, Shareef, 2017). Kako bi se unaprijedilo korisničko iskustvo mobilnog bankarstva i povećao broj odnosno udio aktivnih korisnika biti će neophodno adresirati spomenute probleme.

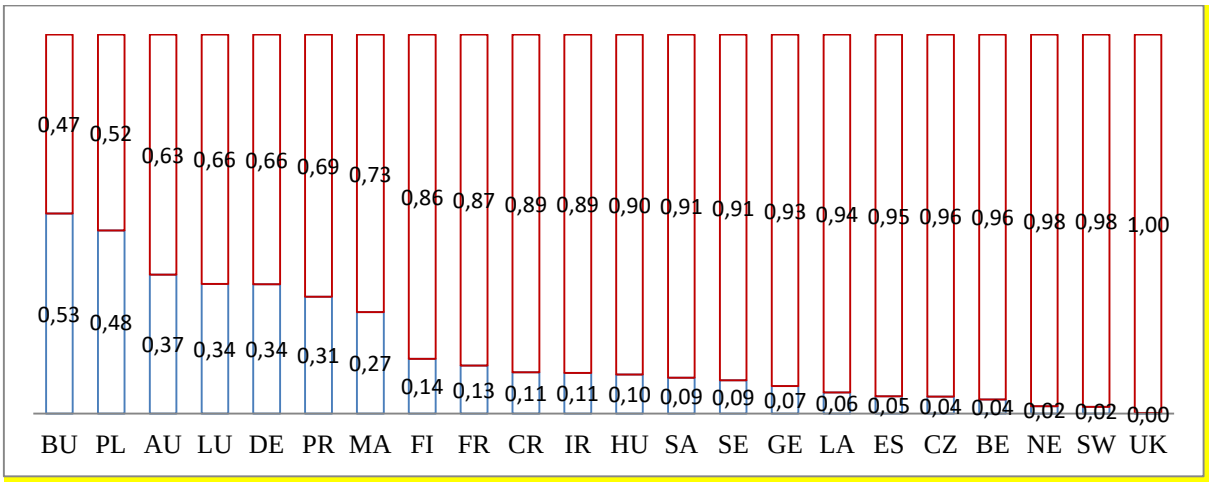
U nastavku se može razmatrati pokazatelj digitalizacije bankovnog sustava u periodu 2005.-2015. Na slici 14 i slici 15 prikazani su udjeli elektroničkih i ručno zadanih platnih naloga na razini zemalja Europske unije. Može se primijetiti kako se u navedenom razdoblju značajno povećao omjer elektronički zadanih naloga. Na razvijenim financijskim tržištima, Ujedinjenom Kraljevstvu (0,2%), Nizozemskoj (4%) i Švedskoj (6%) već se 2005. godine neznatan dio transakcija provodi na osnovi papirnato zadanih naloga, bez značajne promjene omjera 2015. godine. Najveći omjer papirnato zadanih transakcija 2005. godine imale su Italija (3,07), Cipar (2,41), Grčka (1,87), Rumunjska (1,27), Njemačka (72%), Portugal (72%) i Latvija (52%). Prema podacima iz 2015. godine najveći omjer ručno zadanih naloga imale su Cipar (2,12), Španjolska (1,95), Italija (0,81), Rumunjska (0,73), Grčka (0,57), Bugarska (0,53) i Poljska (0,48). Unutar financijskog tržišta Republike Hrvatske 2015. godine omjer papirnato i elektronički zadanih transakacija iznosio je 0,11. Unutar navedene podjele postoje razlike između zemalja koje se ne mogu pripisati stupnju funancijske razvijenosti nego su uzrokovane drugim čimbenicima. Zaključno, može se reći kako podaci o platnoj infrastrukturi Europske unije pokazuju kako se smanjuje važnost i udio transakcija koje su zadane izvan elektroničkih kanala komunikacije pri čemu je odnos dosegao razinu jedan prema osam.



Slika 14. Udio elektronički iniciranih platnih naloga, 2005.

IT 3,07; CY 2,41; GR 1,87; RO 1,27; SP 0,39; BU-Bugarska; PL-Poljska; AU-Austrija; LU-Luksemburg; DE-Njemačka; PR-Portugal; MA-Malta; FI-Finska; FR-Francuska; CR-Cipar; IR-Irska; HU-Mađarska; SA-Slovačka; SE-Slovenija; GE-Grčka; LA-Latvija; ES-Estonija; CZ-Češka; BE-Belgija; NE-Nizozemska; SW-Švedska; UK-Ujedinjeno Kraljevstvo,

Izvor: ECB, 2018



Slika 15. Udio elektronički iniciranih platnih naloga, 2015.

Izvor: CY 2,12; SP 1,95; IT 0,81; RO 0,73; GR 0,57; BU-Bugarska; PL-Poljska; AU-Austrija; LU-Luksemburg; DE-Njemačka; PR-Portugal; MA-Malta; FI-Finska; FR-Francuska; CR-Cipar; IR-Irska; HU-Mađarska; SA-Slovačka; SE-Slovenija; GE-Grčka; LA-Latvija; ES-Estonija; CZ-Češka; BE-Belgija; NE-Nizozemska; SW-Švedska; UK-Ujedinjeno Kraljevstvo

Izvor: ECB, 2018

U tablici 13 može se razmatrati značaj mobilnih uređaja prema svim ostalim platnim servisima na financijskom tržištu Republike Hrvatske. Građani su imali ukupno 6.881.359 otvorenih računa, dok su poslovni subjekti imali ukupno 582.141 računa. Najveći udio računa građana i poslovnih subjekata mogao se teretiti putem POS uređaja, respektivno 48,7% i 41,9%. Drugi najvažniji servis za građane i poslovne subjekte bio je Internet (16,5% i 37,7%). Najveća razlika

u važnosti platnih servisa između građana i poslovnih subjekata bila je u slučaju Interneta pri čemu je udio poslovnih subjekata bio 21,2% veći. Udio računa koji ima registriranu uslugu mobilnog bankarstva za građane bio je 6,27%, a poslovne subjekate 4,73%. Iako je udio računa koji imaju uslugu mobilnog bankarstva relativno malen postoji značajan ekonomski potencijal spomentuog kanala komunikacije.

Tablica 13. Platni servisi prema broju računa, građani, poslovni subjekti, 31.12.2013.

	Potrošač	%	Nepotrošač	%	df%
Internet	1.139.077	16,55	219.843	37,76	21,21
Telebanking	0	0,00	3.825	0,66	0,66
Mobilni telefon	431.501	6,27	27.549	4,73	-1,54
Fiksni telefon	221.189	3,21	6.156	1,06	-2,16
Direktni debitni transfer	658.821	9,57	2.466	0,42	-9,15
Trajni nalog	1.062.423	15,44	11.807	2,03	-13,41
POS (EFTPOS)	3.351.868	48,71	243.991	41,91	-6,80
Ostalo	16.480	0,24	66.504	11,42	11,18
Ukupno	6.881.359		582.141		

Iskazani su podaci o raspoloživim tehničko-tehnološkim uslugama (servisima) kojima se klijentima banke omogućuju dodatni načini zadavanja plaćanja na teret njihovih transakcijskih računa u Banci. Podaci su iskazani prema broju ugovorenih korisnika pojedinih servisa.
%-udio u ukupnom broju računa
df%-razlika udjela između poslovnih subjekata i građana
Internet – usluga ugovorena između imatelja transakcijskog računa i Banke kojom je imatelju transakcijskog računa omogućeno zadavanje naloga za plaćanje na teret tog računa pomoću usluge elektroničkog bankarstva temeljene na internetskoj tehnologiji.
Telebanking – usluga ugovorena između imatelja transakcijskog računa i Banke kojom je imatelju transakcijskog računa omogućeno zadavanje naloga za plaćanje na teret tog računa putem usluge elektroničkog bankarstva temeljenog na komunikacijskoj tehnologiji fiksne telefonske mreže (dial-up linije), pri čemu je korisnička aplikacija prethodno instalirana na radnoj stanici korisnika usluge.
Mobilni telefon – usluga ugovorena između imatelja transakcijskog računa i Banke kojom je imatelju transakcijskog računa omogućeno zadavanje naloga za plaćanje na teret tog računa putem usluge elektroničkog bankarstva preko mobilnih telefona, prema ugovorenom modelu.
Fiksni telefon – usluga ugovorena između imatelja transakcijskog računa i Banke kojom je imatelju transakcijskog računa omogućeno zadavanje naloga za plaćanje na teret tog računa pomoću telefonskog uređaja preko linije u fiksnoj telefonskoj mreži, prema ugovorenom modelu.
Direktni debitni transfer – usluga ugovorena između imatelja transakcijskog računa i Banke, pri čemu imatelj transakcijskog računa kao platitelj odobrava Banci da na teret njegova transakcijskog računa provede plaćanje po nalogu za plaćanje izdanom od primatelja.
Trajni nalog – usluga ugovorena između imatelja transakcijskog računa i Banke, pri čemu imatelj transakcijskog računa kao platitelj odobrava Banci da na teret njegova transakcijskog računa ispostavi nalog za plaćanje i provede plaćanje u određenom iznosu u korist određenog primatelja.
POS (EFTPOS) – usluga ugovorena između imatelja transakcijskog računa i Banke kojom je imatelju transakcijskog računa omogućeno zadavanje naloga za plaćanje na teret tog računa preko POS (EFTPOS) uređaja pomoću debitnih platnih kartica.
Ostalo – uključuje ostale usluge ugovorene između imatelja transakcijskog računa i Banke kojima se imatelju transakcijskog računa omogućuje korištenje ostalih načina za podnošenje naloga za plaćanje na teret tog računa elektroničkim putem (koji nisu sadržani u danim kategorijama) i ostale ugovorene usluge Banke na temelju kojih imatelj transakcijskog računa u Banci odobrava Banci da na teret tog računa izvrši određena plaćanja na način određen ugovorom.
df%-razlika udjela između građana i poslovnih subjekata
Izvor: autorica prema HNB, 2017c

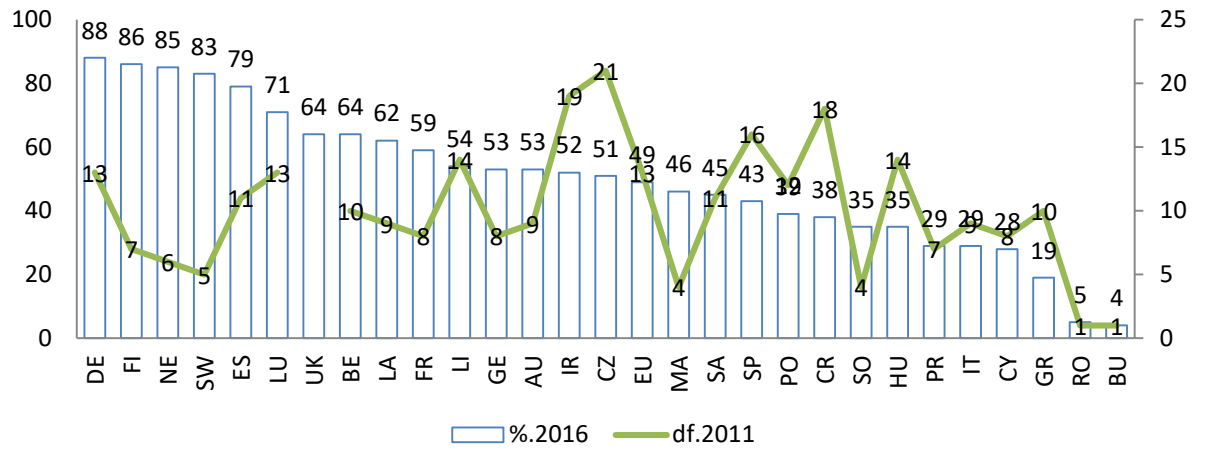
Nadalje, 2016. godine broj računa s platnim servisom preko Interneta porastao je svega 12,1%, dok je udio mobilnog telefona kao platno prometnog servisa porastao 90,2%. Navedena dinamika jasno svjedoči o razvoju i rastu popularnosti mobilnog bankarstva.

Tablica 14. Broj računa korisnika prema platno prometnim servisima

Potrošač			*Nepotrošač*
Internet	1.277.133	Internet	252.736
Telebanking	0	Telebanking	2.594
Mobilni telefon	821.114	Mobilni telefon	41.458
E-račun	42.822	E-račun	69
Trajni nalog	1.133.644	Trajni nalog	11.428
Izravno terećenje	1.075.055	Izravno terećenje	1.562
Ostalo	78.264	Ostalo	2.012

Potrošač jest fizička osoba koja u ugovorima o platnim uslugama obuhvaćenima Zakonom o platnom prometu (NN, br. 133/2009. i 136/2012.) djeluje izvan područja svoje gospodarske djelatnosti ili slobodnog zanimanja.
Nepotrošač jest pravna ili fizička osoba koja nije potrošač.
Uključuju se: pravne osobe (npr. trgovačka društva, ustanove, zadruge, udruge, zaklade i dr.), obrtnici i druge fizičke osobe koje obavljaju slobodna zanimanja ili gospodarsku djelatnost kad sklapaju ugovor o platnim uslugama ili ugovor o izdavanju elektroničkog novca unutar područja svoje gospodarske djelatnosti ili slobodnog zanimanja i subjekti koji nemaju pravnu sposobnost, a mogu biti vlasnici računa za plaćanje (npr. tijela državne uprave, predstavništva i dr.).
Izvor: autorica prema HNB, 2017a

Na slici 16 može se vidjeti komparativna analiza korisnika Internet bankarstva na razini zemalja Europske unije. U prosjeku zemalja Europke unije 2016. godine 49% pojedinaca koristilo je Internet bankarstvo. U odnosu na 2011 godinu dogodio se rast od 21%. U Republici Hrvatskoj 2016. godine bilo je 38% korisnika s porastom u odnosu na 2011. godinu od 12%. U odnosu na Republiku Hrvatsku koja se nalazi na 20. mjestu manji udio korisnika imale su Bugarska (4%), Rumunjska (10%), Grčka (19%), Cipar (28%), Italija (29%), Portugal (29%), Mađarska (35%) i Slovenija (35%). Najveći udio korisnika Internet bankarstva imale su Danska (88%), Finska (86%) i Nizozemska (85%). Najveća promjena udjela korisnika Internet bankarstva dogodila se u Češkoj pri čemu je u periodu 2011.-2016. godine udio korisnika porastao 21%, a iznosi 51%. Može se primijetiti kako su veće stope rasta bile prisutne u zemljama koje postoji inicijalno niža razina usvajanja Internet bankarstva. Kao što je cititano u Milic i sur. (2017), Ruzic napominje kako je 2013. godine u Europi bilo 42 milijuna korisnika Internet bankarstva putem mobitela i 19 milijuna putem tableta, a očekuje se kako će do kraja 2018. biti 214 milijuna korisnika.



Slika 16. Udio korisnka Internetskog bankarstva
Izvor: prilagođeno prema Milić, Kovačević, Štefanac, 2017: 5

U nastavku se može vidjeti razvoj i važnost mobilnog bankarstva prema broju i vrijednosti transakcija prema kategorijama bez gotovinskog/elektroničkog plaćanja na financijskom tržištu Republike Hrvatske. Od ukupnog broja transakcija prvih šest mjeseci 2013. godine 99.766.780, najveći broj transakcija zadan je elektroničkim putem neovisno o segmentu klijenata (60,2%) pri čemu je važnost elektroničkih kanala 2013. godine u odnosu na 2005. godinu porasla ua 19,4%. Unutar elektroničkih kanala, POS uređaji su odradili najveći broj transakcija, 37,3% za građane i 28,4% za poslovne subjekte. Mobilnim telefonom zadano je svega 0,4% transakcija za građane i 0,2% za poslovne subjekte. Rast udjela broja transakcija 2016. godine u odnosu na 2005. godinu bio je 0,4% i 0,0%. Drugi najvažniji elektronički kanal komunikacije prema broju zadanih transakcija bio je Internet, za građane 15,3% i poslovne subjekte 54,9%, s rastom 2013. godine u odnosu na 2005. godinu 8,26% i -29,9%.

Tablica 15 Podaci o bezgotovinskim platnom prometu prema broju transakcija, VI.2005; VI.2013.

	Potrošač	Pr%	Nepotrošač	Pr %	Ukupno	Pr%
Ukupno	100,00		100,00		100,00	
Obrasci - ukupno	**3,31**	-2,31	15,30	-43,77	6,58	**-15,03**
Obrasci zaprimljeni u Banci	3,29	-0,96	8,49	-12,29	4,71	-2,93
Obrasci zaprimljeni preko treće strane	0,02	-1,35	6,81	-31,48	1,87	-12,10
Elektronički	53,68	18,24	77,69	-47,55	**60,23**	**19,41**
Internet	15,36	8,26	54,93	-29,96	26,16	9,28
Telebanking	0,00	0,00	4,02	-2,81	1,10	-0,10
Mobilni telefon	0,47	0,41	0,24	0,00	0,41	0,37
Fiksni telefon	0,07	-0,29	0,09	-0,33	0,07	-0,27
Transakcijski bankomat	0,00	0,00	0,00	0,00	0,00	0,00
POS (EFTPOS)	37,33	10,68	4,83	-1,76	28,46	12,19
ostalo	0,44	-0,82	13,59	-12,69	4,03	-2,06
Na temelju zaprimljenih osnova	**0,03**	**-5,51**	**0,02**	-1,08	**0,03**	**-3,65**
Sudska rješenja	0,00	-0,01	0,00	-0,81	0,00	-0,34
Mjenice	0,00	0,00	0,02	-0,14	0,01	-0,05
Zadužnice	0,00	0,00	0,00	-0,13	0,00	-0,06
Čekovi - ukupno	0,03	-5,50	0,00	0,00	0,02	-3,20
Na temelju ugovorne ovlasti	**42,96**	**-10,43**	**6,86**	**-6,60**	**33,11**	**-0,77**
Direktni debitni transfer	2,80	-0,69	0,07	-0,11	2,06	-0,03
Trajni nalog	7,27	-0,43	0,47	-0,16	5,42	0,86
Ukupno prema broju	72.546.759		27.220.021		99.766.780	

Pr%-razlika između VI.2005 i VI.2013.

Iskazani su podaci o platnim transakcijama izvršenima na teret transakcijskih računa platnog prometa u bankama na temelju podnesenih naloga za bezgotovinsko plaćanje tijekom izvještajnog razdoblja. Platne transakcije su iskazane prema broju te prema načinu zaprimanja naloga za plaćanje. Podaci se odnose na ukupnu vrijednost tih podataka tijekom izvještajnog razdoblja, pri čemu se u tu vrijednost uključuju prvi i posljednji dan izvještajnog razdoblja. Podaci o novčanoj vrijednosti iskazani su u kunama bez lipa.

Izvor: HNB, 2017d

Uzimajući u obzir ukupnu vrijednost transakcija prvih šest mjeseci 2013. godine 523.067.186 kuna može se vidjeti kako su elektronički kanala i dalje na prvom mjestu (59,6%) pri čemu je njihova važnost 2013. godine u odnosu na 2005. godinu porasla 7,1% . Unutar elektroničkih kanala, putem Interneta odrađen je najveći iznos transakcija, 28,6% za građane i 37,5% za poslovne subjekte. Mobilnim telefonom zadano je svega 1,27% transakcija za građane i 0,1% za poslovne subjekte. Rast udjela broja transakcija 2016. godine u odnosu na 2005. godinu bio je 1,26% i -1,25%. Drugi najvažniji elektronički kanal komunikacije prema iznosu transakcija bio je POS uređaj, za građane 15,4%% i poslovne subjekte 1,08%, s rastom 2013. godine u odnosu na 2005. godinu 2,9% i 0,57%.

Tablica 16. Podaci o bezgotovinskim platnom prometu prema vrijednosti transakcija, 2005, 2013

	Potrošač	%	Nepotrošač	%	Ukupno	Pr%
Ukupno	**100,00**		100,00		100,00	
Obrasci - ukupno	**37,07**	**5,23**	**23,42**	**-12,90**	**24,26**	**-11,90**
Obrasci zaprimljeni u Banci	37,03	14,88	21,25	2,01	22,23	2,89
Obrasci zaprimljeni preko treće strane	0,04	-9,65	2,17	-14,91	2,04	-14,79
Elektronički	**45,49**	**15,37**	**60,55**	**7,28**	**59,61**	**7,13**
Internet	28,65	12,61	38,12	8,15	37,53	8,03
Telebanking	0,00	0,00	3,72	-1,25	3,48	-1,32
Mobilni telefon	1,27	1,26	0,03	0,03	0,10	0,10
fiksni telefon	0,10	-0,46	0,01	-0,03	0,02	-0,04
transakcijski bankomat	0,00	0,00	0,00	0,00	0,00	0,00
POS (EFTPOS)	15,42	2,09	0,13	0,07	1,08	0,57
ostalo	0,06	-0,13	18,54	0,32	17,39	-0,22
Na temelju zaprimljenih osnova	0,03	-7,80	1,47	0,80	1,38	0,47
Sudska rješenja	0,00	-0,25	0,00	-0,16	0,00	-0,16
Mjenice	0,00	0,00	1,47	1,05	1,37	0,97
Zadužnice	0,00	-0,03	0,00	-0,08	0,00	-0,08
Čekovi - ukupno	0,03	-7,51	0,00	0,00	0,00	-0,25
Na temelju ugovorne ovlasti	**17,35**	**-12,79**	**14,27**	**4,51**	**14,46**	**4,02**
Direktni debitni transfer	1,49	-2,10	9,07	6,59	8,60	6,08
Trajni nalog	13,70	-10,53	2,33	-0,69	3,03	-0,70
Ostale ugovorne ovlasti	2,17	-0,15	2,87	-1,38	2,83	-1,36
Nerazvrstane platne transakcije	0,05	-0,02	0,30	0,30	0,29	0,28
	32.464.413,3		**490.602.772,7**		**523.067.186,0**	

Iskazani su podaci o platnim transakcijama izvršenima na teret transakcijskih računa platnog prometa u bankama na temelju podnesenih naloga za bezgotovinsko plaćanje tijekom izvještajnog razdoblja. Platne transakcije su iskazane prema novčanoj vrijednosti te prema načinu zaprimanja naloga za plaćanje. Podaci se odnose na ukupnu vrijednost tih podataka tijekom izvještajnog razdoblja, pri čemu se u tu vrijednost uključuju prvi i posljednji dan izvještajnog razdoblja. Podaci o novčanoj vrijednosti iskazani su u kunama bez lipa.
Pr%-razlika između VI.2005 i VI.2013.
Izvor: HNB, 2017d

U nastavku može vidjeti analiza kartičnog plaćanja prema vrstama kartice i načinu izvršenja. Prema vrijednosti transakcija i vrsti kartice dominiraju debitne kartice, a prema načinu izvršenja bankomati (15.929.598t HRK), zatim POS uređaji (5.704.240t HRK), Internet (79.691t HRK) i mobilni Internet (764tHRK). Promatrajući debitna kartična plaćanja prema broju transakcija putem internetom učinjeno je 1,80% ukupnih transakcija preko bankomata i 1,37% ukupnih transakcija preko POS uređaja. Promatrajući debitna kartična plaćanja prema vrijednosti putem interneta učinjeno je 0,50% ukupnih transakcija preko bankomata i 1,39% ukupnih transakcija preko POS uređaja. Promatrajući debitna kartična plaćanja prema broju transakcija putem mobilnog interneta učinjeno je 0,04% ukupnih transakcija preko bankomata i 0,03% ukupnih transakcija preko POS uređaja. Promatrajući debitna kartična plaćanja prema vrijednosti putem mobilnog interneta učinjeno je 0,00% ukupnih transakcija preko bankomata i 0,01% ukupnih transakcija preko POS uređaja. Unutar transakcija kartičnog plaćanja putem Interneta prema

broju transakcija najzastupljenije su bile debitne kartice (420.920tHRK), a prema vrijednsoti kartice odgođenog plaćanja (81.799tHRK). Unutar transakcija kartičnog plaćanja putem mobilnog interneta prema broju transakcija i prema vrijednosti najzastupljenije su bile debitne kartice (10.035tHRK; 81.799tHRK). Ukoliko se promatra tip klijenta u poslovne svrhe najveći broj i vrijednost transakcija kartičnog plaćanja provedeni su putem POS uređaja (3.280.193tHRK; 1.358.026tHRK). Prema načinu izvršenja u opće svrhe najveći broj transakcija kartičnog plaćanja provedeni su putem POS uređaja (49.467.144tHRK), ali prema vrijednosti putem bankomata (15.938.655tHRK). Konačno, može se primijetiti kako prema broju i vrijednosti transakcija kartičnog plaćanja neovisno o načinu izvršenja udio Interneta i mobilnog bankarstva je relativno malen.

Tablica 17. Kartična plaćanja prema načinu izvršenja i prema vrstama kartice, IV. 2013.

	Bankomat		**POS**		**Internet**		**Mobilni**		**Ostalo**	
Tip kartice	BT	VT, t	BT	VT, t	BT	VT, t	BT	VT,t	BT	VT, t
Kreditne	77.782	61.478	476.007	121.113	35.452	8.623	0	0	4.259	7.715
Revolving	527.508	448.753	5.403.107	1.268.181	167.254	49.166	3.314	161	1.398.257	193.248
Odgođeno plaćanje	538.409	646.423	6.257.129	1.542.081	280.388	**81.799**	31	4	34.921	47.362
Charge	116.202	99.224	9.729.318	2.294.068	132.789	29.764	381	14	167.570	92.577
Debitne	**23.321.901**	**15.929.598**	**30.685.139**	**5.704.240**	**420.920**	79.691	**10.035**	**764**	**693.839**	**876.426**
Prepaid	26.658	11.456	146.078	28.215	94.201	14.576	0	0	7.829	2.466
Ostalo	24.701	10.900	50.559	14.230	6.160	1.069	0	0	6.624	5.634
Tip klijenta										
Opća	23.773.100	15.938.655	49.467.144	9.614.102	1.074.973	224.305	13.747	942	2.231.044	1.085.370
Poslovna	860.061	1.269.177	3.280.193	1.358.026	62.191	40.383	14	1	82.255	140.057
Ukupno	**24.633.161**	**17.207.832**	**52.747.337**	**10.972.128**	**1.137.164**	**264.689**	**13.761**	**943**	**2.313.299**	**1.225.427**

Kreditna kartica – upotreba kreditne kartice ne uvjetuje korisniku osigurano pokriće za izvršenje transakcije u trenutku njezina zadavanja. Troškovi stvoreni upotrebom kreditne kartice tijekom određenog razdoblja naplaćuju se naknadno, nakon određenog vremena. Za izvršenje plaćanja kreditnom karticom korisniku je odobren kredit. Korisnik kreditne kartice može izvršavati plaćanja (uključuje i podizanje gotovog novca pomoću kartice) do iznosa odobrenog kredita (limita). Iznos ukupnih troškova nastalih upotrebom kreditne kartice u određenom vremenskom razdoblju pri naplati se automatski dijeli na ugovoreni rok otplate i broj otplatnih rata. Korisnik po dospijeću svake otplatne rate plaća pripadajući dio ukupnih troškova. Za korišteni kredit korisnik plaća ugovorenu kamatu. U većini slučajeva korisnik kartice plaća i godišnju članarinu.

Revolving kartica – upotreba revolving kartice ne uvjetuje korisniku osigurano pokriće za izvršenje transakcije u trenutku njezina zadavanja. Troškovi stvoreni upotrebom revolving kartice tijekom određenog razdoblja naplaćuju se naknadno, nakon određenog vremena. Za izvršenje plaćanja revolving karticom korisniku je odobren kredit. Korisnik revolving kartice može izvršavati plaćanja (uključujući i podizanje gotovog novca pomoću kartice) do iznosa odobrenoga kredita (limita). Iznos ukupnih troškova nastalih upotrebom revolving kartice u određenom razdoblju korisnik može platiti u cijelosti do dana dospijeća plaćanja za učinjene troškove ili postupno, u ratama, prema ugovorenom modelu naplate. Za kredit korisnik plaća ugovorenu kamatu. U većini slučajeva korisnik kartice plaća i godišnju članarinu.

Kartica s odgođenom naplatom (engl. delayed debit card) – upotreba kartice s odgođenom naplatom ne uvjetuje korisniku osigurano pokriće za izvršenje transakcije u trenutku njezina zadavanja. Korisnik kartice može izvršavati plaćanja do iznosa određenog (ugovorenog) limita. Iznos ukupnih troškova stvorenih upotrebom kartice s odgođenom naplatom tijekom određenog razdoblja podmiruje se u cijelosti naknadno, na dan dospijeća plaćanja za ukupne troškove. Za nastale troškove korisnik ne plaća kamatu. Iznos ukupnih troškova naplaćuje se neposrednim terećenjem transakcijskog računa korisnika u Banci, na naloga za plaćanje podnesenog na teret tog računa od izdavatelja kartice s odgođenom naplatom. U većini slučajeva korisnik kartice s odgođenom naplatom plaća i godišnju članarinu (naknadu za korištenje).

Charge kartica – upotreba kartice s odgođenom naplatom ne uvjetuje korisniku osigurano pokriće za izvršenje transakcije u trenutku njezina zadavanja. Charge kartice izdaju nebankovne institucije koje omogućuju korisniku izvršenje plaćanja do iznosa određenog (ugovorenog) limita. Iznos ukupnih troškova stvorenih upotrebom charge kartice tijekom određenog razdoblja korisnik podmiruje u cijelosti naknadno, do dana dospijeća plaćanja za učinjene ukupne troškove. U većini slučajeva korisnik charge kartice plaća i godišnju članarinu.

Debitna kartica – upotreba debitne kartice uvjetuje korisniku osigurano pokriće za izvršenje transakcije u trenutku njezina zadavanja. Debitnu karticu izdaje banka koja omogućuje korisniku izvršenje plaćanja neposrednim terećenjem njegovog transakcijskog računa u banci. Korisnik debitne kartice može izvršavati plaćanja ili podizati gotov novac do visine pokrića na transakcijskom računu u Banci na teret kojega se izvršavaju plaćanja obavljena debitnom karticom. Pod pokrićem na transakcijskom računu u Banci podrazumijeva se i odobreno prekoračenje.

Prepaid kartica – upotreba prepaid kartice uvjetuje korisniku osigurano pokriće za izvršenje transakcije prije njezina zadavanja, pri čemu je osigurano pokriće visina novčanog iznosa koji je korisnik unaprijed uplatio izdavatelju kartice. Unaprijed uplaćena novčana vrijednost može biti pohranjena na samoj kartici (na čipu) ili može biti pohranjena (evidentirana) kod izdavatelja, npr. na njegovu posebnom računu vezanom uz pripadajuću karticu (nije transakcijski račun klijenta). Plaćanja prepaid karticom mogu se izvršavati do visine evidentirane novčane

vrijednosti kartice. Za svako izvršeno plaćanje umanjuje se evidentirana novčana vrijednost kartice, a korisnik može izvršavati daljnja plaćanja do iznosa preostale evidentirane novčane vrijednosti.
Opća – platne kartice koje su izdane na ime građana bez obzira na vrstu i korisničku funkciju kartice. U ovu kategoriju ubrajaju se sve platne kartice: osnovne, dodatne, studentske i sl.
Poslovna – platne kartice koje su izdane na ime poslovnih subjekata bez obzira na vrstu kartice ili njezinu korisničku funkciju. U ovu kategoriju ubrajaju se sve poslovne platne kartice, npr. company card, corporate card, business card i sl.
Izvor: autorica prema HNB, 2018

Na financijskom tržištu Republike Hrvatske u odnosu na tradicionalne kanale komunikacija mobilni uređaji trenutno čine relativno manje važan servis banke za građane i poslovne subjekte. Ako se pored udjela ugovorenih usluga uzme u obzir broj i vrijednost transkacija važnost mobilnog bankarstva još je manji. Obzirom na identificirane globalne trendove može se reći kako postoji značaj potencijal rasta važnosti mobilnih transakcija u Republici Hrvatskoj te kako će taj kanal komunikacije s bankom biti važan element stjecanja konkurentske prednosti na financijskom tržištu Republike Hrvatske.

4.2 Distribucija proizvoda i usluga putem mobilnog bankarstva

Prema financijskom izvještaju najveće banke u Republici Hrvatskoj napominje se da je modernizacija poslovanja banaka obilježena digitalizacijom, a za sve veći broj korisnika kao primarni kanal komunikacije za obavljanje platnog prometa koristi Internet i mobitel. Napominje se kako čak 93% građana svoje transakcija plaćanja provodi putem osobnog računala ili mobitela, a raste i udio drugih bankovnih proizvoda i usluga koje se obavljaju putem izravnih elektroničkih kanala komunikacije. Samo u Zagrebačkoj banci sklopljeno je skoro 800.000 ugovora elektroničkog Internet bankarstva te su za potrebe digitalnog poslovanja uložena značajna sredstava. Također, banka je podržala razvoj digitalizacije javnog sektora, a svojim klijentima omogućila je pristup portalu e-Građani.

Kao što je citirano u Kumar, Kumar i Shareef (2017) polazeći od tri pojavna oblika Internet bankarstva: web stranice, SMS-a i aplikacije na mobitelu analiza hrvatskog tržišta bankarske industrije nudi pregled funkcionalnosti jedne od najvažnijih inovacija bankarske industrije.

Druga najveća banka (prema udjelu aktive u kreditnim institucijama, vidjeti poglavlje 2.1.2), 2000. godine, prva je na tržištu Republike Hrvatske ponudila Internet bankarstvo. Četri godine kasnije ista je banka bila prva koja je ponudila rješenje za mobilno bankarstvo (u Hrvatskoj i regiji), a isto je prihvatilo 150 tisuća korisnika. Početkom 2018. godine banka je revidirala i unaprijedila svoju aplikaciju mobilnog bankarstva s nekoliko značajnih inovacija. Nova aplikacija omogućila je stvaranje dodane vrijednosti te intenzivniju interakciju s bankom. Brzi prikaz stanja (Fast balance) omogućio je korisnicima mobilnih uređaja (IOS i Android) te korisnicima Apple pametnog sata kontrolu stanja računa iako se ne nalaze unutar aplikacije. Nadalje, sofisticirani digitalni potpis sada supstituira osobni potpis te je moguće ugovoriti nove proizvode i usluge neovisno dolasku u poslovnicu. Funkcionalnost SAVE omogućava inovativan, impulzivan te interaktivan oblik virtualne štednje koji dodirom prsta može izvršiti male dnevne uplate. Također, uvodene su nove mogućnosti plaćanja unutar banke bez IBAN broja odnosno pri čemu je dovoljno da su primatelj nalazi unutar imenika klijenta te da je dio PAY zajednice, a između vlasničkih računa klijenta te između računa klijenta i računa opunomoćenika moguće je transferirati novac bez PIN-a (autorizacija je potrebna isključivo pri aktivaciji opcije). Opcija pouzdani primatelj omogućva brzo plaćanje bez provedbe autorizacije, a može se koristiti za članove obitelji, prijatelje i partnere. Dodatno, uplatnice bez 2D koda imaju mogućnost skeniranja i automatskog popunjavanja naloga putem kamere. Osim

navedenih noviteta unaprijeđena je funkcionalnost pregleda investicijskog portfelja te prodaja, kupnja i zamjene udjela u investicijskim fondovima kao i ilustrativni prikazi mjesečnih promjena vrijednosti udjela u fondovima za jednostavnije upravljanje ulaganjima klijenta. Također, omogućen je personaliziran prikaza ovisno učestalosti upotrebe pojednih opcija (PBZ, 2018a). Ulaganje u tehnologiju nije rezultiralo isključivo inovacijama u mobilnon bankarstvu, veće je banka bila poznata po svojim inovacijama ranije: mogućnost udaljnog upravljanja portfeljem Zagrebačke burze (2007. godine), beskontaktno plaćanje (uz pomoć Visa Inspire-a, Wave2PAY stickera ili mobitela), potpisne pločice (interaktivni uređaj za digitalni potpis dokumenata za jednostavnu i sigurnu autorizaciju potpisom ili PIN-om unutar poslovnice). Banka njeguje strategiju poticanja inovacije unutar poduzeća, a klijente potiče na usvajanje istih. U tu svrhu pokrenut je program pod nazivom inovacija za uštedu kojom banka svojim klijentima s više grupa proizvoda unutar banke ili povezanih društava, odobrava popuste za naknade i snižene kametne stope. Korištenjem nekoliko grupa proizvoda[38], cijene naknada po svakom proizvodu mogu se smanjitit do 30% (PBZ, 2018b).

Također, najveća banka na tržištu Republike Hrvatske među prvima je ponudila Internet bankarstvo 2007. godine. Iste godine, M-zaba, najveće banke kao oblik Internet bankarstva za građane imala je 2,5 tisuće korisnika. Tri odnosno četri godine kasnije, 2010. i 2011. godine banka je ponudila aplikacije za mobilne telefone (prvo IOS, a zatim i Androd sustave). Vrlo brzo nakon toga, 2014. godine putem mobilne aplikacije uvodi mogućnost plaćanja računa očitavanjem 2D koda, a 2016. godine mogućnost odobravanja gotovinskih kredita (vrijeme potrebno za sklapanje ugovora iznosilo je svega 10-tak minuta, a odobrenim sredstvima se moglo raspolagati trenutno). Krajem 2017. godine usluga mobilnog bankarstva najveće banke u RH brojila je 340.000 korisnika koji obavljaju 930.000 financijskih transakcija mjesečno te predstavlja najćešći kanal komunikacije s bankom, a stopa prihvaćanja usluge dosgenula je 80% ukupnog broja klijenata koji su isprobali uslugu. Također, neke od najnovijih inovacija unutar mobilnog bankarstva omogućile su otvaranje tekućeg računa i žiro računa bez odlaska u poslovnicu te uslugu m-novčanika koja omogućuje beskontaktno plaćanje mobitelom (ZABA, 2018a).

[38] Grupe proizvoda mogu biti: tekući račun u kunama i u stranoj valuti, žiro račun u kunama i stranoj valuti, poslovni račun, štedna knjižica/ Digitalno bankarstvo/ Revolving i shopping kartice (American Express, MasterCard i Visa Classic)/ Charge kartice (American Express, MasterCard i Visa Classic)/ Krediti/Oročena štednja/Stambena štednja u stambenoj štedionici/ Investicijski fondovi

Analizom tržišta bankarske industrije u Republici Hrvatskoj utvrđno je kako od ukupno 28 banaka od čega je tri u postupku stečaja (BSD, 2018a; Tesla banka, 2018a, Štedna Banka 2018) svih 25 banaka nudi neki oblik Internet bankarstva iako za 3 od 25 banaka nema opis funkcionalnosti konkretnog proizvoda. U Tablici 18 može se vidjeti lista funkcionalnosti koju su banke ponudile unutar svojih rješenja za Internet bankarstvo. *Provjera stanja i prometa na računima, karticama, štednjama i kreditima* predstavlja neizostavni dio ponude proizvoda svih banaka. Sljedeća najčešća funkcionalnost bila je *Transfer novca s računa na račun unutar Hrvatske* (95,2%: samo jedna banka nije ponudila tu funkcionalnost). *Provjera tečajne liste'*bila je moguća u 85,7% rješenja za Internet bankarstvo, dok su ostale funkcionalnosti redom prema učestalosti bile: *Kupoprodaja deviza* (71,4%), *M-foto/2D skeniranje koda računa* (66,7%), *Lokacijske usluge* (47,6%), *Kupovina bonova za mobitel* (28,6%), *Ugovaranje depozita* (19%) i *Financijski planer* (19%). Obzirom na njihovu učestalost sve ostale funkcionalnosti u tablici 18 mogu se smatrati svojevrsnim novitetima ili tržišnim profiliranjem. *Transfer novca na račune u inozemstvu* i *Upravljanje dnevnim limitima kartica* bilo je moguće u samo tri banke (14,3%). *Trgovanje udjelima u fondovima , HAC, Ugovaranje sastanaka* i *Plaćanje mobitelom na odabranim prodajnim mjestima* bilo je moguće u samo dvije banke *(9,5%). Otvaranje računa, Ugovaranje gotovinskog kredita, Trgovanje na svjetskim burzama, Obvezno autoosiguranje, Osiguranje imovine, Osiguranje od privatne odgovornosti, Putno osiguranje, Dopunsko zdravstveno, Upravljanje bodovima programa lojalnosti, Podizanje gotovine na bankomatu bez kartice, Deblokada PIN-ova, Aktivacija kartica, Promjena PIN-a za token i Kalkulator za izračun kredita i depozita* bili su moguće u samo po jednoj banci (ista banka ne uključuje sve navedene funkcionalnosti). Najveći broj funkcionalnosti Internet bankarstva (21) imala je najveća banka, pri čemu se ističu opcije: *Otvaranje računa, Ugovaranje gotovinskih kredita te ugovaranje različitih vrsta polica osiguranja: Obvezno autoosiguranje, Osiguranje imovine, Osiguranje od privatne odgovornosti, Putno osiguranje* i *Dopunsko zdravstveno,* dok je druga banka s najvećim brojem funkcionalnosti (13) bila sedma banka po veličini pri čemu se ističu opcije: *Nadoplata hrvatskih autocesta (dostupno još samo u najvećoj banci), Ugovaranje sastanaka (dostupno još samo u jednoj banci: rang veličine aktive 18), Podizanje gotovine na bankomatu bez kartice* (pored korištenja mobitela na prodajnim lokacijama fizičkih trgovaca, podizanje gotovine na bankomatu bez kartice također pripada u skup inovacija u svrhu stvaranja digitalnog novčanika*), Deblokada PIN-ova i Aktivacija kartica.* Treća banka s najvećim brojem funkcionalnosti mobilnog bankarstva (10) bila je druga najveća banka.

Na temelju navedenog može se vidjeti kako distribucijski kanal mobilnog bankarstva omogućuje pristup gotovo svim proizvodima i uslugama koje klijent može koristiti odlaskom u poslovnicu. Iako fizički kontakt s predstavnikom banke u poslovnici ima dimenziju usluge koje se teško u potpunosti može simulirati putem mobilnog bankarstva (ljudski faktor kao socio-psihološki element), komunikacija putem Internet ima svoje prednosti u odnosu na tradicionalno bankarstvo (nije potrebno doći na fizičku lokaciju, nema čekanja, privatnost, nemogućnost pogreške kao rezultat ljudskog faktora i sl.). U početku mobilnog bankarstva značajan nedostatak komunikacije putem Internet bilo je upravo financijsko savjetovanje klijenta odnosno pretpostavljalo se da klijent zna što mu trebi i što želi iako to ne mora biti tako. Kako bi banke putem mobilnog bankarstva kompenzirale efekt financijskog savjetovanja na fizičkoj lokaciji banke u kontaku s predstavnikom, neke su banke ponudile različite funkcionalnosti unutar programskih rješenja gdje klijent korištenjem kalkulatora za izračun kredita i depozita te financijski planer može gotovo samostalno upravljati osobnim financijama nevisno osnovnom obrazovanju i struci. Osim široke lepeze uobičajenih financijskih usluga te inovativnih rješenja automatizacije, autorizacije i pogodnosti pružanja istih, mobilno bankarstvo postaje kanal komunikacije za efikasno pružanje različitih komplementarnih proizvod i usluga. Koristeći svoju reputaciju i kredibilitet banka putem mobilnog bankarstva može ponuditi različlite police osiguranja (obvezno autoosiguranje, osiguranje imovine, osiguranje od privatne odgovornosti, putno osiguranje, dopunsko zdravstveno) odnosno putem već postojeće infrastrukure, pri čemu jedinični trošak transakcije ostaje zanemariv, direktno pristupa velikom broju klijenata[39]. Obzirom kako je tržište osiguranja u Republici Hrvatskoj vrlo dinamično, plasman te vrste proizvoda i usluga može biti probitačan za sve sudionike: osiguravajuće društvo, banku i klijenta. Uvođenjem reputacije banaka na tržište osiguranja klijent može efikasnije upravljati svojim portefljem polica osiguranja. Nije potrebno održavati samostalnu mrežu posrednika između osiguravajućeg društva i klijenata već infrastruktura banke omogućavaju jednostavno ugovaranje polica osiguranja pri čemu reputacija banke garantira poštivanje prava i obveza koje iz njih proizlaze. Iako se prikupljanje depozita i odoboravanje kredita smatra osnovnom poslovnom aktivnosti banaka zbog složenosti procesa isto je rijetko ili nikako integrirano u mobilno bankarstvo banaka Republike Hrvatske. Samo 4/28 (14,2%) banaka putem mobilnog bankarstva nudi opciju ugovaranja depoziata, a samo

[39] od ukupno 28 banaka u RH samo najveća banka (prema udjelu aktive) putem mobilnog bankarstva distribuira proizvode osiguranja

1/28 (3,57%) banaka ima mogućnost odobravanja gotovinskog kredita. Gotovinski krediti putem mobilnog bankarstva podrazumijevaju realizaciju manjih iznosa novca bez javnog bilježnika, donošenja i ovjere dokumentacije u poslovnicu koji banka može odobriti putem mobilnog bankarstva u svega nekoliko minuta. Prema regulativi Europske unije i Republike Hrvatske za autorizaciju kredita bez odlaska u poslovnicu koristi se napredni elektronički potpis jednake pravne snage vlastoručnog (ZABA, 2018b). Obzirom na elektronički potpis moguće je putem mobilnog bankarstva odobriti gotovinski kredita manjeg iznosa, ali hipotekarni ili investicijski kredit nije moguće realizirati putem mobilnog bankarstva niti jedne Hrvatske banke. Naime, iako mobilno bankarstvo podrazumijevajući visok stupnj pogodnosti s pristupom velikom broju opcija trenutno nudi mogućnost upravljanja gotovo svim aspektima financija klijenta, mobilno bankarstvo na tržištu banaka Republike Hrvatske nije bez ograničenja i još uvijek ne predstavlja potpuni ekvivalent tradicionalnog bankarstva.

Tablica 18. Popis funkcionalnosti mobilnog bankrstva banakrskog tržišta u Republici Hrvatskoj

Popis funkcionalnosti mobilnog bankrstva	*Udio banaka*
Provjera stanja i prometa računa, kartica, štednje i kredita	100
Transfer novca na račune u Hrvatskoj	95,2
Tečajna lista	85,7
Kupoprodaja deviza	71,4
M-foto/2D skeniranje koda računa	66,7
Lokacijske usluge	47,6
Bonovi za mobitel	28,6
Ugovaranje depozita	19,0
Financijski planer	19,0
Transfer novca na račune u inozemstvu	14,3
Upravljanje dnevnim limitima kartica	14,3
Trgovanje udjelima u fondovima	9,5
Hrvatske autoceste	9,5
Ugovaranje sastanaka	9,5
Plaćanje mobitelom na odabranim prodajnim mjestima	9,5
Otvaranje računa	4,8
Ugovoranje gotovinskog kredita	4,8
Trgovanje na svjetskim burzama	4,8
Obvezno autoosiguranje	4,8
Osiguranje imovine	4,8
Osiguranje od privatne odgovornosti	4,8
Putno osiguranje	4,8
Dopunsko zdravstveno	4,8
Upravljanje bodovima programa lojalnosti	4,8
Podizanje gotovine na bankomatu bez kartice	4,8
Deblokada PIN-ova	4,8
Aktivacija kartica	4,8
Promjena PIN-a za token	4,8
Kalkulator za izračun kredita i depozita	4,8

Izvor: obrada autorice prema dostupnim podatcima JABA, 2018; KABA, 2018; KBZ, 2018a; KBZ, 2018b; PABA, 2018; POBA, 2018; J&T banka, 2018; Kentbanka, 2018; BKS, 2018; PBZ, 2018c; Addiko, 2018; Croatia, 2018; Erste bank, 2018; HPB, 2018; Imex, 2018; OTP, 2018; Primorska banka, 2018; RBA, 2018; Sberbanka, 2018b; SLB, 2018; STB, 2018; ZABA, 2018c; Veneto, 2018; Kovanica, 2018; BSD, 2018b; Tesla banka, 2018b; SABA, 2018

Iako na bankarskom tržištu Republike Hrvatske odobravanje hipotekarnih ili investicijskih kredita putem mobilnog bankarstva nije moguće (tradicionalne banke na odobravanje hipotekarnih i investicijskih resursa troše 21% ukupnih resursa), neki sustavi mobilnog bankarstva digitalnih banaka temeljito prate svoje klijente (financijske tokove, sklapanje ugovora, podaci državnih agencija, knjigovodstvena dokumentacija), a putem istih moguće je odobravati hipotekarne ili investicijske kredite. Putem mobilnog bankarstva pojedine banke

omogućavaju ugovaranje predodobrenih nenamjenskih kredita koje su klijentu dostupni u nekoliko klikova tj. sekundi. Za razliku od tradicionalnih banaka gdje je za postavljanje investicijskog zajma potrebno 22 sata i 10 sati za hipotekarani kredit, za iste proizvode putem mobilnog bankarstvo potrebno je 6 i 3 sata. Mobilno bankarstvo nastoji postići maskimalno transparentan proces, a klijent ima garanciju kako će zahtjev biti procesuiran u zadanom roku i u relanom vremenu pratiti procesa. Obzirom na prirodu složenosti procesa odnosno kako bi se odobravanje kredita u odnosu na tradicionalno bankarstvo ubrzalo banke su morale napustiti obradu dijela dokumentacije odnosno zahtjeve rješavati isključivo neophodnu dokumentaciju. Istovremeno se smanjuje potreba za ljudskim resursima u procesu odobravanja kredita, a isti se može preusmjeriti na unaprjeđenje kvalitete odlučivanja. Također, putem mobilnog bankarstva klijent može samostalno upravljati životnim ciklusom kredita (zahtjevi povezani s jamstvom, ispis tablice amortizacije kredita). Slično kao što banka ažurno odrađuje svoj dio obveza prema klijentu, također se putem obavijesti mobilnog bankarstva može podsjetiti klijenta na dospijeće njegovih obveza (EFMA, 2017b).

Može se očekivati kako će digitalizacija redefinirati lepezu ponude tradicionalnih banaka. Nudeći financijske proizvode i usluge nije neočekivano kako će banke putem svojih portala ponuditi usluge drugih komplementarnih pružatelja koji se nalaze izvan domene financijskog tržišta (smještaj, putovanja, elektronička trgovina). Otvoreni API sustavi omogućvaju stvaranje čitavih ekosusutava koji će integrirati i ostale financijske ili nefinancijske proizvode i usluge drugih organizacija kako bi povećali kvalitetu iskustva korisnika koji sada više ne mora napuštati sučelje banke kako bi zadovoljio svoje potrebe. Također, i banka će imati koristi od ostvarenja dodatnih prihoda. Održivost koncepta već je potvrđena u okviru nefinancijskih ekosustava. Primjerice, digitalni sustavi kao što je kineski Tencent WeChat dizajniran je prvenstveno kao aplikacija za dopisivanje koja sada broji 700 milijuna korisnika. Naime, osim dopisivanja sada je putem iste aplikacije moguće izvršiti plaćanje, kupiti ulaznice i naručiti prijevoz, a od 700 milijuna korisnika čak 1/3 koristi uslugu plaćanja. Iako je ciljano tržište aplikacije bila prvenstveno Kina, već sada postoji aplikacija za Europu WeChat pay koja treba opsluživati kineske turise u regiji. Također, jedan od važnih ekosustava pandan američkom Amazonu poznat je pod nazivom Alibaba koji broji 500 milijuna korisnika. Prvenstveno je dizajniran za potrebe distribucije, ali sada nudi usluge plaćanja, drugih financijskih proizvoda i turističkih putovanja (EFMA, 2017d).

4.3 Upravljanje odnosima s klijentima kroz mobilno bankarstvo

S fokusom na potpuno bankarstvo i elektroničke transakcije preko Interneta mijenja se struktura poslovnih aktivnosti banaka. Banke koriste tehnološke promjene da privuku nove klijente i zadrže postojeće, a neki sudionici koriste tehnologiju upravo da zaobiđu barijere ulaska u industriju. Iako je tehnologija značajno unaprijedila kvalitetu usluga, menadžeri su suočeni izazovima u odabiru klijenata, opetovanim prilagodbama regulativi i namjeri da se neprimjetno integriraju u neprekidno globalno poslovanje (Parameswar, Dhir, Dhir, 2017).

Suvereni sustav upravljanja odnosima s klijentima podrazumijevaju IT infrastrukturu odnosno informacije na osnovi kojih se mogu kreirati primjereni proizvodi i usluge za pojedine klijente, njihova cijena, oblik i vrijeme komunikacije istih od banke prema klijentima. Također, elektroničke platforme nisu više isključivo pružatelji i sakupljači informacija nego djeluju kao instrumenti sklapanja ugovora (Kunac, 2012).

Mobilno bankarstvo ima sposobnost osigurati gotovo neograničenu dostupnost i reaktivnost banke ne velik broj zahtjeva klijenata svakodnevno i cjelodnevno. Osiguravajući navedene performanse raste operativna efikasnost, zadovoljstvo klijenata te se iskorištavaju komercijalne prilike za banke. Prilikom upravljanja odnosima s klijentima javljaju se brojni izazovi, ali dosadašnja iskustva banaka su pokazala kako samo 20% zahtjeva nadilazi osnovne operacije banke (provedba plaćanja, objašnjenje transakcija, tehnički problemi (zaboravljena lozinka, nemogućnost pristupa servisu i sl.) zahtjevi za podacima banke, policama osiguranja, opće informacije o proizvodima i uslugama). Mobilno bankarstvo omogućuje klijentima da samostalno rješavaju većinu svojih potreba te nudi dodatne mogućnosti koje nisu dostupne u okviru tradicionalnog bankarstva: modifikacija limita potrošnje, privremenu blokadu računa zametnutih kartica ili ugovaranje proizvoda na zahtjev putem mobilnog uređaja. Rast broja usluga i proizvoda koje su dostupne klijentu putem mobilnog bankarstva zahtjeva mogućnost diferencirane ponude ovisno potrebema i rizicima koji se mogu povezati s klijentom. Naime, sustav vrednovanja koji ocjenjuje klijenta obzirom na tek započet odnos s bankom ili dosadašnje ponašanje može povećati ili ograničiti broj usluga koji mu je dostupan. Iako klijent može gotovo potpuno autonomno upravljati svojim financijama, ukoliko želi, savjetodavni agent mu je kontinuirano dostupan. Direktna komunukacija s agentom najčešće se povezuje s prigovorima koji zahtjevaju rezoluciju banke bez identifikacije krivca, zahtjevima pri čemu ljudski faktor stvara dodanu vrijednost komercijalnog utjecaja, zahtjevima visokog rizika

(hipotekarni poslovi) i situacije gdje sustav umjetne inteligencije ocjenjuje kako je nastala visoka razina stresa za klijenta. Uz pomoć AI-a klijentima se nudi paleta proizvoda i usluga i cijene koje su usklađene s njihovim karakteristikama. Zahvaljujuči digitalizaciji komunikacije klijent može ostvariti interakciju sa sustavima umjetne inteligencije (AI). Sustavi umjetne inteligencije (AI) koriste NLP i NLG, a putem sinhronizirane pisane komunikacije mogu rješavati opće i specifične zahtjeve klijenata. Nastavno razumijevanju i generiranju prirodnog jezika odnosno upita klijenta, praćenjem lokacije i podataka baze za upravljenje odnosima s klijentima (dob, prihod, status vlasništva nekretnine i njezine lokacije), AI može dinamički generirati i ažurirati sadržaj specifičan potrebama klijenata (FAQ lista, promotivne poruke) (EFMA, 2017b). Primjerice, Intese Sanpaolo, lansirala je inovativan sustav upravljanja odnosima s klijentima. U centru sustava nalazi se klijent, a sustav je baziran na RTDM[40] infrastrukturi. Infrastruktura omogućuje interakciju svih komunikacijskih kanala u realnom vremenu uključujuči aplikacije trećih strana prema banci. Sustav je povećao efikasnost komercijalnih projekata (2017. godine rast prodaje za 12 milijuna eura i 5 milijuna eura smanjenih troškova) i zadovoljstvo korisnika pravovremenom i personaliziranom ponudom. Čak i kada se komunikacija između klijenta i banke događa uživo, prethodno sastanku zaposlenik već ima informaciju koje su eventualne potrebe klijenta. Također, bolje poznavanja klijenta smanjuje broj upita odnosno zahtjeva prema korisničkoj podršci. Komercijalne poruke rezultat su ponašanja klijenata povezane s njegovim interesima, strukturom imovine i proizvodima koje klijent ima ili koristi u banci te ključnim trenucima u životu (kupnja nekretnine, svadba, rođenje djeteta, novo radno mjesto, obljetnice i sl.) Također, važno je napomenuti kako s reakcijama korisnika sustav s vremenom evoluira i povećava efikasnost bančinog sustava upravljanja s klijentima (Intesa Sanpaolo, 2017).

Iako su neke organizacije iskoristile digitalne tehnologije da prošire svoju ponudu odnosno unaprijede distribucijske kanale, organizacijska kultura i modeli pristupa klijentima dugo zadržavaju tradicionalne strukture. U skladu s prethodno rečenim Delloite prilikom analize financijskog sektora 2016. godine napominje kako postoje dva osnovna modela provedbe digitalizacije. Prvi pristup podrazumijeva digitalizaciju poslovanja, a drugi stvaranje digitalnog poduzeća. Može se primijetiti kako postoji zajednički nazivnik oba pristupa. S jedne strane, iskustvo klijenta predstavlja važnu odrednicu oba pristupa, a uvođenje digitalne tehnologije u

[40] akronim od engl. Real Time Data Monitoring

svrhu povećanja kvalitete sastavni dio obje strategije, dok s druge strane postoje odrednice koje su oprečne, a ističe se sklonost organizacije riziku. Digitalne organizacije u odnosu na tradicionalne nastupaju agresivnije što je često popraćeno s problemima, ali i brzim učenjem.

Tablica 19. Nasljeđe organizacijske strukture organizacija financijskog sektora i digitalizacija poduzeća

Odrednice kulture	*Digitalizacija poslovanja*	*Digitalno poduzeće*
Prilagodba na promjene u okruženje	**Uvođenje inovacije, ali manjom dinamikom**	**Poduzetnost**
	Dugotrajan opstanak	Kontinuirana disrupcija ekosustava
	Orijentacija na inovacije	Nejednakost dinamike digitalizacije i poslovanja
	Tehnološka promjena se prihvaća sa zadrškom	Opetovana prilagodba
		Fleksibilnost talenta
		Niska robusnost, brzo učenje
		Promjena prirode poslovanja i topologije rada
		Suradnja
Radno okruženje	**Strukturirano**	Dijeljenje informacija
	Geografska zavisnost	Geografska nezavisnost
	Precizno definirane potrebne uloge i vještine	Isprepletene strukture timova
	Unaprijed definirane operacije	Orijentiranost prema suradnji
	Unaprijed definirani timovi	Potreba za dinimičkim razvojem vještina
		Distribucija ovlasti
Organizacijska struktura	**Hijerarhija**	Dinamika kombinacije tradicionalnih i netradicionalnih interesnih skupina
	Odlučivanje je direktno povezano s pozicijom, neovisno vještinama odnosno izvrsnošću	Dinamika u snazi i pravima odlučivanja
	Visoka razina hijerarhije	Horizontalna i dinamična hijerarhija
Sklonost prema riziku	**Opreznost**	**Istraživački pristup**
	Sklonost prema riziku determinirana je regulacijom	Moduliranje granica sigurnosti i rizika
	Ustanovljene opearcije razdvajaju manje i više rizične poslove	
Iskustvo klijenata	**Orijentiranost na klijenta**	**Klijent kao okosnica poslovanja**
	Analitika za potrebe predviđanja potreba korisnika	Odgovor na zahtjeve klijenta u realnom vremenu
	Poček u vremenu zaprimanja povratnih informacija klijenta i reakcije poduzeća	Veća uključenost klijenta
	Praćenja povratnih informacija od klijenata	

Izvor: autorica prema Andrus, Kejriwal, Wadhwani, 2016

Digitalno poduzeće može se opisati uz pomoć osam osnovnih karakteristika:

1. Poduzetnost (fleksibilnost koja omogućava prilagodbu disruptivnim tehnologijama stvarajući okolnosti koje podrazumijevaju novo radno okruženje odnosno redefiniran pristup obavljanju posla i zadržavanje zaposlenika),

2. Opetovana prilagodba: (kontinuirano prikupljanje i analiza povratnih informacija od strane klijenata te njihovu inkorporaciju u ponudu poduzeća),
3. Brzi plasman inovativnih proizvoda, brza povratna sprega i brzo učenje (inovativni proizvodi postaju dio ponude uz minimlana testiranja),
4. Fleksibilnost talenata (realokacija talenata obzirom na dinamične potrebe),
5. Kontinuirana inovacija (kontinuirano propitivanje postojećeg stanja, proizvod i usulga),
6. Suradnja i dijeljenje infromacija (virtualna i fizička suradnja unutar promijenjivih timova u svrhu postizanja zajedničkih ciljeva),
7. Dinamička distribucija ovlasti (horizontalne strukture koje uključuju veći dio interesnih skupina) i
8. Sklonost riziku (svjesno preuzimanje rizika koji se mogu povezati sa zaštitom osobnih podataka i cyber-napadima).

Gotovo idealan primjer transformacije u digitalno poduzeće bankarske industrije predstavlja BBVA (Banca Online de BBVA). Ne samo da je banka unaprijedila iskustvo klijenata nudeći najnovije digitalne proizvode uloženi su značajni napori u transformaciju k spomenutim karakteristikama digitalnog poduzeća. U periodu 2006.-2013. investicije u tehnološku infrastrukturu su udvostručene i dosegnule ukupno €2,4 milijarde pri čemu je standard industrije (20%) više nego dvostruko nadmašen. U okviru DBA (Digital Banking Area) stvorena je nezavisna 100% digitalna jedinica banke koja ima zadaću transformirati organizacijsku kulturu grupe. Do 2015. započeto je više od 50 inovativnih projekata koji uključuju skoro 500 zaposlenika. Kako bi se ubrzala transformacija, imenovani su i novi članovi visokih upravljačkih struktura. Naglasak je stavljen na informacijsko vođeno poslovno odlučivanje u svrhu stvaranja dodane vrijednosti za klijente, a banka je zauzela vodeću poziciju unutar rastuće konkurencije tehnoloških konkurenata financijskog sektora.

4.4 Model mjerenja kvalitete mobilnog bankarstva

Mobilno bankarstvo kao i svaka usluga osnažena IT tehnologijom ima svoje rizike: menadžerske, tehnološke i bihevioralne. Rizici se mogu povezati s klijentima kao korisnicima, programskim rješenjima, mobilnim uređajem, bankom ili pružateljem usluga. Uzrok može biti nedostatka integriteta izvora komunikacije, manjak povjerenja između banke i klijenata (u kontekstu privatnosti), neadekvatna autentifikacija i nedostupnost u smislu prekida tijekom komunikacije unutar mreže. Razmjena informacija putem globalnog sustava za mobilne komunikacije (GSM-a) i mobilne mreže tada je ili kompromitirana ili njezina sigurnost nije adekvatno potvrđena (Kumar, Kumar, Shareef, 2017).

Sigurnost usluge mobilnog bankarstva je od ključne važnosti za korisnike, a tehnike koje danas ugrožavaju sigurnost mobilnog bankarstva bile su u povijesti usmjerene na osobna računala. Neki od najčešćih problema vezanih uz povredu sigurnosti su problemi povezani s gubitkom i krađom uređaja te s napadom zlonamjernih programa unutar uređaja ili aplikacije.

Zbog reputacije, banke ulažu velike napore u očuvanju sigurnosti svojih sustava te ulažu u razvoj sigurnosnih sustava najnovije tehnologije. Edukacija korisnika, automatizacija i pravni okvir mogu smanjiti vjerojatnost zloupotrebe, ali ga ne mogu u potpunosti eliminirati. Klijent svoju percepciju sigurnosti povezuje i s percepcijom privatnosti te želi biti uvjeren kako postoji sigurnost osjetljivih informacija.

Jednostavnost korištenja servisa koji upravljaju financijama je od ključne važnosti u procesu definiranja mobilnog bankarstva. U tu svrhu koriste povratne informacije klijenata u cilju povećavanja jednostavnosti korištenja usluge i zadovoljstva klijenta. Maksimiziranjem interaktivnosti i postizanjem jednostavnosti navigacije želi se vrijeme i trud za upravljanje financijama svesti na minimum. Korisnička podrška može poslužiti kao podrška i imati edukacijski element za klijente.

Na dostupnost usluge mobilnog bankarstva utječe od isporuke električne energije, pokrivenosti mobilne mreže, nedostupnosti širokopojasne komunikacije do visoke cijene Internet usluga.

Osim dostupnosti financijskih usluga, važna karakteristika usvajanja mobilnog bankarstva je dostupnost sustava podrške.

4.4.1 Sigurnost usluge

Popularizacija upotrebe mobilnih uređaja za pregled Internetskih stranica i mobilnih plaćanja rezultira sve većim brojem hakerskih napada. Svake godine incidenti koji su povezani sa sve sofisticiranijim napadima stvaraju visoke troškove u poslovanju kreditnih institucija (EFMA, 2017c).

Regulacija na temelju koje se derivira sigurnost mobilnog bankarstva rezultat je Zakona o kreditnim institucijama, Zakona o platnom prometu, Zakona o elektroničkom potpisu, Zakona o elektroničkoj trgovini, Zakona o elektroničkoj ispravi, Zakona o zaštiti osobnih podataka i svih drugih Uredaba, propisa i odluka koje iz njih proizlaze. Također, Hrvatska narodna banka prilikom nadzora i kontrole daje naputke i smjernice kako bi povećala sigurnost elektroničkog poslovanja banke.

Istraživanje provedeno u Republici Hrvatskoj navodi kako je sigurnost i percepcija sigurnosti primarni nedostatak Internet bankarstva. Razina znanja klijenata o tehnologijama koje se koriste u Internet bankarstvu nije adekvatna te u strahu od otuđenja imovine i osjetljivih informacija klijenti često ne žele koristiti navedeni oblik komunikacije s bankom (Milanović Glavan, Ćibarić, 2015). Dostupnost financija putem mobilnih uređaja istovremeno predstavlja visoku razinu pogodnosti, ali i rizik. Zbog svoje široke upototrebe pametni telefoni su česta meta hakera. Svaki od pametnih telefona koji se koristi mobilnim bankarstvom predstavlja ulaz u informacijsku mrežu banke. Unatoč promjenama tehnologije metode detekcije zloupotrebe i dalje se mogu povezati s istim aktivnostima: instalacija zlonamjernog programa koji prikuplja korisnička imena i lozinke korisnika, prikupljanje podataka za potrebe autentifikacije putem elektroničkih poruka maskiranih kao da dolaze od strane prušatelja usluga, identifikacija korisnika i lozinke uz pomoć presretanja nesigurne veze na lokacijama javne bežične mreže (EFMA, 2017c). Kada važne i povjerljive informacije napuštajući banku prolaze kroz otvorenu mobilnu mrežu sigurnost usluge mobilnog bankarstva postaje primarni rizik za klijenta. Paik (2010) je istraživao upravo aspekte tehničke sigurnosti mobilnog bankarstva i napominje kako se prijetnje sigurnosti mobilne komunikacije mogu povezati s ranjivošću protokola (zadrška ili ponavljanje), presretanja komunikacije unutar nezaštićene mobilne mreže ili dupliciranja SIM kartice zbog nedostatka enkripcije.

Neki od alata i tehnika koji su danas prijetnja sigurnosti mobilnog bankarstva u početku su bili usmjereni na osobna računala, ali su kasnije modicirani i specijalizirani upravo za mobilno

bankarstvo. Iako je načelno teže hakirati mobitele nego osobna računala (McGarvey, 2012), u svakom trenutku zlonamjernim programima zaraženo je 11 milijuna mobilnih uređaja (Multz, 2014), a njih 60% usmjereno je upravo na aplikacije mobilnog bankarstva (Urrico, 2015; Valcke, 2016). Mobilni telefoni opremeljeni su nekim funkcionalnostima koje još uvijek nisu prisutne kod osobnih računala. Primjerice putem aplikacije i online računa vlasnika postoji mogućnost brisanja svih podataka koji se nalaze na uređaju, a prijava je moguća putem bilo kojeg web preglednika. Važno je napomenuti kako su bez otvaranja operativnog sustava mobilnog uređaja opcije hakera ograničene. Kreditne institucije i banke ulažu velike napore kako bi unaprijedili sigurnosne performanse aplikacija mobilnog bankarstva. Istovremeno banke pokušavaju educirati klijente koji svojim ponašanjem mogu značajno pridonositi izloženosti rizicima mobilnog bankarstva. Neotvaranje operativnog sustava, instalacija sigurnosnih zaštitnih programa te izbjegavanje javnih mreža za slanje osjetljivih informacija može smanjiti vjerojatnost hakiranja. Neki korisnici otključavaju svoje mobilne telefone kako bi pristupali besplatnim aplikacijama izvan originalne Google Play ili iStore trgovine. Naime, iako 78% klijenata nije preuzimalo aplikacije nepoznatih izvora, 76% nije koristilo javne WiFi mreže za slanje osjetljivih informacija, Robert McGarvey napominje kako zbog nedostatka kvalitete samih aplikacija banaka ipak postoji rizik. Uz pomoć specijaliziranog privatnog poduzeća provedena je analiza razine sigurnosti postojećih aplikacija mobilnog bankarstva. Uzorak se sastojao od deset aplikacija kreditnih institucija različitih veličina, dok su rezultati pokazali kako 80% aplikacija ima neki oblik sigurnosnog propusta, a najveći broj sigurnosnih propusta imale su aplikacije kreditnih unija. Ako je aplikacija za mobilno bankarstvo ili web stranica nesigurna potencijalni napadači imaju mogućnost pristupiti podacima kreditnih institucija. Najčešći operativni sustavi za mobilne uređaje, Android i iOS podržavaju specijalizirane protokole aplikacija za mobilno bankarstvo kojima klijenti pristupaju svojim bankovnim računima, ali iako neke aplikacije za prijenos informacija putem Interneta koriste SSL[41] protokole još uvijek preko 90% aplikacija inicira nezaštićene veze, a isto ih čini izloženim sigurnosnim rizicima prilikom prijave. Iako je rizik inherentan u oba operativna sustava, Ballasy (2014) naglašava da je 2014. godine 99% mobilnih zlonamjernih programa bilo usmjereno upravo na Android operativne sustave. Iako je većina napada trenutno usmjerena na Android uređaje to ne implicira da su korisnici iOS uređaja zaštićeni (Roniet, 2017). Iako rizici postoje, istraživanje percepcije o sigurnosti mobilnog bankarstva pokazalo je

[41] akronim od engl. Secure Socket Layer

da klijenti smatraju da su banke učinile dovoljno da ih zaštite od rizika mobilnog bankarstva, a isto smatraju sigurnijim od upotrebe osobnog računala iako ne znaju što banke zapravo rade (Crosman, 2014).

Najčešće povrede sigurnosti koje su dosad identificirane mogu se podijeliti odnosno klasificirati u tri skupine:

1. sigurnosni problemi koji se mogu povezati s gubitkom ili krađom uređaja,
2. sigurnosni problemi povezani s napadom zlonamjernih programa unutar uređaja ili aplikacije i
3. sigurnosne probleme koji uključuju oboje: krađu i zlonamjerne programe.

Obzirom da više od polovice korisnika mobilnih uređaja ne koristi niti najjednostavniji oblik zaštite uređaja od zloupotrebe prilikom otuđenja (lozinku za otključavanje tipkovnice) napadači relativno jednostavno mogu zadobiti pristup uređaju (Stiakakis, Georgiadis, Andronoudi, 2016). Nadalje, zlonamjerni programi mogu biti integrirani u naizgled korisnu ili krivotvorenu aplikaciju/ datoteku (preuzetu ili poslanu putem Interneta ili QR koda), a u trenutku instalacije traže manjak sigurnosti ili uzrokuju neželjeno ponašanje. Pokazalo se kako 98% aplikacija nema sustav protumjera kako bi se izbjegao problem krivotovorenja (pomoću lako dostupnih alata s Interneta moguće je provesti obrnuti inženjering te stvoriti kopiju aplikacije), a preko polovice aplikacija izloženo je JavaScript injekcijama. Zlonamjerni programi najčešće se povezuju s neovlaštenim provođenjem financijskih transakcija, traženjem otkupnine za otključavanje mobilnog uređaja, uspostavljanje poziva i slanja neuobičajeno skupih SMS/MMS poruka (ukoliko postoji ugovorena pretplata ili unaprijed uplaćena sredstava na računu korisnik će snositi nastale troškove) i otuđenjem osjetljivih informacija (elektroničke poruke, imenik, privatnu ili poslovnu dokmentaciju) (Stiakakis, Georgiadis, Andronoudi, 2016; Roniet, 2017). Kako bi osigurali pristup financijskim transakcijama, Robin Sidel napominje da hakeri pretraživajući Internet odnosno preuzimajući aplikacije s web stranica najvećih financijskih institucija mogu imitirati prijavne prozore za autentifikaciju i prevarom priskrbiti lozinke korisnika mobilnog bankarstva (Sidel, 2016).

Kao rezultat rastuće dostupnosti usluga, raste i rizik zloupotrebe (Dini i sur., 2014), od čega je 17% incidenata bilo korporativnog karaktera (Roniet, 2017), poduzeća ulažu velike napore u kupovinu i razvoj sustava najnovije i najsigurnije tehnologije (Kunac, 2012). Primjerice, prema regulaciji središnje banke SAD-a, ukoliko se dogodio incident unutar domene elektroničkog

transfera novca koji nije moguće povratiti, klijenti koji isto prijave u roku dva dana snose trošak samo do protuvrijednosti od svega nekoliko stotina kuna (50$) (The Federal Reserve, 2017).

Nadalje, ponašanje korisnika također predstavlja važan preduvjet cjelovitosti sustava sigurnosti. Neovisno intenzitetu ulaganja u mehanizme zaštite i posljedično sofisticiranosti isti mogu biti djelotvorni samo ako su ispravo korišteni. Snažna kriptografija, dokazano ispravni protokoli i nepostojanje grešaka kodiranja neće imati svoju funkciju ako u trenutku potrebe za privatnošću ostanu isključeni od strane korisnika, korisnik odustane od komunikacijskih protokola kada nije siguran koje ključeve koristiti ili zabunom konfigurira pristupne kontrole koje će privatne poruke učiniti dostupne svima. Obzirom kako sve veći broj korisnika često ograničenog ili nikakvog znanja o sigurnosnim mehanizmima koristi računalne resurse spomenuto ostaje problem dizajniranja sučelja. Edukacija korisnika, automatizacija i pravni okvir mogu smanjiti vjerojatnost zloupotrebe, ali ne ga i u potpunosti eliminirati. Pojedinačni korisnici ne moraju nužno imati resurse da pravnim putem rješavaju problem napadača ili mogu u potpunosti biti nesvjesni da se napad dogodio. Kako bi smanjili sigurnosne rizike neke od najvećih banaka (Bank of America i Wells Fargo) nastoje povećati razinu informiranosti i znanja svojih klijenata. Klijenti koji aktiviraju mobilno bankarstvo dobivaju kratke brošure te se putem web stranica banaka mogu informirati o detaljima sigurnosnih aspekata njihovih aplikacija (kako zaštititi svoje financije, kako izbjeći prijevare i lažne aplikacije). Automatizacija sigurnosnih protokola može postići adekvatnu razinu sigurnosti određenih komunikacijskih kanala, ali istovremeno ograničiti određene funkcionalnosti. Adekvatna edukacija korisnika može biti preduvjet rada u poduzeću, ali teško se može očekivati kako će privatni korisnici kontinuirano i samoinicijativno stjecati potrebne vještine. Međusobno povezane karakteristike sustava kao što je motiviranost korisnika da se bavi sigurnošću, razumijevanje pravila koje deriviraju razinu pristupa određenim resursima na svojevrsnoj razini apstrakcije, nedostatak povratne sprege usklađenosti preferencija korisnika i sigurnosnog sustava, vremenski okvir i razina sigurnosti najslabije točke u lancu komunikacije zajedno imaju konačan utjecaj na razinu sigurnosti (Ruoti i sur., 2015). Kako bi se minimizirao rizik, banke nastoje osigurati sigurnije aplikacije, informirati klijente o potencijalno lažnom predstavljanju drugih osoba u ime banke kako bi oni sami izbjegli isto ili obavijestili banku da bi se smanjio broj prevarenih korisnika ili osnažiti potrebnu autentifikaciju prethodno provedbi transakcija. Posljedično direktivi Europske unije PSD2 (Payment Service Directive), banke putem API-a dio svojih usluga pružaju u suradnji s trećim pružateljima koji su često primarno orijentirani na inovacije, a manje na sigurnost te banke moraju adresirati potencijalni

kompromis trećih pružatelja. Preporuča se da banke jednom godišnje putem službene komunikacije informaraju svoje klijente o sigurnom komuniciranju s bankom odnosno da se te informacije učine dostupnim putem mobilne aplikacije ili web stranice.

Također, važno je uspostaviti sustav gdje se klijenti mogu javiti banci ukoliko primjete neuobičajene aktivnosti, a ukoliko se utvrdi da prijetnja postoji, banka može poslati obavijest koja će upozoriti na konkretni pokušaj zloupotrebe i na taj način smanjiti štete koje eventualno mogu nastati od strane neopreznih korisnika. Preporuke korisnicima mogu uključivati savjete kao što su: redovno ažuriranje mobilnih uređaja (nadogradnja često uklučuje sigurnosne zakrpe za nedavno oktrivene slabosti programskih protokola), korištenje sigurne veze (javne bežične mreže imaju značajno niže sigurnosne protokole te je napadačima jednostavnije presresti komunikaciju i dočepati se nekriptiranih podataka klijenta), zanemarivanje elektroničke pošte koja traži korisnička imena i lozinke klijenta iako se čini da je poslana od strane pružatelja usluge odnosno banke, prelazak miša preko poveznica kako bi se provjerilo vode li ponuđeni internetski linkovi na web stranice banke, sadrže li internetske adrese SSL certifikate (oznaka lokota ili https-a) te korištenje jedinstvene i složene lozinke. Složenost autentifikacije korisnika može se razlikovati prema važnosti operacije koju korisnik želi provesti. Elementi autentifikacije mogu se podijeliti u četri kategorije. Prva kategorija podrazumijeva hardver kao što je USB kartica, token, čip kartica, magnetna traka ili pametni telefon, druga ono što klijent zna kao lozinku ili sigurnosno pitanje, treća biometrijske certifikate (očitanje šarenice, prepoznavanje glasa i lica, otisak prsta, uzorak otkucaja srca), a četvrta kategorija uzorak odnosno pravilnosti u klijentovim prijašnjim radnjama (potpis ili brzina tipkanja).

Za potrebe osnovnih operacija kao što je pregled stanja računa može biti dovoljan jedan oblik autentifikacije, dok za neke osjetljivije operacije kao što je transfer sredstava (posebice novim primateljima) sustav može zahtjevati kombinaciju dviju kategorija od kojih će barem jedna biti višekratno upotrebljiva. Idealni proces autentifikacije zahtijevao bi najmanje koraka, a trebao bi izbjeći upotrebu dodatnog hardvera za generiranje jednokratnih lozinki (Krol, Philippou, De Cristofaro i Sasse, 2015). Ukoliko se želi obaviti transfer sredstava, a uzorak ponašanja potvrđuje klijenta dodatna konfirmacija može nepotrebno narušavati njegovo iskustvo odnosno doživaljaj mobilne usluge, ali ako isto nije zadovoljeno opravdano je tražiti potvrdu putem neke od ostalih kategorija autentifikacije. Također, kako bi se zaštitio interes klijenta, mogu se koristiti podaci o broju pokušaja da se korisnik ulogira unutar aplikacije i podaci o njegovoj lokaciji (neuobičajena lokacija napadača može biti signal da se događa neka vrsta zloupotrebe).

To su mehanizmi zaštite prvog reda koji imaju zadaću spriječiti rizik prevare, ali ponekad samo te mjere nisu dovoljne. Naime, kako bi se izbjegao trošak za klijenta, rizične transakcije moraju biti detektirane u realnom vremenu. Mehinizmi zaštite drugog reda uključuju: fizičke ili programske certifikate i tokene, otisak prsta, prepoznavanje lica ili glasa i slično. Iako su neke od navedenih mjera učinkovite mogu narušavati iskustvo korisnika: fizički certifikati i tokeni često nisu ergonomični, a njihove softverske verzije iako troškovno prihvatljiviji šalju se na uređaje na kojima se već ionako pokušava provesti autentifikacija. Preporuča se upotreba softverskih verzija tokena sa OOB[42] autentifikacijom. Šalju se prema klijentu od strane pružatelja usluge, a upravljaju integriranim sustavom obavještavanja o upotrebi, stranicama opisa prethodno autentifikaciji te kreiranjem jednokratne lozinke (posljedično potencijalnim sigurnosnim rizicima nije preporučljivo koristiti OTP (jednokratne lozinke) koji se šalju putem SMS). Također, digitalne platforme omogućavaju stvaranje autonomnih sustava za sprječavanje zloupotrebe koji zahvaljujući procesima mašinskog učenja konstantno napreduju. Podaci prikupljeni o ponašanju klijenata (iznosi transakcija, lista platitelja i primatelja, učestalost upotrebe, lokacije realizacije kartičnog plaćanja i lokacije mobilnog uređaja) omogućuju kreiranje digitalnog profila koji povećava sigurnost komunikacije (EFMA, 2017c).

Konačno, mjere moraju biti usklađene s regulativom te se mora postići ravnoteža između pružanja dovoljne zaštite i neometanog tijeka iskustva korisnika. Da bi banka mogla koristiti spomenute mehanizme, odnosno osobne podatke kao što je lokacija korisnika klijent mora dati svoj izričiti pristanak (EFMA, 2017c). Svilar i Zupancic (2016) napominju kako je svega 69% ispitanika svjesno metode autentifikacije koja se koristi za prijavu u sustav, a 88% smatra kako ista ne narušava kvalitetu iskustva upotrebe Internet bankarstva. Iako su inženjeri i korisnici Internet bankarstva svjesni važnosti sigurnosti aplikacija, korisničko iskustvo ne smije biti narušeno procesom autentifikacije.

Osim poštivanja regulatornih mjera kako bi zadržale svoje klijente banke moraju ponuditi svojevrsne garancije prilikom digitalizacije svojih usluga osiguravajući sigurnu autentifikaciju i zaštitu osobnih podataka te protumjere za različite pokušaje zloupotrebe. Osjećaj sigurnosti klijenta također se povezuje s njegovom percepcijom privatnosti. Iako su klijenti sve više odvažni u korištenju digitalne tehnologije žele biti uvjereni kako postoji sigurnost osjetljivih

[42] akronim od engl. Out of Band

informacija. Prema izvještaju HSBC-a o razini povjerenja u inovativnu tehnologiju ispitanici u prvom redu ističu sigurnost osobnih podatka (56% ispitanika), zatim hakiranje bankovnih računa (56% ispitanika) i kloniranje bankovne kartice (54% ispitanika), dok 87% ispitanika smatra zloupotrebu osobnih podatka jednako važnim kao gubitak novca. Ukoliko klijent smatra kako postoji mogućnost da će treća strana pristupiti osjetljivim informacijama te ih upotrijebiti na ilegalan ili uznemirujuć sigurnost mobilnog bankarstva je kompromitirana (Changchit, Lonkani, Sampet, 2017). Naime, regulacija Europske unije GDPR[43] obavezuje poduzeća na dobivanje izričitog i informiranog pristanka klijenta za prikupljenje i obradu osobnih podataka. Klijentima se na razumljiv način mora prezentirati koji će se osobni podaci koristiti u koju svrhu (promotivne poruke, upravljanje rizikom i sl.). Primjerice korištenje obrazaca s unaprijed popunjenim izjavama odnosno bilo koja vrsta deriviranog pristanka je zabranjena, a nepoštivanje odredbi kažnjivo sa do 4% godišnjeg prihoda ili 20 milijuna dolara. Klijent ima pravo sporiti sve automatizirane odluke za koje mora biti moguće utvrditi kada i zašto su nastale te zahtjevati brisanje osobnih podatka ili transfer istih kod novog pružatelja usluga. Također, regulativom je propisano kako svi osobni podaci moraju biti pridruženi korisniku te kodirani da bi se minimizirala šteta koja može nastati u slučaju curenja podataka. Transparentnost prikupljanja, obrade i sigurnost podataka klijenata može biti izvor konkurentske prednost. Istraživanje je pokazalo kako 56% ispitanika s bankom izbjegava koristiti komunikaciju putem mobilnog telefona zbog sigurnosnih razloga, ali isto tako 60% ispitanika navodi kako za pružanje financijskih usluga preferira banke. Ukoliko žele zadržati i povećati postojeće povjerenje klijenata trebale bi uložiti značajne napore u osiguranje sigurnosti mobilne komunikacije. Sigurnost se mora očitovati na sve tri razine: registraciji klijenta u svrhu potvrde identiteta, pristupu uslugama bez autentifikacije te identifikaciji i blokiranju svih neuobičajenih transakcija (EFMA, 2017a). Direktor inovacijskog procesa jedne od najpropulzivnijih banaka SAD-a navodi kako je upravo ravnoteža između dinamike ulaganja u nove tehnologije, pogodnosti i sigurnosti klijenata osnova osiguravanja i zadržavanja konkurentske prednosti. Zadržati povjerenje i pratiti trendove svakako je važnije nego biti nositelj disruptivne tehnologije. Orijentacija na disruptivne tehnologije nije svrsishodna sama po sebi. Resursi organizacije trebaju biti orijentirani na rješenja koja povećavaju kvalitetu iskustva korisnika, rješavaju neki problem ili adresiraju potrebu klijenata na drugačiji način (EFMA, 2017d).

[43] akronim od engl. General Data Protection Regulation

4.4.2 Jednostavnost korištenja

Mobilno bankarstvo se odnosi na komunikaciju klijenta s bankom putem uređaja kao što je mobitel ili tablet. Iako mobilno plaćanje odnosno plaćanje računa na prodajnim mjestima bez novčanika može biti jedna od opcija mobilnog bankarstva koja se povezuje s projektom digitalnog novčanika, mobilno bankarstvo podrazumijeva širi raspon financijskih usluga koje u odnosu na tradicionalno bankarstvo u poslovnicama ili Internet bankarstva na računalima podrazumijeva financije koje su neovisne o lokaciji klijenta, a bankovne transakcije čine iznimno efikasnima (Laukkanen, 2017).

Banke su daleko napredovale u kvaliteti pružanja financijskih usluga. Kako bi se povećala jednostavnost upotrebe servisa koji omogućuju upravljanje financijama klijenata njihovo se iskustvo analizira do najsitnijih detalja. Banke putem različitih programskih rješenja koriste povratne informacije klijenata te kontinuirano povećavaju jednostavnost korištenja odnosno zadovoljstvo klijenta. Nastoji se povećati razina interaktivnosti i jednostavnosti navigacije kako bi vrijeme i trud potrebno za upravljanje financijama bilo svedeno na minimum. Naime, jednostavnost korištenja u prvom redu podrazumijeva percipiranu složenost navigacije. Korisnička podrška može poslužiti kao potpora, ali nije neophodna. Korisnik može negativno reagirati na direktnu verbalnu ili tekstualnu komunikaciju s korisničkom podrškom tijekom korištenja Internet bankarstva (Sikdar, Kumar, Makkad, 2015). Kao što je citirano u Changchit, Lonkani i Sampet, (2017), te Davis, Bagozzi i Warshaw naglašavaju da jednostavnost podrazumijeva percepciju potencijalnog korisnika/klijenta koliko će upotreba odabrane aplikacije zahtjevati uloženog truda. Predstavlja individualni odgovor na tehnološko rješenje i važan preduvjet usvajanje inovativnih tehnoloških rješenja. Tehnološke kompetencije podrazumijevaju znanje pojedinca koje će omogućiti efikasno korištenje informacijske tehnologije. Pojedinci s većom razinom znanja i efikasnošću će biti motivirani da koriste tehnologijom obogaćene usluge te imaju veću vjerojatnost korištenja i usvajanja tehnologije mobilnog bankarstva. Oni klijenti koji koriste više inovativne tehnologije imati će percepciju veće jednpstavnosti novih tehnoloških rješenja (Yang 2010).

Čak i najjednostavniji sustavi imaju opcije duboko unutar navigacijske strukture. Ukoliko iskustvo navigacije kroz sučelje mobilnog bankarstva nije intuitivno ili usklađeno s logikom već postojećih sustava za iskusnog korisnika mobilnih uređaja s bankovnim računom, korisnici zemalja u razvoju koji se prvi puta susreću ili koriste mobilne uređaje manje od godinu dana

teško će savladavati novitete upravljanja mobilnim bankarstvom (Peevers, Douglas, Jask, 2008). Također, pokazalo se da kratke video upute, instrukcije koje se sastoje od niza koraka koje klijent treba učiniti kako bi realizirao određene funkcionalnosti mobilnog bankarstva, odgovori na često postavljena pitanja i probne verzije programskih rješenja mogu imati pozitivan utjecaj na stopu prihvaćnja aplikacija mobilnog bankarstva (EFMA, 2017c).

Smatra se kako će upravo Fintech novoosnovana poduzeća upotrebom digitalne tehnologije utjecati na gotovo sve aspekte tradicionalnog bankarstva. Između-ostalog jedna od zadaća Fintech organizacija je da svojim inovacijama kreiraju jednostavnije aplikacije za klijente banaka. Neke od poboljšanih funkcionalnosti koje su mogu očekivati su optimizacija sučelja, personalizacija aplikacija, foto/glasovno prepoznavanje, 3D grafika i gamifikacija (EFMA, 2017d). Primjerice, britansko poduzeće kao „plug and play“ platforma pod komercijalnim nazivom „Bud“ na osnovi API-a putem strateških partnerstava s bankama nudi potpunu kontrolu svih finacijskih proizvoda i usluga za ukupno 30 milijuna klijenta osiguravajući jednostavnost sučelja i postupka prijave (EFMA, 2017d).

Za nove korisnike digitalnog bankarstvo sučelje navigacije ne mora nužno biti jedini izazov. Razumijevanje i prihvaćanje ideje digitalnog transfera virtualnog novca za mnoge pojedince zemalja u razvoju može ostati nesavladiva prepreka (Singh, 2007) . Ljudi koji su cijeli svoj život naučili raditi s gotovinom zasigurno prati sustav vjerovanja, nedoumica i zabrinutost koje treba adresirati prethodno prihvaćanju mobitela kao supstituta klasičnog novčanika.

4.4.3 Dostupnost usluge

Razvoj tehnologije i različite inovacije dovele su do stvaranja afirmativne klime za plasman mobilnog bankarstva, a prema istraživanju koje provodi Moser (2015) usvajanje mobilnog bankarstva povezano je s pogodnošću, efikasnošću i dostupnošću. Kao što je citirano u Teo, Wei-Han Tan, i sur. (2015), Hayashi navodi kako mobilno bankarstvo klijentima osigurava veću dostupnost, pogodnost i kontrolu njihovih financija, a dostupnost usluge mobilnog bankarstva može se povezivati s nestalnom isporukom električne energije, pokrivenosti mobilne mreže, nedostupnosti konačne povezivosti širokopojasne komunikacije i visokom cijenom Internet usluga (Sharma, Pandey, 2015).

Nestalnost isporuke električne energije podrazumijeva stabilnost energetske infrastrukture te se prvenstveno povezuje s uslugom fiksnog Interneta, dok su mobilni uređaji obzirom na internu bateriju manje pogođeni spomenutim infrastrukturnim nedostatkom. Krajem 2017. godine Internetom se koristilo 48% populacije svijeta, od čega je najveća incidencija korisnika bila u Europi (79,6%), zatim Sjevernoj i Južnoj Americi (65,9%), Aziji i Pacifiku (43,9%), Arapskim zemljama (43,7%), a najmanja u Africi (21,8%). Također, važno je napomenuti kako se povećava udio mobilnog Interneta. U periodu 2012.-2017. godine broj pretplatnika na mobilni Internet razvijenih zemalja rastao je 7% godišnje, a zemalja u razvoju 35% godišnje, dok je incidencija korisnika 2017. godine razvijenih zemalja bila 95%, a zemalja u razvoju 49%. Komparativno, stopa rasta broja pretplatnika fiksnog interneta u prosjeku je iznosila 9%, a prosječna incidencija bila je 12%. Cijena mobilnog i fiksnog Interneta 2016. godine bila je znatno niža u razvijenim zemljama i iznosila RZ=PPP$15,4/NZ=PPP$33,4 i RZ=PPP$30,5/NZ=61,3%. Važno je napomenuti kako se pod mobilnom pretplatom Interneta smatra minimum prometa od 1GB mjesečno. Nadalje, iako postoji rast incidencije brzog Interneta (10Mbit) koji u razvijenim zemljama 2016. godine čini 24%, udio istog broja pretplata u zemljama u razvoju relativno je nizak (6%) (ITU, 2017).

Kada je uspostavljena odgovarajuća infrastrukrura mobilno bankarstvo ima mogućnost povećati uključenost društvenih segmenta financijskog tržišta koji su dosad bili isključeni. Također, raste mreža sudionika koji čine nevidljivu infrastrukturu sustava plaćanja između trgovaca i klijenata banke. S pojavom mobilnog bankarstva raste dostupnost kredita i mogućnost investiranja.

Osim dostupnosti financijskih usluga, važna karakteristika usvajanja mobilnog bankarstva je dostupnost sustava podrške. Motwani (2016) naglašava važnost navođenja, potpore i osobne prilagodbe aplikacije mobilnog bankarstva odnosno mobilnog uređaja. Ewe, Yap i Lee (2015) kažu da će spremnost ljudi na usvajanje mobilnog bankarstva biti veća ako postoji veća ponuda komplementarnih usluga i proizvoda koje se uklapaju u životni stil klijenta. Moser (2015) smatra kako bi u budućnosti i društvene mreže mogle biti integrirane u sustav m1obilnog bankarstva. OBS podrazumijeva suradnju banaka s različim vrstama organizacija kao što su Twitter, Facebook, Google, vladine agencije i slično. Fidor banka u Njemačkoj putem svoje interne zajednice i Facebook Connecta nudi mogućnost investicijskog savjetovanja i preporuke za upravljanje troškovima kućanstva, ocjenu financijskih savjetnika i reviziju različitih

financijskih proizvoda i usluga. Banka financijski potiče učlanjenje u zajednicu i aktivnost, a trošak osvajanja novog klijenta ne prelazi jednu petinu iznosa tradicionalnih banaka (Wilkinson, 2017). DenizBank u Turskoj uz pomoć svoje društvene aplikacije putem Facebooka, Twittera, instant poruka ili elektroničke pošte nudi mogućnost besplatnog transfera novca 24/7. Putem iste aplikacije moguće je zatražiti i manji zajam (EFMA, 2017a). Društvene mreže također mogu biti korisne i prilikom izgradnje reputacije. Banke koriste marketinške alate kao što su Google Adwords, a poveznice na društvenim mrežama važan su preduvjet konačnog odabira klijenta. Da bi strategija povećanja prepoznatiljivosti brenda digitalne banke bila efikasna važno je da potencijalni korisnik bude kontinuirano izložen utjecaju banke (prethodno odabiru pružatelja financijskih usluga klijenti u prosjeku razmatraju svega dvije banke).

5 EMPRIJSKO ISTRAŽIVANJA POVEZANOSTI KVALITETE MOBILNOG BANKARSTVA I REPUTACIJE BANAKA

5.1 Instrument istraživanja

Sigurnost mobilnog bankarstva definiramo kao sposobnost sustava da onemogući neovlašteni pristup informacijama i sredstvima na računima korisnika. U Tablici 20 navedeni su konstrukti sigurnosti mobilnog bankarstva: S1. Nadogradnja aplikacije mobilnog bankarstva je sigurna; S2. Aplikacija mobilnog bankarstva je stabilna; S3. Učitavanje nove verzije aplikacije se izvršava točno i u kratkom vremenu; S4. Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme; S5. Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća; S6. Korištenje aplikacije mobilnog bankarstva je sigurno. Ispitanici su navedene tvrdnje ocijenili od jedan do sedam ovisno je li se s njima uopće ne slažu ili u potpunosti slažu.

Tablica 20. Konstrukt sigurnosti mobilnog bankarstva

Šifra	Tvrdnja	1 - uopće se ne slažem	2	3	4	5	6	7 - u potpunosti se slažem
S1.	Nadogradnja aplikacije mobilnog bankarstva je sigurna	1	2	3	4	5	6	7
S2.	Aplikacija mobilnog bankarstva je stabilna	1	2	3	4	5	6	7
S3.	Učitavanje nove verzije aplikacije se izvršava točno i u kratkom vremenu	1	2	3	4	5	6	7
S4.	Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme	1	2	3	4	5	6	7
S5.	Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća	1	2	3	4	5	6	7
S6.	Korištenje aplikacije mobilnog bankarstva je sigurno	1	2	3	4	5	6	7

Izvor: autorica prema Wang, Lo, Hui, 2003

Jednostavnost korištenja mobilnog bankarstva omogućava intuitivno korištenje sustava. U Tablici 21 navedeni su konstrukti jednostavnosti korištenja mobilnog bankarstva: J1. Preuzimanje i učitavanje aplikacije mobilnog bankarstva je jednostavno; J2. Aktiviranje aplikacije mobilnog bankarstva je jednostavno; J3. Pretraživanje aplikacije mobilnog bankarstva je jednostavno; J4. Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno; J5. Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno; J6. Aplikacija mobilnog bankarstva je jednostavna za korištenje. Ispitanici su

navedene tvrdnje ocijenili od jedan do sedam ovisno je li se s njima uopće ne slažu ili u potpunosti slažu.

Tablica 21. Konstrukt jednostavnosti korištenja mobilnog bankarstva

Šifra	Tvrdnja	1 - uopće se ne slažem	2	3	4	5	6	7 - u potpunosti se slažem
J1.	Preuzimanje i učitavanje aplikacije mobilnog bankarstva je jednostavno	1	2	3	4	5	6	7
J2.	Aktiviranje aplikacije mobilnog bankarstva je jednostavno	1	2	3	4	5	6	7
J3.	Pretraživanje aplikacije mobilnog bankarstva je jednostavno	1	2	3	4	5	6	7
J4.	Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno	1	2	3	4	5	6	7
J5.	Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno	1	2	3	4	5	6	7
J6.	Aplikacija mobilnog bankarstva je jednostavna za korištenje	1	2	3	4	5	6	7

Izvor: autorica prema Wang, Lo, Hui, 2003

Dostupnost usluga mobilnog bankarstva definira se kao mogućnost: (i) provođenja jednostavnih bankovnih transakcija, (ii) ugovaranja bankovnih usluga, (iii) korištenja personaliziranih usluga. U Tablici 22 opisani su konstrukti dostupnosti usluga mobilnog bankarstva: D1. Aplikacija omogućava ugovaranje depozitnih proizvoda; D2. Aplikacija omogućava ugovaranje i/ili popunjavanje zahtjeva za kreditne proizvode; D3. Aplikacija omogućava kupovinu udjela u fondovima; D4. Aplikacija omogućava ugovaranje police osiguranja; D5. Aplikacija omogućava ugovaranje kartica; D6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati); D7. Aplikacija omogućava personaliziranu komunikaciju; D8. Preko aplikacije dobivam personalizirane ponude. Ispitanici su navedene tvrdnje ocijenili od jedan do sedam ovisno je li se s njima uopće ne slažu ili u potpunosti slažu.

Tablica 22. Konstruktu dostupnosti usluga mobilnog bankarstva

Šifra	Tvrdnja	1 - uopće se ne slažem	2	3	4	5	6	7 - u potpunosti se slažem
D1.	Aplikacija omogućava ugovaranje depozitnih proizvoda.	1	2	3	4	5	6	7
D2.	Aplikacija omogućava ugovaranje i/ili popunjavanje zahtjeva za kreditne proizvode.	1	2	3	4	5	6	7
D3.	Aplikacija omogućava kupovinu udjela u fondovima.	1	2	3	4	5	6	7
D4.	Aplikacija omogućava ugovaranje police osiguranja.	1	2	3	4	5	6	7
D5.	Aplikacija omogućava ugovaranje kartica.	1	2	3	4	5	6	7
D6.	Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati).	1	2	3	4	5	6	7
D7.	Aplikacija omogućava personaliziranu komunikaciju.	1	2	3	4	5	6	7
D8.	Preko aplikacije dobivam personalizirane ponude.	1	2	3	4	5	6	7

Izvor: autorica

Percipiranu kvalitetu usluge mobilnog bankarstva definiramo kao percepciju klijenata banke da je sustav mobilnog bankarstva sposoban pružiti uslugu koja će u visokoj mjeri zadovoljiti njihove potrebe i očekivanja. U Tablici 23 opisani su konstrukti percipirane kvalitete usluge mobilnog bankarstva: K1. Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna; K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete; K3. Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja; K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan; K5. Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke. Ispitanici su navedene tvrdnje ocijenili od jedan do sedam ovisno je li se s njima uopće ne slažu ili u potpunosti slažu.

Tablica 23. Konstrukt percipirane kvalitete usluge mobilnog bankarstva

Šifra	Tvrdnja	1 - uopće se ne slažem	2	3	4	5	6	7 - u potpunosti se slažem
K1.	Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna.	1	2	3	4	5	6	7
K2.	Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete.	1	2	3	4	5	6	7
K3.	Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja.	1	2	3	4	5	6	7
K4.	Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan.	1	2	3	4	5	6	7
K5.	Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke.	1	2	3	4	5	6	7

Izvor: prema Wang, Lo, Hui, 2003

Reputaciju banaka definiramo kao percepciju klijenata da je banka vjerodostojna, pouzdana, odgovorna i dostojna njihovog povjerenja. U Tablici 24 opisani su konstrukti reputacije banaka: R1. Banka za koju imam dobar osjećaj; R2. Banka kojoj vjerujem; R3. Banka koju poštujem; R4. Banka koja ima tradiciju; R5. Banka koja ima snagu međunarodne organizacije; R6. Banka koja cijeni mene kao klijenta; R7. Banka ima dobru ukupnu reputaciju. Ispitanici su navedene tvrdnje ocijenili od jedan do sedam ovisno je li se s njima uopće ne slažu ili u potpunosti slažu.

Tablica 24. Konstrukt reputacije banaka

Šifra	Tvrdnja	1 - uopće se ne slažem	2	3	4	5	6	7 - u potpunosti se slažem
R1.	Banka za koju imam dobar osjećaj.	1	2	3	4	5	6	7
R2.	Banka kojoj vjerujem.	1	2	3	4	5	6	7
R3.	Banka koju poštujem.	1	2	3	4	5	6	7
R4.	Banka koja ima tradiciju.	1	2	3	4	5	6	7
R5.	Banka koja ima snagu međunarodne organizacije.	1	2	3	4	5	6	7
R6.	Banka koja cijeni mene kao klijenta.	1	2	3	4	5	6	7
R7.	Banka ima dobru ukupnu reputaciju.	1	2	3	4	5	6	7

Izvor: autor prema Ponzi, Fombrun, Gardberg, 2011

Osim ocijenjivanja tvrdnji vezanih uz navedene konstrukte, ispitanici su trebali navesti koja im je glavna banka od navedenih deset najvećih u Hrvatskoj te koliko često koriste mobilno bankarstvo. Zadnji G. dio upitnika obuhvatio je demografske podatke o ispitanicima koji se odnose na spol, dob, obrazovanje te prebivalište.

5.2 Uzorak istraživanja

Tablica 25 prikazuje glavnu banku ispitanika kod koje koriste mobilno bankarstvo. Više od polovice ispitanika su klijenti Privredne banke Zagreb (58,60%) i kod nje koriste mobilno bankarstvo., a slijede ih ispitanici koji su klijenti Zagrebačke banke (21,51%). Manje od 10% ispitanika koriste mobilno bankarstvo u ostalim navedenim bankama: Poštanska banka (2,96%); Raiffeisen banka (3,23%), Splitska banka Societe Generale (2,15%), Erste banka (8,06%), Hypo banka (1,34%), OTP banka (2,15%).

Tablica 25. Glavna banka ispitanika kod koje koriste mobilno bankarstvo

	Broj ispitanika	Struktura u %	Kumulativ %
1. Zagrebačka banka	80	21,51	21,51
2. Privredna banka Zagreb	218	58,60	80,11
3. Poštanska banka	11	2,96	83,06
4. Raiffeisen banka	12	3,23	86,29
5. Splitska banka Societe Generale	8	2,15	88,44
6. Erste banka	30	8,06	96,51
7. Hypo banka	5	1,34	97,85
9. OTP banka	8	2,15	100
Ukupno	372	100	

Izvor: autorica, obrada istraživanja siječanj, 2017

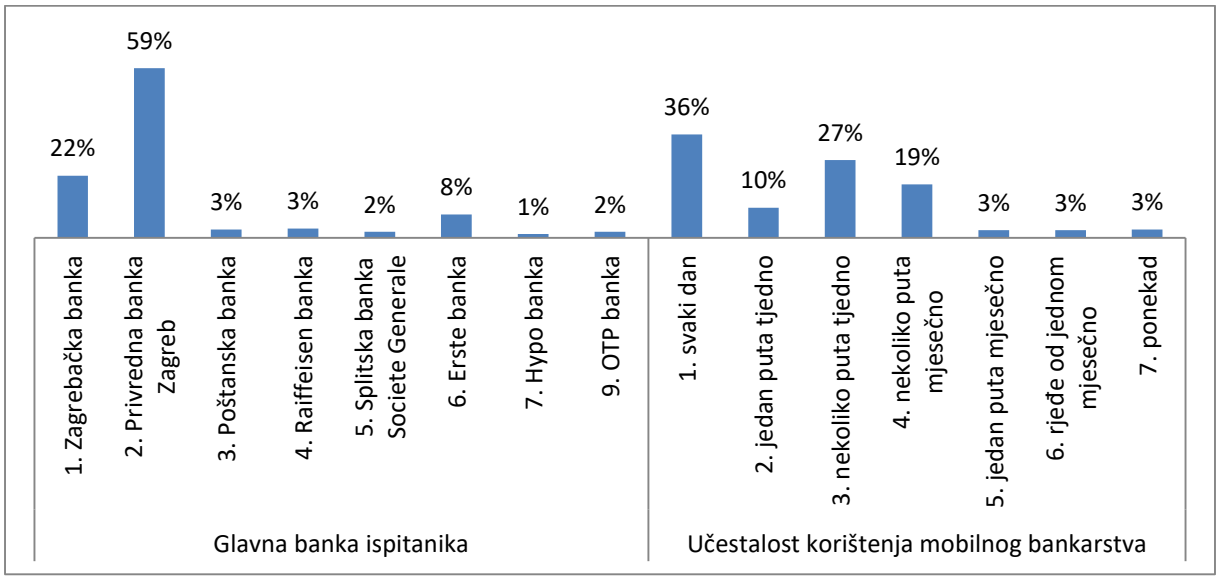
Tablica 26 prikazuje učestalost korištenja mobilnog bankarstva. Otprilike trećina ispitanika koristi mobilno bankarstvo svaki dan (35,75%), dok četvrtina ispitanika mobilno bankarstvo koristi nekoliko puta tjedno (26,88%). Najmanje ispitanika mobilno bankarstvo koristi najrjeđe (2,69%): jedan puta mjesečno, rjeđe od jednom mjesečno i ponekad.

Tablica 26. Učestalost korištenja mobilnog bankarstva

	Broj ispitanika	Struktura u %	Kumulativ %
1. svaki dan	133	35,75	35,75
2. jedan puta tjedno	39	10,48	46,24
3. nekoliko puta tjedno	100	26,88	73,12
4. nekoliko puta mjesečno	69	18,55	91,67
5. jedan puta mjesečno	10	2,69	94,35
6. rjeđe od jednom mjesečno	10	2,69	97,04
7. ponekad	11	2,96	100
Ukupno	372	100	

Izvor: autorica, obrada istraživanja siječanj, 2017

Slika 17 prikazuje strukturu ispitanika s obzirom na glavnu banku i učestalost korištenja mobilnog bankarstva. Privredna banka Zagreb se ističe kao glavna banka kod koje najviše ispitanika koriste mobilno bankarstvo (59%) svaki dan (36%).



Slika 17. Struktura ispitanika s obzirom na glavnu banku i učestalost korištenja mobilnog bankarstva
Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 27 prikazuje spol ispitanika. Više od polovice ispitanika su ženskog spola (57,80%), dok je nešto manji udio ispitanika muškog spola (42,20%).

Tablica 27. Spol ispitanika

	Broj ispitanika	Struktura u %	Kumulativ %
Muško	157	42,20	42,20
Žensko	215	57,80	100
Ukupno	372	100	

Izvor: autorica, obrada istraživanja siječanj, 2017

Tablica 28 prikazuje dob ispitanika. Najviše ispitanika imaju od 30 do 39 godina (34,95%). Približno je jednak udio ispitanika od 20 do 29 godina (27,15%), kao i onih od 40 do 49 godina (29,57%). Najmanje je ispitanika starijih od 50 godina: 50-59 godina (7,26%), 60-64 godina (0,54%), više od 65 godina (0,54%).

Tablica 28. Dob ispitanika

	Broj ispitanika	Struktura u %	Kumulativ %
1. 20-29 godina	101	27,15	27,15
2. 30-39 godina	130	34,95	62,10
3. 40-49 godina	110	29,57	91,67
4. 50-59 godina	27	7,26	98,92
5. 60-64 godina	2	0,54	99,46
6. više od 65 godina	2	0,54	100,00
Ukupno	372	100	

Izvor: Autorica, obrada istraživanja siječanj, 2017

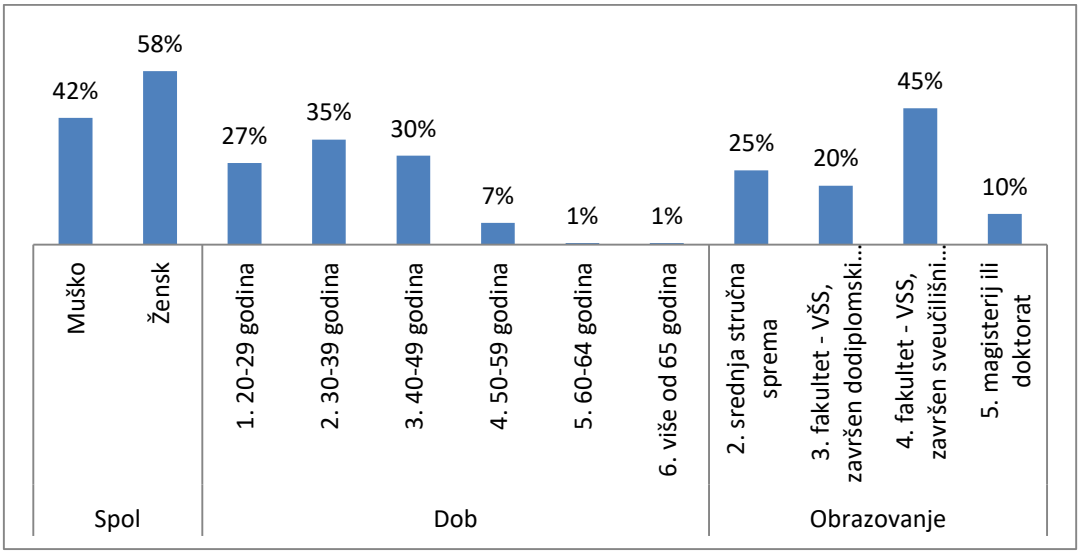
Tablica 29 prikazuje obrazovanje ispitanika. Najviše ispitanika imaju fakultet - VSS, završen sveučilišni diplomski studij, završen stručni studij (45,43%). Otprilike četvrtina ispitanika imaju srednju stručnu spremu (24,73%). Najmanje ispitanika imaju najviši stupanj obrazovanja, magisterij ili doktorat (10,22%).

Tablica 29. Obrazovanje ispitanika

	Broj ispitanika	Struktura u %	Kumulativ %
2. srednja stručna sprema	92	24,73	24,73
3. fakultet - VŠS, završen dodiplomski studij	73	19,62	44,35
4. fakultet - VSS, završen sveučilišni diplomski studij, završen stručni studij	169	45,43	89,78
5. magisterij ili doktorat	38	10,22	100
Ukupno	372	100,00	

Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 18 prikazuje strukturu ispitanika s obzirom na spol, dob i obrazovanje. Većina ispitanika su osobe ženskog spola (58%), imaju od 30 do 39 godina (35%) i fakultetski su obrazovani (45%).



Slika 18. Struktura ispitanika s obzirom na spol, dob i obrazovanje
Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 30 prikazuje veličinu mjesta stanovanja ispitanika. Više od polovice ispitanika živi u mjestu koje ima više od 100.000 stanovnika (63,98%). Približno je jednak udio onih ispitanika koji žive na selu (12,37%) i u gradu od 10.000 do 50.000 stanovnika (12,90%). Najmanje ispitanika živi u gradu do 10.000 stanovnika (5,91%) kao i u gradu od 50.000 do 100.000 stanovnika (4,84%).

Tablica 30. Veličina mjesta stanovanja ispitanika

	Broj ispitanika	Struktura u %	Kumulativ %
1. selo	46	12,37	12,37
2. grad do 10.000 stanovnika	22	5,91	18,28
3. grad od 10.000 do 50.000 stanovnika	48	12,90	31,18
4. grad od 50.000 – 100.000 stanovnika	18	4,84	36,02
5. više od 100.000 stanovnika	238	63,98	100
Ukupno	372	100	

Izvor: autorica, obrada istraživanja siječanj, 2017

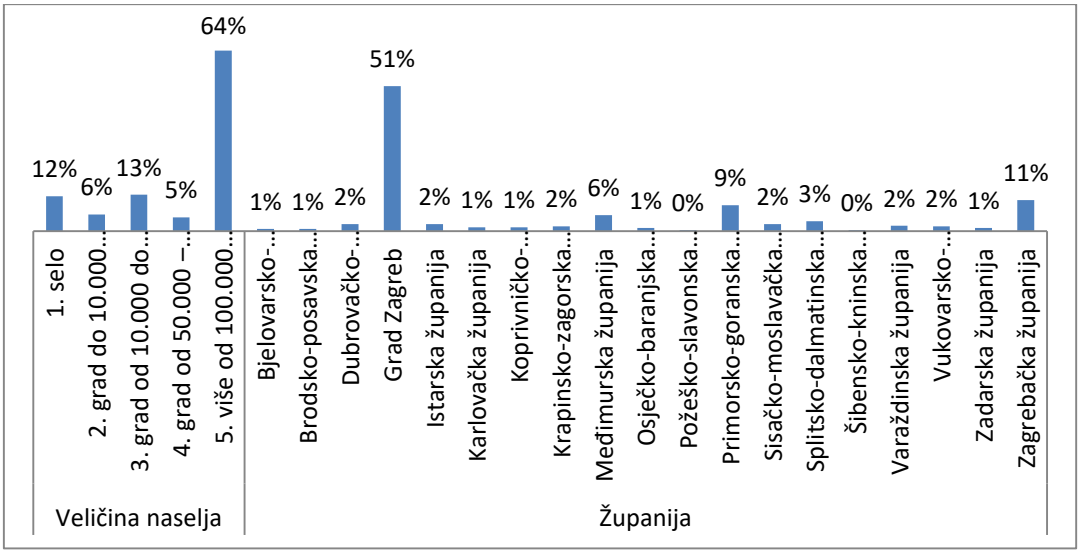
Tablica 31 prikazuje županije stanovanja ispitanika. Više od polovice ispitanika živi u Gradu Zagrebu (51,34%), a slijede ih ispitanici iz Zagrebačke (11,02%) kao i Primorsko –goranske županije (9,14%). U ostalim županijama živi manje od 3% ispitanika, i to najmanje u sljedećim županijama: Bjelovarsko-bilogorska županija (0,81%), Brodsko-posavska županija (0,81%), Požeško-slavonska županija (0,27%), Šibensko-kninska županija (0,27%).

Tablica 31. Županija stanovanja ispitanika

	Broj ispitanika	Struktura u %	Kumulativ %
Bjelovarsko-bilogorska županija	3	0,81	0,81
Brodsko-posavska županija	3	0,81	1,61
Dubrovačko-neretvanska župani	9	2,42	4,03
Grad Zagreb	191	51,34	55,38
Istarska županija	9	2,42	57,80
Karlovačka županija	5	1,34	59,14
Koprivničko-križevačka župa	5	1,34	60,48
Krapinsko-zagorska županija	6	1,61	62,10
Međimurska županija	21	5,65	67,74
Osječko-baranjska županija	4	1,08	68,82
Požeško-slavonska županija	1	0,27	69,09
Primorsko-goranska županija	34	9,14	78,23
Sisačko-moslavačka županija	9	2,42	80,65
Splitsko-dalmatinska županija	13	3,49	84,14
Šibensko-kninska županija	1	0,27	84,41
Varaždinska županija	7	1,88	86,29
Vukovarsko-srijemska županija	6	1,61	87,90
Zadarska županija	4	1,08	88,98
Zagrebačka županija	41	11,02	100,00
Ukupno	372	100	

Izvor: autorica, obrada istraživanja siječanj, 2017

Slika 19 prikazuje strukturu ispitanika s obzirom na veličinu naselja i županiju. Najviše ispitanika žive u urbanim sredinama, odnosno u gradu s više od 100.000 stanovnika (64%) kao i u Gradu Zagrebu (51%).



Slika 19. Struktura ispitanika s obzirom na veličinu naselja i županiju
Izvor: autorica, obrada istraživanja siječanj, 2017

5.3 Rezultati istraživanja

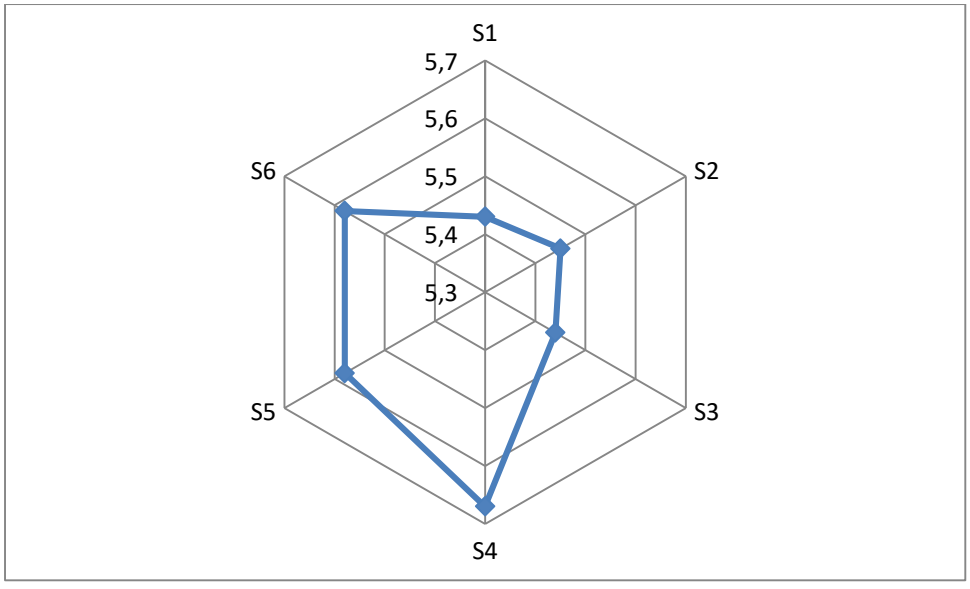
Tablica 32 prikazuje deskriptivnu statistiku sigurnosti mobilnog bankarstva. Svih šest navedenih konstrukata sigurnosti mobilnog bankarstva ima približno jednaku prosječnu ocjenu. Ipak, najveću prosječnu ocjenu ima konstrukt S4. Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme (5,67), dok najmanju prosječnu ocjenu ima konstrukt S1. Nadogradnja aplikacije mobilnog bankarstva je sigurna (5,43).

Tablica 32. Deskriptivna statistika sigurnosti mobilnog bankarstva

	N	Min	Max	Prosjek	St. Dev.
S1	372	1	7	5,43	1,432
S2	372	1	7	5,45	1,409
S3	372	1	7	5,44	1,485
S4	372	1	7	5,67	1,387
S5	372	1	7	5,58	1,447
S6	372	1	7	5,58	1,419

Izvor: autorica, obrada istraživanja siječanj, 2017

Slika 20 prikazuje prosječne vrijednosti ocjena sigurnosti mobilnog bankarstva. Svih šest navedenih konstrukata ispitanici su ocijenili s visokim ocjenama, višim od pet, pri čemu se posebno ističe konstrukt S4. Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme (5,67).



Slika 20. Prosječne vrijednosti ocjena sigurnosti mobilnog bankarstva
Izvor: autorica, obrada istraživanja siječanj, 2017

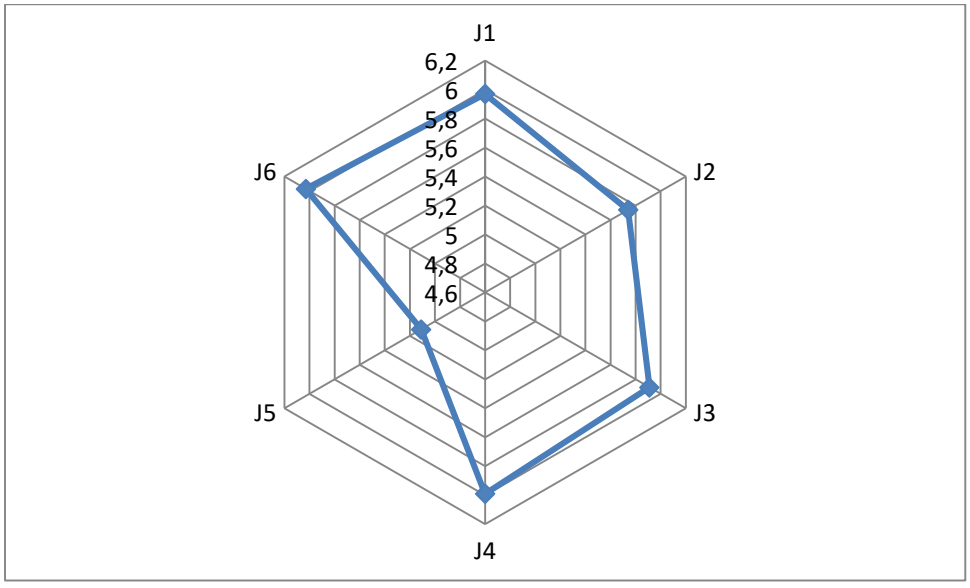
Tablica 33 prikazuje deskriptivnu statistiku jednostavnosti mobilnog bankarstva. Svih šest navedenih konstrukata jednostavnosti mobilnog bankarstva imaju visoke prosječne ocjene. Ipak, najveću prosječnu ocjenu ima konstrukt J6. Aplikacija mobilnog bankarstva je jednostavna za korištenje (6,03), dok najmanju prosječnu ocjenu ima konstrukt J5. Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno (5,11).

Tablica 33. Deskriptivna statistika jednostavnosti mobilnog bankarstva

	N	Min	Max	Prosjek	St. Dev.
J1	372	1	7	5,97	1,375
J2	372	1	7	5,74	1,467
J3	372	1	7	5,91	1,378
J4	372	1	7	5,99	1,307
J5	372	1	7	5,11	1,550
J6	372	1	7	6,03	1,285

Izvor: autorica, obrada istraživanja siječanj, 2017

Slika 21 prikazuje prosječne vrijednosti ocjena jednostavnosti mobilnog bankarstva. Svih šest navedenih konstrukata ispitanici su ocijenili s visokim ocjenama, višim od pet, pri čemu se posebno ističe konstrukt J6. Aplikacija mobilnog bankarstva je jednostavna za korištenje (6,03).



Slika 21. Prosječne vrijednosti ocjena jednostavnosti mobilnog bankarstva
Izvor: Autorica, obrada istraživanja siječanj, 2017

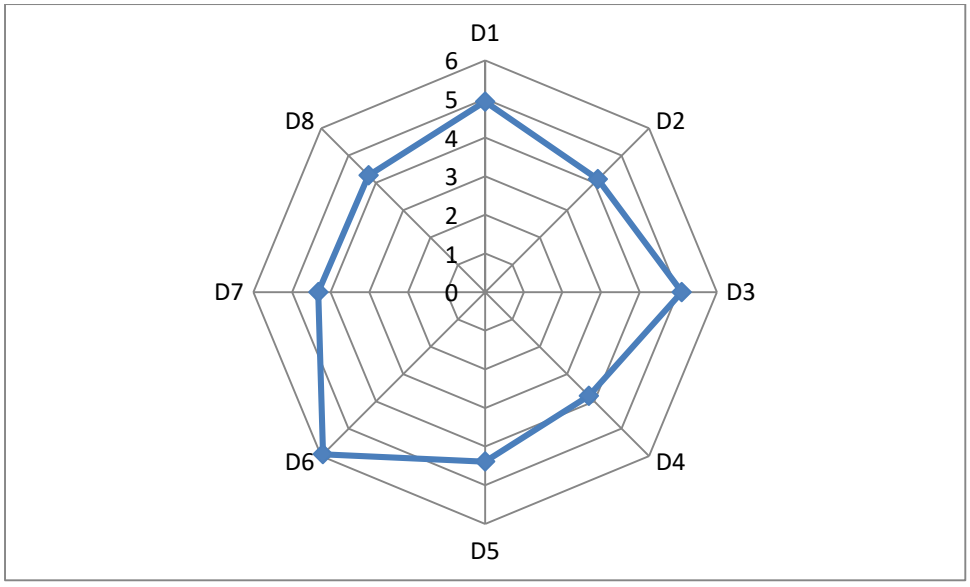
Tablica 34 prikazuje deskriptivnu statistiku dostupnosti mobilnog bankarstva. Najveću prosječnu ocjenu ima konstrukt D6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati (5,94). Jedino konstrukt D4. Aplikacija omogućava ugovaranje police osiguranja ima prosječnu ocjenu nižu od četiri (3,80).

Tablica 34. Deskriptivna statistika dostupnosti mobilnog bankarstva

	N	Min	Max	Prosjek	St. Dev.
D1	372	1	7	4,93	1,987
D2	372	1	7	4,13	2,003
D3	372	1	7	5,09	1,993
D4	372	1	7	3,80	2,148
D5	372	1	7	4,39	2,113
D6	372	1	7	5,94	1,706
D7	372	1	7	4,32	1,898
D8	372	1	7	4,27	2,017

Izvor: Autorica temeljem obrade istraživanja siječanj, 2017

Slika 22 prikazuje prosječne vrijednosti ocjena dostupnosti mobilnog bankarstva. Svih šest navedenih konstrukata imaju prilično visoke prosječne ocjene, pri čemu se posebno ističe konstrukt D6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati (5,94).



Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 22. Prosječne vrijednosti ocjena dostupnosti mobilnog bankarstva

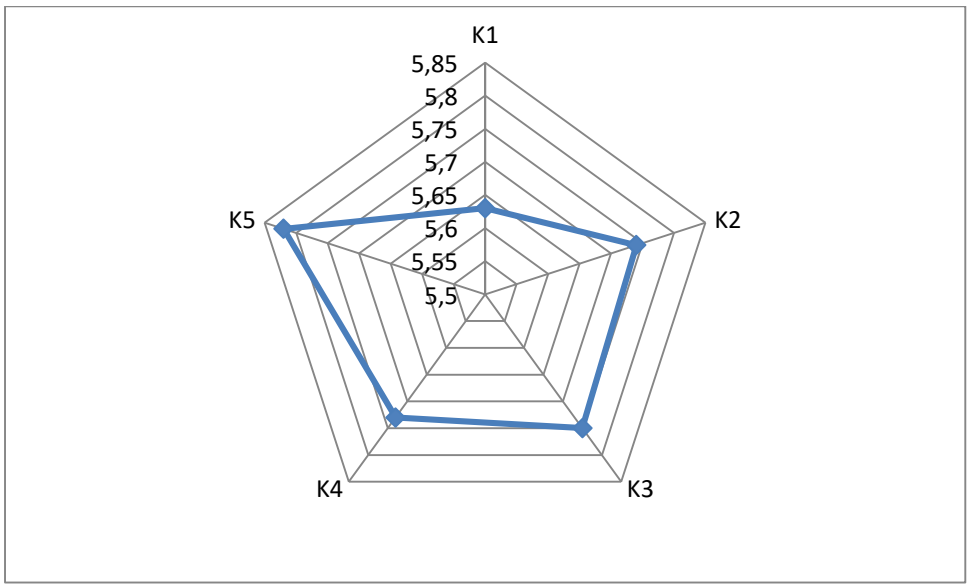
Tablica 35 prikazuje deskriptivnu statistiku percipirane kvalitete mobilnog bankarstva. Svih pet navedenih konstrukata percipirane kvalitete mobilnog bankarstva imaju približno jednake prosječne ocjene. Ipak, najveću prosječnu ocjenu ima konstrukt K5. Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke (5,82), dok najmanju prosječnu ocjenu ima konstrukt K1. Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna (5,63).

Tablica 35. Deskriptivna statistika percipirane kvalitete mobilnog bankarstva

	N	Min	Max	Prosjek	St. Dev.
K1	372	1	7	5,63	1,359
K2	372	1	7	5,74	1,385
K3	372	1	7	5,75	1,431
K4	372	1	7	5,73	1,293
K5	372	1	7	5,82	1,378

Izvor: autorica, obrada istraživanja siječanj, 2017

Slika 23 prikazuje prosječne vrijednosti ocjena percipirane kvalitete mobilnog bankarstva. Svih pet navedenih konstrukata ispitanici su ocijenili s visokim ocjenama, višim od pet, pri čemu se posebno ističe konstrukt K5. Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke (5,82).



Slika 23. Prosječne vrijednosti ocjena percipirane kvalitete mobilnog bankarstva

Izvor: autorica, obrada istraživanja siječanj, 2017

Tablica 36 prikazuje deskriptivnu statistiku reputacije banke. Svih sedam navedenih konstrukata reputacije banke imaju približno jednake prosječne ocjene. Ipak, najveću prosječnu ocjenu ima konstrukt R4. Banka koja ima tradiciju (5,75), dok najmanju prosječnu ocjenu ima konstrukt R6. Banka koja cijeni mene kao klijenta (5,19).

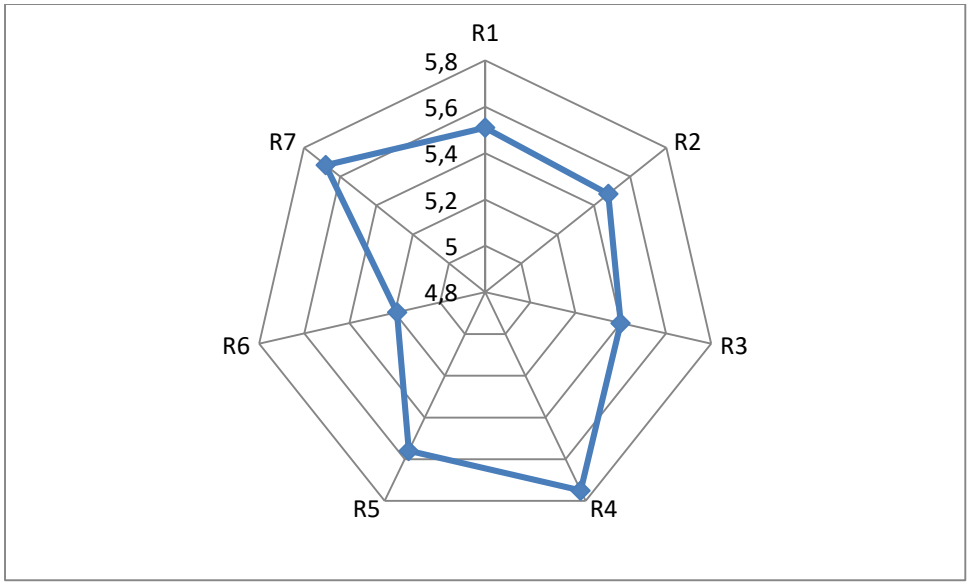
Tablica 36. Deskriptivna statistika reputacije banke

	N	Min	Max	Prosjek	St. Dev.
R1	372	1	7	5,51	1,495

R2	372	1	7	5,48	1,592
R3	372	1	7	5,40	1,607
R4	372	1	7	5,75	1,377
R5	372	1	7	5,56	1,557
R6	372	1	7	5,19	1,615
R7	372	1	7	5,68	1,398

Izvor: autorica, obrada istraživanja siječanj, 2017.

Slika 24 prikazuje prosječne vrijednosti ocjena reputacije banke. Svih sedam navedenih konstrukata ispitanici su ocijenili s visokim ocjenama, višim od pet, pri čemu se posebno ističe konstrukt R4. Banka koja ima tradiciju (5,75).



Slika 24. Prosječne vrijednosti ocjena reputacije banke

Izvor: autorica, obrada istraživanja siječanj, 2017

Tablica 37 prikazuje koeficijente pouzdanosti dimenzija istraživanja: Sigurnost, Jednostavnost, Dostupnost, Kvaliteta i Reputacija. Podaci pokazuju kako je za sve dimenzije Cronbach's alpha veći od 0,8, što ukazuje na njihovu konzistentnost.

Tablica 37. Koeficijenti pouzdanosti dimenzija istraživanja

Dimenzija	Cronbach's alpha koeficijent
Sigurnost	0,929
Jednostavnost	0,927
Dostupnost	0,863
Kvaliteta	0,965
Reputacija	0,949

Izvor: autorica, obrada istraživanja siječanj, 2017

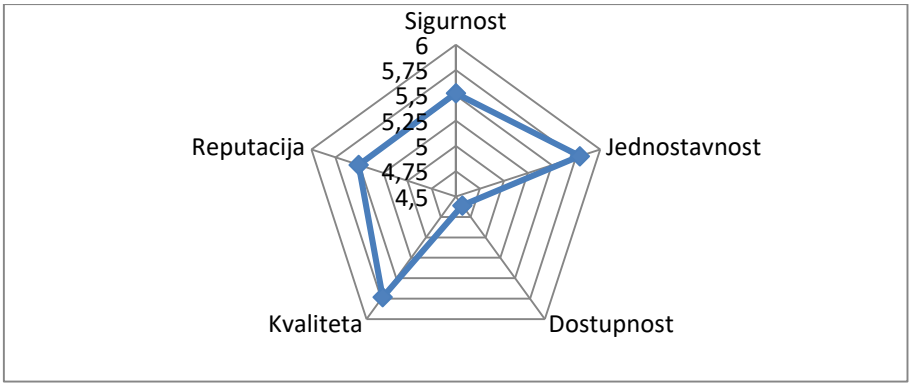
Tablica 38 prikazuje deskriptivnu statistiku prosječnih vrijednosti dimenzija istraživanja. Prosječne ocjene su iznad pet za četiri dimenzije: Sigurnost (5,52), Jednostavnost (5,79), Kvaliteta (5,73), Reputacija (5,51). Jedino dimenzija koja se odnosi na Dostupnost ima najmanju prosječnu ocjenu (4,61).

Tablica 38. Deskriptivna statistika prosječnih vrijednosti dimenzija istraživanja

	N	Min	Max	Prosjek	St. Dev.
Sigurnost	372	1,00	7,00	5,52	1,229
Jednostavnost	372	1,00	7,00	5,79	1,196
Dostupnost	372	1,00	7,00	4,61	1,421
Kvaliteta	372	1,00	7,00	5,73	1,283
Reputacija	372	1,00	7,00	5,51	1,332

Izvor: autorica, obrada istraživanja siječanj, 2017.

Slika 25 prikazuje prosječne vrijednosti ocjena dimenzija istraživanja. Najveću prosječnu ocjenu ima dimenzija Jednostavnost (5,79), dok najnižu prosječnu ocjenu ima dimenzija Dostupnost (4,61).



Slika 25. Prosječne vrijednosti ocjena dimenzija istraživanja

Izvor: autorica, obrada istraživanja siječanj, 2017.

Dimenzija kvalitete: K1 - Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna

Tablica 39 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu K1 (*Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna*). Formiran je model čiji je korigirani koeficijent determinacije 0,709 što ukazuje kako je modelom protumačeno 70,9% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 2,024, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 39. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K1

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,851[a]	0725	0,709	0,733	2,024
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6					
Zavisna varijabla: K1					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 40 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu K1 (*Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 40. Anova analiza regresijskog modela – Zavisna varijabla: K1

ANOVA						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	496,384	20	24,819	46,234	0,000***
	Neprotumačena odstupanja	188,422	351	0,537		
	Total	684,806	371			
Zavisna varijabla: K1						
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017.

Tablica 41 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu K1 (*Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna*). Osam nezavisnih varijabli imaju statistički značajan utjecaj na zavisnu varijablu.

Nezavisne varijable S2 (*Aplikacija mobilnog bankarstva je stabilna*), S5 (*Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća*) i D7 (*Aplikacija omogućava personaliziranu komunikaciju*) imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 5% vjerojatnosti dok nezavisne varijable J4 (Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno) i D1 (Aplikacija omogućava ugovaranje depozitnih proizvoda) imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 10% vjerojatnosti.

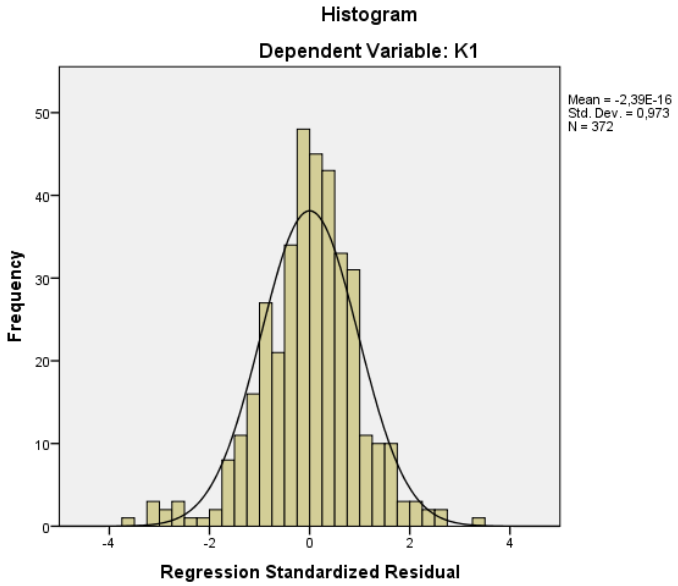
Nezavisne varijable koje imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti su: S4 (Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme), J3 (Pretraživanje aplikacije mobilnog bankarstva je jednostavno), D6 (Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)).

Tablica 41. Procjene parametara regresijskog modela - Zavisna varijabla: K1

Procjene parametara						
Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	P-vrijednost
		B	Stand. pogr.	Beta		
1	(Konstanta)	-0,172	0,206		-0,835	0,404
	S1	0,013	0,052	0,014	0,251	0,802
	S2	0,108	0,052	0,112	2,085	0,038**
	S3	0,047	0,044	0,051	1,065	0,288
	S4	0,147	0,052	0,150	2,821	0,005***
	S5	0,113	0,049	0,120	2,283	0,023**
	S6	-0,018	,050	-0,018	-0,353	0,724
	J1	-0,055	0,050	-0,056	-1,105	0,270
	J2	-0,022	0,045	-0,024	-0,489	0,625
	J3	0,226	0,058	0,229	3,878	0,000***
	J4	0,122	0,063	0,117	1,948	0,052*
	J5	0,007	0,035	0,008	0,207	0,836
	J6	0,090	0,071	0,085	1,261	0,208
	D1	0,056	0,030	0,082	1,861	0,064*
	D2	-0,013	0,028	-0,019	-0,466	0,641
	D3	0,021	0,030	0,030	0,702	0,483
	D4	0,032	0,024	0,050	1,323	0,187
	D5	-0,018	0,029	-0,028	-0,616	0,538
	D6	0,084	00,030	0,106	2,802	0,005***
	D7	0,068	0,027	0,095	2,572	0,011**
	D8	0,039	0,029	0,058	1,373	0,171
Zavisna varijabla: K1						

Napomena: *** 1% značajnosti, ** 5%, * 10%
Izvor: Autorica, obrada istraživanja siječanj, 2017.

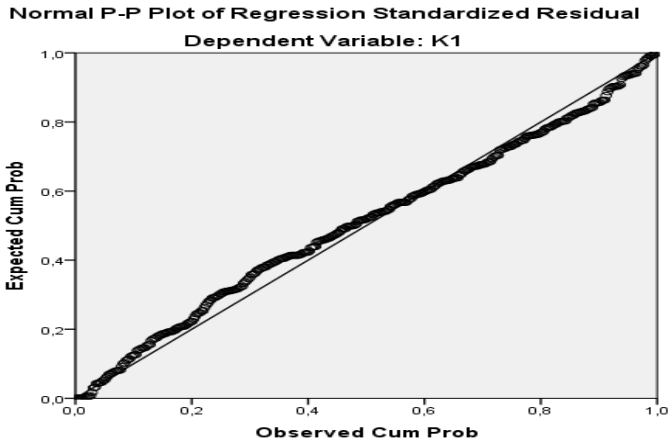
Slika 26 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable K1 (Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna). Grafikon pokazuje da je distribucija odgovora simetrična.



Slika 26. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K1

Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 27 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable K1 (Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna).
Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 27. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K1
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija kvalitete: K2 - Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete

Tablica 42 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*). Formiran je model čiji je korigirani koeficijent determinacije 0,721 što ukazuje kako je modelom protumačeno 72,1% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 2,164, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 42. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K2

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,858[a]	0,736	0,721	0,732	2,164
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6					
Zavisna varijabla: K2					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 43 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 43. Anova analiza regresijskog modela – Zavisna varijabla: K2

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	523,855	20	26,193	48,941	0,000***
	Neprotumačena odstupanja	187,852	351	0,535		
	Total	711,707	371			
Zavisna varijabla: K2						
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 44 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*). Deset nezavisnih varijabli imaju statistički značajan utjecaj na zavisnu varijablu.

Nezavisne varijable S2 (*Aplikacija mobilnog bankarstva je stabilna*), S4 (*Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme*), S5 (*Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća*) i D6 (*Aplikacija omogućava plaćanje 2d bar code-om (opcija*

slikaj i plati)) imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti, dok nezavisna varijabla D8 (*Preko aplikacije dobivam personalizirane ponude*) ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 10% vjerojatnosti.

Nezavisne varijable koje imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 5% vjerojatnosti su: J3 (Pretraživanje aplikacije mobilnog bankarstva je jednostavno), J4 (*Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno*), J5 (*Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno*), D1 (*Aplikacija omogućava ugovaranje depozitnih proizvoda*) i D7 (*Aplikacija omogućava personaliziranu komunikaciju*)

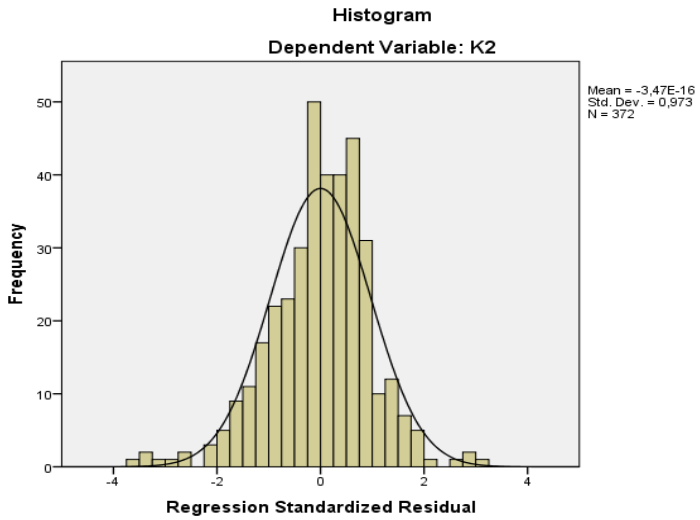
Tablica 44 Procjene parametara regresijskog modela - Zavisna varijabla: K2

Procjene parametara						
		Nestandardizirani koeficijenti		Standardizirani koeficijenti		
Model		B	Stand. pogr.	Beta	t	P-vrijednost
1	(Konstanta)	-0,152	0,205		-0,742	0,459
	S1	-0,030	0,052	-0,031	-0,566	0,572
	S2	0,145	0,052	0,148	2,801	0,005***
	S3	-0,001	0,044	-0,001	-0,024	0,981
	S4	0,188	0,052	0,188	3,616	0,000***
	S5	0,137	0,049	0,144	2,786	0,006***
	S6	-0,032	0,050	-0,033	-0,651	0,515
	J1	-0,067	0,050	-0,066	-1,349	0,178
	J2	-0,072	0,045	-0,077	-1,594	0,112
	J3	0,167	0,058	0,166	2,869	0,004**
	J4	0,136	0,063	0,129	2,182	0,030**
	J5	0,073	0,035	0,081	2,090	0,037**
	J6	0,108	0,071	0,100	1,523	0,129
	D1	0,065	0,030	0,093	2,161	0,031**
	D2	0,017	0,028	0,024	0,598	0,550
	D3	-0,030	0,030	-0,044	-1,029	0,304
	D4	0,027	0,024	0,042	1,128	0,260
	D5	-0,046	0,029	-0,070	-1,577	0,116
	D6	0,171	0,030	0,210	5,695	0,000***
	D7	0,056	0,026	0,077	2,128	0,034**
	D8	0,049	0,029	0,072	1,724	0,086*
Zavisna varijabla: K2						

Napomena: *** 1% značajnosti, ** 5%, * 10%

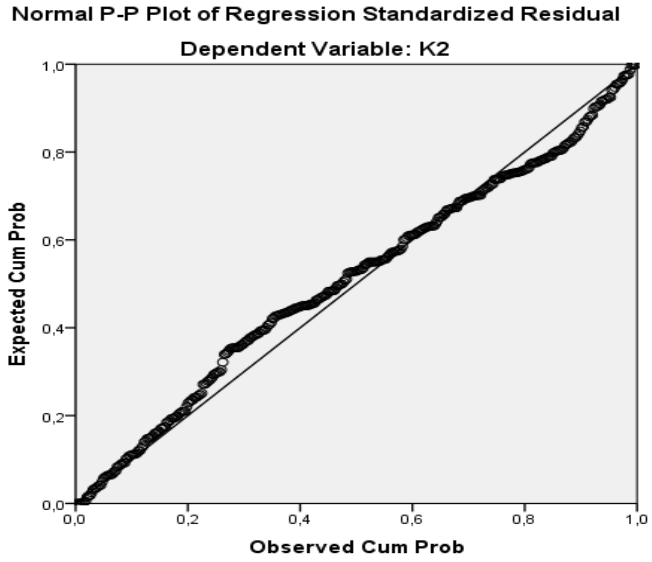
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 28 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*). Grafikon pokazuje da je distribucija odgovora simetrična.



Slika 28. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K2
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 29 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*). Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 29. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K2
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija kvalitete: K3 - Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja

Tablica 45 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu K3 (*Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja*). Formiran je model čiji je korigirani koeficijent determinacije 0,706 što ukazuje kako je modelom protumačeno 70,6% odstupanja zavisne varijable. Durbin-Watson koef. iznosi 1,997 čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 45. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K3

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,850[a]	0,722	0,706	0,776	1,997
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6					
Zavisna varijabla: K3					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 46 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu K3 (*Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 46. Anova analiza regresijskog modela – Zavisna varijabla: K3

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	548,030	20	27,401	45,536	0,000***
	Neprotumačena odstupanja	211,218	351	0,602		
	Total	759,247	371			
Zavisna varijabla: K3						
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 5. 28 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu K3 (*Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja*). Deset nezavisnih varijabli imaju statistički značajan utjecaj na zavisnu varijablu.

Nezavisne varijable S4 (*Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme*), J3 (*Pretraživanje aplikacije mobilnog bankarstva je jednostavno*), J6 (*Aplikacija mobilnog*

bankarstva je jednostavna za korištenje) i D6 (*Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati))* imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti, dok nezavisne varijable S5 (*Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća*) i J1 (*Preuzimanje i učitavanje aplikacije mobilnog bankarstva je jednostavno*) imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 5% vjerojatnosti.

Nezavisne varijable koje imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 10% vjerojatnosti su: S6 (*Korištenje aplikacije mobilnog bankarstva je sigurno*), D1 (*Aplikacija omogućava ugovaranje depozitnih proizvoda*), D2 (*Aplikacija omogućava ugovaranje i/ili popunjavanje zahtjeva za kreditne proizvode*) i D7 (*Aplikacija omogućava personaliziranu komunikaciju*).

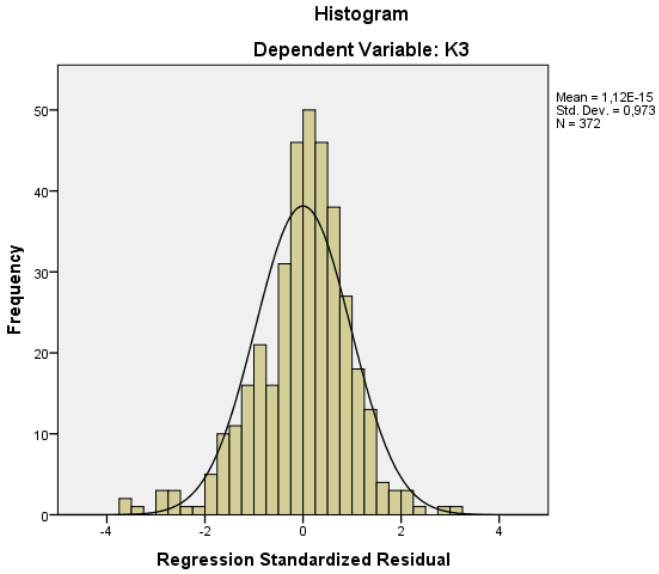
Tablica 47. Procjene parametara regresijskog modela - Zavisna varijabla: K3

Procjene parametara						
Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	P-vrijednost
		B	Stand. pogr.	Beta		
1	(Konstanta)	-0,347	0,218		-1,595	0,112
	S1	-0,064	0,056	-0,064	-1,149	0,251
	S2	0,073	0,055	0,072	1,324	0,186
	S3	-0,029	0,047	-0,030	-0,610	0,542
	S4	0,205	0,055	0,199	3,723	0,000***
	S5	0,130	0,052	0,131	2,484	0,013**
	S6	0,092	0,053	0,091	1,740	0,083*
	J1	0,127	0,053	0,122	2,409	0,016**
	J2	-0,019	0,048	-0,020	-0,395	0,693
	J3	0,194	0,062	0,187	3,153	0,002***
	J4	0,078	0,066	0,072	1,183	0,238
	J5	-0,014	0,037	-0,015	-0,371	0,711
	J6	0,283	0,075	0,254	3,748	0,000***
	D1	0,057	0,032	0,080	1,800	0,073*
	D2	0,049	0,029	0,069	1,659	0,098*
	D3	-0,012	0,031	-0,017	-0,381	0,703
	D4	-0,024	0,026	-0,036	-0,942	0,347
	D5	0,033	0,031	0,049	1,065	0,287
	D6	0,102	0,032	0,122	3,210	0,001***
	D7	0,050	0,028	0,066	1,782	0,076*
	D8	0,027	0,030	0,038	0,898	0,370
Zavisna varijabla: K3						

Napomena: *** 1% značajnosti, ** 5%, * 10%

Izvor: Autorica, obrada istraživanja siječanj, 2017

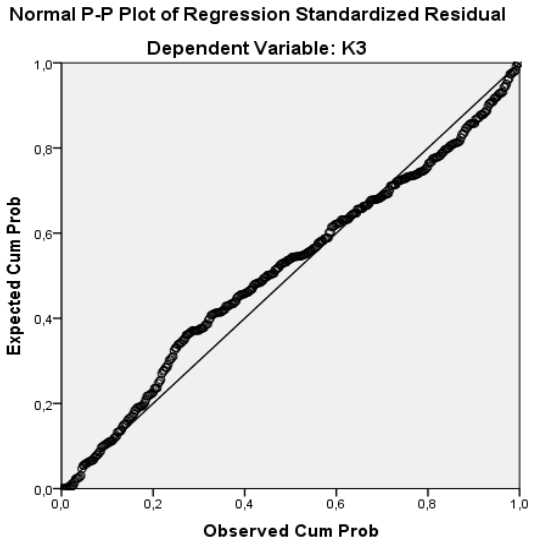
Slika 30 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable K3 (*Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja*). Grafikon pokazuje da je distribucija odgovora simetrična.



Slika 30. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K3

Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 31 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable K3 (Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja). Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 31. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K3

Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija kvalitete: K4 - Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan

Tablica 48 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*). Formiran je model čiji je korigirani koeficijent determinacije 0,735 što ukazuje kako je modelom protumačeno 73,5% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 2,137, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 48. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K4

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,865[a]	0,749	0,735	0,666	2,137
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6					
Zavisna varijabla: K4					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 49 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 49. Anova analiza regresijskog modela – Zavisna varijabla: K4

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	464,324	20	23,216	52,334	0,000***
	Neprotumačena odstupanja	155,708	351	0,444		
	Total	620,032	371			
Zavisna varijabla: K4						
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 50 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*). Sedam nezavisnih varijabli imaju statistički značajan utjecaj na zavisnu varijablu.

Nezavisne varijable S2 (*Aplikacija mobilnog bankarstva je stabilna*), S6 (*Korištenje aplikacije mobilnog bankarstva je sigurno*), J6 (*Aplikacija mobilnog bankarstva je jednostavna za korištenje*) i D6 (*Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)*) imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti dok nezavisna varijabla J5 (*Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno*) ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 10% vjerojatnosti.

Nezavisne varijable koje imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 5% vjerojatnosti su: S5 (*Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća*) i D1 (*Aplikacija omogućava ugovaranje depozitnih proizvoda*).

Tablica 50. Procjene parametara regresijskog modela - Zavisna varijabla: K4

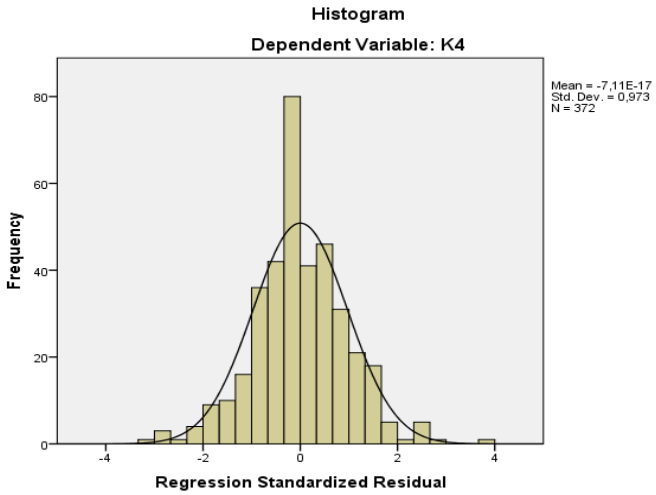
Procjene parametara						
Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	P-vrijednost
		B	Stand. pogr.	Beta		
1	(Konstanta)	0,086	0,187		0,459	0,647
	S1	-0,060	0,048	-0,066	-1,255	0,210
	S2	0,159	0,047	0,173	3,370	0,001***
	S3	0,003	0,040	0,003	0,073	0,942
	S4	0,046	0,047	0,049	0,965	0,335
	S5	0,093	0,045	0,104	2,064	0,040**
	S6	0,229	0,045	0,251	5,044	0,000***
	J1	-0,005	0,045	-0,005	-0,112	0,911
	J2	-0,022	0,041	-0,025	-0,523	0,601
	J3	0,029	0,053	0,031	0,555	0,579
	J4	0,082	0,057	0,083	1,437	0,151
	J5	0,055	0,032	0,066	1,734	0,084*
	J6	0,219	0,065	0,218	3,389	0,001***
	D1	0,060	0,027	0,092	2,178	0,030**
	D2	-0,004	0,025	-0,006	-0,151	0,880
	D3	-0,044	0,027	-0,067	-1,628	0,104
	D4	0,001	0,022	0,002	0,059	0,953
	D5	0,021	0,027	0,035	0,795	0,427
	D6	0,087	0,027	0,115	3,190	0,002***
	D7	0,023	0,024	0,034	0,974	0,331
	D8	0,034	0,026	0,053	1,296	0,196
Zavisna varijabla: K4						

Napomena: *** 1% značajnosti, ** 5%, * 10%

Izvor: Autorica, obrada istraživanja siječanj, 2017

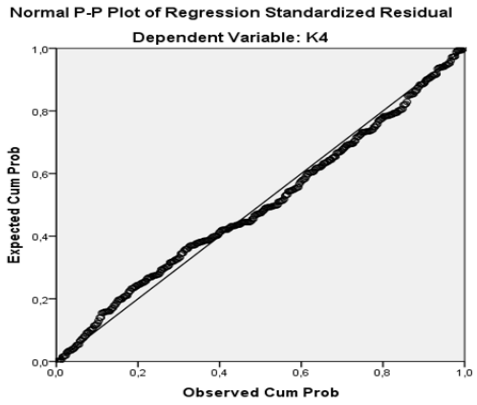
Slika 32 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja*

mobilnog bankarstva moje glavne banke je adekvatan). Grafikon pokazuje da je distribucija odgovora simetrična.



Slika 32 Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K4
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 33 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*). Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 33. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K4
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija kvalitete: K5 - Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke

Tablica 51 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu K5 (*Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke*). Formiran je model čiji je korigirani koeficijent determinacije 0,728 što ukazuje kako je modelom protumačeno 72,8% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 2,186, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 51. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K5

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,862[a]	0,742	0,728	0,720	2,186
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6					
Zavisna varijabla: K5					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 52 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu K5 (*Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 52. Anova analiza regresijskog modela – Zavisna varijabla: K5

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	523,226	20	26,161	50,535	0,000***
	Neprotumačena odstupanja	181,707	351	0,518		
	Total	704,933	371			
Zavisna varijabla: K5						
Nezavisne varijable: (Konstanta), D8, S2, D4, D6, D1, J5, D7, J1, D2, D3, S3, S6, D5, J2, S5, J4, S4, S1, J3, J6						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 5. 34 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu K5 (*Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke*). Pet nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu. Nezavisne varijable S2 (*Aplikacija mobilnog bankarstva je stabilna*), J6 (*Aplikacija mobilnog bankarstva je jednostavna za korištenje*), D1 (*Aplikacija omogućava ugovaranje depozitnih proizvoda*) i D6 (*Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)*), dok

nezavisna varijabla J4 (*Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno*) ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 5% vjerojatnosti.

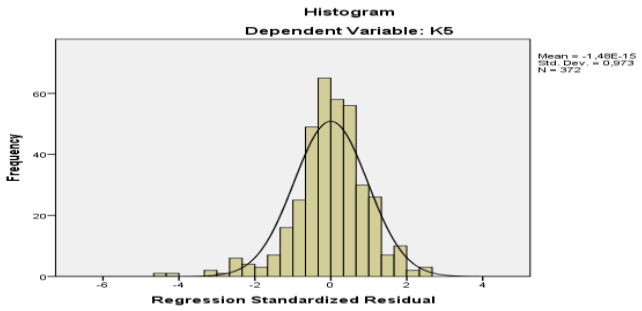
Tablica 53. Procjene parametara regresijskog modela - Zavisna varijabla: K5

Procjene parametara						
Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	P-vrijednost
		B	Stand. pogr.	Beta		
1	(Konstanta)	-0,219	0,202		-1,084	0,279
	S1	-0,022	0,052	-0,022	-0,419	0,676
	S2	0,166	0,051	0,169	3,252	0,001***
	S3	0,036	0,043	0,039	0,832	0,406
	S4	0,047	0,051	0,048	0,930	0,353
	S5	0,072	0,049	0,076	1,492	0,137
	S6	0,081	0,049	0,083	1,645	0,101
	J1	-0,072	0,049	-0,072	-1,476	0,141
	J2	0,015	0,045	0,016	0,333	0,739
	J3	0,077	0,057	0,077	1,340	0,181
	J4	0,127	0,061	0,120	2,064	0,040**
	J5	-0,029	0,034	-0,033	-0,848	0,397
	J6	0,281	0,070	0,262	4,023	0,000***
	D1	0,089	0,030	0,128	2,989	0,003***
	D2	0,003	0,027	0,004	0,095	0,924
	D3	-0,002	0,029	-0,003	-0,071	0,943
	D4	0,020	0,024	0,031	0,833	0,405
	D5	0,020	0,029	0,030	0,689	0,491
	D6	0,129	0,029	0,160	4,391	0,000***
	D7	0,017	0,026	0,024	0,662	0,509
	D8	0,017	0,028	0,025	0,612	0,541
Zavisna varijabla: K5						

Napomena: *** 1% značajnosti, ** 5%

Izvor: Autorica, obrada istraživanja siječanj, 2017

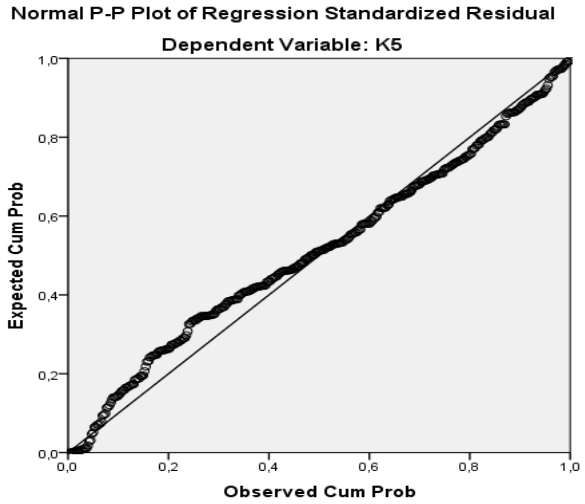
Slika 34 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable K5 (*Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke*). Grafikon pokazuje da je distribucija odgovora desno asimetrična.



Slika 33. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K5

Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 35 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable K5 (Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke). Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 34. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K5
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija reprezentativnosti: R1 - Banka za koju imam dobar osjećaj

Tablica 54 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu R1 (*Banka za koju imam dobar osjećaj*). Formiran je model čiji je korigirani koeficijent determinacije 0,441 što ukazuje kako je modelom protumačeno 44,1% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 1,919, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 54. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R1

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,670[a]	0,449	0,441	1,117	1,919
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2					
Zavisna varijabla: R1					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 55 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu R1 (*Banka za koju imam dobar osjećaj*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 55. Anova analiza regresijskog modela – Zavisna varijabla: R1

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	372,102	5	74,420	59,618	0,000***
	Neprotumačena odstupanja	456,874	366	1,248		
	Total	828,976	371			
Zavisna varijabla: R1						
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 56 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu R1 (*Banka za koju imam dobar osjećaj*). Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu.

Nezavisne varijable koje imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti su: K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*) i K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*).

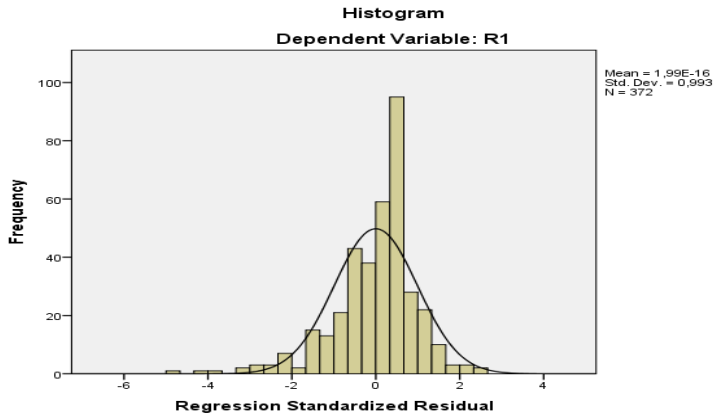
Tablica 56. Procjene parametara regresijskog modela - Zavisna varijabla: R1

Procjene parametara						
		Nestandardizirani koeficijenti		Standardizirani koeficijenti		
Model		B	Stand. pogr.	Beta	t	P-vrijednost
1	(Konstanta)	1,026	0,271		3,793	0,000
	K1	0,087	0,096	0,079	0,899	0,369
	K2	0,422	0,103	0,391	4,082	0,000***
	K3	-0,152	0,100	-0,145	-1,520	0,129
	K4	0,402	0,106	0,348	3,793	0,000***
	K5	0,024	0,110	0,022	0,220	0,826
Zavisna varijabla: R1						

Napomena: *** 1% značajnosti

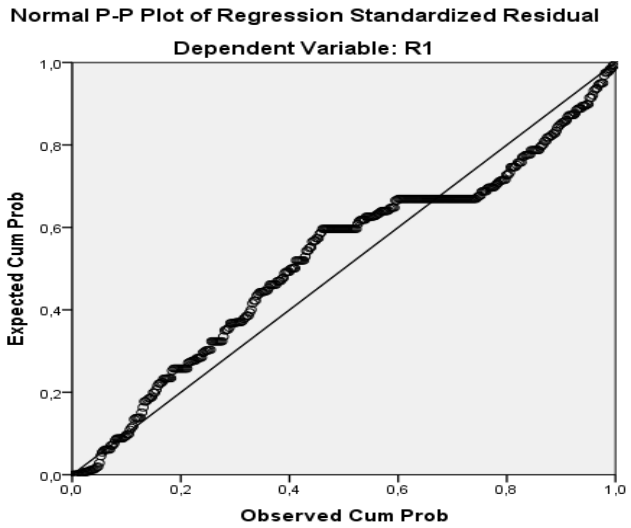
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 36 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable R1 (*Banka za koju imam dobar osjećaj*). Grafikon pokazuje da je distribucija odgovora desno asimetrična.



Slika 35. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R1
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 37 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable R1 (Banka za koju imam dobar osjećaj).Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 36. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R1
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija reprezentativnosti: R2 - Banka kojoj vjerujem

Tablica 57 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu R2 (*Banka kojoj vjerujem*). Formiran je model čiji je korigirani koeficijent determinacije 0,450 što ukazuje kako je modelom protumačeno 45,0% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 1,819, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 57. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R2

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,676[a]	0,458	0,450	1,181	1,819
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2					
Zavisna varijabla: R2					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 58 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu R2 (*Banka kojoj vjerujem*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 58. Anova analiza regresijskog modela – Zavisna varijabla: R2

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	430,525	5	86,105	61,756	0,000***
	Neprotumačena odstupanja	510,303	366	1,394		
	Total	940,828	371			
Zavisna varijabla: R2						
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 59 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu R2 (*Banka kojoj vjerujem*). Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu.

Nezavisne varijable koje imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti su: K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*) i

K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*).

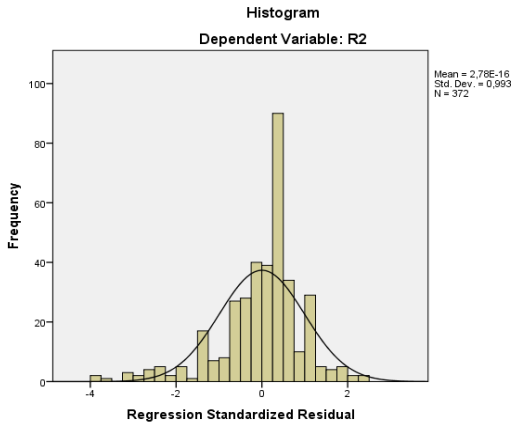
Tablica 59. Procjene parametara regresijskog modela - Zavisna varijabla: R2

Procjene parametara						
Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	P-vrijednost
		B	Stand. pogr.	Beta		
1	(Konstanta)	0,661	0,286		2,311	0,021
	K1	0,041	0,102	0,035	0,404	0,686
	K2	0,429	0,109	0,373	3,929	0,000***
	K3	-0,006	0,105	-0,005	-0,054	0,957
	K4	0,417	0,112	0,338	3,716	0,000***
	K5	-0,039	0,117	-0,034	-0,338	0,735
Zavisna varijabla: R2						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

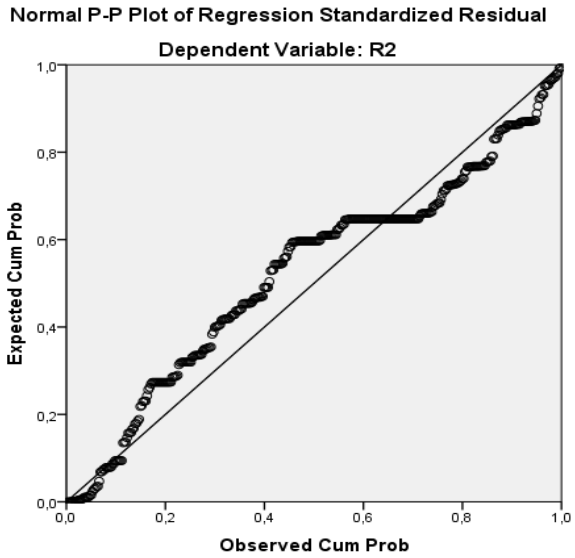
Slika 38 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable R2 (*Banka kojoj vjerujem*). Grafikon pokazuje da je distribucija odgovora desno asimetrična.



Slika 37. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R2

Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 39 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable R2 (*Banka kojoj vjerujem*).Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 38. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R2
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija reprezentativnosti: R3 - Banka koju poštujem

Tablica 60 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu R3 (*Banka koju poštujem*). Formiran je model čiji je korigirani koeficijent determinacije 0,380 što ukazuje kako je modelom protumačeno 38,0% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 1,822, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 60 Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R3

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,623[a]	0,388	0,380	1,265	1,822
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2					
Zavisna varijabla: R3					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 61 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu R3 (*Banka koju poštujem*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 61. Anova analiza regresijskog modela – Zavisna varijabla: R3

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	371,925	5	74,385	46,491	0,000***
	Neprotumačena odstupanja	585,591	366	1,600		
	Total	957,516	371			
Zavisna varijabla: R3						
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 62 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu R3 (*Banka koju poštujem*).

Nezavisna varijabla koja ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti je K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*).

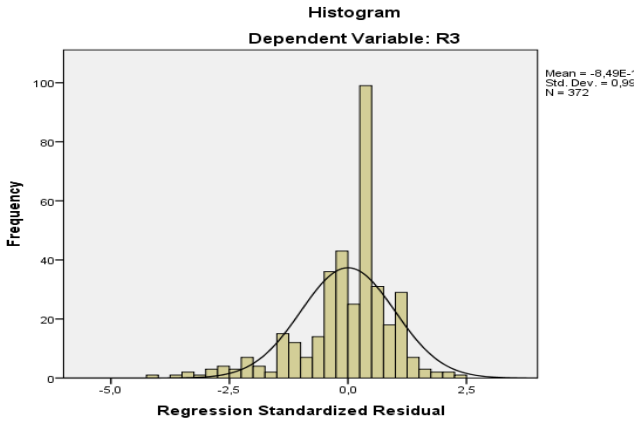
Tablica 62. Procjene parametara regresijskog modela - Zavisna varijabla: R3

Procjene parametara						
		Nestandardizirani koeficijenti		Standardizirani koeficijenti		
Model		B	Stand. pogr.	Beta	t	P-vrijednost
1	(Konstanta)	1,001	0,306		3,265	0,001
	K1	0,111	0,109	0,094	1,017	0,310
	K2	0,472	0,117	0,407	4,036	0,000***
	K3	0,010	0,113	0,009	0,087	0,931
	K4	0,198	0,120	0,159	1,644	0,101
	K5	-0,020	0,125	-0,017	-0,163	0,871
Zavisna varijabla: R3						

Napomena: *** 1% značajnosti

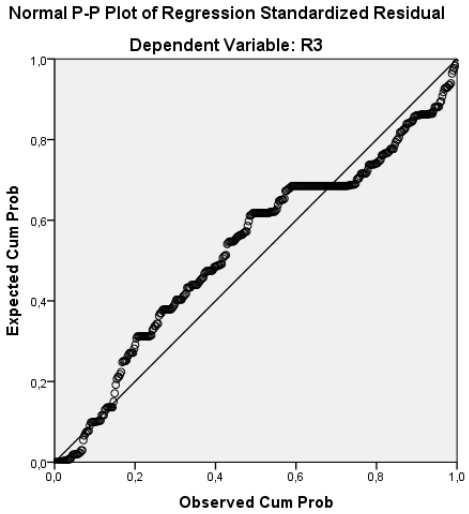
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 40 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable R3 (*Banka koju poštujem*). Grafikon pokazuje da je distribucija odgovora desno asimetrična.



Slika 39. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R3
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 41 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable R3 (*Banka koju poštujem*).Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 40. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R3
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija reprezentativnosti: R4 - Banka koja ima tradiciju

Tablica 63 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu R4 (*Banka koja ima tradiciju*). Formiran je model čiji je korigirani koeficijent determinacije 0,391 što ukazuje kako je modelom protumačeno 39,1% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 2,049, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 63. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R4

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,632[a]	0,399	0,391	1,075	2,049
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2					
Zavisna varijabla: R4					

Izvor: Autor, obrada istraživanja siječanj, 2017

Tablica 64 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu R4 (*Banka koja ima tradiciju*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 64. Anova analiza regresijskog modela – Zavisna varijabla: R4

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	280,918	5	56,184	48,632	0,000***
	Neprotumačena odstupanja	422,832	366	1,155		
	Total	703,750	371			
Zavisna varijabla: R4						
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 65 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu R4 (*Banka koja ima tradiciju*). Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu.

Nezavisna varijabla koja ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti je K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*), dok nezavisna varijabla koja ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 5% vjerojatnosti je K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*).

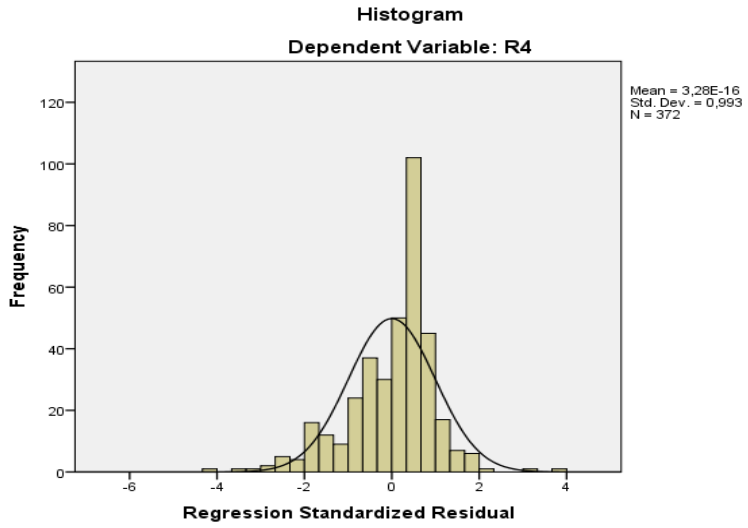
Tablica 65. Procjene parametara regresijskog modela - Zavisna varijabla: R4

Procjene parametara						
Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	P-vrijednost
		B	Stand. pogr.	Beta		
1	(Konstanta)	1,873	0,260		7,192	0,000
	K1	0,104	0,093	0,103	1,123	0,262
	K2	0,337	0,099	0,339	3,391	0,001***
	K3	0,022	0,096	0,023	0,230	0,818
	K4	0,227	0,102	0,213	2,225	0,027**
	K5	-0,012	0,106	-0,012	-0,114	0,909
Zavisna varijabla: R4						

Napomena: *** 1% značajnosti, ** 5%

Izvor: Autorica, obrada istraživanja siječanj, 2017

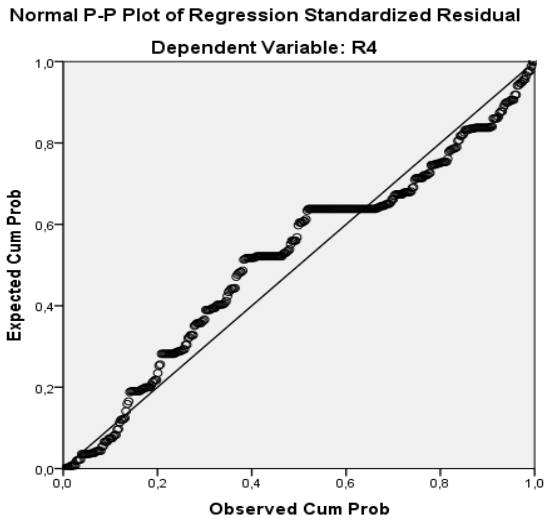
Slika 42 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable R4 (*Banka koja ima tradiciju*). Grafikon pokazuje da je distribucija odgovora desno asimetrična.



Slika 41. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R4

Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 43 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable R4 (*Banka koja ima tradiciju*). Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 42. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R4

Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija reprezentativnosti: R5 - Banka koja ima snagu međunarodne organizacije

Tablica 66 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu R5 (*Banka koja ima snagu međunarodne organizacije*). Formiran je model čiji je korigirani koeficijent determinacije 0,364 što ukazuje kako je modelom protumačeno 36,4% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 1,927, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 66. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R5

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,610[a]	0,372	0,364	1,242	1,927
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2					
Zavisna varijabla: R5					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 67 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu R5 (*Banka koja ima snagu međunarodne organizacije*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 67. Anova analiza regresijskog modela – Zavisna varijabla: R5

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	334,776	5	66,955	43,379	0,000***
	Neprotumačena odstupanja	564,923	366	1,544		
	Total	899,699	371			
Zavisna varijabla: R5						
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 68 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu R5 (*Banka koja ima snagu međunarodne organizacije*). Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu. Nezavisna varijabla koja ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti je K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*), dok nezavisna varijabla koja ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 10% vjerojatnosti je K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*).

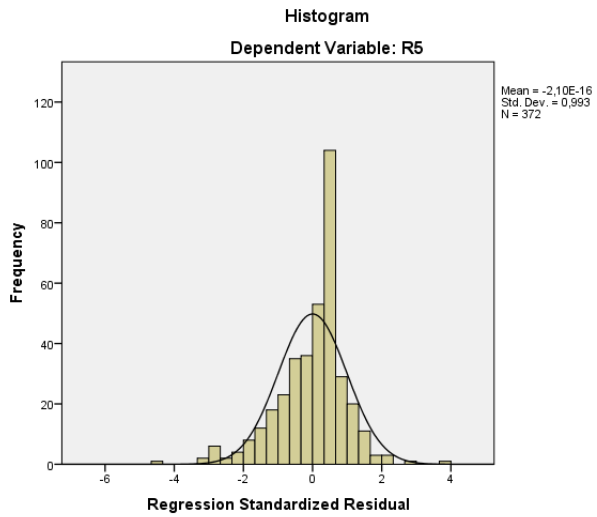
Tablica 68. Procjene parametara regresijskog modela - Zavisna varijabla: R5

Procjene parametara						
		Nestandardizirani koeficijenti		Standardizirani koeficijenti		
Model		B	Stand. pogr.	Beta	t	P-vrijednost
1	(Konstanta)	1,327	0,301		4,408	0,000
	K1	-0,023	0,107	-0,020	-0,219	0,827
	K2	0,327	0,115	0,291	2,845	0,005***
	K3	0,086	0,111	0,079	0,777	0,438
	K4	0,225	0,118	0,187	1,909	0,057*
	K5	0,121	0,123	0,107	0,985	0,325
Zavisna varijabla: R5						

Napomena: *** 1% značajnosti, * 10%

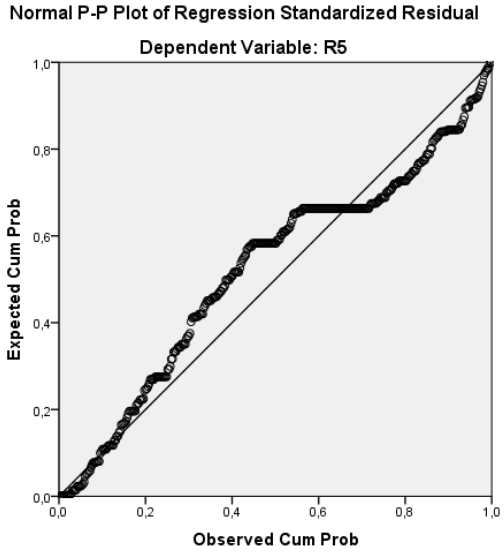
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 44 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable R5 (*Banka koja ima snagu međunarodne organizacije*). Grafikon pokazuje da je distribucija odgovora desno asimetrična.



Slika 43. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R5
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 45 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable R5 (*Banka koja ima snagu međunarodne organizacije*).Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 44. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R5
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija reprezentativnosti: R6 - Banka koja cijeni mene kao klijenta

Tablica 69 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu R6 (*Banka koja cijeni mene kao klijenta*). Formiran je model čiji je korigirani koeficijent determinacije 0,284 što ukazuje kako je modelom protumačeno 28,4% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 1,947, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 69. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R6

Pokazatelji reprezentativnosti					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,542[a]	0,293	0,284	1,367	1,947
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2					
Zavisna varijabla: R6					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 70 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu R6 (*Banka koja cijeni mene kao klijenta*). Anova analiza za prikazani model je statistički značajna uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 70. Anova analiza regresijskog modela – Zavisna varijabla: R6

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	283,993	5	56,799	30,383	0,000***
	Neprotumačena odstupanja	684,209	366	1,869		
	Total	968,202	371			
Zavisna varijabla: R6						
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 71 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu R6 (*Banka koja cijeni mene kao klijenta*). Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu. Nezavisna varijabla koja ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti je K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*), dok nezavisna varijabla koja ima statistički značajan pozitivan utjecaj na zavisnu varijablu uz 5% vjerojatnosti je K4 (*Prosječan rezultat ukupne procjene*

pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan).

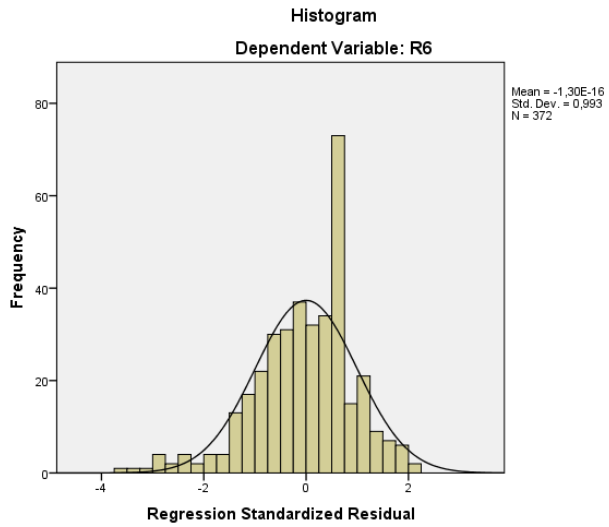
Tablica 71. Procjene parametara regresijskog modela - Zavisna varijabla: R6

Procjene parametara						
Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	P-vrijednost
		B	Stand. pogr.	Beta		
1	(Konstanta)	1,323	0,331		3,996	0,000
	K1	0,040	0,118	0,034	0,338	0,736
	K2	0,448	0,126	0,384	3,542	0,000***
	K3	-0,071	0,122	-0,063	-0,581	0,561
	K4	0,279	0,130	0,224	2,152	0,032**
	K5	-0,021	0,135	-0,018	-0,158	0,874
Zavisna varijabla: R6						

Napomena: *** 1% značajnosti, ** 5%

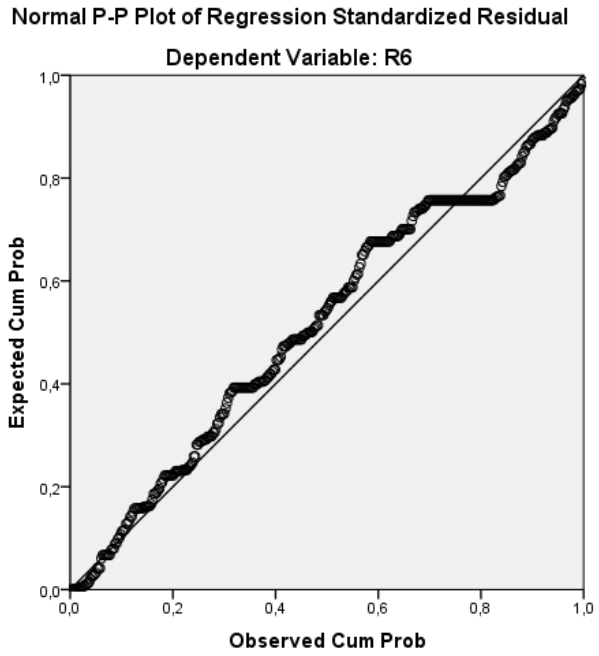
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 46 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable R6 (*Banka koja cijeni mene kao klijenta*). Grafikon pokazuje da je distribucija odgovora desno asimetrična.



Slika 45. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R6
Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 47 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable R6 (Banka koja cijeni mene kao klijenta). Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 46. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R6
Izvor: Autorica, obrada istraživanja siječanj, 2017

Dimenzija reprezentativnosti: R7 - Banka ima dobru ukupnu reputaciju

Tablica 72 prikazuje pokazatelje reprezentativnosti regresijskog modela uz zavisnu varijablu R7 (*Banka ima dobru ukupnu reputaciju*). Formiran je model čiji je korigirani koeficijent determinacije 0,382 što ukazuje kako je modelom protumačeno 38,2% odstupanja zavisne varijable. Durbin-Watson koeficijent iznosi 2,047, čime se može zaključiti kako u modelu ne postoji probem autokorelacije.

Tablica 72. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R7

Reprezentativnost[b]					
Model	R	Koeficijent determinacije	Korigirani koeficijent determinacije	Stand. pogr.	Durbin-Watson
1	0,625[a]	0,390	0,382	1,099	2,047
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2					
Zavisna varijabla: R7					

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 73 prikazuje rezultate Anova analize regresijskog modela uz zavisnu varijablu R7 (*Banka ima dobru ukupnu reputaciju*). Anova analiza za prikazani model je statistički značajna

uz 1% vjerojatnosti, što ukazuje kako barem jedna od nezavisnih varijabli ima statistički značajan utjecaj na zavisnu varijablu.

Tablica 73. Anova analiza regresijskog modela – Zavisna varijabla: R7

ANOVA[a]						
Model		Suma kvadrata	df	Sredina kvadrata	F	P-vrijednost
1	Protumačen modelom	282,931	5	56,586	46,856	0,000***
	Neprotumačena odstupanja	442,001	366	1,208		
	Total	724,933	371			
Zavisna varijabla: R7						
Nezavisne varijable: (Konstanta), K5, K1, K4, K3, K2						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 74 prikazuje procjenu vrijednosti parametara regresijskog modela uz zavisnu varijablu R7 (*Banka ima dobru ukupnu reputaciju*). Osam nezavisnih varijabli imaju statistički značajan utjecaj na zavisnu varijablu. Dvije nezavisne varijable koje imaju statistički značajan pozitivan utjecaj na zavisnu varijablu uz 1% vjerojatnosti su: K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*) i K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*).

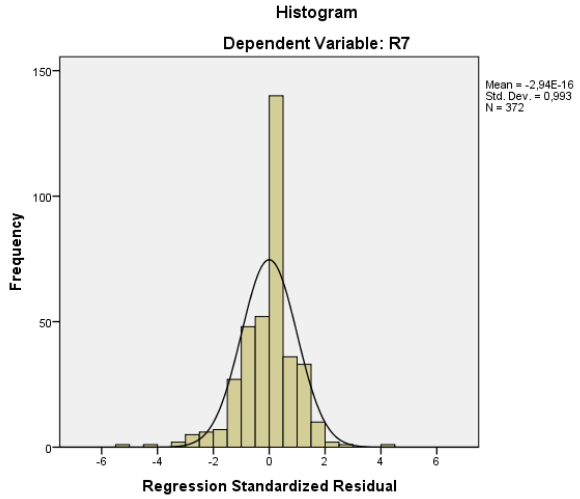
Tablica 74. Procjene parametara regresijskog modela - Zavisna varijabla: R7

Procjene parametara						
		Nestandardizirani koeficijenti		Stand. koef.		
Model		B	Stand. pogr.	Beta	t	P-vrijednost
1	(Konstanta)	1,761	0,266		6,614	0,000
	K1	-0,014	0,095	-0,014	-0,151	0,880
	K2	0,306	0,102	0,304	3,015	0,003***
	K3	-0,041	0,098	-0,042	-0,415	0,678
	K4	0,278	0,104	0,257	2,661	0,008***
	K5	0,152	0,109	0,150	1,401	0,162
Zavisna varijabla: R7						

Napomena: *** 1% značajnosti

Izvor: Autorica, obrada istraživanja siječanj, 2017

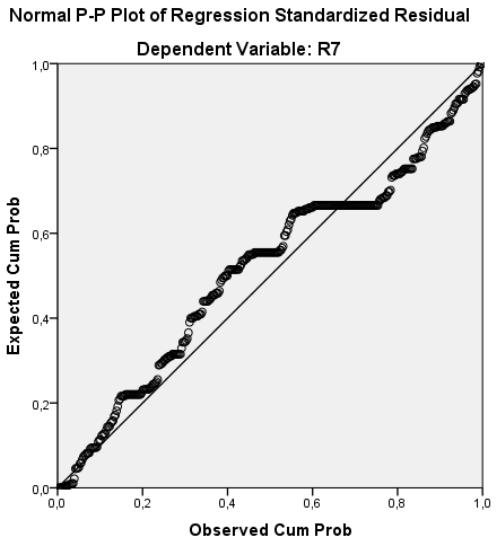
Slika 48 prikazuje histogram reziduala (neprotumačenih odstupanja) zavisne varijable R7 (*Banka ima dobru ukupnu reputaciju*). Grafikon pokazuje da je distribucija odgovora simetrična.



Slika 47. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R7

Izvor: Autorica, obrada istraživanja siječanj, 2017

Slika 49 prikazuje normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable R7 (*Banka ima dobru ukupnu reputaciju*). Grafikon potvrđuje rezultate testa o normalnosti reziduala.



Slika 48. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R7

Izvor: Autorica, obrada istraživanja siječanj, 2017

5.4 Diskusija rezultata istraživanja

Tablica 75 prikazuje sumarne rezultate regresijskih modela za sljedeće zavisne varijable: K1 (*Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna*), K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*), K3 (*Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja*), K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*) i K5 (*Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke*).

Nezavisne varijable, koje se odnose na sigurnost mobilnog bankarstva, statistički su značajno povezane s većinom zavisnih varijabli. Nezavisne varijable S2 (*Aplikacija mobilnog bankarstva je stabilna*) i S5 (*Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća*) imaju statistički značajan pozitivan utjecaj na četiri zavisne varijable.

Nezavisne varijable, koje se odnose na jednostavnost korištenja mobilnog bankarstva, statistički su značajno povezane s najmanje zavisnih varijabli. Nezavisne varijable J3 (*Pretraživanje aplikacije mobilnog bankarstva je jednostavno*), J4 (*Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno*) i J6 (*Aplikacija mobilnog bankarstva je jednostavna za korištenje*) imaju statistički značajan pozitivan utjecaj na tri zavisne varijable.
Nezavisne varijable, koje se odnose na dostupnost usluga mobilnog bankarstva, statistički su značajno povezane s većinom zavisnih varijabli. Nezavisne varijable D1 (*Aplikacija omogućava ugovaranje depozitnih proizvoda*) i D6 (*Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)*) imaju statistički značajan pozitivan utjecaj na sve zavisne varijable.

Durbin-Watson koeficijent je približno jednak dva i više za gotovo sve varijable čime se može zaključiti kako u modelu ne postoji probem autokorelacije. Vrijednosti korigiranog koeficijenta determinacije kreću se u rasponu od 0,706 do 0,735.

Tablica 75. Sumarni rezultati regresijskih modela – Zavisne varijable: K1, K2, K3, K4, K5

	K1	K2	K3	K4	K5
(Konstanta)	-0,172	-0,152	-0,347	0,086	-0,219
S1	0,013	-0,030	-0,064	-0,060	-0,022
S2	0,108**	0,145***	0,073	0,159***	0,166***
S3	0,047	-0,001	-0,029	0,003	0,036
S4	0,147***	0,188***	0,205***	0,046	0,047
S5	0,113**	0,137***	0,130**	0,093**	0,072
S6	-0,018	-0,032	0,092*	0,229***	0,081
J1	-0,055	-0,067	0,127**	-0,005	-0,072
J2	-0,022	-0,072	-0,019	-0,022	0,015
J3	0,226***	0,167**	0,194***	0,029	0,077
J4	0,122*	0,136**	0,078	0,082	0,127**
J5	0,007	0,073**	-0,014	0,055*	-0,029
J6	0,090	0,108	0,283***	0,219***	0,281***
D1	0,056*	0,065**	0,057*	0,060**	0,089***
D2	-0,013	0,017	0,049*	-0,004	0,003
D3	0,021	-0,030	-0,012	-0,044	-0,002
D4	0,032	0,027	-0,024	0,001	0,020
D5	-0,018	-0,046	0,033	0,021	0,020
D6	0,084***	0,171***	0,102***	0,087***	0,129***
D7	0,068**	0,056**	0,050*	0,023	0,017
D8	0,039	0,049*	0,027	0,034	0,017
Prilagođeni koeficijent determinacije	0,709	0,721	0,706	0,735	0,728
Durbin-Watson	2,024	2,164	1,997	2,137	2,186

Napomena: *** 1% značajnosti, ** 5%, * 10%

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 76 prikazuje testiranje hipoteza korištenjem regresijskih modela za pet zavisnih varijabli: K1, K2, K3, K4, K5 koje se odnose na percipiranu kvalitetu usluga mobilnog bankarstva.

Na zavisnu varijablu *K1. Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna* statistički značajan utjecaj ima osam nezavisnih varijabli iz sljedećih dimenzija: *Sigurnost, Jednostavnost* i *Dostupnost.* Tri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K1. Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna* unutar dimenzije *Sigurnost.* Varijable *S2. Aplikacija mobilnog bankarstva je stabilna* i *S5. Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća* imaju pozitivan utjecaj uz 5% značajnosti na zavisnu varijablu K1, dok varijabla *S4. Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme* ima pozitivan utjecaj uz 1% značajnosti. Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K1. Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna* unutar dimenzije *Jednostavnost.* Varijabla *J3. Pretraživanje aplikacije mobilnog*

bankarstva je jednostavno ima pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu K1, dok varijabla *J4. Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno* ima pozitivan utjecaj uz 10% značajnosti. Tri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K1. Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna* unutar dimenzije *Dostupnost.* Varijabla *D1. Aplikacija omogućava ugovaranje depozitnih proizvoda* ima pozitivan utjecaj uz 10% značajnosti na zavisnu varijablu K1, varijabla *D6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)* ima pozitivan utjecaj uz 1% značajnosti, dok varijabla *D7. Aplikacija omogućava personaliziranu komunikaciju* ima pozitivan utjecaj uz 5% značajnosti.

Na zavisnu varijablu *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* statistički značajan utjecaj ima devet nezavisnih varijabli iz sljedećih dimenzija: *Sigurnost, Jednostavnost* i *Dostupnost.* Tri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* unutar dimenzije *Sigurnost.* Varijable *S2. Aplikacija mobilnog bankarstva je stabilna, S4. Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme* i *S5. Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća* imaju pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu K2. Tri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* unutar dimenzije *Jednostavnost.* Varijable *J3. Pretraživanje aplikacije mobilnog bankarstva je jednostavno, J4. Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno* i *J5. Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno* imaju pozitivan utjecaj uz 5% značajnosti na zavisnu varijablu K2. Tri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* unutar dimenzije *Dostupnost.* Varijable *D1. Aplikacija omogućava ugovaranje depozitnih proizvoda* i *D7. Aplikacija omogućava personaliziranu komunikaciju* imaju pozitivan utjecaj uz 5% značajnosti na zavisnu varijablu K2, dok varijabla *D6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)* ima pozitivan utjecaj uz 1% značajnosti.

Na zavisnu varijablu *K3.Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja* statistički značajan utjecaj ima deset nezavisnih varijabli iz sljedećih dimenzija: *Sigurnost, Jednostavnost* i *Dostupnost.* Tri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K3.Aplikacija mobilnog bankarstva moje glavne*

banke u potpunosti zadovoljava moje potrebe i očekivanja unutar dimenzije *Sigurnost.* Varijabla *S4. Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme* ima pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu K3, varijabla *S5. Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća* ima pozitivan utjecaj uz 5% značajnosti, dok varijabla *S6. Korištenje aplikacije mobilnog bankarstva je sigurno* – pozitivan utjecaj uz 10% značajnosti na zavisnu varijablu K3. Tri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K3.Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja* unutar dimenzije *Jednostavnost.* Varijabla *J1. Preuzimanje i učitavanje aplikacije mobilnog bankarstva je jednostavno* ima pozitivan utjecaj uz 5% značajnosti na zavisnu varijablu K3, dok varijable *J3.* Pretraživanje aplikacije mobilnog bankarstva je jednostavno i *J6. Aplikacija mobilnog bankarstva je jednostavna za korištenje* imaju pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu K3. Četiri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K3.Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja* unutar dimenzije *Dostupnost.* Varijable *D1. Aplikacija omogućava ugovaranje depozitnih proizvoda, D2. Aplikacija omogućava ugovaranje i/ili popunjavanje zahtjeva za kreditne proizvode* i *D7. Aplikacija omogućava personaliziranu komunikaciju* imaju pozitivan utjecaj uz 10% značajnosti na zavisnu varijablu K3, dok varijabla *D6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)* ima pozitivan utjecaj uz 1% značajnosti.

Na zavisnu varijablu *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* statistički značajan utjecaj ima sedam nezavisnih varijabli iz sljedećih dimenzija: *Sigurnost, Jednostavnost* i *Dostupnost.* Tri nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* unutar dimenzije *Sigurnost.* Varijable *S2. Aplikacija mobilnog bankarstva je stabilna* i *S6. Korištenje aplikacije mobilnog bankarstva je sigurno* imaju pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu K4, dok varijabla *S5. Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća* ima pozitivan utjecaj uz 5% značajnosti. Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* unutar dimenzije *Jednostavnost.* Varijabla *J5. Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno* ima pozitivan utjecaj uz 10% značajnosti na zavisnu

varijablu K4, dok varijabla *J6. Aplikacija mobilnog bankarstva je jednostavna za korištenje* ima pozitivan utjecaj uz 1% značajnosti. Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* unutar dimenzije *Dostupnost.* Varijabla *D1. Aplikacija omogućava ugovaranje depozitnih proizvoda* ima pozitivan utjecaj uz 5% značajnosti na zavisnu varijablu K4, dok varijabla *D6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)* ima pozitivan utjecaj uz 1% značajnosti.

Na zavisnu varijablu *K5. Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke* statistički značajan utjecaj ima pet nezavisnih varijabli iz sljedećih dimenzija: *Sigurnost, Jednostavnost* i *Dostupnost.* Jedna nezavisna varijabla ima statistički značajan utjecaj na zavisnu varijablu *K5. Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke* unutar dimenzije *Sigurnost.* Varijabla *S2. Aplikacija mobilnog bankarstva je stabilna* ima pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu K5. Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K5. Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke* unutar dimenzije *Jednostavnost.* Varijabla *J4. Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno* ima pozitivan utjecaj uz 5% značajnosti na zavisnu varijablu K5, dok varijabla *J6. Aplikacija mobilnog bankarstva je jednostavna za korištenje* ima pozitivan utjecaj uz 1% značajnosti. Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *K5. Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke* unutar dimenzije *Dostupnost.* Varijable *D1. Aplikacija omogućava ugovaranje depozitnih proizvoda* i *D6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)* imaju pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu K5.

Rezultati testiranja hipoteza korištenjem regresijskih modela pokazuju kako su hipoteze H1, H2 i H3 prihvaćene.

Tablica 76. Testiranje hipoteza korištenjem regresijskih modela– Zavisne varijable: K1, K2, K3, K4, K5

		K1	K2	K3	K4	K5
	(Konstanta)	∅	∅	∅	∅	∅
Sigurnost (H1)	S1	∅	∅	∅	∅	∅
	S2	5%	1%	∅	1%	1%
	S3	∅	∅	∅	∅	∅
	S4	1%	1%	1%	∅	∅
	S5	5%	1%	5%	5%	∅
	S6	∅	∅	10%	1%	∅
Jednostavnost (H2)	J1	∅	∅	5%	∅	∅
	J2	∅	∅	∅	∅	∅
	J3	1%	5%	1%	∅	∅
	J4	10%	5%	∅	∅	5%
	J5	∅	5%	∅	10%	∅
	J6	∅	∅	1%	1%	1%
Dostupnost (H3)	D1	10%	5%	10%	5%	1%
	D2	∅	∅	10%	∅	∅
	D3	∅	∅	∅	∅	∅
	D4	∅	∅	∅	∅	∅
	D5	∅	∅	∅	∅	∅
	D6	1%	1%	1%	1%	1%
	D7	5%	5%	10%	∅	∅
	D8	∅	∅	∅	∅	∅
Statistički značajne čestice	Sigurnost (H1)	3/6 (50%)	3/6 (50%)	1/6 (16,7%)	2/6 (33,3%)	1/6 (16,7%)
	Jednostavnost (H2)	2/6 (33,3%)	3/6 (50%)	2/6 (33%)	2/6 (33,3%)	2/6 (33,3%)
	Dostupnost (H3)	3/8 (37,5%)	3/8 (37,5%)	4/8 (50%)	2/8 (25%)	2/8 (25%)

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 77 prikazuje sumarne rezultate regresijskih modela za sljedeće zavisne varijable: R1. Banka za koju imam dobar osjećaj; R2. Banka kojoj vjerujem; R3. Banka koju poštujem; R4. Banka koja ima tradiciju; R5. Banka koja ima snagu međunarodne organizacije; R6. Banka koja cijeni mene kao klijenta; R7. Banka ima dobru ukupnu reputaciju.

Dvije nezavisne varijable, K2 i K4, koje se odnose na percipiranu kvalitetu usluga mobilnog bankarstva statistički su značajno povezane s gotovo svim zavisnim varijablama. Nezavisna varijabla K2 (*Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete*) ima statistički značajan pozitivan utjecaj uz 1% vjerojatnosti za sve zavisne varijable. Nezavisna varijabla K4 (*Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan*) ima statistički značajan

pozitivan utjecaj na sljedeće zavisne varijable: R1, R2, R7 (uz 1% vjerojatnosti), R4, R6 (uz 5% vjerojatnosti) te na zavisnu varijablu R5 (uz 10% vjerojatnosti).

Durbin-Watson koeficijent je približno jednak dva za gotovo sve varijable čime se može zaključiti kako u modelu ne postoji probem autokorelacije. Vrijednosti korigiranog koeficijenta determinacije kreću se u rasponu od 0,284 do 0,450.

Tablica 77. Sumarni rezultati regresijskih modela – Zavisne varijable: R1, R2, R3, R4, R5, R6, R7

	R1	R2	R3	R4	R5	R6	R7
(Konstanta)	1,026	0,661	1,001	1,873	1,327	1,323	1,761
K1	0,087	0,041	0,111	0,104	-0,023	0,040	-0,014
K2	0,422***	0,429***	0,472***	0,337***	0,327***	0,448***	0,306***
K3	-0,152	-0,006	0,010	0,022	0,086	-0,071	-0,041
K4	0,402***	0,417***	0,198	0,227**	0,225*	0,279**	0,278***
K5	0,024	-0,039	-0,020	-0,012	0,121	-0,021	0,152
Prilagođeni koeficijent determinacije	0,441	0,450	0,380	0,391	0,364	0,284	0,382
Durbin-Watson	1,919	1,819	1,822	2,049	1,927	1,947	2,047

Napomena: *** 1% značajnosti, ** 5%, * 10%

Izvor: Autorica, obrada istraživanja siječanj, 2017

Tablica 78 prikazuje testiranje hipoteza korištenjem regresijskih modela za sedam zavisnih varijabli: R1, R2, R3, R4, R5, R6, R7 koje se odnose na reputaciju banaka.

Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *R1. Banka za koju imam dobar osjećaj* unutar dimenzije *Percipirana kvaliteta.* Varijable *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* i *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* imaju pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu R1.

Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *R2. Banka kojoj vjerujem* unutar dimenzije *Percipirana kvaliteta.* Varijable *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete i K4. Prosječan rezultat ukupne procjene*

pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan imaju pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu R2.
Jedna nezavisna varijabla ima statistički značajan utjecaj na zavisnu varijablu *R3. Banka koju poštujem* su unutar dimenzije *Percipirana kvaliteta.* Varijabla *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* ima pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu R3.

Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *R4. Banka koja ima tradiciju* unutar dimenzije *Percipirana kvaliteta.* Varijabla *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* ima pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu R4, dok varijabla *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* ima pozitivan utjecaj uz 5% značajnosti.

Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *R5. Banka koja ima snagu međunarodne organizacije* unutar dimenzije *Percipirana kvaliteta.* Varijabla *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* ima pozitivan utjecaj uz 1% značajnosti na zavisnu varijable R5, dok varijabla *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* ima pozitivan utjecaj uz 10% značajnosti.

Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *R6. Banka koja cijeni mene kao klijenta* unutar dimenzije *Percipirana kvaliteta.* Varijabla *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* ima pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu R6, dok varijabla *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* ima pozitivan utjecaj uz 5% značajnosti.

Dvije nezavisne varijable imaju statistički značajan utjecaj na zavisnu varijablu *R7. Banka ima dobru ukupnu reputaciju* unutar dimenzije *Percipirana kvaliteta.* Varijable *K2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete* i *K4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan* imaju pozitivan utjecaj uz 1% značajnosti na zavisnu varijablu R7.

Rezultati testiranja hipoteza korištenjem regresijskih modela pokazuju kako je hipoteza H4 prihvaćena.

Tablica 78. Testiranje hipoteza korištenjem regresijskih modela– Zavisne varijable: R1, R2, R3, R4, R5, R6, R7

		R1	R2	R3	R4	R5	R6	R7
	(Konstanta)	∅	∅	∅	∅	∅	∅	∅
Percipirana kvaliteta (H4)	K1	∅	∅	∅	∅	∅	∅	∅
	K2	1%	1%	1%	1%	1%	1%	1%
	K3	∅	∅	∅	∅	∅	∅	∅
	K4	1%	1%	∅	5%	10%	5%	1%
	K5	∅	∅	∅	∅	∅	∅	∅
Statistički značajne čestice	Percipirana kvaliteta (H4)	2/5 (40%)	2/5 (40%)	1/5 (20%)	2/5 (40%)	2/5 (40%)	2/5 (40%)	2/5 (40%)

Izvor: Autorica, obrada istraživanja siječanj, 2017

5.5 Ograničenja istraživanja i preporuke za buduća istraživanja

Ograničenja istraživanja prvenstveno su rezultat uzorkovanja. Rezultati dobiveni na 372 ispitanika ne moraju se nužno u potpunosti podudarati s rezultatima populacije. Također, iako je Privredna banka jedna od najvećih banaka u Republici Hrvatskoj uzorkom dominiraju ispitanici koji su njezini klijenti (58,6%).

Pojedine mjere varijabli prikupljene istraživanjem rezultat su percepcije klijenata, a time predstavljaju procjenu odabranih parametara koji se ne moraju u potpunosti podudarati sa nominalnim kategorijama. To se prvenstveno odnosi na percepciju sigurnosti, jednostavnosti i kvalitete mobilne usluge.

Također, obzirom da 60% stanovništva u Republici Hrvatskoj živi u gradovima, a udio ruralnog stanovništva u istraživanju predstavlja 12,37% ukupnih ispitanika, uzorak ne predstavlja istovjetnu sliku ukupne distribucije stanovništva prema navedenom kriteriju (The World Bank Group, 2018).

Konačno, istraživanje je koncipirano na način da istražuje posredan utjecaj primjene inovativne tehnologije odnosno konkretno mobilnog bankarstva putem percipirane razine kvalitete usluge banaka na njihovu reputaciju. Iako mobilno bankarstvo predstavlja relativno novi oblik komunikacije klijenata s bankom spomenuto svakako ne čini potpuni skup inovativnih tehnoloških rješenja koje diferenciraju kvalitetu usluge banaka i same banke. Također, utjecaj na kvalitetu usluge banke može imati čitav niz drugih faktora koji ne pripadaju tehnološkoj domeni, a reputacija ne mora nužno biti rezultat isključivo kvalitete ponuđene odnosno pružene usluge.

Obzirom na snažnu dinamiku razvoja tehnike i velikog broja tehničkih inovacija bankarske industrije, buduća istraživanja mogu biti usmjerena na razmatranje prednosti tehnologija odnosno tehnoloških strategija koje će biti fokusirane na druge specifične tehnologije odabrane industrije: API sustave, upotrebu umjetne inteligencije, Blockchaina, robotike, NLP-a, NLG-a, Cloud computing-a, virtualne stvarnosti i ostalih tehničko-tehnoloških inovacija.

6 ZAKLJUČAK

Promatrajući koncentraciju sustava financijskih institucija može se primijetiti kako zemlje koje predstavljaju razvijena tržišta imaju snažno razvijen i fragmentiran financijski sustav, dok su manje zemlje izuzev Austrije i Luksemburga imale snažniju konsolidaciju i koncentraciju. Pokazatelji koncentracije kreditnih institucija Europske unije u razdoblju 2005.-2014. kontinuirano su rasli, a razlozi su prvenstveno bili u restrukturiranju pojedinih zemalja kao što je Grčka, Španjolska, Malta i Cipar. Prema koeficijentima koncentracije tri najveće kreditne institucije u RH upravljaju C3=58,3% ukupne imovine, pet najvećih upravlja C5=74,9% ukupne imovine, odnosno deset najvećih upravlja C10=90,7% ukupne imovine kreditnih institucija.

Obzirom da se udio stranog vlasništva kreditnih institucija na razini zemalja članica Europske unije kretao se u rasponu od 96% do 0,03%, a na tržištu RH udio stranog vlasništva trenutno iznosi (89,9%) pri čemu se istovremeno dogodila i značajna konsolidacija C10=90,7% može se pretpostaviti kako se poslovni modeli kreditnih institucija koji su se pokazali uspješnima u najrazvijenijim financijskim tržištima transferiraju na tržište Republike Hrvatske. U budućnosti može se očekivati jačanje konkurencije i smanjenje stopa profitabilnosti banaka. Važno je napomenuti kako profitabilnost banke nije isključivo rezultat njezine veličine. Očekuje se kako će upravo tehnološka strategija razvoja banaka biti presudan čimbenik uspjeha na tržištu financijskog sustava RH. Jačanje konkurencija neće biti samo rezultat konkurencije između banaka nego i drugih Fintech organizacija koje dosad nisu bile prisutne na tržištu

Prosječna profitabilnost kapitala promjenjive kompozicije zemalja Europske unije 2007. godine iznosila je ROE=10,6% (ROA=0,5%) nakon čega se 2008. godine razina profitabilnosti smanjuje te iznosi negativnih ROE=-1,5% (ROA=-0,1%), dok je 2013. prosječna stopa profitabilnosti bila pozitivna te iznosila ROE=2,2% (ROA=0,1%). Prosječna stopa profitabilnost imovine banaka 2016. godine u RH iznosila je ROA=0,92%, a prosječna ponderirana profitabilnosti kapitala ROE=7,23%. Prema računu dobiti i gubitka može se zaključiti kako je osnova poslovnog rezultata banaka u Republici Hrvatskoj neto kamatni prihod, a čini 76,45% ukupnih operativnih prihoda. Osim neto kamatnih prihoda, operativne prihode činile su još dvije stavke: neto prihodi od provizija i naknada s 21,51% udjela i neto ostali nekamatni prihod koji čini svega 2,04% ukupnog udjela. Nekamatni prihodi rezultat su pružanja usluga banaka prema klijentima, a za efikasnost i kvalitetu pružanja tih usluga važno

je osigurati tehnološku infrastrukturu. Kada postoji visok stupanj konkurencije, osim raspona kamatne stope (osnovne djelatnosti banke) i nekamatnih prihoda (naknade i provizije), uspjeh banke biti će rezultat mogućnosti upotrebe ekonomije obujma i diversifikacije ponude, a ekonomija obujma može se povezivati s razvojem tehnike i padajućom funkcijom prosječnih fiksnih troškova masovnog bankarstva. Dodatno, na uspjeh banke mogu utjecati stavke izvan bilance (koje su 2015. godine činile 54,8 milijarde HRK obuhvaćajući prvenstveno revolving plasmane, kreditne linije i garancije, od čega je 58,3% plasirano sektoru poduzeća, a 36,2% sektoru stanovništva) (HNB, 2016), racionalizacija općih troškova poslovanja, sposobnost procjene i upravljanja kreditnim rizikom i kvaliteta zaposlenika.

Nakon financijske krize 2008. godine dogodio se zaokret u poslovanju banaka. Prestaje dominacija strategije rasta, a prevladavaju modeli čija je zadaća osigurati preživljavanje. Bankarski sektor je restrukturiran, odnosno banke su revalorizirale svoje plasmane. Kako bi udovoljile novoj regulaciji adekvatnosti kapitala i smanjenja poluge banke su promijenile strukturu svojih izvora imovine. Nadalje, iako je nakon krize zadnjih nekoliko godina većina banaka bila orijentirana na smanjenje troškova, racionalizaciju poslovne mreže i rast efikasnosti smanjuju se prosječne stope profitabilnosti. Prethodno financijskoj krizi, 2001.-2006. globalni bankarski prosjek povrata na kapital iznosio je 16,9%, nakon krize 2009.-2014., 10,6%, a 2014. godine negativan trend se nastavlja. Iako su negativni trendovi u sektoru bankarstva rezultat gospodarskog ciklusa odnosno kontrakcije, nisu sve banke ostvarile jednak neuspjeh ili uspjeh. Očigledan je porast heterogenosti unutar bankarskog sektora, pri čemu je prosječno odstupanje od prosjeka u razdoblju 1993.-2003. bilo svega 5%, dok je za razdoblje 2003.-2013. isti pokazatelj dosegnuo 9%. Trend pada profitabilnosti odnosno rasta diferencijacije upućuju na potrebu da banke revidiraju odnosno redizajniraju svoje strategije rasta i razvoja.

Kao rezultat napretka tehnike pojavili su se digitalni konkurenti, solidarno kreditiranje i mogućnost pružanja prekogranične usluge platnih transakcija, a banke se nikako ne žele naći s pogrešne strane tehnološke revolucije. Kratkoročni izraz strategije mnogih banaka dosada je bio definiran kvartalnim razinama profita, a neostvarenje tih ciljeva podrazumijevalo je odricanja za buduće koristi, dok jasno određena strategija banke uključuje odabir tržišta, portfolio usluga i troškovno vodstvo. Može se reći kako su banke dosad orijentirane na centralno računalo, efikasnost osobne obrade klijenata, bankomata, komunikacije telefonom i kartičnog plaćanja pod utjecajem digitalizacije reorganizirale svoje poslovanje i transakcije prvenstveno izvan poslovnica banaka na mobilne uređaja te uz pomoć napredne analitike

ponašanja korisnika počele isporučivati visoko personaliziranu uslugu. Uporaba robotike, umjetne inteligencije i platformi omogućili su zadovoljavanje potreba klijenata u realnom vremenu te istovremeno promjenili strukturu bankarstva. Za banke je važno zauzeti poziciju na tržištu digitalnih komunikacija odnosno banke se trebaju potruditi da preusmjere promet na svoje digitalne kapacitete kako bi mogle nastaviti dominirati u pružajnu široke lepeze financijskih usluga. Strategija mora uzeti u obzir potrebe korisnika, tehnička i regulatorna ograničenja, a banka će postaviti kriterije preuzimanja rizika te uzeti u obzir odstupanja koji su rezultat ekonomskih ciklusa.

Obzirom kako je poslovni rezultat banke prvenstveno rezultat razlike u kamatnim stopama, a prosječni povrat na vlasnički kapital predstavlja relativno skup izvor financiranja, privlačenje depozita ostaje važno strateško pitanje poslovanja banaka. Operativni troškovi važan su preduvjet liderstva standardne tržišne utakmice unutar financijskog tržišta, ali nisu nužno dovoljni da neutraliziraju utjecaj disruptivnih tehnologija i poslovnih modela koji redefiniraju okvir tržišne utakmice. Može se reći da velike banke brže povećavaju stupanj automatizacije, a veličina banke podrazumijeva kapacitete za implementaciju nove infrastrukture. Ipak, treba napomenuti kako profitabilnost banke nije isključivo rezultat njezine veličine. Također, nefokusiran i neodmjeren pristup koji podrazumijeva strategiju sveobuhvatne integracije tehnoloških inovacija neće biti realan neovisno veličini poduzeća. Strategija svih organizacija financijskog tržišta uključujući banke morati će pomiriti operativnu efikasnost i fleksibilnost organizacije kako bi se nesmetano odvijao inovacijski proces.

Može se očekivati kako će banke na osnovi ekonomije dijeljenja, eksternalizacije, i automatizacije u budućnosti gotovo u potpunosti harmonizirati svoje operativne troškove, a izvore konkurentske prednosti tražiti kroz diferencijaciju. Iako strategija diferencijacije podrazumijeva kreiranje palete proizvoda ili usluga koji će kreditnu instituciju diferencirati od konkurencije, strategija može potencijalno uključivati i segmentaciju klijenata.

U vidu povećanja efikasnosti kao posljedice dinamike unutar industrije očekuje se također i promjena strukture dobavnih lanaca. Za svaki od proizvoda neovisno jesu li oni vlastiti, zajednički ili proizvodi treće strane, banka ima svoje izvore i distribucijske kanale te može odlučiti hoće li te aktivnosti zadržati unutar poduzeća ili provesti eksternalizaciju. Sudionici postojećih dobavnih lanaca će nastojati izbjeći tradicionalne posrednike te se udružiti s onim organizacijama koje direktno nastupaju prema klijetima. Svaka odluka donesena unutar banke

mora pratiti odabranu strategiju i podrazumijevati ćće različitu strukturu imovine i potrebne kompetencije koje su neophodne za njezinu realizaciju.

Ulaskom novih konkurenata, raste i kvaliteta iskustva klijenta, a ukoliko banke žele zadržati vodeću poziciju unutar financijskog tržišta one će morati redefinirati svoje poslovne modele. Banke se moraju orijentirati na disruptivne tehnologije, a pobjednici će biti one organizacije koje iskoriste digitalizaciju za kreiranje iskustva klijenata koje će nadilaziti industrijski standard. Također, banke moraju odlučiti hoće li preuzeti ulogu distributera ili ulogu upravitelja platforme. Može se očekivati da će Fintech organizacije ciljano biti orijentirane na segmente tržišta gdje postoji određeno nezadovoljstvo ili nezadovoljena potreba klijenta, a posebice ako su isti mogu povezati s visokim iznosima naknada i provizija. Ograničenost kapaciteta koji su dosad bili prepreka pružanju financijskih usluga stanovništvu, malim i srednjim poduzetnicima odnosno poslovanju malih i srednjih banaka donosno fintech organizacija, razvojem digitalizacije smanjuju važnost jednog od najvažnijih izvora konkurentske prednosti postojećih lidera. Može se očekivati kako će male i srednje banke te fintech organizacije u skladu sa svojim strategijama pomno odabirati tržišne segmente, a digitalizacija će stvarati nove prilike za prodaju proizvoda i plasman usluga na istoj razini kvalitete ili u nekim aspektima iznad kvalitete proizvoda i usluga velikih banaka. Inovacije u svijetu financijskih usluga nisu rezultat slučajnosti. Može se očekivati kako će nova poduzeća (Fintech organizacije) ciljano biti orijentirane na segmente tržišta gdje postoji određeno nezadovoljstvo ili nezadovoljena potreba klijenta, posebice ako su isti mogu povezati s visokim iznosima naknada i provizija. Prema računu dobiti i gubitka banaka u Republici Hrvatskoj neto kamatni prihod iznosio je 76,45% ukupnih operativnih prihoda, ali su osim neto kamatnih prihoda, operativne prihode činile još dvije stavke: neto prihodi od provizija i naknada s 21,51% udjela i neto ostali nekamatni prihod koji čini svega 2,04% ukupnog udjela.

Na listi 20 najvećih banaka Europe 2017. godine u odnosu na prije deset godina nalazi se jedna trećina potpuno novih imena (EFMA, 2017d). Uvođenje digitalizacije u pozadinske procese poslovanja banaka označilo je početak digitalne revolucije. Digitalne organizacije danas kvalitetom svoje usluge postaju lideri industrije, a brzina promjene prijeti onima koji se oslanjaju na povijesnu reputaciju ili samo ubrzano slijede lidere. Promjene su rezultat očekivanja klijenata i pojave tehnoloških eksperata na tržištu financijskih usluga. Uloga bankarstva u suštini ostaje gotovo nepromijenjena, ali je način distribucije financijskih proizvoda značajno izmijenjen.

Unutar korporativnog sektora bankarske industrije može se izdvojiti nekoliko ključnih izvora reputacije: financijski parametri, strateška orijentacija, društvena odgovornost, ljudski resursi, inovacije i kvaliteta. Može se reći kako su financijski indikatori povezani s ostalim pokazateljima uspješnosti poslovanja. Financijski parametri mogu se povezati s društveno odgovornim poslovanjem i reputacijom banke. Odnos između aktivnosti banke, njezine reputacije i ekonomskih efekata ostaje važan element strategije banke. Društveno odgovorno poslovanje smatra se važnom odrednicom reputacije, a reputacija preduvjetom financijskih performansi. Ispravno formulirana strategija mora moći odgovoriti na pitanja koje su ključne tehnologije, kako će utjecati na prihode, konkurentnost i operativu te konačno što će organizacija učiniti da zaštiti osnovno poslovanje, iskoristi nove prilike i smanji razinu rizika. Dobro postavljena strategija podrazumijeva i adekvatne ljudske resurse. Razvoj informatičke infrastrukture ima zadaću smanjiti koncentraciju klijenata na zaposlenika banke, ali osobni kontakt ostaje važan element bankarske industrije. Banke su svjesne važnosti osobnog kontakta u pružanju financijskih usluga, a ključni element stvaranja odnosa klijenta s bankom ostaje bankar.

Inovacije podrazumijevaju redefiniranje odnosa s klijentima, upotrebu novih tehnoloških rješenja i osiguranje dodatnih prihoda. Tehnologija omogućava nove distribucijske kanale, nove proizvode, osvajanje tržišta i povećanje kvalitete usluge. Posljedično razvoju IT tehnologije: sustavima poslovne inteligencije te inovativnih strategija upravljanja rizicima poslovanje banaka značajno je izmijenjeno. Kvaliteta proizvoda i usluga ipak ostaje biti presudna odrednica dugoročnog uspjeha. Kvaliteta je predispozicija zadovoljstva klijenata, lojalnosti i rasta profitabilnost poslovanja. Napuštajući orijentaciju isključivo na cjenovne čimbenike, banke inovativnim tehnološkim rješenjima unaprjeđuju kvalitetu svojih usluga. Očekuje se veća dinamika u procesima digitalizacije s integracijom OBS-a temeljenog na API sustavima, umjetne inteligencije, Blockchaina, robotike, NLP-a, NLG-a, Cloud computing-a, virtualne stvarnosti i ostalih tehničko-tehnoloških inovacija.

Rastuće platforme i decentralizirana tehnologija omogućili su nove načine agregiranja i analize informacija, povećali stupanj povezanosti, smanjili trošak pristupa informacijama i sudjelovanja u financijskim transakcijama. Inovacije ojačane novim algoritmima i modernim računarskim procesorima zamjenjuju nekad ručno odrađivane aktivnosti nudeći pristupačnije i brže skalom neograničene proizvode i usluge.

Posljedično tehnološkom napretku, demografskim promjenama i promjenama životnog stila korisnika, smanjuje se utjecaj tradicionalnog bankarstva putem poslovnica i raste utjecaj digitalnog bankarstva s posebnim naglaskom na mobilno bankarstvo (m-bankarstvo). Razvoj industrije telekomunikacija i prihvaćanje pametnih telefona stvorili su izniman ekonomski potencijal, a banke su prepoznale važnost novonastalog kanala komunikacije za plasman financijskih usluga. Krajem 2016. godine pametni telefon posjedovalo je 2,15 milijardi ljudi, dok se očekuje kako će 2018. godine biti to biti 2,56 milijardi, a sve veća upotreba pametnih telefona utjecala je na preferenciju klijenata banke za mobilnošću. U prosjeku Europskih zemalja trenutno je proporcija korisnika mobilnog bankarstva dosegnula 47%. Ipak, napominje se kako većina klijenata koristi prvenstveno osnovne funkcionalnosti mobilnog bankarstva dok je udio korisnika složenijih transakcija relativno nizak.. U razdoblju 2005.-2015. godine značajno se povećao omjer elektronički zadanih naloga. Može se reći kako podaci o platnoj infrastrukturi Europske unije pokazali su kako se smanjuje važnost i udio transakcija koje su zadane izvan elektroničkih kanala komunikacije pri čemu je odnos dosegao razinu jedan prema osam. Na financijskom tržištu Republike Hrvatske 2015. godine omjer papirnato i elektronički zadanih transakcija iznosio je 0,11. Od ukupnog broja transakcija prvih šest mjeseci 2013. godine 99.766.780, najveći broj transakcija zadan je elektroničkim putem neovisno o segmentu klijenata (60,2%) pri čemu je važnost elektroničkih kanala 2013. godine u odnosu na 2005. godinu porasla za 19,4%. U prosjeku zemalja Europske unije 2016. godine 49% pojedinaca koristilo je Internet bankarstvo. U odnosu na 2011 godinu dogodio se rast od 21%. U Republici Hrvatskoj 2016. godine bilo je 35% korisnika s porastom u odnosu na 2011. godinu od 12%. Ipak, trenutno na financijskom tržištu Republike Hrvatske u odnosu na tradicionalne kanale komunikacija mobilni uređaji trenutno čine relativno manje važan servis banke za građane i poslovne subjekte. Ako se pored udjela ugovorenih usluga uzme u obzir broj i vrijednost transakcija važnost mobilnog bankarstva relativno je niska. Unatoč tome obzirom na postojeće trendove može se reći kako važnost mobilnih transakcija u Republici Hrvatskoj raste te kako će u budućnosti mobilni kanal komunikacije s bankom biti važan element stjecanja konkurentske prednosti na financijskom tržištu Republike Hrvatske.

Analizom tržišta mobilnog bankarstva u Republici Hrvatskoj utvrđeno je da od ukupno 28 banaka od čega je tri u postupku stečaja (Banka Splitsko-Dalmatinska d.d., 2018; Tesla banka, 2018a; Štedbanka d.d., 2018) svih 25 banaka nudi neki oblik Internet bankarstva iako za 3 od

25 banaka nema opisa funkcionalnosti konkretnog proizvoda. Može se reći kako distribucijski kanal mobilnog bankarstva omogućuje pristup gotovo svim proizvodima i uslugama koje klijent može koristiti odlaskom u poslovnicu (provjera stanja i prometa računa, kartica, štednje i kredita, transfer novca na račune u Hrvatskoj, tečajna lista, kupoprodaja deviza, m-foto/2d skeniranje koda računa, lokacijske usluge, bonovi za mobitel, ugovaranje depozita, financijski planer, transfer novca na račune u inozemstvu, upravljanje dnevnim limitima kartica, trgovanje udjelima u fondovima, hrvatske autoceste, ugovaranje sastanaka, plaćanje mobitelom na odabranim prodajnim mjestima, otvaranje računa, ugovaranje gotovinskog, kredita, trgovanje na svjetskim burzama, obvezno auto osiguranje, osiguranje imovine, osiguranje od privatne odgovornosti, putno osiguranje, dopunsko zdravstveno, upravljanje bodovima programa lojalnosti, podizanje gotovine na bankomatu bez kartice, deblokada pin-ova, aktivacija kartica, promjena pinova).

Nadalje, iako mobilno bankarstvo podrazumijeva visok stupanj pogodnosti s pristupom velikom broju opcija trenutno nudi mogućnost upravljanja gotovo svim aspektima financija klijenta, mobilno bankarstvo na tržištu banaka Republike Hrvatske nije bez ograničenja i još uvijek ne predstavlja potpuni ekvivalent tradicionalnog bankarstva. Primjerice, iako na bankarskom tržištu Republike Hrvatske odobravanje hipotekarnih ili investicijskih kredita putem mobilnog bankarstva nije moguće (tradicionalne banke na odobravanje hipotekarnih i investicijskih resursa troše 21% ukupnih resursa), neki sustavi mobilnog bankarstva digitalnih banaka temeljito prate svoje klijente (financijske tokove, sklapanje ugovora, podaci državnih agencija, knjigovodstvena dokumentacija), a putem istih moguće je odobravati hipotekarne ili investicijske kredite.

Očekuje se kako će digitalizacija redefinirati lepezu ponude tradicionalnih banaka. Nudeći financijske proizvode i usluge vjerojatno je kako će banke putem svoji portala ponuditi usluge drugih komplementarnih pružatelja koji se nalaze izvan domene financijskog tržišta (smještaj, putovanja, elektronička trgovina). Otvoreni API sustavi omogućavaju stvaranje čitavih eko-sustava koji će integrirati i ostale financijske ili nefinancijske proizvode i usluge drugih organizacija kako bi povećali kvalitetu iskustva korisnika koji sada više ne mora napuštati sučelje banke kako bi zadovoljio svoje potrebe. Također, i banka će imati koristi od ostvarenja dodatnih prihoda. Održivost koncepta već je potvrđena u okviru nefinancijskih ekosustava.

Suvereni sustav upravljanja odnosima s klijentima podrazumijevaju IT infrastrukturu odnosno informacije na osnovi kojih se mogu kreirati primjereni proizvodi i usluge za pojedine klijente, njihova cijena, oblik i vrijeme komunikacije istih od banke prema klijentima. Mobilno bankarstvo ima sposobnost osigurati gotovo neograničenu dostupnost i reaktivnost banke ne velik broj zahtjeva klijenata svakodnevno i cjelodnevno. Osiguravajući navedene performanse raste operativna efikasnost, zadovoljstvo klijenata te se iskorištavaju komercijalne prilike za banke.

Popularizacija upotrebe mobilnih uređaja za pregled Internetskih stranica i mobilnih plaćanja rezultira sve većim brojem hakerskih napada. Svake godine incidenti koji su povezani sa sve sofisticiranijim napadima stvaraju visoke troškove u poslovanju kreditnih institucija. Iako je načelno teže hakirati mobitele nego osobna računala , u svakom trenutku zlonamjernim programima zaraženo je 11 milijuna mobilnih uređaja, a njih 60% usmjereno je upravo na aplikacije mobilnog bankarstva (vidjeti potpoglavlje 4.1.1). Najčešće povrede sigurnosti koje su dosad identificirane mogu se podijeliti odnosno klasificirati u tri skupine: (1) sigurnosni problemi koji se mogu povezati s gubitkom ili krađom uređaja, (2) sigurnosni problemi povezani s napadom zlonamjernih programa unutar uređaja ili aplikacije i (3) sigurnosne probleme koji uključuju oboje: krađu i zlonamjerne programe. Nadalje, ponašanje korisnika također predstavlja važan preduvjet cjelovitosti sustava sigurnosti. Neovisno intenzitetu ulaganja u mehanizme zaštite i posljedično sofisticiranosti isti mogu biti djelotvorni samo ako su ispravo korišteni. Konačno, mjere moraju biti usklađene s regulativom te se mora postići ravnoteža između pružanja dovoljne zaštite i neometanog tijeka iskustva korisnika. Ukoliko banke žele zadržati i povećati postojeće povjerenje klijenata trebale bi uložiti značajne napore u osiguranje sigurnosti mobilne komunikacije. Sigurnost se mora očitovati na sve tri razine: registraciji klijenta u svrhu potvrde identiteta, pristupu uslugama bez autentifikacije te identifikaciji i blokiranju svih neuobičajenih transakcija.

Banke su daleko napredovale u kvaliteti pružanja financijskih usluga. Kako bi se povećala jednostavnost upotrebe servisa koji omogućuju upravljanje financijama klijenata njihovo se iskustvo analizira do najsitnijih detalja. Banke putem različitih programskih rješenja koriste povratne informacije klijenata te kontinuirano povećavaju jednostavnost korištenja odnosno zadovoljstvo klijenta. Nastoji se povećati razina interaktivnosti i jednostavnosti navigacije kako bi vrijeme i trud potrebno za upravljanje financijama bilo svedeno na minimum. Naime, jednostavnost korištenja u prvom redu podrazumijeva percipiranu složenost navigacije. Za nove

korisnike digitalnog bankarstvo sučelje navigacije ne mora nužno biti jedini izazov. Razumijevanje i prihvaćanje ideje digitalnog transfera virtualnog novca za mnoge pojedince zemalja u razvoju može ostati nesavladiva prepreka. Ljudi koji su cijeli svoj život naučili raditi s gotovinom zasigurno prati sustav vjerovanja, nedoumica i zabrinutost koje treba adresirati prethodno prihvaćanju mobitela kao supstituta klasičnog novčanika.

Iako mobilno bankarstvo klijentima osigurava veću dostupnost, pogodnost i kontrolu njihovih financija, važan preduvjet ostvarenju prednosti mobilnog bankarstva uvjetovan je dostupnošću usluge mobilnog bankarstva te se povezuje kontinuiranom isporukom električne energije, pokrivenošću mobilne mreže, dostupnosti konačne povezivosti širokopojasne komunikacije i visokom cijenom Internet usluga. Krajem 2017. godine Internetom se koristilo 48% populacije svijeta, a u periodu 2012.-2017. godine broj pretplatnika na mobilni Internet razvijenih zemalja rastao je 7% godišnje, zemalja u razvoju 35% godišnje, dok je incidencija korisnika 2017. godine razvijenih zemalja bila 95%, a zemalja u razvoju 49%. Komparativno, stopa rasta broja pretplatnika fiksnog interneta u prosjeku je iznosila 9%, a prosječna incidencija bila je 12%, dok je cijena mobilnog i fiksnog Interneta 2016. godine bila je znatno niža u razvijenim zemljama.

Mobilno bankarstvo čini dio tehnološke strategije banke, a istraživanje pokazuje kako od ukupno 372, 94,35% svih klijenata banke koristi uslugu, od čega njih 35,75% čini to svakodnevno. Preduvjete kvalitete mobilnog bankarstva odnosno reputacije banke činile su sigurnost, jednostavnost i dostupnost. Najvažniji aspekt sigurnosti povezuje se s izvršavanjem funkcionalnosti aplikacije na vrijeme i točno (5,67), a najmanje važan aspekt sigurnosti bila je nadogradnja aplikacije mobilnog bankarstva (5,43). Najvažniji aspekt jednostavnosti mobilnog bankarstva povezuje se sa dizajnom aplikacije (6,03), a najmanje važan aspekt s kontaktiranjem djelatnika banke (5,11). Najvažniji aspekt dostupnosti povezuje se s ugovaranjem ili popunjavanjem zahtjeva za kreditne proizvode (5,94), a najmanje važan aspekt dostupnosti za plaćanje 2d bar kodom (4,13). Od prethodno navedena tri konstrukta u prosjeku je najvažniji aspekt bio jednostavnost (5,79), zatim sigurnost (5,52) i konačno dostupnost (4,61). Nadalje najveći utjecaj na kvalitetu ima zadovoljstvo (5,82), a najmanji utjecaj sveukupne usluga klijentima (5,63). U slučaju reputacije banke najvažnija je tradicija (5,75), a najmanje važan osjećaj klijenta o tome koliko ga njegova banka cijeni (5,19).

U prvom modelu kvalitete usluge mobilnog bankarstva pri čemu je zavisna varijabla bila prvi aspekt kvalitete poslovanja „Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna“ protumačenost modela bila je 85,1%. Značajne zavisne varijable bile su: S4 (Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme), J3 (Pretraživanje aplikacije mobilnog bankarstva je jednostavno), D6 (Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)), S2 (Aplikacija mobilnog bankarstva je stabilna), S5 (Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća) i D7 (Aplikacija omogućava personaliziranu komunikaciju).

U drugom modelu kvalitete usluge mobilnog bankarstva pri čemu je zavisna varijabla bila drugi aspekt kvalitete poslovanja „Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete“ protumačenost modela bila je 85,8%. Značajne zavisne varijable bile su: S2 (Aplikacija mobilnog bankarstva je stabilna), S4 (Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme), S5 (Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća), D6 (Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)), J3 (Pretraživanje aplikacije mobilnog bankarstva je jednostavno), J4 (Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno), J5 (Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno), D1 (Aplikacija omogućava ugovaranje depozitnih proizvoda) i D7 (Aplikacija omogućava personaliziranu komunikaciju).

U trećem modelu kvalitete usluge mobilnog bankarstva pri čemu je zavisna varijabla „Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja“ protumačenost modela bila je 85%. Značajne zavisne varijable bile su: S4 (Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme), J3 (Pretraživanje aplikacije mobilnog bankarstva je jednostavno), J6 (Aplikacija mobilnog bankarstva je jednostavna za korištenje), D6 (Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)), S5 (Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća) i J1 (Preuzimanje i učitavanje aplikacije mobilnog bankarstva je jednostavno).

U četvrtom modelu pri čemu je zavisna varijabla „Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan“ protumačenost modela bila je 86,5%. Značajne zavisne varijable bile su: S2 (Aplikacija mobilnog bankarstva je stabilna), S6 (Korištenje aplikacije mobilnog bankarstva je sigurno), J6 (Aplikacija mobilnog bankarstva je jednostavna za korištenje), D6 (Aplikacija

omogućava plaćanje 2d bar code-om (opcija slikaj i plati)), S5 (Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća) i D1 (Aplikacija omogućava ugovaranje depozitnih proizvoda).

U petom modelu kvalitete usluge mobilnog bankarstva pri čemu je zavisna varijabla „Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke“ protumačenost modela bila je 86,2%. Značajne zavisne varijable bile su: J4 (Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno), S2 (Aplikacija mobilnog bankarstva je stabilna), J6 (Aplikacija mobilnog bankarstva je jednostavna za korištenje), D1 (Aplikacija omogućava ugovaranje depozitnih proizvoda) i D6 (Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)).

U prvom modelu reputacije banaka pri čemu je zavisna varijabla „Banka za koju imam dobar osjećaj“ protumačenost modela bila je 67%. Značajne zavisne varijable bile su: K2 (Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete) i K4 (Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan).

U drugom modelu reputacije banaka pri čemu je zavisna varijabla „Banka kojoj vjerujem“ protumačenost modela bila je 67,6%. Značajne zavisne varijable bile su: K2 (Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete) i K4 (Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan).

U trećem modelu reputacije banaka pri čemu je zavisna varijabla „Banka kojoj vjerujem“ protumačenost modela bila je 62,3%. Značajna zavisna varijabla bila je samo: K2 (Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete).

U četvrtom modelu reputacije banaka pri čemu je zavisna varijabla „Banka koja ima tradiciju“ protumačenost modela bila je 63,2%. Značajne zavisne varijable bile su: K2 (Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete) i K4 (Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan).

U petom modelu reputacije banaka pri čemu je zavisna varijabla „Banka koja ima snagu međunarodne organizacije“ protumačenost modela bila je 61%. Značajna zavisna varijabla bila je samo: K2 (Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete).

U šestom modelu reputacije banaka pri čemu je zavisna varijabla „Banka koja cijeni mene kao klijenta“ protumačenost modela bila je 54,2%. Značajne zavisne varijabla bile su: K2 (Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete) i K4 (Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan).

U sedmom modelu reputacije banaka pri čemu je zavisna varijabla „Banka ima dobru ukupnu reputaciju“ protumačenost modela bila je 62,5%. Značajne zavisne varijable bile su: K2 (Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete) i K4 (Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan).

Istraživanje omogućuje pogled u razvoj novih spoznaja bankarske industrije koji se temelje na ključnim odrednicama o poslovanju financijskog tržišta Republike Hrvatske. Sukladno navedenom definirane su karakteristike bankarskog tržišta i uloga tehnologije u financijskoj industriji Republike Hrvatske. Osnovna zadaća istraživanja bila je istražiti i analizirati odnosno adekvatno argumentirati utjecaj mobilnog bankarstva na reputaciju banaka Republike Hrvatske.

Doprinos istraživanja očituje se u empirijski potvrđenim spoznajama koja povećavaju obogaćuju postojeći skup znanja unutar područja poslovne ekonomije koje mogu biti korisne prilikom formiranja tehnoloških strategija banaka u okviru financijske industrije. Koristi mogu imati potencijalni ulagači u bankarsku industriju, a i sami korisnici bankarskih usluga. Na osnovi znanstvenih metoda i sustavnog pristupa problematici osigurana je relevantnost rezultata i zaključaka istraživanja.

Na temelju ekstenzivnog pregleda znanstvene i stručne literature tematike i rezultata istraživanja može se derivirati okosnica budućeg razvoja financijskog tržišta koja podrazumijeva dugoročnu održivost i visoku razinu kvalitete proizvoda i usluga banaka.

POPIS KORIŠTENIH IZVORA

1. Abratt, R., Kleyn, N. (2012). Corporate identity, corporate branding and corporate reputations: Reconciliation and integration. *European Journal of Marketing*, 46(7/8), 1048-1063.
2. Accenture Insurance (2017). Will robo-advice make human insurance agents vanish? Dostupno na poveznici: https://insuranceblog.accenture.com/will-robo-advice-make-human-insurance-agents-vanish (15.12.2017.)
3. Adams, P., Hamal, C., Monter, N., T'serclaes, J. W., Walsh, I. (2014). *How to Boost Bank branches in a Multichenl world*. EFMA, The Boston Colsanting Group.
4. Addiko banka (2018). Dostupno na poveznici: https://www.addiko.hr/gradanstvo/line-druge-usluge/addiko-mobile-mobilno-bankarstvo (18.4.2018.)
5. Agarwal, M., Fallah Tehrani, A., Hüllermeier, E. (2015). Preference-based Learning of Ideal Solutions in TOPSIS-like Decision Models. *Journal of Multi-Criteria Decision Analysis*, 22(3-4), 175-183.
6. Akdeniz, B., Calantone, R. J., Voorhees, C. M. (2013). Effectiveness of Marketing Cues on Consumer Perceptions of Quality: The Moderating Roles of Brand Reputation and Third-Party Information. *Psychology & Marketing*, 30(1), 76-89.
7. Akturan, U., Tezcan, N. (2012). Mobile banking adoption of the youth market: Perceptions and intentions. *Marketing Intelligence & Planning*, 30(4), 444-459.
8. Ali, R., Lynch, R., Melewar, T. C., Jin, Z. (2015). The moderating influences on the relationship of corporate reputation with its antecedents and consequences: A meta-analytic review. *Journal of Business Research*, 68(5), 1105-1117.
9. Al-Jabri, I. M., Sohail, M. S. (2012). Mobile banking adoption: Application of diffusion of innovation theory. *Journal of Electronic Commerce Research*, 13(4), 379-391.
10. Ambastha, A., Momaya, K. (2004). Competitiveness of firms: review of theory, frameworks, and models. *Singapore Management Review*, 26(1), 45-61.
11. Andaleeb, S. S., Anwar, S. F. (1996). Factors Influencing Customer Trust in Salespersons in a Developing Country. *Journal of International Marketing*, 4(4), 35-52.
12. Andrus, G., Kejriwal, S., Wadhwani, R. (2016). Digital transformation in financial services: The need to rewire organizational DNA. Dostupno na poveznici: https://www2.deloitte.com/insights/us/en/industry/financial-services/digital-transformation-in-financial-services.html (18.12.2017.)
13. Aras, G., Tezcan, N., Furtuna, O. K. (2018). Multidimensional comprehensive corporate sustainability performance evaluation model: Evidence from an emerging market banking sector. *Journal of Cleaner Production*, 185, 600-609.
14. Arasli, H., Turan Katircioglu, S., Mehtap-Smadi, S. (2005). A comparison of service quality in the banking industry: Some evidence from Turkish-and Greek-speaking areas in Cyprus. *International Journal of Bank Marketing*, 23(7), 508-526.
15. Arrawatia, R., Misra, A. (2014). Competition, concentration and the relevance of new banks' entry in the Indian banking system. *Global Business Review*, 15(2), 223-236.

16. Asfour, H. K., Haddad, S. I. (2014). The Impact of Mobile Banking on Enhancing Customers' E-Satisfaction: An Empirical Study on Commercial Banks in Jordan. *International Business Research*, 7(10), 145-169.
17. Balabanis, G., Phillips, H. C., Lyall, J. (1998). Corporate social responsibility and economic performance in the top British companies: are they linked? *European Business Review*, 98(1), 25-44.
18. Baravelli, M. (2017). Innovation, real investments and change: towards new banking business models. Bancaria, *Bancaria*, 12(12), 42-52.
19. Barkemeyer, R. (2011). Corporate perceptions of sustainability challenges in developed and developing countries: constituting a CSR divide?. *Social Responsibility Journal*, 7(2), 257-281.
20. Barnett, M. L., Jermier, J. M., Lafferty, B. A. (2006). Corporate reputation: The definitional landscape. *Corporate Reputation Review*, 9(1), 26-38.
21. Barnett, M. L., Pollock, T. G. (Eds.). (2012). *The Oxford handbook of corporate reputation*. Oxford: Oxford University Press.
22. Barrios, S., Burgelman, J. C. (2008). Europe needs more Lisbon to make the ICT investments effective. *Intereconomics*, 43(3), 124-134.
23. Beatty, R. P., Ritter, J. R. (1986). Investment banking, reputation, and the underpricing of initial public offerings. *Journal of Financial Economics*, 15(1), 213-232.
24. Beccalli, E., Casu, B., Girardone, C. (2006). Efficiency and stock performance in European banking. *Journal of Business Finance & Accounting*, 33(1–2), 245–262.
25. Behera, A. K. , Nayak, N. C. , Das, H. C., Mohapatra, R. N. (2015). An empirical study of the impact of IT on performance in Indian service industries. *Global Business and Organizational Excellence*, 34(3), 67-78.
26. Bhatt, A. (2016). Factors Affecting Customer's Adoption of Mobile Banking Services. *Journal of Internet Banking and Commerce; Ottawa*, 21(1), 1-22.
27. BKS – BKS banka (2018). Dostupno na poveznici: https://www.bks.hr/BKSWebp/BKS/bks_hr/Pravne_osobe/Racuni/OnlineBanking/index.jsp (18.4.2018.)
28. Bloomberg (n.d.). Company Overview of AMP Credit Technologies (H.K.) Limited. Dostupno na poveznici: https://www.bloomberg.com/research/stocks/private/snapshot.asp?privcapId=271354633 (13.7.2018.)
29. Board Of Governors Of The Federal Reservesystem. (2013). *Consumers and Mobile Financial Services.* Dostupno na poveznici: https://www.federalreserve.gov/consumerscommunities/mobile_finance.htm (10.5.2018.)
30. Boot, A. W. (2000). Relationship banking: What do we know? *Journal of Financial Intermediation*, 9(1), 7-25.
31. Bratton, J., Gold, J. (2017). *Human resource management: theory and practice*. Palgrave.
32. Brickson, S. L. (2005). Organizational identity orientation: Forging a link between organizational identity and organizations' relations with stakeholders. *Administrative Science Quarterly*, 50(4), 576-609.
33. BSD – Banka splitsko-dalmatinska u stječaju (2018a). Obavijest dužnicima Banke splitsko-dalmatinske d.d. u stečaju. Dostupno na poveznici: http://www.bsd.hr/novosti/213-obavijest-duznicima-banke-splitsko-dalmatinske-dd-u-stecaju (10.4.2018.)

34. BSD (2018b). Dostupno na poveznici: http://www.bsd.hr (23.4.2018.)
35. Busch, W. (2013). *Banking 2020 As the Storm Abates, North American Banks Must Chart a New Course to Capture Emerging Opportunities*. Accenture. Dostupno na poveznici: https://www.accenture.com/us-en/industries/banking-index (5.6.2018.)
36. Cable, D. M., Graham, M. E. (2000). The determinants of job seekers' reputation perceptions. *Journal of Organizational Behavior*, 21(8), 929-947.
37. Cai, S., Jun, M. (2003). Internet users' perceptions of online service quality: a comparison of online buyers and information searchers. *Managing Service Quality: An International Journal*, 13(6), 504-519.
38. Camner, G. (2018). Unlocking mobile money interoperability and merchant payments across Africa through Mowali, *GSMA*. Dostupno na poveznici: https://www.gsma.com/mobilefordevelopment/programme/mobile-money/unlocking-mobile-money-interoperability-and-merchant-payments-across-africa-through-mowali/ (10.1.2019.)
39. Campanella, F., Peruta, M. R. D., Giudice, M. D. (2017). The Effects of Technological Innovation on the Banking Sector. *Journal of the Knowledge Economy*, 8(1), 356–368.
40. Capgemini (2012). *Trends in Retail Banking Channels: Improving Client Service and Operating Costs*. Capgemini. Dostupno na poveznici: https://www.capgemini.com/resource-file-access/resource/pdf/Trends_in_Retail_Banking_Channels__Improving_Client_Service_and_Operating_Costs.pdf (5.6.2018.)
41. Capgemini. EFMA (2013). 2013 World Retail Banking Report. Caapgemini, EFMA. Dostupno na povenici: https://www.capgemini.com/resource-file-access/resource/pdf/wrbr_2013_0.pdf (10.6.2018.)
42. Capgemini. EFMA (2014). 2014 World Retail Banking Report. Caapgemini, EFMA. Dostupno na poveznici: https://www.capgemini.com/thought-leadership/world-retail-banking-report-2014 (10.6.2018.)
43. Carter, R. B., Dark, F. H. (1992). An empirical examination of investment banking reputation measures. *Financial Review*, 27(3), 355-374.
44. Casalo, L. V., Flavián, C., Guinalíu, M. (2007). The role of security, privacy, usability and reputation in the development of online banking. *Online Information Review*, 31(5), 583-603.
45. Casaló, L. V., Flavián, C., Guinalíu, M. (2008). The role of satisfaction and website usability in developing customer loyalty and positive word-of-mouth in the e-banking services. *International Journal of Bank Marketing*, 26(6), 399-417.
46. Changchit, C., Lonkani, R., Sampet, J. (2017). Mobile banking: Exploring determinants of its adoption. *Journal of Organizational Computing and Electronic Commerce*, 27(3), 239-261.
47. Chen, C. (2013). Perceived risk, usage frequency of mobile banking services.*Managing Service Quality: An International Journal*, 23(5), 410-436.
48. Chernev, A., Blair, S. (2015). Doing Well by Doing Good: The Benevolent Halo of Corporate Social Responsibility. *Journal of Consumer Research*, 41(6), 1412-1425.
49. Chiu, J. L., Bool, N. C., Chiu, C. L. (2017). Challenges and factors influencing initial trust and behavioral intention to use mobile banking services in the Philippines. *Asia Pacific Journal of Innovation and Entrepreneurship*, 11(2), 246-278.
50. Cognizant (2018). Retail's Next Frontier. Dostupno na poveznici: https://www.cognizant.com/retail-technology-solutions (20.9.2018.)

51. Consumers and Mobile Financial Services (2015). Board of Governors of the Federal Reserve System Washington: Dostupno na poveznici: http://www.federalreserve.gov/econresdata/consumers-and-mobile-financial-services-report-201503.pdf (3.9.2018.)
52. Cracknell, D. (2004). Electronic banking for the poor – panacea, potential and pitfalls, *Small Enterprise Development*, 15(4), 8-24.
53. Cramer, J. (2002). From financial to sustainable profit. *Corporate Social Responsibility and Environmental Management*, 9(2), 99-106.
54. CreditEase (2018). Wealth Management issues. Dostupno na poveznici: http://english.creditease.cn/, (10.10.2018.)
55. Crosman, P. (2014). First Major Mobile Banking Security Threat Hits the U.S, American Banker. Dostupno na poveznici: https://www.americanbanker.com/news/first-major-mobile-banking-security-threat-hits-the-us (14.5.2018.)
56. Dabholkar, P. (1994). Technology based service delivery. *Advances in Services Marketing and Management*, 3, 241-271.
57. Dash, M., Tech, M. (2014). Determinants of Customers' Adoption of Mobile Banking: An Empirical Study by Integrating Diffusion of Innovation with Attitude. *Journal of Internet Banking and Commerce*, 19(3), 1-21.
58. Davies, G., Chun, R., Vinhas da Silva, R., Roper, S. (2003.). *Corporate Reputation and Competitiveness*. London: Routledge.
59. Davies, R. (2016). RBS to cut 550 jobs as part of plan to automate investment advice, The Guardian. Dostupno na poveznici: https://www.theguardian.com/business/2016/mar/13/rbs-royal-bank-scotland-cut-550-jobs-automating-investment-advice (11.12.2017.)
60. Dean, D. H. (2003). Consumer perception of corporate donations effects of company reputation for social responsibility and type of donation. *Journal of Advertising*, 32(4), 91-102.
61. Deephouse, D. L., Carter, S. M. (2005). An examination of differences between organizational legitimacy and organizational reputation. *Journal of Management Studies*, 42(2), 329-360.
62. DeGennaro, R. P. (2006). Merchant Acquirers and Payment Card Processors: A Look inside the Black Box. *Economic Review - Federal Reserve Bank of Atlanta; Atlanta*, 91(1), 27-II.
63. Del Brio, J., Lizarzaburu, E. R. (2017). Corporate Reputation and Corporate Social Responsibility and its impact in the financial sector, Journal of Customer Behaviour, 16(1), 91-105
64. Dell'Atti, S., Trotta, A., Iannuzzi, A. P., Demaria, F. (2017). Corporate Social Responsibility Engagement as a Determinant of Bank Reputation: An Empirical Analysis. *Corporate Social Responsibility and Environmental Management*, *24*(6), 589-605.
65. Demartini, P., Paoloni, P. (2013). Awareness of your own intangible assets: A hypothesis of overlapping between ICS and CSRS processes. *Journal of Intellectual Capital*, 14(3), 360-375.
66. Deutsche Bank (2017). ROBIN offers portfolio management for retail investors. Dostupno na poveznici: https://www.db.com/newsroom_news/2017/deutsche-bank-robin-offers-portfolio-management-for-retail-investors-en-11743.htm (6.3.2018.)
67. Dijkmans, C., Kerkhof, P., Beukeboom, C. J. (2015). A stage to engage: Social media use and corporate reputation. *Tourism Management*, 47(C), 58-67.

68. Dimitriadis, S., Kouremenos, A., Kyrezis, N. (2011). Trust-based segmentation: Preliminary evidence from technology-enabled bank channels. *International Journal of Bank Marketing*, 29(1), 5-31.
69. Dinc, I. S. (2000). Bank reputation, bank commitment, and the effects of competition in credit markets. *Review of Financial Studies*, 13(3), 781-812.
70. Dini, G., Martinelli, F., Matteucci, I., Saracino, A., Sgandurra, D. (2014). Introducing Probabilities in Contract-Based Approaches for Mobile Application Security, 284–299. U: Garcia-Alfaro, J., Navarro-Arribas, G., Cuppens-Boulahia, N., Roudier, Y. *Data Privacy Management and Autonomous Spontaneous Security*, Springer, Berlin: Heidelberg.
71. Dlačić, J., Žabkar, V. (2012). Predanost u odnosu, relacijska pravednost te imidž poduzeća kao elementi razvoja odanosti potrošača. *Ekonomska istraživanja*, 25(2), 503-524.
72. Dolphin, R. R. (2004). Corporate reputation – a value creation strategy, *Corporate Governance*, 4(3), 77-92.
73. Donner, J., Tellez, C. A. (2008). Mobile banking and economic development: linking adoption, impact, and use. *Asian Journal of Communication*, 18(4), 318-332.
74. Đorđević, M. (2010). Corporate communications and stakeholder management. *Marketing*, 41(3), 195-206.
75. Dowling, G. R., Gardberg, N. A. (2012). Keeping score: The challenges of measuring corporate reputation, 34-68. U: Pollock, T. G., Barnett, M. L. (ur.) *The Oxford handbook of corporate reputations*, Oxford: Oxford University Press.
76. Du, S., Bhattacharya, C. B., Sen, S. (2010). Maximizing business returns to corporate social responsibility (CSR): The role of CSR communication. *International Journal of Management Reviews*, 12(1), 8-19.
77. Dumičić, K., Pavković, A., Akalović Antić, J. (2012). Mjerenje koncentracije u bankarstvu u Republici Hrvatskoj. *Proceedings of the Faculty of Economics and Business in Zagreb*, 10(2), 117-136.
78. Dumičić, M., Ljubaj, I. (2017). Odgođeni oporavak kreditne aktivnosti u Hrvatskoj: uzrokovan ponudom ili potražnjom?, HNB. Dostupno na poveznici: https://www.hnb.hr/documents/20182/1919187/i-047.pdf/40a15ef8-11b5-4c95-a9a2-3c4b78f8d212 (25.9.2017.)
79. DZS- Državni zavod za statistiku (2016). Procjene stanovništva Republike Hrvatske u 2015.Dostupno na poveznici: https://www.dzs.hr/Hrv_Eng/publication/2016/07-01-04_01_2016.htm (28.7.2017.)
80. ECB- European Central Bank (2015). Report on financial structures-2015. Dostupno na poveznici: https://www.ecb.europa.eu/pub/pdf/other/reportonfinancialstructures201510.en.pdf (3.4.2017.)
81. ECB- European Central Bank (2016). Report on financial structures-2016. Dostupno na poveznici: https://www.ecb.europa.eu/pub/pdf/other/reportonfinancialstructures201610.en.pdf (29.6.2017.)
82. ECB - European Central Bank (2017a). CBD: Statistics on Consolidated Banking Data. Dostupno na poveznici: https://sdw.ecb.europa.eu/browseExplanation.do?node=9689684 (25.06.2017.)
83. ECB - European Central Bank (2017b). CBD Dostupno na poveznici: *http://sdw.ecb.europa.eu/reports.do?node=1000001404*, (30.6.2017.)
84. ECB – European Central Bank (2017c). Statistics on Consolidated Banking Data (17520) Domestic banking groups and stand alone banks, Net interest income [full sample], Net fee and commision income [full sample],

85. ECB – Europan Central Bank (2017d). CBD - Statistics on Consolidated Banking Data. Dostupno na poveznici: https://www.ecb.europa.eu/stats/supervisory_prudential_statistics/consolidated_banking_data/html/index.en.htm, (20.2.2017.)
86. ECB – Europan Central Bank (2017e). Structural financial indicators – query. https://www.ecb.europa.eu/press/pr/date/2018/html/ecb.pr180523_1.en.html (7.5.2017.)
87. ECB – Europan Central Bank (2018). Payments and Settlement Systems Statistics, credit transfers initiated in paper based form and credit transfers initiated ellectronically, Dostupno na poveznici: http://sdw.ecb.europa.eu (11.11.2018.)
88. EFMA (2013). *The Global Retail Banking Digital Marketing Report 2013*. EFMA. Dostupno na poveznici: https://www.wipro.com/documents/the-global-retail-banking-digital-marketing-report-2013.pdf (11.6.2017.)
89. EFMA (2014). Yearbook 2014 *A review and analysis of the global retail banking industry*. EFMA. Dostupno na poveznici: http://www.efma.com/ressources/studies/2014/1-1C4A97_E_study.pdf (11.6.2017.)
90. EFMA (2017a). Building the future of mobile banking – Part I, Wavestone. Dostupno na poveznici: https://www.wavestone.com/app/uploads/2017/04/mobile-banking-future-efma.pdf (28.9.2018.)
91. EFMA (2017b). Building the future of mobile banking – Part II: Organisation and processes, Wavestone. Dostupno na poveznici: https://www.wavestone.com/app/uploads/2017/09/Efma_Wavestone-Report-%E2%80%93-Mobile-Banking_Part-2_LR_Value-Add_170907.pdf (28.9.2018.)
92. EFMA (2017c). Building the future of mobile banking – Part III: Security and regulatory issues, Wavestone. Dostupno na poveznici: https://www.wavestone.com/app/uploads/2018/01/Efma_Wavestone-Report-%E2%80%93-Mobile-Banking_Part-3_regulatory-and-security-issues-1.pdf (28.9.2018.)
93. EFMA (2017d). Innovation in retail banking 2017: Reimagine banking, Wavestone. Dostupno na poveznici: https://www.efma.com/study/detail/26476 (21.1.2018)
94. EFMA, INDRA (2014) From the Traditional Banking System to the Customer Centric Financial Ecosystem. EFMA, INDRA Financial services. Dostupno na poveznici: https://www.efma.com/study/detail/18815 (11.6.2017.)
95. EFMA, McKinsey (2011). FACE-to-FACE: A €15-20Bn Multichannel opportunity Report. EFMA, McKinsey. Dostupno na poveznici: https://www.efma.com/study/detail/22347 (10.6.2017.)
96. Eid, M. I. (2011). Determinants of e-commerce customer satisfaction, trust, and loyalty in Saudi Arabia. *Journal of Electronic Commerce Research*, 12(1), 78-93.
97. Ein Presswire (2017). Alpaca partners with Jibun Bank to provide FX forecast AI. Dostupno na poveznici: https://www.einpresswire.com/article/393091271/alpaca-partners-with-jibun-bank-to-provide-fx-forecast-ai (16.2.2018.)
98. Ekatah, I., Samy, M., Bampton, R., Halabi, A. (2011). The Relationship Between Corporate Social Responsibility and Profitability: The Case of Royal Dutch Shell Plc. *Corporate Reputation Review*, 14(4), 249-261.
99. Ennew, C. T, Waite N. (2007). *Financial services marketing: an international guide to principles and practice*. Oxford: ButterworthHeinemann Elsevier.

100. Ennew, C., Sekhon, H. S. (2014). *Trust and trustworthiness in retail financial services*. The Routledge Companion to Financial Services Marketing. London: Routledge.
101. Ensor, B., Montez, T. (2012). *The Business Case For Personal Financial Management*. Seattle: Forrester Research.
102. Erste bank (2018). mbanking. Dostupno na poveznici: https://www.erstebank.hr/hr/gradjanstvo/e-bankarstvo/mbanking (18.4.2018.)
103. Etter, M., Ravasi, D., Colleoni, E. (2019). Social media and the formation of organizational reputation. *Academy of Management Review*, 44(1), 28-52.
104. Ewe, S. Y., Yap, S. F., Lee, C. K. C. (2015). Network externalities and the perception of innovation characteristics: mobile banking. *Marketing Intelligence & Planning*, 33(4), 592-611.
105. Federal Reserve Board (2015). Consumers and Mobile Financial Services 2015. Dostupno na poveznici: https://www.federalreserve.gov/econresdata/consumers-and-mobile-financial-services-report-201503.pdf (25.10.2017.)
106. Felsenthal, M., Hahn, R. (2018). Financial Inclusion on the Rise, But Gaps Remain, Global Findex Database Shows. Dostupno na poveznici: http://www.worldbank.org/en/news/press-release/2018/04/19/financial-inclusion-on-the-rise-but-gaps-remain-global-findex-database-shows (8.9.2018.)
107. Ferreira, J. J., Marques, C. S., Azevedo, C. (2011). Competitiveness, resources, and capabilities: empirical evidence from retail banking. *Service Business*, 5(4), 313-337.
108. Fijalkowska, J., Zyznarska-Dworczak, B., Garsztka, P. (2018). Corporate Social-Environmental Performance versus Financial Performance of Banks in Central and Eastern European Countries. *Sustainability*, 10(3), 772 1-22.
109. Flatt, S. J., Kowalczyk, S. J. (2008). Creating competitive advantage through intangible assets: The direct and indirect effects of corporate culture and reputation. *Advances in Competitiveness Research*, 16(1-2), 13.
110. Flavian, C., Guinaliu, M., Torres, E. (2005). The influence of corporate image on consumer trust: A comparative analysis in traditional versus internet banking. *Internet Research*, 15(4), 447-470.
111. Floh, A., Treiblmaier, H. (2006). What keeps the e-banking customer loyal? A multigroup analysis of the moderating role of consumer characteristics on e-loyalty in the financial service industry. *Journal of Electronic Commerce Research*. 7(2), 87-110.
112. Fombrun, C. J. (2001). Corporate Reputations as Economic Asset, 289-312. U: Hitt, M., Freeman, E. R., Harisson, S. J. (ur.) *The Blackwell Handbook of Strategic Management*, Oxford: Blackwell Publishers.
113. Fombrun, C. J., Gardberg, N. A., Sever, J. M. (2000). The Reputation QuotientSM: A multi-stakeholder measure of corporate reputation. *Journal of Brand Management*, *7*(4), 241-255.
114. Fombrun, C., J. Riel, C. B. M. (1997). The reputational landscape. *Corporate reputation review*, 1(1-2), 1-16.
115. Fombrun, C., Shanley, M. (1990). Whats in a Name - Reputation Building and Corporate-Strategy. Academy of Management Journal, 33(2), 233-258.
116. Forcadell, F. J., Aracil, E. (2017). European banks' reputation for corporate social responsibility. *Corporate Social Responsibility and Environmental Management*, 24(1), 1-14.

117. Foster, E. C. (2014). Human resource management. 253-269. U: Foster, E. C. (ur.) *Software Engineering – A Methodical Approach*, Apress: Berkeley.
118. Funk, J. L. (2005). The future of the mobile phone Internet: an analysis of technological trajectories and lead users in the Japanese market. *Technology in Society*, 27(1), 69-83.
119. Ganguli, S. and Roy, S.K. (2011). Generic technology - based service quality dimensions in banking, impact on customer satisfaction and loyalty. *International Journal of Bank Marketing*, 28(2), 167-178.
120. Ganguli, S., Roy, S. K. (2011). Generic technology-based service quality dimensions in banking: Impact on customer satisfaction and loyalty. *International Journal of Bank Marketing*, 29(2), 168-189.
121. Gaultier-Gaillard, S., Louisot, J. P., Rayner, J. Select and Implement the Appropriate Risk Management Technique, 109-133. U: Louisot, J.-P., Ketcham, C. (ur.) (2014).. *ERM Enterprise Risk Management: Issues and Cases*, New York: John Wiley & Sons.
122. Gaultier-Gaillard, S., Louisot, J. P., Rayner, J. Managing reputational risk – From theory to practice. U: Klewes, J., Wreschniok, R. (ur.) (2009). *Reputation Capital: Building and Maintaining Trust in the 21st Century*. Heidelberg, Springer
123. Gera P., (2013). The RE-banking Revolution Innovative Practices from Non-Banking, Accenture. Dostupno na poveznici: http://www.accenture.com/sitecollectiondocuments/pdf/accenture-re-banking-revolution.pdf (20.5.2015.)
124. Gold, R. S. (2012). The strategy-focused IT organization: A ten-year track record of success. *Global Business and Organizational Excellence*, 31(3), 41–57.
125. Gomez-Carrasco, P., Michelon, G. (2017). The Power of Stakeholders' Voice: The Effects of Social Media Activism on Stock Markets. *Business Strategy and the Environment*, *26*(6), 855–872.
126. Gorondutse, A. H., Ahmad, A., Nasidi, M. (2014). Corporate Reputation on Performance of Banking Industries in Nigeria: Using PLS-SEM Tool of Analysis. *European Journal of Business and Management*, 6(24), 71–79.
127. Grgić, D. (2012). Indeks reputacije poduzeća: empirijsko istraživanje u bankovnom sektoru. Market-Tržište, 24(1), 23–45.
128. Grgić, D. (2012). Indeks reputacije poduzeća: empirijsko istraživanje u bankovnom sektoru. *Tržište*, 24(1), 23-45
129. Ha, K. H., Canedoli, A., Baur, A. W., Bick, M. (2012). Mobile banking—insights on its increasing relevance and most common drivers of adoption. *Electronic Markets*, 22(4), 217-227.
130. Hadley, J., Nielsen, N. P., Olsen, T., Turne, G (2015). The Return of Corporate Strategy in Banking, Bain & Co. Dostupno na poveznici: https://www.bain.com/insights/the-return-of-corporate-strategy-in-banking (26.9.2017.)
131. Hamel, G. (2012). *What Matters Now: How to Win in a World of Relentless Change, Ferocious Competition, and Unstoppable Innovation*. Jossey Bass, San Francisco
132. Hanafizadeh, P., Behboudi, M., Koshksaray, A. A., Tabar, M. J. S. (2014). Mobile-banking adoption by Iranian bank clients. *Telematics and Informatics*, 31(1), 62-78.
133. Harrison, J. S., Bosse, D. A., Phillips, R. A. (2010). Managing for stakeholders, stakeholder utility functions, and competitive advantage. *Strategic Management Journal*, 31(1), 58-74.

134. Helm, S. V. (2013). How corporate reputation affects customers' reactions to price increases. *Journal of Revenue & Pricing Management*, 12(5), 402-415.
135. HNB - Hrvatska narodna banka (2002). Izvješće o razvoju i radu funkcije nadzora banaka u Republici Hrvatskoj, HNB. Dostupno na poveznici: http://old.hnb.hr/supervizija/snk-izvjesce.pdf (8.11.2017.)
136. HNB - Hrvatska narodna banka (2011). Bilten o bankama-23. Dostupno na poveznici: https://www.hnb.hr/-/bilten-o-bankama-23 (24.6.2017.)
137. HNB - Hrvatska narodna banka (2013). Zakon o kreditnim institucijama Republike Hrvatske, Narodne novine, broj 117/08, 74/09 i 153/09. Dostupno na poveznici: http://old.hnb.hr/propisi/zakoni-htm-pdf/h-zakon-o-kreditnim-institucijama-zadnji-54-2013.pdf (16.3.2017.)
138. HNB - Hrvatska narodna banka (2016). Bilten o bankama-29, HNB. Dostupno na poveznici: https://www.hnb.hr/-/bilten-o-bankama-29 (28.6.2017.)
139. HNB - Hrvatska narodna banka (2017a). Broj korisnika prema platno prometnim servisima - 31.12.2016. Dostupno na poveznici: http://www.hnb.hr/statistika/statisticki-podaci/platne-usluge/racuni, (6.9.2018.)
140. HNB - Hrvatska narodna banka (2017b). Kamatne stope kotirane na međubankarskom tržištu. Dostupno na poveznici: http://www.hnb.hr/documents/20182/f386021b-965a-4949-a89e-356ef834d8a9 (10.7.2018.)
141. HNB - Hrvatska narodna banka (2017c). Platno-prometna infrastruktura. Dostupno na poveznici: http://old.hnb.hr/platni-promet/h-statisticki-podaci-o-pp.htm (8.9.2018.)
142. HNB - Hrvatska narodna banka (2017c). Bezgotovinski i gotovinski platni promet. Dostupno na poveznici: http://old.hnb.hr/platni-promet/h-statisticki-podaci-o-pp.htm (8.9.2018.)
143. HNB - Hrvatska narodna banka (2018). Bonitetni podaci i pokazatelji poslovanja kreditnih institucija. Dostupno na poveznici: https://www.hnb.hr/statistika/statisticki-podaci/financijski-sektor/druge-monetarne-financijske-institucije/kreditne-institucije/pokazatelji-poslovanja-kreditnih-institucija (29.6.2018.)
144. Hoppermann, J., (2013). *Market Overview: Off-The-Shelf Channel Banking Solutions Can Differentiate And Manage Costs*. Seattle: Forrester Research.
145. Houben, A., Kakes, J. (2002). ICT innovation and economic performance: The role of financial intermediation. *Kyklos*, 55(4), 543-562.
146. HPB – Hrvatska poštanska banka (2018). mHPB. Dostupno na poveznici: https://www.hpb.hr/gradanstvo/e-banka/mhpb (20.4.2018.)
147. Ihlen, Ø., Berntzen, Ø. (2007). When lobbying backfires: Balancing lobby efforts with insights from stakeholder theory. *Journal of Communication Management*, 11(3), 235-246.
148. Intesa SanPaolo (2017). Sustainability Report 2016: Offering Valued Service to Customers, Intesa SanPolo. Dostupno na poveznici: http://intesa16csr.message-asp.com/en/social-and-relational-capital/offering-valued-service-customers (20.9.2018.)
149. Imex banka (2018). Dostupno na poveznici: https://www.imexbanka.hr/internet-bankarstvo (20.4.2018.)
150. Ioannou, I., Serafeim, G. (2015). The Impact of Corporate Social Responsibility on Investment Recommendations: Analysts' Perceptions and Shifting Institutional Logics Dostupno na poveznici: https://dash.harvard.edu/bitstream/handle/1/12534952/ioannou%2Cserafeim_the-impact-of-csr-on-investment-recommendations.pdf?sequence=1 (18.12.2018.)

151. ISACA- Information Systems Audit and Control Association (2011). Mobile Payments: Risk, Security and Assurance Issues, ISACA. Dostupno na poveznici: https://www.isaca.org/Groups/Professional-English/pci-compliance/GroupDocuments/MobilePaymentsWP.pdf (22.9.2018.)
152. ITU – International Telecommunication Union (). ICT Facts and Figures 2017, ITU. Dostupno na poveznici: https://www.itu.int/en/ITU-D/Statistics/Documents/facts/ICTFactsFigures2017.pdf (25.8.2018.)
153. Ivanišević Hernaus, A. (2016). Društvena odgovornost u financijskom sektoru. *EFZG Working Paper Series/EFZG Serija članaka u nastajanju*, (08), 1-17.
154. Ivashina, V., Scharfstein, D. (2010). Bank lending during the financial crisis of 2008. *Journal of Financial Economics*, *97*(3), 319–338.
155. Ivatury, G. and Mas, I. 2008. The early experience with branchless banking, Washington, DC: CGAP.
156. Ivić, P., Grubišić, D. (2013). Međuovisnost društveno odgovornog ponašanja i poslovne uspješnosti. Poslovna izvrsnost : znanstveni časopis za promicanje kulture kvalitete i poslovne izvrsnosti, 7(2), 83–101.
157. J&T banka (2018). E-bankarstvo. Dostupno na poveznici: https://evaba.com.hr/ (17.4.2018.)
158. Jankov, LJ. (2000). Problemi banaka: Uzroci, načini rješavanja i posljedice. Dostupno na poveznici: http://old.hnb.hr/publikac/pregledi/p-002.pdf (25.9.2017.)
159. Jayawardhena, C. (2004). Measurement of service quality in internet banking: the development of an instrument. *Journal of Marketing Management*, 20(1-2), 185-207.
160. Jayawardhena, C., Foley, P. (2000). Changes in the banking sector–the case of Internet banking in the UK. *Internet Research*, 10(1), 19-31.
161. Jerman, M., Kavčić, S., Kavčić, B. (2010). The significance of intangibles: a comparative analysis between Croatia, Slovenia, Czech Republic, Germany and the USA. *Ekonomska istraživanja*, 23(2), 60-70.
162. Jeucken, M. H., Bouma, J. J. (1999). The changing environment of banks. *Greener Management International*, 27, 20-35.
163. Jo, H., Kim, H., Park, K. (2015). Corporate Environmental Responsibility and Firm Performance in the Financial Services Sector. *Journal of Business Ethics*, 131(2), 257-284.
164. Jones, B., Temperley, J., Lima, A. (2009). Corporate reputation in the era of Web 2.0: the case of Primark. *Journal of marketing management*, 25(9-10), 927-939.
165. Jones, S., Heaton, P., Rudin, R. and Schneider, E. (2012). 'Unraveling the IT Productivity Paradox – Lessons for Health Care', *The New England Journal of Medicine*, 366, 2243-2245.
166. Ju, J., Wei, S. J. (2011). When is quality of financial system a source of comparative advantage? *Journal of International Economics*, 84(2), 178-187.
167. Jun, M., Cai, S. (2001). The key determinants of internet banking service quality: a content analysis. *International journal of bank marketing*, 19(7), 276-291.
168. KABA – Karlovačka banka (2018). Dostupno na poveznici: http://www.kaba.hr/gradanstvo/mkaba (15.4.2018.)
169. Kanchan, A., (2012). Trends in Retail Banking Channels: Improving Client Service and Operating Costs. Capgemini. Dostupno na poveznici: https://www.capgemini.com/resource-file-

access/resource/pdf/Trends_in_Retail_Banking_Channels__Improving_Client_Service_and_Operating_Costs.pdf (20.5.2018.)

170. Kao, C. (2000). Labour standards and international competitiveness. *International Journal of Manpower*, 21(3/4), 322-330.
171. Karjaluoto, H. (2002). Selection criteria for a mode of bill payment: Empirical investigation among Finnish bank customers. *International Journal of Retail & Distribution Management*, 30(6), 331-339.
172. KBZ – Kreditna banka Zagreb (2018a). Dostupno na poveznici: http://www.kbz.hr/bankarstvo/KBZ-Net-banking-privatne-osobe (15.4.2018.)
173. KBZ – Kreditna banka Zagreb (2018b). Dostupno na poveznici: http://www.kbz.hr/racuni/kbz-internet-bankarstvo (15.4.2018.)
174. Kensho (2018). Dostupno na poveznici: https://www.kensho.com/, (28.3.2018.)
175. Kentbanka (2018). Internetsko bankarstvo. Dostupno na poveznici: http://www.kentbank.hr/203/internetske-usluge (17.4.2018.)
176. Kim, C., Galliers, R. D. (2004). Toward a diffusion model for Internet systems. *Internet Research*, 14(2), 155-166.
177. Kim, C., Tao, W., Shin, N., Kim, K. (2010). An empirical study of customers' perceptions of security and trust in e-payment systems. Electronic Commerce Research and Applications, 9(1), 84-95.
178. Kimble, C., Milolidakis, G. (2015). Big data and business intelligence: Debunking the myths. *Global Business and Organizational Excellence*, 35(1), 23-34.
179. KOFAX (2017). 2017 Digital Banking Report: Account Opening and Onboarding Benchmarking Study. Dostupno na poveznici: https://www.kofax.com/Learn/Reports/rp_digital-banking-report-account-opening-benchmark--study_en (26.10.2017.)
180. Kolar, T. (2006). Benchmarking market orientation of banks in transitional markets: Exploring a modified approach. *International Journal of Bank Marketing*, 24(2), 76-97.
181. Kossman, S. (2017). 8 FAQs about EMV credit cards. Dostupno na: https://www.creditcards.com/credit-card-news/emv-faq-chip-cards-answers-1264.php (20.1.2018.)
182. Kovanica (2018). Internet bankarstvo. Dostupno na poveznici: https://www.kovanica.hr/internet-bankarstvo-konet (23.4.2018.)
183. KPMG Central and Eastern Europe (2011). Mobile Payments in Central and Eastern Europe. KPMG. Dostupno na poveznici: https://www.kpmg.de/docs/cee_mobile_payments_0701.pdf (10.6.2018.)
184. Krol, K., Philippou, E., De Cristofaro, E., Sasse, M. A. (2015). 'They brought in the horrible key ring thing!' Analysing the Usability of Two-Factor Authentication in UK Online Banking. To appear in NDSS Workshop on Usable Security (USEC 2015). Dostupno na poveznici: http://arxiv.org/abs/1501.04434v1 (17.12.2019.)
185. Kumar, N., Gangal, V. K. (2011). Customer Satisfaction in New Generation Banks (a case study of HDFC Bank). *Journal of Arts, Science and Commerce*, 2(4), 177-186.
186. Kumar, V., Kumar, U., Shareef, M. A. (2017). Mobile banking: a tradeoff between mobile technology and service for consumer behavioural intentions. *Transnational Corporations Review*, 9(4), 319–330.
187. Kunac, J. (2012). Bankarsko komuniciranje s javnostima. *Media, Culture and Public Relations*, *3*(1), 68–77.

188. Kundid Novokmet, A., Bilić, B. (2016). Društvena odgovornost banaka u vrijeme financijske krize: ususret direktivi Europske unije o nefinancijskom izvještavanju. *Oeconomica Jadertina*, 6(1), 54–69.
189. Kundid, A. (2012). Društveno odgovorno poslovanje banaka u republici hrvatskoj. *Ekonomska misao i praksa*, (2), 497-528.
190. Kundid, A., Rogošić, A. (2011). Bank Online Reporting: Comparative Advantage, Formalism of Fashion? *Global Business & Economics Anthology*, II(2), 500-518.
191. Kundid, A., Škrabić, B., Ercegovac, R. (2011). Determinants of bank profitability in Croatia. *Croatian Operational Research Review*, *2*(1), 168-182.
192. Laguir, I., Marais, M., El Baz, J., Stekelorum, R. (2018). Reversing the business rationale for environmental commitment in banking: Does financial performance lead to higher environmental performance? *Management Decision*, 56(2), 358-375.
193. Lange, D., Lee, P. M., Dai, Y. (2011). Organizational reputation: A review. *Journal of Management*, 37(1), 153-184.
194. Lasi, H., Fettke, P., Kemper, H.-G., Feld, T., Hoffmann, M. (2014). Industry 4.0. Business & Information Systems Engineering: *The International Journal of Wirtschaftsinformatik*, 6(4), 239-242.
195. Laukkanen, T. (2017). Mobile banking. *International Journal of Bank Marketing*, 35(7), 1042-1043.
196. Lee, K., Carter, S. (2009). *Global Marketing Management*, 2. izdanje, Oxford: Oxford University Press.
197. Leng, S. Y., Talib, A., Gunardi, A. (2018). Financial technologies: A note on mobile payment. *Jurnal Keuangan Dan Perbankan*, *22*(1), 51-62.
198. Lin, H. F. (2011). An empirical investigation of mobile banking adoption: the effect of innovation attributes and knowledge-based trust. *International Journal of Information Management*, 31(3), 252-260.
199. Ljubaj, I., Petrović, S. (2016). Bilješka o kunskom kreditiranju, HNB. Dostupno na poveznici: https://www.hnb.hr/documents/20182/1197894/p-029.pdf/8a6cc815-aed2-401b-8d70-ecfa750ec220 (30.9.2017.)
200. Lu, Y., Cao, Y., Wang, B., Yang, S. (2011). A study on factors that affect users' behavioural intention to transfer usage from the offline to the online channel. *Computers in Human Behavior*, 27(1), 355-364.
201. Lun, M., Ma, J. (2015). *The Analysis of Mobile Financial Competitiveness Based on Analytic Hierarchy Process*. Berlin and Heidelberg: Springer.
202. MacDonald, J., Tompkins, T. (2017). The history of credit cards. Dostupno na poveznici: https://www.creditcards.com/credit-card-news/history-of-credit-cards.php (22.1.2018.)
203. MacMillan, K., Money, K., Downing, S. Hillenbrand, C. (2005). Reputation in Relationships: Measuring Experiences, Emotions and Behaviors. *Corporate Reputation Review*, 8(3), 214-232
204. Mahon, J., Wartick, S. (2003). Dealing with stakeholders: How reputation, credibility and framing influence the game, *Corporate Reputation Review*, 6(1), 19-35
205. Malik, G., Gulati, K. (2013). An exploratory study on adoption and use of SMS/mobile banking in India with special reference to public sector banks. *Pacific Business Review International*, 5(11), 7-77.
206. Mansor, M., Idris, A. (2015). Employee retention in the Malaysian banking industry: Do flexible practices work? *South African Journal of Business Management*, *46*(1), 1-9.

207. Mas, I., Rosenberg J. (2009). The Role of Mobile Operators in Expanding Access to Finance, CGAP. Dostupno na poveznici: https://www.cgap.org/sites/default/files/CGAP-Brief-The-Role-of-Mobile-Operators-in-Expanding-Access-to-Finance-May-2009.pdf (26.9.2017.)
208. Matarranz, V., Scopa, E., Vlaar, R., (2011). Retail Distribution 2015 – Full Digitalisation with a human touch. EMEA Banking Practice. Dostupno na poveznici: http://www.mckinseyonmarketingandsales.com/retail-bank-distribution-2015-full-digitalisation-with-a-human-touch (10.6.2017.)
209. McGarvey, R (2012). 5 Top Malware Threats to Online and Mobile Banking, Credit Union Times. Dostupno na poveznici: https://www.cutimes.com/2012/06/04/5-top-malware-threats-to-online-and-mobile-banking/?slreturn=20190121041824 (4.5.2018.)
210. McWilliams, A., Siegel, D. (2001). Corporate social responsibility: A theory of the firm perspective. *Academy of Management Review*, 26(1), 117-127.
211. Mian, A., Sufi, A. (2009). The Consequences of Mortgage Credit Expansion: Evidence from the U.S. Mortgage Default Crisis. *The Quarterly Journal of Economics*, *124*(4), 1449-1496.
212. Mihaljek, D. (2014). Domestic bank intermediation in emerging market economies during the 2008-09 crisis. *Financial Theory and Practice*, *38*(4), 381-404.
213. Milanović Glavan, L., Ćibarić, A. (2015). Analiza korištenja internet bankarstva među studentskom populacijom u Republici Hrvatskoj. *Zbornik radova Veleučilišta u Šibeniku*, 3-4, 69-79.
214. Milić, D. C., Kovačević, D., Štefanac, K. (2017). Synergy of information communication technologies and the banking system in the functioning of successful banking operations. *Ekonomski vjesnik*, 30(2), 473-488.
215. Mobile Payments Today (2017). Payment card use sees double-digit global growth in 2016. Dostupno na poveznici: https://nilsonreport.com/upload/pdf/Payment_card_use_sees_double-digit_global_growth_in_2016_-_Mobile_Payments_Today.pdf (20.1.2018.)
216. Monzo (2016). Send £10 to Siri. Dostupno na poveznici: https://monzo.com/blog/2016/09/26/send-10-to-siri/ (3.6.2018.)
217. Morris, T. (2012). *Innovations in Banking.* London: Routledge.
218. Moser, F. (2015). Mobile Banking: A fashionable concept or an institutionalized channel in future retail banking? Analyzing patterns in the practical and academic mobile banking literature. *International Journal of Bank Marketing*, 33(2), 162-177.
219. Motwani, B. (2016). An Empirical Study on the Influence of Gender on Mobile Banking Services. *International Journal of Knowledge Management and Practices; New Delhi*, *4*(2), 1-8.
220. Multz, J. (2014). How mobile devices affect your credit union and members. Credit Union Times. Dostupno na poveznici: https://www.cutimes.com/2014/02/16/how-mobile-devices-affect-your-credit-union-and-members/?slreturn=20190123123042 (9.10.2016.)
221. Murali, S. (2016). Disruptive Innovation Indian Banking Industry. *The Management Accountant Journal*, 51(8), 63-70.
222. N26 (2018). The Mobile Bank - The world at your fingertips. Dostupno na poveznici: https://n26.com/en-eu (20.1.2018.)

223. Nicolò, D. (2015). Towards a Theory on Corporate Reputation and Survival of Young Firms. *Procedia Economics and Finance*, 22, 296-303.
224. Olmedo-Cifuentes, I., Martínez-León, I. M., Davies, G. (2014). Managing internal stakeholders' views of corporate reputation. *Service Business*, 8(1), 83-111.
225. Omazić, M. A. (2007). Društvena odgovornost i strategije hrvatskih poduzeća, Doktorska disertacija, Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.
226. Omazić, M. A., Vlahov, R. D. (2011). The Good, The Bad, and The Ugly: The Case of a Multinacional Corporation in Croatia. *Human resource management*, 6 (83), 83-97.
227. Orlitzky, M., Schmidt, F. L., Rynes, S. L. (2003). Corporate social and financial performance: A meta-analysis. *Organization Studies*, 24(3), 403-441.
228. Özdağoğlu, A., Güler, M. E. (2016). E-service quality of Internet based banking using combined fuzzy AHP and fuzzy TOPSIS. *Technical Gazette*, 23(4), 1109-1116.
229. Page M., Molina M., Jones G., Makarov D. (2013). The Mobile Economy. GSMA, AT Kearney. Dostupno na poveznici: https://www.atkearney.com/documents/10192/760890/The_Mobile_Economy_2013.pdf (20.5.2018.)
230. Paik, M. (2010). Stragglers of the herd get eaten: security concerns for GSM mobile banking applications, HotMobile' 10, *Proceedings of the Eleventh Workshop on Mobile Computing Systems and Applications*, 22-23 February, Annapolis, MD, 54-59.
231. Panian, Ž., Ćurko, K. (ur). (2010). *Poslovni informacijski sustavi*. Zagreb: Element.
232. Parameswar, N., Dhir, S., Dhir, S. (2017). Banking on Innovation, Innovation in Banking at ICICI Bank. *Global Business and Organizational Excellence*, 36(2), 6-16.
233. PBZ – Privredna banka Zagreb (2018a). Digitalno bankarstvo. Dostupno na poveznici: https://www.pbz.hr/hr/gradani/pbz-digitalno-bankarstvo, (12.9.2018.)
234. PBZ – Privredna banka Zagreb (2018a). Inovacija. Dostupno na poveznici: https://www.pbz.hr/hr/gradani/inovacija, (12.9.2018.)
235. Peachey, K. (2014). The emergence of the counter-free bank branch, BBC. Dostupno na poveznici: https://www.bbc.com/news/business-28851597 (8.7.2016.)
236. Peevers, G., Douglas, D., Marshall, D., Jack, M.A. (2011). On the role of SMS for transaction confirmation with IVR telephone banking. *International Journal of Bank Marketin*, 28(3), 206-223.
237. Peevers, G., Douglas, G. and Jack, M.A. 2008. A usability comparison of three alternative message formats for an SMS banking service. *International Journal of Human-Computer Studies*, 66: 113-123.
238. Pirson, M., Malhotra, D. (2011). Foundations of organizational trust: what matters to different stakeholders? *Organization Science*, 22(4), 1087-1104.
239. Pisnik, A., Dlačić, J., Milfelner, B. (2016). Važnost percipirane vrijednosti usluga kod bankarskih usluga. *Market-Tržište*, *28*(2), 191-212.
240. Podrug, N., Rašić Bakarić, I., Slijepčević, S. (2007). Identificiranje i analiza temeljnih kriterija za odabir banke u Hrvatskoj-ciljna skupina studenti. *Zbornik Ekonomskog fakulteta u Zagrebu*, *5*(1), 255-272.
241. Poh, L. T., Kilicman, A., Ibrahim, S. N. I. (2018). On intellectual capital and financial performances of banks in Malaysia. *Cogent Economics & Finance*, *6*(1), 14531574., 1-15.

242. Ponzi, L. J., Fombrun, C. J., Gardberg, N. A. (2011). RepTrak™ Pulse: Conceptualizing and validating a short-form measure of corporate reputation. *Corporate Reputation Review*, 14(1), 15-35.
243. Prabhu, J., Stewart, D. W. (2001). Signaling strategies in competitive interaction: Building reputations and hiding the truth. *Journal of Marketing Research*, 38(1), 62-72.
244. Prahalad, C. K., Ramaswamy, V. (2013). *The future of competition: Co-creating unique value with customers*. Boston: Harvard Business Press.
245. Premalatha, R. J., Suresh, P. G., Kumar, K. C. A., Venkatram, S. H. (2017). A Study on Future Prospects of Plastic Money in Indian Banking System. *Journal of Commerce and Management Thought,* 8(4), 743-759.
246. Prga, I. (2002). Neki aspekti upravljanja bankovnim krizama. *Ekonomski pregled*, 53(5-6), 495-506.
247. Proença, J. F., Branco, M. C. (2014). Corporate social responsibility practices and motivations in a peripheral country: two Portuguese illustrative cases. *Corporate Governance*, 14(2), 252-264.
248. Ptischel, J., Mazzon, J. A. and Hernandez, J. M. C. (2010). Mobile banking: proposition of an integrated adoption intention framework; *International Journal of Bank Marketing*, 27(5), 378-408.
249. Ravasi, D., Rindova, V., Etter, M., Cornelissen, J. (2018). The formation of organizational reputation. *Academy of Management Annals*, 12(2), 574-599.
250. Raynor, E.M., Ahmed, M. (2013). Three Rules for Making a Company Truly Great. Dostupno na poveznici: https://hbr.org/2013/04/three-rules-for-making-a-company-truly-great (21.9.2018.)
251. Raynor, M. E., Ahmed, M. (2013). Three Rules for Making a Company Truly Great. *Harvard Business Review*, 91(4), 108-117.
252. RBC- Royal bank of Canada (2017). RBC first bank in Canada to enable bill payments using Siri. Dostupno na poveznici: http://www.rbc.com/newsroom/news/2017/20170801-siri.html (3.6.2018.)
253. Rego, A., Leal, S., Cunha, M. P. (2011). Rethinking the employees' perceptions of corporate citizenship dimensionalization. *Journal of Business Ethics*, 104(2), 207-218.
254. Reputation Institute (2018). Dostupno na poveznici: https://www.reputationinstitute.com/reputation-measurement-services/reptrak-framework (16.9.2018.)
255. Roberts, P. W., Dowling, G. R. (2002). Corporate reputation and sustained superior financial performance. *Strategic Management Journal*, 23(12), 1077-1093.
256. Robinhood (2018). Invest for free. Dostupno na poveznici: https://www.robinhood.com (20.1.2019.)
257. Rod, M., Ashill, N. J., Shao, J., Carruthers, J. (2009). An examination of the relationship between service quality dimensions, overall internet banking service quality and customer satisfaction: A New Zealand study. *Marketing Intelligence & Planning*, 27(1), 103-126.
258. Rogošić, A. (2014). Corporate social responsibility reporting of the banks in Bosnia and Herzegovina, Croatia and Montenegro. *Theoretical & Applied Economics*, *21*(9), 71-82.
259. Rogošić, A., Kundid, A. (2012). Izvještavanje o društvenoj odgovornosti banaka u hrvatskoj. *Praktični menadžment : stručni časopis za teoriju i praksu menadžmenta*, 3(2), 15-20.
260. Ruoti, S., Andersen, J., Zappala, D., Seamons, K. (2015). *Why Johnny Still, Still Can't Encrypt: Evaluating the Usability of a Modern PGP Client.* Computing Research Repositary.

261. Sääksjärvi, M., Samiee, S. (2011). Relationships among brand identity, brand image and brand preference: differences between cyber and extension retail brands over time. *Journal of interactive marketing*, 25(3), 169-177.
262. Saaty, T. L. (2008). Decision making with the analytic hierarchy process. *International journal of services sciences*, 1(1), 83-98.
263. SABA – Samoborska banka (2018). Dostupno na poveznici: https://ibank.sabank.hr (25.4.2018.)
264. Saeidi, S. P., Sofian, S., Saeidi, P., Saeidi, S. P., Saaeidi, S. A. (2015). How does corporate social responsibility contribute to firm financial performance? The mediating role of competitive advantage, reputation, and customer satisfaction. *Journal of Business Research*, 68(2), 341-350.
265. Sagib, G. K., Zapan, B. (2014). Bangladeshi mobile banking service quality and customer satisfaction and loyalty, Management & Marketing. *Challenges for the Knowledge Society*, 9(3), 331-346.
266. Sangle, P. S., Awasthi, P. (2011). Consumer's expectations from mobile CRM services: a banking context. *Business Process Management Journal*, 17(6), 898-918.
267. Saraiva, P. P., Serrasqueiro, Z. M. S. (2007). Corporate Sustainability in the Portuguese Financial Institutions. *Social Responsibility Journal*, 3(2), 82-94.
268. Sarstedt, M., Wilczynski, P., Melewar, T. C. (2013). Measuring reputation in global markets—A comparison of reputation measures' convergent and criterion validities. *Journal of World Business*, 48(3), 329-339.
269. Sathye, S., Sathye, M. (2017). Do ATMs Increase Technical Efficiency of Banks in a Developing Country? *Evidence from Indian Banks. Australian Accounting Review*, 27(1), 101-111.
270. Sberbank (2018a). The Corporate University. Dostupno na poveznici: https://sberbank-university.ru/en/ (11.11.2018.)
271. Sberbanka (2018b). On-line usluge. Dostupno na poveznici: https://www.sberbank.hr/gradjani/online-usluge/sberbank2go (21.4.2018.)
272. Schaeck, K., Cihák, M. (2014). Competition, efficiency, and stability in banking. *Financial Management*, 43(1), 215-241.
273. Schaffer, P. L. (ur.) (2018). *The Impact of Cybersecurity Incidents on Financial Institutions*, Generali Global Assistance. Dostupno na poveznici: https://static1.squarespace.com/static/555f9696e4b0767a7f0769b3/t/5ab1ae2d8a922dca86e30ee8/1521593911874/The+Impact+of+Cybersecurity+Incidents+on+Financial+Institutions+WHITE+PAPER.pdf (18.12.2019.)
274. Severović, K., Žajdala, N., Cvetković Šoštarić, B. (2009). Konceptualni model kao alat za upravljanje kvalitetom bankarskih usluga. *Ekonomski vjesnik / Econviews : Review of contemporary business, entrepreneurship and economic issues*, XXII(1), 147-160.
275. Shaikh, A. A., Karjaluoto, H. (2015). Mobile banking adoption: A literature review. *Telematics and Informatics*, 32(1), 129-142.
276. Shapshaka, T. (2018). How Mobile Money Continues To Boom In Africa, *Forbes*. Dostupno na poveznici: https://www.forbes.com/sites/tobyshapshak/2018/11/27/how-mobile-money-continues-to-boom-in-africa/#282cec2b205c (10.1.2019.)

277. Sharma, A. (2011). Mobile banking as technology adoption and challenges. *International Journal of Multidisciplinary Research*, 1(6), 147-157.
278. Sharma, P. K., Pandey, V. (2015). Broadband Services in India: Problems and Prospects. *Pacific Business Review International*, 8(5), 102-112.
279. Shirvan, K., Elahe, M., Hasan, S., Mohammad, P. (2014). Marketing, Competitive Strategies and Operational Coordination for Performance Improvement in Banking Industry. *Advances in Natural & Applied Sciences*, 8(7), 806-814.
280. Sičenica, B. (2001). Uloga promocije u marketingu hrvatskih banaka. Ekonomski pregled, 52(5–6), 730-745.
281. Sidel, R. (2016). Mobile Bank Heist: Hackers Target Your Phone. Dostupno na poveznici: https://www.wsj.com/articles/mobile-bank-heist-hackers-target-your-phone-1472119200 (18.5.2018.)
282. Sikdar, P., Kumar, A., Makkad, M. (2015). Online banking adoption: A factor validation and satisfaction causation study in the context of Indian banking customers, *International Journal of Bank Marketing*, 33(6), 760-785.
283. Singh, K. (2011). Innovated Technology in Banking Services. *Journal of Internet Banking and Commerce; Ottawa*, 16(2), 1-15.
284. Singh, S. (2007). *The digital packaging of electronic money*, 469–475. U: Aykin, N. (ur.) *Usability and internationalization - Global and local user interfaces*, New York: Springer
285. SLB – Slatinska banka (2018). m-bank. Dostupno na poveznici: https://www.slatinska-banka.hr/mbank.php (22.4.2018.)
286. Smith, J., Love, P. E., Wyatt, R. (2001). To build or not to build? Assessing the strategic needs of construction industry clients and their stakeholders. *Structural Survey*, 19(2), 121-132.
287. STB – Splitska banka (2018). Dostupno na poveznici: https://www.splitskabanka.hr/online-bankarstvo/sb-smartnet-mobilno-bankarstvo (22.4.2018.)
288. Steiner, N. (2017). Mobile Operators and Fintech, GSMA – GSM Association. Dostupno na poveznici: https://www.gsma.com/identity/wp-content/uploads/2017/04/Mobile-Operators-and-Fintech.pdf (27.9.2018.)
289. Stiakakis, E., Georgiadis, C. K., Andronoudi, A. (2016). Users' Perceptions About Mobile Security Breaches. *Information Systems and e-Bussines Management*, 14(4), 857-882.
290. Surroca, J., Tribó, J. A., Waddock, S. (2010). Corporate responsibility and financial performance: The role of intangible resources. *Strategic Management Journal*, 31(5), 463-490.
291. Sushil (2013). Does continuous change imply continuity? *Global Journal of Flexible Systems Management*, 14(3), 123-124.
292. Svilar, A., Zupančič, J. (2016). User Experience with Security Elements in Internet and Mobile Banking. *Organizacija*, 49(4), 251-260.
293. Szwajca, D. (2016). Corporate Reputation and Customer Loyalty as the Measures of Competitive Enterprise Position - Empirical Analyses on the Example of Polish Banking Sector. *Oeconomia Copernicana*, *7*(1), 91-106.
294. Šandrk Nukić, I., Šuvak, N. (2013). Utjecaj upravljanja ljudskim potencijalima na percepciju organizacijske uspješnosti u hrvatskim građevinskim poduzećima. *Poslovna izvrsnost*, 7(2), 125-140.

295. Štedbanka u stečaju (2018). Dostupno na poveznici: http://www.stedbanka.hr/ (10.4.2018.)
296. Teece, D. J., Pisano, G., Shuen, A. (1997). Dynamic capabilities and strategic management. *Strategic management journal*, 18(7), 509-533.
297. Teo, A.-C., Tan, G. W.-H., Ooi, K.-B., Hew, T.-S., Yew, K.-T. (2015). The effects of convenience and speed in m-payment. *Industrial Management & Data Systems*, 115(2), 311-331.
298. Terzidis, K., Papadopoulou, E., Kosmidis, K. (2013). Customer e-loyalty to internet banking: an empirical analysis, *Global Business and Economics Review*, 15(2/3), 148-162.
299. Tesla banka u stečaju (2018). Dostupno na poveznici: http://www.tesla-banka.hr/o_nama/teslabanka/9/HR, (10.4.2018.)
300. Tesla banka u stečaju (2018b). Dostupno na poveznici: http://www.tesla-banka.hr (23.04.2018.)
301. The Harris Poll (2018). The Reputations Of The Most Visible Companies. Dostupno na poveznici: http://www.theharrispoll.com/reputation-quotient (25.9.2018.)
302. The Federal Reserve (2017). Compliance Guide to Small Entities-Regulation E: Electronic Fund Transfers 12 CFR 205. Dostupno na poveznici: https://www.federalreserve.gov/supervisionreg/regecg.htm (19.5.2018)
303. The Financial Brand (2017). Cardless ATMs Going Mainstream. Dostupno na poveznici: https://thefinancialbrand.com/65205/cardless-atm-withdrawals/ (22.1.2018.)
304. The World Bank Group (2018). World Urbanization Prospects. Dostupno na poveznici: https://data.worldbank.org/indicator/sp.urb.totl.in.zs (5.9.2018.)
305. Thrassou, A., Philip, L. R.(2008). Motivators and critical factors in mobile banking communications: The case of Kuwait. *Journal for Global Business advancement*, 1(4), 327-349.
306. Tinnilä, M. (2012). Impact of future trends on banking services. *Journal of Internet Banking and Commerce*, 17(2), 1-15.
307. Tipurić, D. (1996). Porterov model industrijske strukture. *Poslovna analiza*, (3/4), 30-37.
308. Tipurić, D. (2014) *Iluzija strategije: Razotkrivanje socijalno konstruirane zbilje poduzeća.* Zagreb: Sinergija.
309. Treen, E., Pitt, L., Bredican, J., Farshid, M. (2017). App service: How do consumers perceive the quality of financial service apps on smart devices? *Journal of Financial Services Marketing*, 22(3), 119-125
310. Urrico, R. (2015,). Cyberattacks target mobile banking. *Credit Union Times*. Dostupno na poveznici: https://www.cuinsight.com/cyberattacks-target-mobile-banking.html (17. 12.2018.).
311. Valcke, J. (2016). Best practices in mobile security. *Biometric Technology Today*, 3, 9-11.
312. Vejačka, M., Štofa, T. (2017). Influence of Security and Trust on Electronic Banking Adoption in Slovakia. *E+M Ekonomie a Management; Liberec*, 20(4), 135-150.
313. Veneto bank (2018). Internet bankarstvo. Dostupno na poveznici: http://venetobanka.hr/hr/internetsko-bankarstvo (23.4.2018.)
314. Vidaković, N. (2014). Bank's choice of loan portfolio under high regulation – example of Croatia. *Financije i pravo*, 2(1), 29-44.
315. Vlašić, G., Langer, J. (2012). Concept of reputation: different perspectives and robust empirical understandings. *Tržište*, 24(2), 219-244.

316. Vojvodić Rosenzweig, V., Volarević, H., Varović, M. (2013). A multi-criteria analysis of the banking system in the Republic of Croatia. *Financial Theory and Practice*, 37(4), 403–422.
317. Walker, K. (2010). A systematic review of the corporate reputation literature: Definition, measurement, and theory. *Corporate Reputation Review*, 12(4), 357-387.
318. Walker, S., Ensor, B. (2014). *European Digital Banking Forecast 2014 to 2018*. Seattle: Forrester Research.
319. Wang, Y., Lo, H. P., Hui, Y. V. (2003). The antecedents of service quality and product quality and their influences on bank reputation: evidence from the banking industry in China. *Managing Service Quality*: *An International Journal*, 13(1), 72-83.
320. Wannemacher, P., da Costa M. (2013). *Global Mobile Banking Functionality Rankings.* Seattle: Forrester Research.
321. Wartick, S. L. (2002). Measuring Corporate Reputation: Definition and Data. *Business & Society*, 41(4), 371-392.
322. Weber, M., Erickson, S. L., Stone, M. (2011). Corporate reputation management: Citibank's use of image restoration strategies during the US banking crisis. *Journal of Organizational Culture, Communications and Conflict*, 15(2), 35-55.
323. WEF – World Economic Forum (2015). The Future of Financial Services How disruptive innovations are reshaping the way financial services are structured, provisioned and consumed, WEF. Dostupno na poveznici: http://www3.weforum.org/docs/WEF_The_future__of_financial_services.pdf (22.7.2017.)
324. WEF – World Economic Forum (2016a). A Blueprint for Digital Identity The Role of Financial Institutions in Building Digital Identity, WEF. Dostupno na poveznici: http://www3.weforum.org/docs/WEF_A_Blueprint_for_Digital_Identity.pdf (28.10.2017.)
325. WEF – World Economic Forum (2016b). The future of financial infrastructure An ambitious look at how blockchain can reshape financial services, WEF. Dostupno na poveznici: http://www3.weforum.org/docs/WEF_The_future_of_financial_infrastructure.pdf (22.7.2017.)
326. WEF – World Economic Forum (2017). Beyond Fintech: A Pragmatic Assessment Of Disruptive Potential In Financial Services, WEF. Dostupno na poveznici: http://www3.weforum.org/docs/Beyond_Fintech_-_A_Pragmatic_Assessment_of_Disruptive_Potential_in_Financial_Services.pdf (22.7.2017.)
327. Wei Shen, O., Yazdanifard, R. (2015). Has Mobile Payment Finally Live Up to Its Expectation in Replacing Cash and Credit?. *International Journal of Management, Accounting and Economics*, 2(5), 488-498.
328. Weill, P., Woerner, S. L. (2018). Is Your Company Ready for a Digital Future? *MIT Sloan Management Review*, 59(2), 21-25.
329. Weisbaum H (2015). Why has Mobile banking growth stalled? Blame Hackers, NBC News. Dostupno na poveznici: https://www.nbcnews.com/business/consumer/why-has-mobile-banking-growth-stalled-blame-hackers-n351851 (18.6.2017.)
330. Wilkinson, D. (2017). Open Banking and the API Economy, DWC – Strategy Innovation Leadership & FinTech Network. Dostupno na poveznici:

http://retailbankinginnovation.fintecnet.com/uploads/2/4/3/8/24384857/fintech_dwc_report_v2.pdf (16.6.2017.)

331. Williams, C. C., Seguí-Mas, E. (2010). Corporate governance and business ethics in the European Union: a cluster analysis. *Journal of Global Responsibility*, 1(1), 98-126.
332. Wu, M., Jayawardhena, C., Hamilton, R. (2014). A comprehensive examination of internet banking user behaviour: evidence from customers yet to adopt, currently using and stopped using, *Journal of Marketing Management*, 30(9-10), 1006-1038.
333. Wu, M.-W., Shen, C.-H. (2013). Corporate social responsibility in the banking industry: Motives and financial performance, *Journal of Banking & Finance*, 37(9), 3529-3547.
334. Wu, M.-W., Shen, C.-H., Chen, T.-H. (2017). Application of multi-level matching between financial performance and corporate social responsibility in the banking industry. *Review of Quantitative Finance and Accounting*, 49(1), 29-63.
335. Xie, B., Lin, Y., Guo, X. (2009). A study on adoption factors of mobile banking services, *Nankai Business Review*, 12(3), 12-19.
336. Yang, K. 2010. The effects of technology self-efficacy and innovativeness on consumer mobile data service adoption between American and Korean consumers. *Journal of International Consumer Marketing* 22(2), 117-127.
337. Yaobin L., Yuzhi C., Bin W. (2011). *Computers in Human Behavior*. London: Elsevier
338. Yousafzai, S. Y., Pallister, J. G., Foxall, G. R. (2005). Strategies for Building and Communicating Trust in Electronic Banking: *A Field Experiment. Psychology & Marketing*, 22(2), 181-201
339. Yu, C. S. (2012). Factors affecting individuals to adopt mobile banking: Empirical evidence from the UTAUT model. *Journal of Electronic Commerce Research*, 13(2), 104-121.
340. ZABA – Zagrebačka banka (2018a). M-zaba aplikacija. Dostupno na poveznici: https://www.zaba.hr/home/m-zaba (15.10.2018.)
341. ZABA – Zagrebačka banka (2018b). E-zaba aplikacija. Dostupno na poveznici: https://www.zaba.hr/home/gotovinski-kredit-e-zaba-i-m-zaba (15.10.2018.)
342. ZABA – Zagrebačka banka (2018c). m-zaba. Dostupno na poveznici: https://www.zaba.hr/home/m-zaba-mobilno-bankarstvo (23.4.2018.)
343. Zemel, M. (2018). The Information Content of Loan Growth in Banks. *Quarterly Journal of Finance*, 8(2), 1850004 1-32.
344. Zhou, T. (2012). Understanding users' initial trust in mobile banking: An elaboration likelihood perspective. *Computers in Human Behavior*, 28(4), 1518-1525.
345. Zopa (2018). The FeelGood Money Company. Dostupno na poveznici: https://www.zopa.com/about, (12.10.2018.)

POPIS SLIKA

Slika 1. Model istraživanja 9
Slika 2. Vlasništvo imovine kreditnih institucija prema zemljama članicama Europske unije 20
Slika 3. Stope profitabilnosti prema promjenjivoj kompoziciji Europske unije u periodu 2007.-2013. 40
Slika 4. Profitabilnost kapitala te imovine banaka na razini zemalja Europske unije, ROE, ROA 41
Slika 5. Stopa promjene koncentracije broja stanovnika na jednu poslovnicu kreditne institucije, jednog zaposlenika i jedan bankomat zemalja Europske unije 43
Slika 6. Koncentracija poslovnih jedinica, zaposlenika i broja bankomata prema zemljama Europe, 2015 44
Slika 7. Udio poslovnih jedinica i bankomata kreditnih institucija prema županijama RH, 2015 46
Slika 8. Koncentracija poslovnih jedinica banke i bankomata prema županijama RH, sortirano prema broju stanovnika na jednu poslovnicu banke, 2015 48
Slika 9. Stopa promjene koncentracije stanovnika na jednu poslovnicu banke u periodu 2012.-2015. 48
Slika 10. Stopa promjene koncentracije stanovnika na jedan bankomat u razdoblju 2012.-2015. 49
Slika 11. ROE, veličina banke, broj bankomata 50
Slika 12. Omjer neto kamatnih prihoda i neto prihoda od provizija i naknada prema zemljama EU, 2008.-2013. 54
Slika 13. Kamatne stope na međubankarskom tržištu (ZIBOR) 61
Slika 14. Udio elektronički iniciranih platnih naloga, 2005 122
Slika 15. Udio elektronički iniciranih platnih naloga, 2015 122
Slika 16. Udio korisnka Internetskog bankarstva 125
Slika 17. Struktura ispitanika s obzirom na glavnu banku i učestalost korištenja mobilnog bankarstva 159
Slika 18. Struktura ispitanika s obzirom na spol, dob i obrazovanje 161
Slika 19. Struktura ispitanika s obzirom na veličinu naselja i županiju 162
Slika 20. Prosječne vrijednosti ocjena sigurnosti mobilnog bankarstva 163
Slika 21. Prosječne vrijednosti ocjena jednostavnosti mobilnog bankarstva 164
Slika 22. Prosječne vrijednosti ocjena dostupnosti mobilnog bankarstva 165
Slika 23. Prosječne vrijednosti ocjena percipirane kvalitete mobilnog bankarstva 166
Slika 24. Prosječne vrijednosti ocjena reputacije banke 167
Slika 25. Prosječne vrijednosti ocjena dimenzija istraživanja 168
Slika 26. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K1 171
Slika 27. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K1 171
Slika 28. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K2 174
Slika 29. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K2 174
Slika 30. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K3 177
Slika 31. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K3 177
Slika 32 Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K4 180
Slika 33. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: K5 182
Slika 34. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: K5 183

Slika 35. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R1 185
Slika 36. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R1 185
Slika 37. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R2 187
Slika 38. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R2 188
Slika 39. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R3 190
Slika 40. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R3 190
Slika 41. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R4 192
Slika 42. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R4 193
Slika 43. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R5 195
Slika 44. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R5 195
Slika 45. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R6 197
Slika 46. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R6 198
Slika 47. Histogram reziduala (neprotumačenih odstupanja) zavisne varijable: R7 200
Slika 48. Normalizirani P-P grafikon reziduala (neprotumačenih odstupanja) zavisne varijable: R7 200

POPIS TABLICA

Tablica 1. Vlasnička struktura kreditnih institucija u RH 19
Tablica 2. Koncentracija kreditnih institucija u pojedinim zemljama članicama Europske unije, 2011-2015, C_5, HHI 23
Tablica 3. Kreditne institucije u Republici Hrvatskoj, 30.6.2016. 25
Tablica 4. Struktura imovine banaka, XII. 2012 - VI. 2016. mil. HRK 51
Tablica 5. Struktura obveza i kapitala banaka, XII. 2012. - VI. 2015. mil. HRK 52
Tablica 6. Račun dobiti i gubitka banaka, mil. HRK 53
Tablica 7. Rizik u plasmanima banaka, VI. 2012.-2016., u 000 HRK 55
Tablica 8. Troškovi izvora financiranja banaka prema valutama, Udio u ukupnim izvorima i troškovima 57
Tablica 9. Kvaliteta kredita po valutama 58
Tablica 10. Struktura depozita banaka prema sektorima 60
Tablica 11. Atributi reputacije 79
Tablica 12. Lista najutjecajnijih časopisa te pripadajućih rang lista poduzeća prema njihovoj reputaciji 80
Tablica 13. Platni servisi prema broju računa, građani, poslovni subjekti, 31.12.2013. 123
Tablica 14. Broj računa korisnika prema platno prometnim servisima 124
Tablica 15 Podaci o bezgotovinskim platnom prometu prema broju transakcija, VI.2005; VI.2013. 126
Tablica 16. Podaci o bezgotovinskim platnom prometu prema vrijednosti transakcija, 2005, 2013 127
Tablica 17. Kartična plaćanja prema načinu izvršenja i prema vrstama kartice, IV. 2013. ... 128
Tablica 18. Popis funkcionalnosti mobilnog bankrstva banakrskog tržišta u Republici Hrvatskoj 135
Tablica 19. Nasljeđe organizacijske strukture organizacija financijskog sektora i digitalizacija poduzeća 139
Tablica 20. Konstrukt sigurnosti mobilnog bankarstva 153
Tablica 21. Konstrukt jednostavnosti korištenja mobilnog bankarstva 154
Tablica 22. Konstruktu dostupnosti usluga mobilnog bankarstva 155
Tablica 23. Konstrukt percipirane kvalitete usluge mobilnog bankarstva 156
Tablica 24. Konstrukt reputacije banaka 156
Tablica 25. Glavna banka ispitanika kod koje koriste mobilno bankarstvo 158
Tablica 26. Učestalost korištenja mobilnog bankarstva 158
Tablica 27. Spol ispitanika 159
Tablica 28. Dob ispitanika 160
Tablica 29. Obrazovanje ispitanika 160
Tablica 30. Veličina mjesta stanovanja ispitanika 161
Tablica 31. Županija stanovanja ispitanika 161
Tablica 32. Deskriptivna statistika sigurnosti mobilnog bankarstva 163
Tablica 33. Deskriptivna statistika jednostavnosti mobilnog bankarstva 164
Tablica 34. Deskriptivna statistika dostupnosti mobilnog bankarstva 165
Tablica 35. Deskriptivna statistika percipirane kvalitete mobilnog bankarstva 166
Tablica 36. Deskriptivna statistika reputacije banke 166
Tablica 37. Koeficijenti pouzdanosti dimenzija istraživanja 168
Tablica 38. Deskriptivna statistika prosječnih vrijednosti dimenzija istraživanja 168
Tablica 39. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K1 169
Tablica 40. Anova analiza regresijskog modela – Zavisna varijabla: K1 169
Tablica 41. Procjene parametara regresijskog modela - Zavisna varijabla: K1 170

Tablica 42. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K2..... 172
Tablica 43. Anova analiza regresijskog modela – Zavisna varijabla: K2 172
Tablica 44 Procjene parametara regresijskog modela - Zavisna varijabla: K2 173
Tablica 45. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K3..... 175
Tablica 46. Anova analiza regresijskog modela – Zavisna varijabla: K3 175
Tablica 47. Procjene parametara regresijskog modela - Zavisna varijabla: K3 176
Tablica 48. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K4..... 178
Tablica 49. Anova analiza regresijskog modela – Zavisna varijabla: K4 178
Tablica 50. Procjene parametara regresijskog modela - Zavisna varijabla: K4 179
Tablica 51. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: K5..... 181
Tablica 52. Anova analiza regresijskog modela – Zavisna varijabla: K5 181
Tablica 53. Procjene parametara regresijskog modela - Zavisna varijabla: K5 182
Tablica 54. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R1..... 183
Tablica 55. Anova analiza regresijskog modela – Zavisna varijabla: R1 184
Tablica 56. Procjene parametara regresijskog modela - Zavisna varijabla: R1 184
Tablica 57. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R2..... 186
Tablica 58. Anova analiza regresijskog modela – Zavisna varijabla: R2 186
Tablica 59. Procjene parametara regresijskog modela - Zavisna varijabla: R2 187
Tablica 60 Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R3..... 188
Tablica 61. Anova analiza regresijskog modela – Zavisna varijabla: R3 189
Tablica 62. Procjene parametara regresijskog modela - Zavisna varijabla: R3 189
Tablica 63. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R4..... 191
Tablica 64. Anova analiza regresijskog modela – Zavisna varijabla: R4 191
Tablica 65. Procjene parametara regresijskog modela - Zavisna varijabla: R4 192
Tablica 66. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R5..... 193
Tablica 67. Anova analiza regresijskog modela – Zavisna varijabla: R5 194
Tablica 68. Procjene parametara regresijskog modela - Zavisna varijabla: R5 194
Tablica 69. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R6..... 196
Tablica 70. Anova analiza regresijskog modela – Zavisna varijabla: R6 196
Tablica 71. Procjene parametara regresijskog modela - Zavisna varijabla: R6 197
Tablica 72. Pokazatelji reprezentativnosti regresijskog modela – Zavisna varijabla: R7..... 198
Tablica 73. Anova analiza regresijskog modela – Zavisna varijabla: R7 199
Tablica 74. Procjene parametara regresijskog modela - Zavisna varijabla: R7 199
Tablica 75. Sumarni rezultati regresijskih modela – Zavisne varijable: K1, K2, K3, K4, K5 202
Tablica 76. Testiranje hipoteza korištenjem regresijskih modela– Zavisne varijable: K1, K2, K3, K4, K5 206
Tablica 77. Sumarni rezultati regresijskih modela – Zavisne varijable: R1, R2, R3, R4, R5, R6, R7..... 207
Tablica 78. Testiranje hipoteza korištenjem regresijskih modela– Zavisne varijable: R1, R2, R3, R4, R5, R6, R7..... 209

ŽIVOTOPIS AUTORICE

Berislava Starešinić rođena je 15.06.1971. u Slavonskom Brodu . Godine 1990. upisala je Ekonomski fakultet u Zagrebu, a diplomirala je 1995. godine. Godine 2000. upisala je Znanstveni poslijediplomski studij „Ekonomija međunarodne razmjene" na Ekonomski fakultet Zagreb, gdje je i magistrirala 2009. godine sa temom magistarskog rada: "*Stupanj globaliziranosti Republike Hrvatske 1996. – 2006.*", uz mentorstvo prof. dr.sc. Ljubo Jurčića. Godine 2010. upisala je Poslijediplomski doktorski studij "Ekonomija" na Ekonomskom fakultetu u Zagrebu. Godine 1995. zapošljava se u Županjskoj banci kao pripravnik, a od 1996. do 1999. godine radi u Kreditnoj banci Zagreb u Sektoru računovodstva i Sektoru upravljanja likvidnosti banke. Od 1999. radi u Privrednoj banci Zagreb u Grupi poslovanja sa stanovništvom, a započela je na radnom mjestu viši analitičar u Sektoru za razvoj distribucijskih kanala. Godine 2004. postaje voditelj tima, 2007. glavni koordinator, a 2012. godine imenovana je za direktora Direkcije za klasično bankarstvo u isotm sektoru. Od 2015. do 2016. godine radi kao pomoćnik diektora Direkcije za prodaju, a od 2016. do danas kao direktor za Razvoj affluent segmenta u funkciji Affluent klijenti. Od 2007. do 2013. godine polazila je Poslovnu školu Privredne banke Zagreb u sklopu programa dodatnog usavršavanja menadžerskih vještina, te je stekla diplomu Općeg menadžmenta i Operativno-prodajnog menadžmenta.

Popis objavljenih radova

1. Starešinić, B. (2009). Stupanj globaliziranosti Republike Hrvatske – Ekonomska percepcija, Ekonomski fakultet Zagreb, PDS Ekonomija međunarodne razmjene; mentor prof. dr.sc. Ljubo Jurčić
2. Starešinić, B., Ivančević, T. (2011). Globalization Index of Croatia between 1996 and 2007 – Economic Perception. 8th International Conference *Economic Integrations, Competition an Cooperation*, Urednik: Kandžija, Vinko. Rijeka, 07.-08.4.2011. Dostupno na CD.

ŽIVOTOPIS MENTORA

Prof. dr. sc. Mislav Ante Omazić redoviti je professor na Katedri za organizaciju i menadžment Ekonomskog fakulteta Sveučilišta u Zagrebu. Doktorat znanosti stekao je
2007. godine na Ekonomskom fakultetu Sveučilišta u Zagrebu pod naslovom Društvena odgovornost i strategije hrvatskih poduzeća. Sudjelovao je u čitavom nizu znanstvenih projekata: "Pact4Youth", "Postani/ostani poduzetnik (POP)", "Hidden Champions" "Fostering Entrepreneurship in Higher Eduction – FoSentHE" i "Korporativno upravljanje i konkurentnost hrvatskih poduzeća" i dobitnik je Dekanove nagrade za izuzetan nastavni rad sa studentima i javnu promociju Institucije, „Oskara za dobrotu" (nagrade koja se dodjeljuje za razvoj civilnog društva) i nagrade "Mijo Mirković". Član je čitavog niza stručnih udruženja i tijela: Global Shapers Community, predsjednik udruge alumnija Ekonomskog fakulteta Sveučilišta u Zagrebu, IBM ambassador, član i su-osnivač lokalne podružnice međunarodne udruge za poticanje izvrsnosti mladih Young Executive Society (YES), osnivač i mentor udruge alumnija "eALUMNI" koja se sastoji od najboljih studenata koji su bili članovi udruge eSTUDENT, član Europskog pokreta, član Hrvatskog akademsko-poslovnog kluba, osnivač i mentor najveće i najaktivnije hrvatske studentske udruge "eSTUDENT" koja svake godine umrežava preko 250 najboljih studenata zagrebačkog sveučilišta i do sada je realizirala preko 70 projekata.

Odabrana bibliografija

1. Tipurić, D.; Omazić, M. A.; Radić, M. (2016): Is there substantial benefit of short-term doctoral workshops in management?, ICERI2016 Proceedings 9th International Conference of Education, Research and Innovation, 14.-16.9.2016., Sevilja, Španjolska, str. 3426-3432.
2. Omazić, M. A.; Matešić, M. (2016): The History of Wishful Thinking-Come True?, str. 141-168. U Stachowicz-Stanusch, A. (ur.): Corporate Social Performance in the Age of Irresponsibility - Cross National Perspective, Charlotte: Information Age Publishing.
3. Omazić, M. A.; Lugović, S. (2015): Trust as a Layer on Semantic Web and Fundament for Development of Socoocognotive Paradigm in Higher Education Information Systems, str. 293-318. U Wankel, C., Stachowicz-Stanusch, A. (ur.): Emerging Web 3.0/Semantic Web Applications in Higher Education, Charlotte (NC): IAP - Information Age Publishing.
4. Pejić-Bach, M.; Omazić, M. A.; Zoroja, J. (2014): Transparency as a Precondition of Systemic Behavior: the Case of European Retailing Banks Regarding Social Responsibility Communication, Systems Research and behavioural science, 32 (2): 256-264.

5. Hruška, D.; Omazić, M. A.; Fuzul, J. (2011): Comparative analysis of contemporary corporate governance issues in selected transition economies of south-east Europe. The 5th International Scientific Conference – Entrepeneuership and Macroeconomic Management Reflections on the World in Turmoil. Conference Proceedings. Vol 1, str. 733-753.
6. Omazić, M. A.; Vlahov, R. D.; Klindžić, M. (2010): The role of Material and Non-Material Rewards in Reducing Barriers To Change Acceptance. ICEBM 2010: International Conference on Economics, Business and Management. December, 2010, Conference Proceedings, Vol 2, str. 10-14.

PRILOZI

Prilog 1 Struktura institucija konsolidiranog izvještavanja prema regulatoru

Grupacija kreditnih institucija	*Krovna institucija*	*Članice grupe*
ERSTE&STEIERMÄRKISCHE BANK	Erste&Steiermärkische Bank d.d., Rijeka	Erste bank AD, Podgorica
		Erste Card Club d.d., Zagreb
		Erste factoring d.o.o., Zagreb
		Erste nekretnine d.o.o., Zagreb
		Erste&Steiermärkische S-Leasing d.o.o., Zagreb
		Erste Card d.o.o., Ljubljana
HRVATSKA POŠTANSKA BANKA	Hrvatska poštanska banka d.d., Zagreb	HPB-Stambena štedionica d.d., Zagreb
HYPO ALPE-ADRIA-BANK	Hypo Alpe-Adria-Bank d.d., Zagreb	Hypo Alpe-Adria-Invest d.d., Zagreb
		Hypo Alpe-Adria-Leasing d.o.o., Zagreb
PRIVREDNA BANKA ZAGREB	Privredna banka Zagreb d.d., Zagreb	PBZ CARD d.o.o., Zagreb
		PBZ Croatia osiguranje d.d. za upravljanje obveznim mirovinskim fondom, Zagreb
		PBZ Leasing d.o.o., Zagreb
		PBZ stambena štedionica d.d., Zagreb
		PBZ-NEKRETNINE d.o.o., Zagreb
RAIFFEISENBANK AUSTRIA	Raiffeisenbank Austria d.d., Zagreb	Raiffeisen Consulting d.o.o., Zagreb
		Raiffeisen Factoring d.o.o., Zagreb
		Raiffeisen Invest d.o.o., Zagreb
		Raiffeisen Leasing d.o.o., Zagreb
		Raiffeisen Bonus d.o.o., Zagreb
		Raiffeisen stambena štedionica d.d., Zagreb
		Raiffeisen društvo za upravljanje obveznim i dobrovoljnim mirovinskim fondovima d.d., Zagreb
		Raiffeisen mirovinsko osiguravajuće društvo d.d., Zagreb
SOCIÉTÉ GÉNÉRALE-SPLITSKA BANKA	Société Générale-Splitska banka d.d., Split	SG Leasing d.o.o., Zagreb
ZAGREBAČKA BANKA	Zagrebačka banka d.d., Zagreb	Prva stambena štedionica d.d., Zagreb
		UniCredit Bank d.d., Mostar
		ZB Invest d.o.o., Zagreb
		UniCredit Leasing Croatia d.o.o., Zagreb

Izvor: *https://www.hnb.hr/statistika/statisticki-podaci/kreditne-institucije/pokazatelji-poslovanja-kreditnih-institucija*, *prilozi*, *[pristupljeno 2.3.2017.]*

Prilog 2 Vlasništvo kreditnih institucija prema udjelu kapitala

NAZIV BANKE	*NAZIV VLASNIKA*	*%*
ZAGREBAČKA BANKA d.d.	UniCredit Bank Austria AG	84,48
	Allianz SE	11,72
PRIVREDNA BANKA ZAGREB d.d.	Intesa Sanpaolo Holding International S.A.	97,47
ERSTE&STEIERMÄRKISCHE BANK d.d.	ESB Holding GmbH	100,00
RAIFFEISENBANK AUSTRIA d.d.	Raiffeisen SEE Region Holding GmbH	100,00
SOCIÉTÉ GÉNÉRALE-SPLITSKA BANKA d.d.	Société Générale SA	100,00
HYPO ALPE-ADRIA-BANK d.d.	Hypo Group Alpe Adria AG	100,00
HRVATSKA POŠTANSKA BANKA d.d.	*Republika Hrvatska*	*40,82*
	HP – Hrvatska pošta d.d.	*21,81*
	Državna agencija za osiguranje štednih depozita i sanaciju banaka	*16,41*
	Hrvatski zavod za mirovinsko osiguranje	*16,00*
	Fond za financiranje razgradnje NEK	*4,28*
OTP BANKA HRVATSKA d.d.	OTP Bank NYRT	100,00
SBERBANK d.d.	Sberbank Europe AG	100,00
KREDITNA BANKA ZAGREB d.d.	Euroherc osiguranje d.d.	19,95
	Agram životno osiguranje d.d.	19,05
	Jadransko osiguranje d.d.	17,99
	Euroleasing d.o.o.	7,71
	Agram invest d.d.	5,71
	Štedbanka d.d.	4,99
	Sunce osiguranje d.d.	4,38
	Primorska banka d.d.	3,86
	Locusta Value IV, otvoreni alternativni investicijski fond s privatnom ponudom	3,06
CROATIA BANKA d.d.	Državna agencija za osiguranje štednih uloga i sanaciju banaka	100,00
PODRAVSKA BANKA d.d.	Antonia Gorgoni	9,91
	Lorenzo Gorgoni	9,87
	Assicurazioni Generali S.p.A.	9,54
	Cerere S.p.A.	9,53
	Miljan Todorović	8,33
	Andrea Montinari	5,76
	Dario Montinari	5,76
	Piero Montinari	5,76
	Sigilfredo Montinari	5,76
	Giovanni Semeraro	4,11
ISTARSKA KREDITNA BANKA UMAG d.d.	Intercommerce d.o.o.	17,16
	Serfin d.o.o.	9,84
	Assicurazioni Generali S.p.A.	7,76
	Marijan Kovačić	6,91
	Terra Istriana Umag d.o.o.	6,37
	Edo Ivančić	3,71
	Branko Kovačić	3,64
	Plava laguna d.d.	3,63
	Željko Paić	3,46
	Nerio Perich	3,45
KARLOVAČKA BANKA d.d.	Marko Vuković	35,98
	Ivan Žabčić	35,98
	Zagrebačka nadbiskupija	8,67
	Marijan Šarić	4,52
IMEX BANKA d.d.	Branko Buljan	58,71
	Ivka Mijić	20,19
	Trajektna luka Split d.d.	4,42
	Ivana Matić	3,99
	Dušanka Mišković	3,99
VABA d.d. BANKA VARAŽDIN	J&T Banka a.s.	67,74
	Alternative upravljanje d.o.o.	21,50
	Validus d.d. u stečaju	3,09
JADRANSKA BANKA d.d.	Bank Alpinum AG	10,74
	Importanne Resort d.o.o.	9,81
	Croatia osiguranje d.d.	7,50

	Importanne d.o.o.	7,17
	Alfa d.d.	5,73
	Jolly Auto Line d.o.o.	5,67
	Vodovod i odvodnja d.o.o.	4,99
	HEK d.o.o.	4,31
	Marko Saređen	3,47
	Ugo grupa d.o.o.	3,40
KENTBANK d.d.	Eksen Holding A.Ş.	100,00
BKS BANK d.d.	BKS Bank AG	100,00
SLATINSKA BANKA d.d.	SZAIF d.d.	24,00
	Državna agencija za osiguranje štednih uloga i sanaciju banaka	8,32
	Dragutin Sokačić	8,03
	Vlastite dionice	7,77
	Banka Splitsko-dalmatinska d.d.	6,62
	Emil Mikulić	3,98
	Ljubica Berišić	3,96
	Josip Galić	3,26
	Milivoj Mrkoci	3,26
	Finesa Credos d.d.	3,16
PARTNER BANKA d.d.	Metroholding d.d.	90,01
	Croduxplin d.o.o.	9,99
VENETO BANKA d.d.	Veneto Banca S.c.p.a.	100,00
BANKA KOVANICA d.d.	Cassa di Risparmio della Repubblica di San Marino S.p.A.	99,67
ŠTEDBANKA d.d.	Šted-Nova d.o.o.	80,74
	Željko Udovičić	9,87
	Šted-invest d.o.o.	6,35
	Redip d.o.o.	3,04
PRIMORSKA BANKA d.d.	C.I.M. Banque SA	71,33
	Francesco Signorio	16,08
	Domenico Petrella	3,50
SAMOBORSKA BANKA d.d.	Aquae Vivae d.d.	83,54
	Samoborka d.d.	5,15
	Tigra d.o.o.	3,13
BANKA SPLITSKO-DALMATINSKA d.d.	Juroslav Buljubašić	46,29
	Irena Kalebić Bašić	9,58
	Venći Čulić Meić	9,22
	Anita Juretić	7,50
	Joško Dvornik	5,75
	Mirko Vukušić	4,04
	Jakiša Medić	3,02
PRVA STAMBENA ŠTEDIONICA d.d.	Zagrebačka banka d.d.	100,00
WÜSTENROT STAMBENA ŠTEDIONICA d.d.	Bausparkasse Wüstenrot AG	100,00
PBZ STAMBENA ŠTEDIONICA d.d.	Privredna banka Zagreb d.d.	100,00
RAIFFEISEN STAMBENA ŠTEDIONICA d.d.	Raiffeisenbank Austria d.d.	100,00
HPB-STAMBENA ŠTEDIONICA d.d.	Hrvatska poštanska banka d.d.	100,00

Izvor: https://www.hnb.hr/statistika/statisticki-podaci/kreditne-institucije/pokazatelji-poslovanja-kreditnih-institucija, izvještaji, *[pristupljeno 28.3.2017.]*

Prilog 3 Lista funkcionalnosti

Lista funkcionalnosti	*R1*	*R2*	*R3*	*R4*	*R5*	*R6*	*R7*	*R8*	*R9*	*R10*	*R11*	*R12*	*R13*	*R14*	*R15*	*R16*	*R17*	*R18*	*R19*	*R20*	*R21*	*R22*	*R23*	*R24*	*R25*	*R26*	*R27*	*R28*
Aktivacija kartica	0	0	0	0	0	0	1	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Bonovi za mobitel	1	1	1	0	0	0	1	1	0	0	0	0	X	0	0	X	0	1	0	0	0	X	X	S	0	0	S	S
Deblokada PIN-ova	0	0	0	0	0	0	1	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Dopunsko zdravstveno	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Financijski planer	0	0	0	0	0	0	0	0	0	1	1	0	X	0	0	X	1	1	0	0	0	X	X	S	0	0	S	S
HAC	1	0	0	0	0	0	1	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Kalkulator za izračun kredita i depozita	0	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	1	0	0	X	X	S	0	0	S	S
Kupoprodaja deviza	1	1	1	0	1	1	1	1	1	1	0	1	X	1	0	X	0	0	1	1	1	X	X	S	1	0	S	S
Lokacijske usluge	1	1	0	0	1	0	1	0	1	1	0	0	X	1	0	X	1	1	1	0	0	X	X	S	0	0	S	S
M-foto/I-račun plaćanje računa	1	1	0	1	1	1	0	1	1	1	1	0	X	1	0	X	1	1	1	1	0	X	X	S	0	0	S	S
Obvezno autoosiguranje	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Osiguranje imovine	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Osiguranje od privatne odgovornosti	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Otvaranje računa	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Plaćanje mobitelom na odabranim prodajnim mjestima	1	1	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Podizanje gotovine na bankomatu bez kartice	0	0	0	0	0	0	1	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Promjena PIN-a za token	0	0	0	0	1	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Provjera stanja i prometa računa, kartica, štednje i kredita	1	1	1	1	1	1	1	1	1	1	1	1	X	1	1	X	1	1	1	1	1	X	X	S	1	1	S	S
Putem IBAN-a ili QR koda prebacivati sredstva drugim korisnicima untar banke	1	1	1	1	1	1	1	1	1	1	1	1	X	1	1	X	1	1	1	1	1	X	X	S	1	1	S	S
Putno osiguranje	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Skeniranje dokumenata i plaćanje	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Tečajna lista	1	1	1	1	1	1	1	1	1	1	1	1	X	1	0	X	0	0	1	1	1	X	X	S	1	1	S	S
Transfer novca na račune u Hrvatskoj	1	1	0	1	1	1	1	1	1	1	1	1	X	1	1	X	1	1	1	1	1	X	X	S	1	1	S	S
Transfer novca na račune u inozemstvu	0	0	0	0	0	1	0	0	0	0	0	0	X	0	0	X	0	0	1	0	1	X	X	S	0	0	S	S
Trgovanje na svjetskim burzama	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Trgovanje udjelima u fondovima	1	1	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Ugovaranje depozita	0	1	0	0	1	1	0	0	0	0	0	0	X	0	0	X	0	1	0	0	0	X	X	S	0	0	S	S
Ugovaranje sastanaka	0	0	0	0	0	0	1	0	0	0	0	0	X	0	0	X	0	1	0	0	0	X	X	S	0	0	S	S
Ugovoranje gotovinskog kredita	1	0	0	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Upravljanje bodovima programa lojalnosti	0	0	1	0	0	0	0	0	0	0	0	0	X	0	0	X	0	0	0	0	0	X	X	S	0	0	S	S
Upravljanje dnevnim limitima kartica	1	0	0	0	0	0	1	0	0	0	0	0	X	0	0	X	0	1	0	0	0	X	X	S	0	0	S	S

Prilog 4 Upitnik
Poštovani,

molim Vas da ispunite anketni upitnik čiji će se podaci koristiti isključivo za pisanje doktorske disertacije pod naslovom: „**Povezanost kvalitete mobilnog bankarstva i reputacije banaka**“.

Hvala puno na Vašem vremenu!

Berislava Starešinić, doktorski kandidat

Sveučilište u Zagrebu, Ekonomski fakultet

Dio G. PODACI O BANCI KOJU ISPITANIK NAJČEŠĆE KORISTI

G1. Koja Vam je glavna banka?:

1. Zagrebačka banka
2. Privredna banka Zagreb
3. Poštanska banka
4. Raiffeisen banka
5. Splitska banka Societe Generale
6. Erste banka
7. Hypo banka
8. Sberbank
9. OTP banka
10. Slatinska Banka
11. druga banka (navesti koja) _____

G2. Koliko često koristite mobilno bankarstvo:

1. svaki dan
2. jedan puta tjedno
3. nekoliko puta tjedno
4. jedan puta mjesečno
5. nekoliko puta mjesečno
6. rjeđe
7. ne koristim aplikaciju

I Indikatori kvalitete mobilnog bankarstva i reputacije banaka

PI-1. Sigurnost mobilnog bankarstva

PI-1.1. Nadogradnja aplikacije mobilnog bankarstva je sigurna
PI-1.2. Aplikacija mobilnog bankarstva je stabilna
PI-1.3. Učitavanje nove verzije aplikacije se izvršava točno i u kratkom vremenu
PI-1.4. Sve funkcionalnosti aplikacije se izvršavaju točno i na vrijeme
PI-1.5. Podrška banke u održavanju aplikacije je adekvatna i zadovoljavajuća
PI-1.6. Korištenje aplikacije mobilnog bankarstva je sigurno

PI-2. Jednostavnog korištenja mobilnog bankarstva

PI-2-1. Preuzimanje i učitavanje aplikacije mobilnog bankarstva je jednostavno
PI-2-2. Aktiviranje aplikacije mobilnog bankarstva je jednostavno
PI-2-3. Pretraživanje aplikacije mobilnog bankarstva je jednostavno
PI-2-4. Izvršavanje plaćanja u aplikaciji mobilnog bankarstva je jednostavno
PI-2-5. Kontaktiranje djelatnika banke putem aplikacije mobilnog bankarstva je jednostavno
PI-2-6. Aplikacija mobilnog bankarstva je jednostavna za korištenje

PI-3. Dostupnost usluga mobilnog bankarstva

PI-3-1. Aplikacija omogućava ugovaranje depozitnih proizvoda
PI-3-2. Aplikacija omogućava ugovaranje i/ili popunjavanje zahtjeva za kreditne proizvode
PI-3-3. Aplikacija omogućava kupovinu udjela u fondovima
PI-3-4. Aplikacija omogućava ugovaranje police osiguranja
PI-3-5. Aplikacija omogućava ugovaranje kartica
PI-3-6. Aplikacija omogućava plaćanje 2d bar code-om (opcija slikaj i plati)
PI-3-7. Aplikacija omogućava personaliziranu komunikaciju
PI-3-8. Preko aplikacije dobivam personalizirane ponude
PI-3-9. Općenito sam zadovoljan/a sa funkcionalnostima aplikacije mobilnog bankarstva

PI-4. Percipirana kvaliteta usluge mobilnog bankarstva

PI-4-1. Sveukupna usluga klijentima kroz mobilno bankarstvo je izvrsna
PI-4-2. Usluga mobilnog bankarstva moje glavne banke je vrlo visoke kvalitete
PI-4-3. Aplikacija mobilnog bankarstva moje glavne banke u potpunosti zadovoljava moje potrebe i očekivanja
PI-4-4. Prosječan rezultat ukupne procjene pouzdanosti, sigurnosti i jednostavnosti korištenja mobilnog bankarstva moje glavne banke je adekvatan
PI-4-5. Općenito sam zadovoljan/zadovoljna sa kvalitetom mobilnog bankarstva moje glavne banke

PI-5. Reputacija Vaše glavne banke

PI-5-1. Banka za koju imam dobar osjećaj
PI-5-1. Banka kojoj vjerujem
PI-5-1. Banka koju poštujem
PI-5-1. Banka koja ima tradiciju
PI-5-1. Banka koja ima snagu međunarodne organizacije
PI-5-1. Banka koja cijeni mene kao klijenta
PI-5-1. Banka ima dobru ukupnu reputaciju

Dio G. PODACI O ISPITANIKU

G1. Spol

12. Muško
13. Žensko

G2. Dob

1. 20 do 29 godina
2. 30-39 godina
3. 40-49 godina
4. 50-59 godina
5. 60-64 godina
6. više od 65 godina

G3. Obrazovanje

1. osnovna škola
2. srednja stručna sprema
3. fakultet - VŠS, završen stručni studij, završen dodiplomski studij
4. fakultet - završen diplomski studij
5. magisterij ili doktorat

G4. Prebivalište:

1. grad
2. selo

H5. Županija _______