

ODNOS PROMJENE U STRUKTURI FINANCIJSKE IMOVINE I NEREALIZIRANIH DOBITAKA/GUBITAKA OD FER VRIJEDNOSTI

Čabo, Marina

Master's thesis / Diplomski rad

2019

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

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:124:943045>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-19**

Repository / Repozitorij:

[REFST - Repository of Economics faculty in Split](#)



UNIVERSITY OF SPLIT



DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

DIPLOMSKI RAD

**ODNOS PROMJENE U STRUKTURI
FINANCIJSKE IMOVINE I NEREALIZIRANIH
DOBITAKA/GUBITAKA OD FER VRIJEDNOSTI**

Mentor:

doc. dr. sc. Šodan Slavko

Student:

Čabo Marina

Split, rujan, 2019. godine

SADRŽAJ DIPLOMSKOG RADA

1. UVOD	3
1.1. Problem istraživanja	3
1.2. Predmet istraživanja	4
1.3. Istraživačke hipoteze	4
1.4. Cilj rada.....	6
1.5. Metode istraživanja	6
1.6. Doprinos	7
1.7. Struktura diplomskog rada	7
2. TEORIJSKI OKVIR ZA MOTIV DONOŠENJA ODLUKE U KLASIFIKACIJI IMOVINE	8
2.1. Pojam i značenje informacija prilikom donošenja odluka	8
2.1.1. Informacijska asimetrija	10
2.1.1. Agencijska teorija.....	12
2.2. Pozitivna računovodstvena teorija	13
3. REGULATORNI OKVIR VEZA ZA PRIZNAVANJE I MJERENJE FINANCIJSKE IMOVINE	15
3.1. Računovodstveni standardi vezano za priznavanje i mjerenje financijske imovine (MRS 39 i MSFI 9)	15
3.2. Mjerenje financijske imovine	18
3.2.1. Početno priznavanje financijske imovine.....	19
3.2.2. Naknadno mjerenje	22
3.3. Reklasifikacija.....	23
4. EMPIRIJSKA ISTRAŽIVANJA.....	27
4.1. Prikupljanje podataka za potrebe istraživanja	27
4.2. Obrada podataka različitim metodama istraživanja	28
4.3. Rezultati obrađenih podataka	29
4.3.1. Deskriptivna statistika.....	29
4.3.2. Regresija	34
4.4. Analiza rezultata obrađenih podataka	40

ZAKLJUČAK.....	42
SAŽETAK.....	44
SUMMARY.....	45
LITERATURA	46
POPIS TABLICA.....	49
POPIS SLIKA.....	50
GRAFIKONI	50

1. UVOD

1.1. Problem istraživanja

Uspješno poslovanje polazi od kvalitetno provedenih odluka, kod kojih važnu ulogu imaju točne i pravovremene informacije. Naime, prema Tipurić (2008), česta pojava je da zbog nemogućnosti preuzimanja i vlasničke i menadžerske uloge, vlasnik za ulogu upravljanja angažira agenta. Problem ovakve raspodjele je odnos između vlasnika i agenta, to jest, njihova obostrana korist. Zbog takvih pojava nastaje problem informacijske asimetrije i moralni hazard.

Informacijska asimetrija je jedna od problema agencijske teorije. Ona predstavlja nejednakost između vlasnika i agenta glede informacija. Prema Tipurić (2008), informacijska asimetrija se dijeli na problem nepovoljnog izbora i problem moralnog hazarda. Moralni hazard je specifičan po tome što se djelovanje agenta teško prati, a on poznavajući tu situaciju, poduzima sve one aktivnosti kako bi imao svoju korist, nakon što je ugovor potpisan.

Navedeni problemi (agencijska teorija i moralni hazard) temelj su za pozitivnu računovodstvenu teoriju. Mogućnost alternativnih izbora računovodstvenih metoda zavisno o različitim situacijama, omogućuju menadžerima da manipuliraju stvarnim informacijama. Postoje tri hipoteze za izbor računovodstvenih alternativa, a to su (Tipurić, 2008):

- ❖ Hipoteza nagradnih planova- vlastiti interes menadžera i primanje bonusa uz fiksni dio plaće,
- ❖ Hipoteza zaduženosti- održavanje i realizacija dužničkih ugovora temeljem odabira određenih računovodstvenih politika,
- ❖ Hipoteza političkih troškova- vlada pod pritiskom javnog interesa nameće dodatne poreze u situacijama iznadprosječnih profita.

Banke, kao i ostali poduzetnici, dužne su sastavljati financijske izvještaje. Kako bi sastavila financijske izvještaje, prema Filipović (2008.), banke su obvezne primjenjivati MSFI (Međunarodni standardi financijskog izvještavanja) i MRS (Međunarodni računovodstveni standardi). U ovome radu naglasak je na MRS 39 i MSFI 9, odnosno na standarde koji se koriste za klasifikaciju financijske imovine.

Financijska imovina se može dijeliti na četiri, odnosno, prema MSFI-u 9, tri kategorije.

Naime, prvobitna podjela je bila na 4 kategorije prema MRS-u 39 koji je kasnije zamijenjen MSFI-em 9. U ovom radu spominje se MRS 39 zato što uzorak banaka koji je analiziran je iz razdoblja od 2014.-2016. godine kada je na snazi i dalje bio MRS 39.

Podjela na četiri kategorije financijske imovine prema MRS-u 39 glasi:

- ❖ Financijska imovina po fer vrijednosti kroz dobit ili gubitak,
- ❖ Ulaganja koja se drže do dospijeca,
- ❖ Zajmovi i potraživanja,
- ❖ Financijska imovina raspoloživa za prodaju.

Nakon 2018. godine na snagu stupa MSFI 9 koji dijeli financijsku imovinu na:

- ❖ Financijsku imovinu po amortiziranom trošku,
- ❖ Po fer vrijednosti kroz ostalu sveobuhvatnu dobit (OSD),
- ❖ Po fer vrijednosti kroz račun dobiti i gubitka.

Odluku o klasifikaciji imovine na jedno od navedenih kategorija donosi računovođa, a može ovisiti o kretanjima na tržištu, također, može ovisiti i o vlastitim interesima prilikom sagledavanja odnosa računovođa-vlasnik.

Dakle, iz navedenog, zaključuje se problem istraživanja: odnos vlasnik- računovođa prilikom odabira načina klasifikacije određene financijske imovine u jednu od četiri kategorije prema MRS-u 39, odnosno tri prema MSFI-u 9, zavisno od vlastitih interesa i/ili kretanjima na tržištu, uz problem informacijske asimetrije i obostrane koristi.

1.2. Predmet istraživanja

Predmet istraživanja ovoga rada je odnos promjene u strukturi financijske imovine i nerealiziranih dobitaka/gubitaka od fer vrijednosti i financijske imovine banaka u Europi.

Navedene promjene rezultat su klasifikacije i reklasifikacije imovine unutar četiri kategorije financijske imovine zavisno od odluka koje se temelje na vlastitim interesima i promjenama u okolini. Istraživanje se odnosi na banke u Europi koje su odabrane zbog većeg broja banaka i većeg obima informacija u odnosu na banke u Hrvatskoj.

1.3. Istraživačke hipoteze

Istraživačke hipoteze glase:

- **H1: Promjena nerealiziranih dobitaka i gubitaka od promjene fer vrijednosti financijske imovine utječe na strukturu financijske imovine u narednoj godini**
- **H2: Promjena u udjelu financijske imovine vrednovane po fer vrijednosti je povezana s nerealiziranim dobitcima/gubitcima od promjene fer vrijednosti u narednoj godini**

Teoretska očekivanja su takva da se smatra da će na strukturu financijske imovine u narednoj godini utjecati promjena nerealiziranih dobitaka i gubitaka od promjene fer vrijednosti financijske imovine, odnosno, da promjena u udjelu financijske imovine vrednovane po fer vrijednosti povezana s nerealiziranim dobitcima/gubitcima od promjene fer vrijednosti u narednoj godini. Dakle, u prvoj hipotezi se pretpostavlja da će banke koje su ostvarile gubitke od fer vrijednosti u narednoj godini smanjivati udio imovine koja je klasificirana u kategorije koje se vrednuju po fer vrijednosti kako i u sljedećoj godini ne bi imali dodatne gubitke.

U drugoj hipotezi se pretpostavlja da se na temelju informacije o reklasifikaciji imovine ili promjene u strukturi financijske imovine mogu iščitati bankovne procjene tržišnih kretanja u narednoj godini. Tako da ako bankovni analitičari procijene rast tržišne vrijednosti financijske imovine u narednoj godini, onda će povećavati udio tih kategorija financijske imovine u tekućoj godini. Dakle, očekuje se da će povećanje udjela financijske imovine vrednovane po fer vrijednosti u tekućoj godini, biti pozitivno povezano s dobitcima od fer vrijednosti u narednoj godini.

Naime, promjene koje utječu na strukturu financijske imovine uglavnom su prouzročene odlukama koje su donesene kao reakcija na određena kretanja na tržištu i kao odluke temeljene na raznim motivima.

Prema istraživanjima Biscof, Bruggemann i Daske (2012.) zaključuje se kako zbog financijske krize iz 2008. godine, došlo je do izmjene MRS 39, gdje im se omogućuje odustajanje od priznavanja određene financijske imovine po fer vrijednosti. Banke koje su bile u najnepovoljnijim položajima su imale koristi od mogućnosti reklasifikacije. Slično istraživanje imao je i Fiecher (2011.) koji zaključuje kako je većina banaka izbjegla velike gubitke po fer vrijednosti zbog provedene reklasifikacije za vrijeme velike financijske krize. Iz navedenih istraživanja može se zaključiti kako promjene u okolini poput financijske krize u 2008. godini mogu utjecati na promjene u strukturi financijske imovine.

Hladika i Perčević (2012.) u svojim istraživanjima navode kako profitabilnosti i financijski položaj banke može uvelike ovisiti o klasifikaciji financijskih instrumenata u jednu od četiri prethodno navedene kategorije. Dakle, odluke o načinu klasifikacije i reklasifikacije financijske imovine mogu utjecati na njenu uspješnost.

1.4.Cilj rada

Cilj ovog rada je utvrditi povezanost strukture financijske imovine i nerealizirane dobiti odnosno gubitka od fer vrijednosti od financijske imovine u bankama Europe, a ciljevi su:

- ❖ Utvrditi agencijski problem i pozitivnu računovodstvenu teoriju kako djeluju na donošenje odluka o klasifikaciji financijske imovine,
- ❖ Utvrditi vrste i oblike financijske imovine,
- ❖ Važnost standarda u klasifikaciji financijske imovine, izmjene nakon financijske krize, te utjecaj na mijenjanje strukture financijske imovine na temelju dosadašnjih istraživanja,
- ❖ Prikazati početno i naknadno vrednovanje financijske imovine, uvjete za provođenje reklasifikacije,
- ❖ Na temelju banaka iz EU doći do zaključka o promjeni u strukturi financijske imovine.

1.5. Metode istraživanja

Kako bi se prikupili podaci i na temelju njih donosili zaključci, potrebno je da se provedu određene metode istraživanja, a to su:

- ❖ *Deskriptivna metode*- postupak je jednostavnog opisivanja ili očitavanja činjenica i empirijski potvrđivanje veza i odnosa,
- ❖ *Metoda eksplanacije*- pomoću ove metode objašnjavaju se važna obilježja uočenih činjenica,
- ❖ *Metoda kompilacije*- postupak je preuzimanja tuđih rezultata znanstvenih istraživačkih radova, to jest, tuđa opažanja, stavova, zaključaka i spoznaja,
- ❖ *Metoda analize*- korištenjem navedene metode dolazi se do zaključaka raščlanjivanjem iz složenih u jednostavne misaone cjeline,
- ❖ *Metoda sinteze*- s ovom metodom omogućuje se istraživanje i objašnjavanje predmeta istraživanja spajanjem jednostavnih cjeline u složenije,
- ❖ *Metoda klasifikacije*- postupak je sistematske i potpune podjele općeg pojma na posebne,
- ❖ *Metoda komparacije*- postupak uspoređivanja promatranih varijabli,
- ❖ *Metoda apstrakcije*- odvajanje bitnih od nebitnih elemenata predmeta istraživanja,
- ❖ *Metoda indukcije*- na temelju pojedinih ili posebnih činjenica dolazi do zaključka o općem sudu,

- ❖ *Metoda dedukcije*- temeljem općih sudova dolazi do zaključaka o pojedinim, konkretnim slučajevima.

1.6. Doprinos

Doprinos ovog rada je u prikazivanju važnosti uloge koju imaju informacije kod donošenja odluka o klasifikaciji financijske imovine, a kasnije i o njenoj reklasifikaciji. Kroz agencijsku i pozitivnu računovodstvenu teoriju pojasnit će se što sve utječe na točnost informacija i na odluku prilikom svrstavanja stavki unutar četiri kategorije financijske imovine. Na temelju postavljenih hipoteza, zaključit će se kako određene promjene stavki financijske imovine utječu na cjelokupnu strukturu financijske imovine. Jako je malo provedeno ovakvih istraživanja u Hrvatskoj, a informacije za praktični dio rada uzete su od banaka iz EU zbog većeg obima informacija i banaka.

1.7. Struktura diplomskog rada

Diplomski rad podijeljen je u 5 cjelina.

U prvom, uvodnom dijelu, navodi se problem i predmet istraživanja, te istraživačke hipoteze na kojima se i temelje problem i predmet istraživanja. Također, pojašnjeno je i koji je cilj i doprinos istraživanja diplomskog rada, te kojim metodama istraživanja je rad obrađen.

Drugo poglavlje se odnosi na teorijski okvir motiva za donošenje odluka o klasifikaciji financijske imovine. Pojašnjena je agencijska i pozitivna računovodstvena teorija i zašto su one bitne za donošenje odluka o klasifikaciji financijske imovine.

U trećem poglavlju pojašnjen je pojam financijske imovine, njene kategorije, te regulatorni okvir za priznavanje navedene imovine. Objašnjeno je što je to klasifikacija, a što reklasifikacija, te na koji način i pod kojim uvjetima se financijska imovina može klasificirati, odnosno reklasificirati. Također, navedeni su i razlozi zašto re/klasificirati, te koji su ishodi navedenih radnji.

U četvrtom dijelu diplomskog rada provedeno je empirijsko istraživanje promjene u strukturi financijske imovine i nerealiziranih dobitaka, odnosno gubitaka od fer vrijednosti financijske imovine. Istraživanje je provedeno na temelju prikupljene baze podataka banaka u Europi.

Zadnje poglavlje diplomskog rada sadrži zaključak provedenog istraživanja na temelju postavljenih hipoteza, te literature, popisa tablica i slika i sažetka.

2. TEORIJSKI OKVIR ZA MOTIV DONOŠENJA ODLUKE U KLASIFIKACIJI IMOVINE

2.1. Pojam i značenje informacija prilikom donošenja odluka

Sagledavajući proces donošenja odluka, među kojima dominiraju informacije kao uvjet za donošenje istih, zapravo je računovodstvo to koje generira većinu informacija prikupljajući, obrađujući kroz kontroliranje podataka i analiziranje povezanosti podataka te prezentirajući ih kao rezultat cjelokupnog procesa. Kako bi se pobliže pojasnilo pojam računovodstva, potrebno je spomenuti kako je to skup informacija koji pomoću njegove opisne i analitičke discipline sažima opsežan broj informacija i priprema ih za potrebe klijenata kako bi uspješno donijeli odluku. Računovodstvo pruža kvantitativne informacije. Naime, često se računovodstvo zamijeni s pojmom knjigovodstva. Knjigovodstvo bilježi ekonomske promjene u novčanim jedinicama u odgovarajućim knjigama. (Belak, 2006.)

Dakle, glavna razlike između ovih disciplina su u tome što knjigovodstvo bilježi poslovne promjene u skladu sa zakonskim propisima, dok računovodstvo prateći zakone, treba još i sagledavati kako poduzeće posluje, koji su mu temeljni problemi i iznalaženje najboljih poteza kako bi njihovo poslovanje unaprijedio (Žager i ostali, 2008.).

Odnosno, smatra se kako je knjigovodstvo dio računovodstva. Sama pretpostavka proizlazi iz strukture računovodstva koja se može primijetiti na slici 1.




Slika 1:Struktura računovodstva

Izvor: izrada autora prema Žager i ostali (2008.)

Prvi dio računovodstvene strukture je orijentirano prema budućnosti – planiranju i stvaranju predračuna. Naime, nakon planiranja, slijedi bilježenje stvarnih poslovnih događaja s vjerodostojnom knjigovodstvenom ispravom koje ima utjecaj na trenutno stanje računovodstvenih kategorija kao što su imovina, obveze, kapital, prihod, rashod i finansijski rezultat, te da se promjena može vrijednosno izraziti gdje nastaju obračuni. Nakon planiranja i

knjigovodstva, sve je veća potreba za kontrolom istih. Nakon kontrole slijedi utvrđivanju povezanosti planiranog od stvarno nastalog događaja gdje faza računovodstvena analiza utvrđuje sve ono što je odstupalo od planiranog. Kraj računovodstvenog procesa je računovodstveno informiranje. (Žager i ostali, 2008.)

Za fazu prezentiranja jako je bitan korisnik kojemu se prezentiraju informacije, jer se iz tog zaključka računovodstvo može dijeliti kao prema sljedećoj slici:



Slika 2: Vrsta računovodstva prema podjeli korisnika informacija

Izvor: izrada autora prema Žager, Mamić Sačer, Sever i Žager, 2017.

Dakle, kao što se može vidjeti i na slici, korisnici informacija mogu biti interni ili eksterni. Ako su interni korisnici informacija, oni se koriste upravljačkim računovodstvom i računovodstvom troškova, dok financijsko računovodstvo uglavnom koriste vanjski ili eksterni korisnici informacija.

Ostale karakteristike gore navedenih računovodstava su (Žager i ostali, 2008.):

1. Financijsko računovodstvo – glavni proizvod su financijski izvještaji, isporučuje povijesne podatke i obvezno je po zakonu,
2. Upravljačko računovodstvo – informacije koje proizlazi iz ove vrste računovodstva su usmjerene na proces planiranja i kontroliranja poslovanja, svojevrsna pomoć menadžmentu poduzeća prilikom donošenja odluka i nije propisano zakonom,
3. Računovodstvo troškova – obuhvaća područje troškova financijskog i upravljačkog računovodstva, nema svoju točnu određenu definiciju, ali smatra se onim oblikom računovodstva koji pruža informaciju uspješnosti poslovanja i cjelokupnim praćenjem

proizvodnje te pruža informacije o prošlim i planiranim troškovima kao i kontrolu istih isključivo za interne potrebe i također nije propisano zakonom.

Financijski izvještaji čine izvor većine informacija i rezultat su cijelog računovodstvenog proces obrade podataka. Pod glavnim karakteristikama financijskih izvještaja spadaju njihova objektivnost i realnost. Važnost financijskih izvještaja je da budu vjerodostojna slika stvarnog poslovanja, a njihova svrha je to da su dobar temelj za donošenje odluke, te su uglavnom namijenjeni vanjskim korisnicima (Žager, Mamić Sačer, Sever i Žager, 2017.). Više o financijskim izvještajima bit će u nastavku rada.

2.1.1. Informacijska asimetrija

Bitnu ulogu informacije imaju i kod investitora i kreditora kao eksternih korisnika informacija. Ali često u tom slučaju pojavljuje se pojam informacijske asimetrije, gdje eksterni korisnici imaju užu sliku poslovanja nego oni interni. Kod informacijske asimetrije, pojavljuju se dvije vrste informacija:


- Javno dostupne,
- Povlaštene informacije.

Ona vrsta informacija koja je poznata se naziva javnom dostupnom informacijom, dok su povlaštene informacije uglavnom dostupne internim korisnicima informacija, jer se smatra kako bi informacije ako postanu dostupne i eksternim korisnicima mogle utjecati na cijenu vrijednosnih papira. Dakle, informacijska asimetrija uvelike može utjecati na cijenu vrijednosnih papira (Tipurić, 2008). Iduće teorije koje će pojasniti o čemu se radi su:

- Problem nepovoljnog izbora,
- Problem moralnog hazarda.

Naime, problem nepovoljnog izbora je jedna od teorija, koja ukazuje na važnost informacija, posebice u slučaju povlaštenih. Utjecaj povlaštenih informacija prikazan je na idućem prikazu/grafikonu:

Cijena dionice



Grafikon 1: Asimetrična informacija


Izvor: izrada autora prema Tipurić D. (2008.)

Dakle, na tržištu postoji odnos prodavač – kupac, gdje prodavač ima pristup povlaštenim informacijama dok kupac uglavnom nema. Prodavatelj s povlaštenom informacijom o ne/održavanosti, ne/kvaliteti,... svog proizvoda prodaje isti pri nekoj određenoj cijeni koju kupac može i ne mora prihvatiti. U situaciji kada se na tržištu nalaze kvalitetan i nekvalitetan proizvod, kupac ne imajući informaciju o kvaliteti i/ili nekvaliteti proizvoda, već zbog mogućnosti nagađanja i pretpostavki će izabrati prosječnu cijenu jer sama prodaja tog proizvoda otvara mu mogućnost razmišljanja kako već proizvod nije kvalitetan dovoljno (bio on kvalitetan ili ne, jer kupac nema tu vrstu informacije) gdje oni kvalitetni i s većom cijenom će zbog toga morati izabrati da li im je prihvatljivo ostati na tržištu po cijeni manjoj od stvarne vrijednosti (koju je kupac spreman platiti), a njihova viša cijena im je opravdana. Nekvalitetni već imaju prednost jer im je prosječna veća od njihove stvarne vrijednosti. To se zove tržište limuna – tržište gdje postoji proizvod šljiva ili limun, odnosno kvalitetan i nekvalitetan proizvod. Ta teorija je pojašnjena na primjeru automobila, gdje prilikom prodaje istih, kupac ne imajući informaciju već pretpostavku, već samom prodajom zaključuje kako je automobil nekvalitetan (veća je vjerojatnost da se na tržištu nalazi većina limuna). Samim tim zaključkom, prodavatelj kvalitetnog (šljiva) ili nekvalitetnog (limun) automobila nalaze se na poziciji iste cijene između kvalitetnog i skupljeg i nekvalitetnog i jeftinijeg – prosječne koje će kupac odabrati. Prodavatelj kvalitetnog i skupljeg to uglavnom neće moći prihvatiti – s tržišta ga izbacuju limuni. (Akerlof, 1970)

Druga teorija informacijske asimetrije zove se problem moralnog hazarda. To je teorija koja naglašava problem promjene ponašanja zbog nesavršenosti ugovora, a smatra se da će menadžer raditi u svoju korist, te ako je cilj kompanije u skladu s njegovim ciljem onda će on uložiti napore da se taj cilj i ostvari, u suprotnom, zbog manjka mogućnosti kontrole menadžera, on će smanjiti napore kako bi maksimizirao korist za dioničara. Drugi naziv za moralni hazard je skriveno djelovanje. Usko u svezi s moralnim hazardom je i agencijska teorija koja temelji svoje razmatranje u vlastitim interesima pojedinaca (Tipurić, 2008.).

2.1.1. Agencijska teorija

Agencijska teorija pojašnjava problem u odnosima principal – agent, onda kada principal angažira agenta. Za obavljanje ugovorene zadaće između principala i agenta, agent će dobiti nagradu za obavljen posao koja je obavezna, a principal efekte odrađene zadaće. U sklopu navedene teorije, promatra se problem interesa. Tipurić (2008.) navodi kako agent ima motiv da za što manje zadaće dobije što veće nagrade – iznalaženje najveće koristi što ukazuje na oportunističko ponašanje, dok principal što veće efekte za što manji trošak – maksimiziranje efekta sa što manjim troškovima, što nije moguće zbog troška nadzora koji je ključan za maksimizaciju efekta, što ukazuje da postoji informacijska asimetrija.



Grafikon 2: Analiza oportunističkog ponašanja

Izvor: izrada autora

Kao što se može prikazati i pomoću grafa, u slučaju postojanja informacijske asimetrije, postoji i oportunističko ponašanje agenta, odnosno, pri većoj informacijskoj asimetriji i koristi agenta, veće je i oportunističko ponašanje.

Ovakvi odnosni proizlaze iz dole tri navedene činjenice prema Tipuriću (2008.):

- Različiti ciljevi,
- Različit pristup informacijama i
- Različita sklonost riziku.

Kod agencijskog odnosa postoje još dva moguća problema, a to su skrivena informacija koja nastaje prije samog agencijskog odnosa gdje se agent prikazuje bolji nego što to on uistinu je, što kasnije ako nastane odnos, zbog tog istog agenta principal snosi veće troškove. Jedan od način da se smanji mogućnost da nastanu veći troškovi je da agent potpiše određene ugovore. Drugi problem je signalizacija koja nastaje u samom agencijskom odnosu gdje agent sam odlučuje kada će signalizirati određenu informaciju, što ovisi o njegovoj koristi.

Kako je već navedeno, moralni hazard i agencijski odnos usko su u vezi. S obzirom na to da kod moralnog hazarda se mijenja ponašanje kod nesavršenih ugovora, što se primjenjuje i kod odnosa agenta i principala gdje mu agent ne isporučuje kvalitetu koja proizlazi iz takvih ugovora.

2.2. Pozitivna računovodstvena teorija

Pozitivna računovodstvena teorija smatra da je korporacija skup ugovora između subjekata koji su često povezani s varijablama iz financijskih izvještaja (Tipurić, 2008). Smatra se da otvaranjem mogućnosti izbor alternativa u računovodstvu otvara mogućnosti iskrivljavanje stvarnog stanja u korist menadžerima. Navedena teorije ne opisuje samo stvarnost kakve je, već je specifična po tome što mogućnošću odabira različitih alternativa, ona mijenja stvarnost. Kako je već navedeno na samom početku rada, postoje tri hipoteze u navedenoj teoriji, a to su:

- Hipoteza nagradnih planova – cilj navedene hipoteze je da menadžer uz maksimalnu osobnu korist maksimizira i bonus uz osnovni dio plaće. Bonus će pokušati povećati ako je povećanje bonusa usko vezano s povećanjem dobiti, što će mu biti također motiv da poveća i dobit s različitim računovodstvenim politikama,
- Hipoteza zaduženosti koja sagledava interes menadžera da održava dužničke ugovore s obzirom na to da je većina ugovora o dužničkom kreditiranju povezana s varijablama iz financijskih izvještaja,


- Hipoteza političkih troškova koja najveći naglasak imaju kada korporacije ostvaruju veće profite nego inače, a vlada tada pod većim pritiskom javnog interesa nameće veće troškove i poreze.

Kako je pozitivna računovodstvena teorija usko u svezi s moralnim hazardom, može se korporacija promatrati kao veliki skup različitih interesa kod velikog broja različitih subjekata. (Tipurić, 2008.)

3. REGULATORNI OKVIR VEZA ZA PRIZNAVANJE I MJERENJE FINANCIJSKE IMOVINE

3.1. Računovodstveni standardi vezano za priznavanje i mjerenje financijske imovine (MRS 39 i MSFI 9)

Kod sastavljanja izvještaja, glavni naglasak imaju standardi. Računovodstveni standardi su detaljna razrada računovodstvenih načela u pogledu metode obuhvata, procesiranja i prezentiranja podataka i informacija, dok su načela tu da određuju koncepciju i osnovnu karakteristiku računovodstva (Žager K., Mamić Sačer, Sever i Žager L., 2017.). Cijela slika o standardima kreće od računovodstvenih pretpostavki, zatim načela koja obuhvaćaju pretpostavke i računovodstveni standardi koji zaokružuju cijelu priču, što se može vidjeti iz prikaza u nastavku:



Slika 3: Nastanak računovodstvenih standarda

Izvor: izrada autora

Pretpostavke koje moraju biti ispunjene su neograničenost vremena poslovanja (neograničeno poslovanje i očekivanje da će u doglednoj budućnosti i dalje poslovati) i nastanak događaja (koncept nastanka događaja temelji se na tome da se transakcije evidentiraju onda kada nastanu a ne kada se vrše uplate ili isplate). Uz navedene pretpostavke, prema Belak (2006.), postoje još i kvalitativna obilježja financijskih izvještaja, a to su:

- Razumljivost – bitna stavka za korisnike, svaka informacija mora biti razumljiva korisniku,
- Važnost - uz razumljivost određene informacije, kako bi korisnik donio odluku, potrebno je da je ta informacija i bitna za donošenje odluka,
- Značajnost – ako izostavljanje ili kriva slika informacija utječe na odluke, onda je ista i značajna,

- d. Pouzdanost – ako informacija nema značajnu pogrešku i pristranost i moguće se pouzdati na istu,
- e. Neutralnost – kako bi informacija bila pouzdana, mora biti i bez pristranosti,
- f. Opreznost – primjenjivanje opreznosti kao što je podcjenjivanje prihoda ili imovine ili precjenjivanje obveza ili rashoda bitno je za pouzdanost i neutralnost financijskih izvještaja,
- g. Potpunost – za pouzdanost informacije potrebno je da one budu i potpune,
- h. Usporedivost – mora biti omogućeno da korisnici mogu usporediti financijske izvještaje kroz vrijeme i s drugim izvještajima od drugih subjekata.

Za banke vrijedi sastavljene sljedećih godišnjih izvještaja prema Zakonu o računovodstvu i Zakonu o Hrvatskoj narodnoj banci (NN 42/2018):

- Izvještaj o financijskom položaju (bilanca) – cjelokupna slika o imovini, obvezama i kapitalu na određeni datum,
- Račun dobiti i gubitka – pregled prihoda i rashoda te financijskog rezultata na određeni datum,
- Izvještaj o ostaloj sveobuhvatnoj dobiti – popunjavaju samo one kreditne institucije koje sastavljaju konsolidirane financijske izvještaje,
- Izvještaj o novčanim tokovima – sastavlja se direktnom ili indirektnom metodom, a raspoređuje stavke u poslovne, financijske i ulagačke aktivnosti,
- Izvještaj o promjenama kapitala – prikazuje promjene stavki kapitala između dva datuma bilance,
- Bilješke uz financijske izvještaje – sadrži dodatne informacije koje nisu prezentirane u gore navedenim izvještajima, te naknade za reviziju, izdatke za istraživanje i razvoj, te izvanbilančne stavke kao što su garancije, akreditive, mjenice, okvirne kredite, rizične stavke, budućnosnice, opcije, ugovore o razmjeni, forward te ostale izvedenice.

Financijske institucije prikupljaju novčana sredstva, usmjeravaju ih u financijske plasmane i obavljaju financijske usluge (Leko, 2002.). Banka je jedan od glavnih predstavnika financijskih institucija s ulogom primanja depozita i odobravanja kredita, a postoje još i nebankovne financijske institucije.

Standardi koje banke upotrebljavaju su MRS i MSFI. Za banke bitni su sljedeći standardi:

- MSFI - 7 Financijski instrument – objavljivanje,
- MRS – 32 Financijski instrument – prezentiranje,
- MRS – 39 Financijski instrument: priznavanje i mjerenje,
- MSFI - 9 Financijski instrument kojemu je cilj zamijeniti MRS – 39.

Prema Belak (2006.) međunarodni računovodstveni standardi su nastali s ciljem ujednačenja računovodstvenih propisa na međunarodnoj razini, dok su 2004. godine počeli razvijati i Međunarodni standardi financijskog izvještavanja.

MRS-39 je međunarodni računovodstveni standard koji služi za priznavanje i mjerenje financijske imovine u financijskim izvještajima, a on je zamijenjen MSFI-om 9. MSFI – 9 je objavljen prvi put 24. srpnja 2014. godine, a na snazi od 01.01.2018. godine. Njegova svrha je u tome što pokušava poboljšati financijsko izvještavanje o financijskim instrumentima s namjerom rješenja problema koji su nastali tijekom financijske krize. (Guzić, 2017.)

Razlika između MRS-a 39 i MSFI-a 9 glede klasifikacije financijskih instrumenata prikazani su u idućoj tablici:

Tabela 1: Usporedba MRS-a 39 i MSFI-a 9


Razlike	MRS-39	MSFI-9
Financijski instrumenti su uređeni:	Pravilima	Načelima
Uporaba:	Složena i komplicirana	Poslovni model i novčani tijek
Korišteni modeli kod umanjivanja vrijednosti:	Višestruki modeli	Jedan model
Priznavanje dobitaka/gubitaka kod obvezama po kreditima	Dio dobitka/gubitka kod izbora opcije fer vrijednosti	Dio ostalog sveobuhvatnog dobitka kod izbora opcije fer vrijednosti
Pravila klasifikacije financijskih instrumenata	Složena pravila	Poslovni model sam određuje kakva će biti promjena klasifikacije

Izvor: izrada autora prema Mrša (2014.)

Iz gore navedene tabele može se primijetiti lakše korištenje standarda prema MSFI-u 9, jednostavnost, provedba klasifikacije financijskih instrumenata je mnogo logičnija jer poslovni model sam određuje kakva će biti promjena pri klasifikaciji. Također, lakoću korištenja omogućuju samim time što se koriste manje detaljnu razradu od standarda – načelima nego što se MRS 39 koristi – složenim pravilima što otežava upotrebu i sklonost prilagodbe ovisno o poslovnom modelu.

3.2. Mjerenje financijske imovine

Financijski instrument je svaki ugovor koji se može podijeliti na 2 kategorije s obzirom na nastanak svega što proizlazi iz istog ugovora – financijska imovina jednog i financijske obveze ili vlasnički ugovor drugog subjekta, a primjenjuju ga sve financijske institucije. (Toth, 2009.)



Slika 4: Podjela financijskog instrumenta

Izvor: izrada autora prema Klačmer i Cingula 2009.

Kao što se može vidjeti iz slike 4, s obzirom na nastanak, financijski instrument se dijeli na primarnu i na sekundarnu skupinu. Kod primarne skupine, postoji još jedna podjela, ali na odnos kod subjekata. Naime, financijska imovina pripada jednom, dok financijske obveze i vlasnički instrument drugom subjektu. Klačmer Čalopa i Cingula (2009.) navode kako financijski instrumenti zamjenjuju novac. Ako se očekuje priljev budućih ekonomskih koristi, onda se financijski instrument može priznati kao financijska imovina, o čemu će biti više riječi u nastavku.

Pod financijskom imovinom spadaju iduće vrste imovine (Abramović i ostali, 2008)

- Udjeli i dionice kod povezanih poduzetnika (ugovor koji dokazuje udjel u kapitalu),
- Zajmovi povezanim poduzetnicima,
- Sudjelujući interesi,
- Ulaganja u vrijednosne papire,
- Dani krediti i depoziti i

- Ostala financijska imovina.

U primarnoj skupini uz financijsku imovinu postoje i financijske obveze i vlasnički instrument. Prema Toth (2009.) financijske obveze se mogu tumačiti kao vrsta ugovorne obveze isplate (novca ili financijske imovine) ili razmjene financijske imovine ili obveza u mogućnostima da se pružaju lošiji uvjeti drugim subjektima kod razmjene. Također financijske obveze se mogu sagledavati kao isporuka vlastitih vlasničkih instrumenata kroz dvije vrste instrumenata. No, prije podjele, potrebno je pojasniti što je to vlasnički instrument. Vlasnički instrument se može smatrati udjelom imovine drugog subjekta gdje su obveze već oduzete od tog iznosa. Dakle, postoji derivatna i nederivatna vrsta financijske imovine, za koje vrijedi karakteristika promjenjivosti o različitim učincima ako se radi o nederivatnoj, ili suprotno, nepromjenjivost ako je riječ o derivatnoj financijskoj imovini. Tako vrijedi i za derivatne i nederivatne instrumente. U slučaju isplate derivatnih instrumenata, subjekt isplaćuje fiksni broj instrumenata umjesto novca ili neke druge financijske imovine, dok kod nederivatne, isplaćuje različiti broj instrumenata.

U sekundarnoj skupini nalaze se izvanbilančne stavke za koje se smatra da su obveze za podmirenje gdje će uslijediti odljev novčanih sredstava kreditne institucije zbog kojih se ista izlaže kreditnom riziku jer nema mogućnosti povrata budućih odljeva sredstava. Za primjer se mogu navesti garancije, jamstva, preuzete obveze iz ugovora o kreditu i tako dalje prema Zakonu o kreditnim institucijama i Zakonu o Hrvatskoj narodnoj banci. (NN 114/2017)

3.2.1. Početno priznavanje financijske imovine

U ovom radu, naglasak je na financijskoj imovini, za koju je već navedeno na početku samog rada da se dijeli na iduće četiri kategorije prema MRS-u 39. U nastavku prikazana je tablica sa podjelom prema MRS-u 39 na četiri kategorije financijske imovine skupa sa opisom istih:

Financijska imovina po fer vrijednosti kroz dobit ili gubitak	•Ima namjenu prodaje ili trgovanja.
Ulaganja koja se drže do dospelja	•Imovina sa kojom se ne trguje i služi za držanje do dospelja.
Zajmovi i potraživanja	•Nastala od strane društva i ne kotira na tržištu.
Financijska imovina raspoloživa za prodaju	•Ne spada u nijednu drugu kategoriju financijske imovine.

Slika 5: Kategorije financijske imovine prema MRS-u 39

Izvor: izrada autora prema Mijoč i Liović 2015.godine

Dakle, kao što je vidljivo iz slike 5, prema MRS-u 39 postoje četiri vrste financijske imovine. Ona vrsta financijske imovine koja je namijenjena trgovanju ili prodaji ali u kratkom roku, naziva se financijska imovina po fer vrijednosti kroz dobit ili gubitak. Nadalje, ulaganja koja se drže do dospelja su nederivatna vrsta financijske imovine koja imaju karakteristiku fiksnog iznosa plaćanja i dospelja. Također, kao i kod ulaganja koja se drže do dospelja, nederivatnom vrstom financijske imovine se smatraju zajmovi i potraživanja s također fiksnim iznosom plaćanja. Naziv financijska imovina raspoloživa za prodaju kontradiktoran je njenoj karakteristici, naime prodaja joj je sporedna aktivnost. (Mijoč i Liović, 2015.)

Kao što je već navedeno financijski instrument ili ugovor kojemu se vrijednost ne mijena ovisno o promjenama kamatne stope, cijene nekog drugog financijskog instrumenta, cijene robe i tečaja stranih valuta, koji ne zahtijeva početno ulaganje (neto) i koji se podmiruje na buduću datum se zove derivat. (Abramović, 2008.)

Nadalje, prema MRS-u 39, financijska imovina se početno mjeri prema trošku stjecanja. Razlika financijske imovine po fer vrijednosti kroz račun dobiti ili gubitka od ostale financijske imovine je u tome što se jedina početno mjeri prema fer vrijednosti bez transakcijskih troškova, dok se ostatak financijske imovine mjeri kao trošak stjecanja koji sadrži fer vrijednost skupa sa transakcijskim troškom.

Nakon što je MSFI-9 stupio na snagu podjela financijske imovine glasi:

- Financijska imovina po amortiziranom trošku,

- Po fer vrijednosti kroz ostalu sveobuhvatnu dobit (OSD),
- Po fer vrijednosti kroz račun dobiti i gubitka.

U nastavku je prikazana svaka od financijske imovine prema gore navedenim kategorijama poslovnog modela i obilježjem financijske imovine s ugovorenim novčanim tijekom prema Kramar i Abičić (2018.) prema kojima se ista i razvrstava:

- ✚ Financijska imovina po amortiziranom trošku je financijska imovina koja se drži zbog prikupljanja ugovorenih tijekova novca, a plaćanja instrumenta se sastoji od plaćanja glavnice i kamatama na nepodmirenu glavicu,
- ✚ Po fer vrijednosti kroz ostalu sveobuhvatnu dobit (OSD) ako se drži zbog naplate ugovorenog tijeka novca i kod prodaje financijske imovine, što se tiče ugovorenih novčanih tijekova, vrijedi isto kao i za financijsku imovinu po amortiziranom trošku,
- ✚ U treću kategoriju spada sve ono što ne odgovara opisu prethodne dvije kategorije skupa sa instrumentima koji se drže zbog trgovanja, ne procjenjuje se prema amortiziranom trošku niti se procjenjuje prema fer vrijednosti kroz ostali sveobuhvatni dobitak – u ovo spada kategorija po fer vrijednosti kroz račun dobiti i gubitka.

Prilikom klasifikacije financijske imovine prema MSFI-u 9, specifična je klasifikacija iste prema kategorijama poslovnog modela i obilježjem financijske imovine s ugovorenim novčanim tijekom. Ulaganje u vlasničke instrumente prema poslovnom modelu i prema novčanim tokovima financijske imovine prvobitno se klasificira u kategoriju fer vrijednosti kroz račun dobiti i gubitka, no ako nije namijenjena trgovanju, postoji mogućnost da se klasificira u fer vrijednost kroz ostalu sveobuhvatnu dobit.

Financijska imovina se **početno mjeri** na dva načina – trošak stjecanja po fer vrijednosti i trošak stjecanja po fer vrijednosti uvećanom za transakcijske troškove kao što je slučaj i kod MRS-a 39. Fer vrijednost predstavljaju troškove stjecanja gdje je trošak stjecanja dionica jednak iznosu knjigovodstvenoj vrijednosti dionica. Svi osim jednog, imaju fer vrijednost, odnosno trošak stjecanja + transakcijski trošak. Financijska imovina po fer vrijednosti kroz dobitak ili gubitak je jedina koja sadrži fer vrijednosti bez transakcijski troškova, što je također navedeno kod MRS-a 39. (Guzić, 2017.).

Ova kategorija imovine nema transakcijski trošak jer ona tereti rashode razdoblja kao ona vrsta troškova koja je direktno povezana s kupnjom dionica poput trošak naknade brokera. Transakcijski troškovi su troškovi koji se izravno pripisuju kupnji, izdavanju ili prodaji financijske imovine. (Belak, 2010.)

3.2.2. Naknadno mjerenje

Uz to što se svaka financijska imovina početno mjeri, ona se također mjeri i naknadno kao što je prikazano u idućoj tablici zajedno sa računovodstvenim učincima naknadnog mjerenja financijske imovine:

Tabela 2: Naknadno mjerenje financijske imovine

	Povećanje fer vrijednosti	Smanjenje fer vrijednosti	Smanjenje financijske imovine
Financijska imovina po FV kroz dobit ili gubitak	Povećanje financijske imovine i prihoda	Smanjenje financijske imovine i rashod	-
Financijska imovina koja se drži do dospjeća	-	-	Prihod od kamata uz potencijalni gubitak od umanjenja vrijednosti
Zajmovi i potraživanja	-	-	Prihod od kamata uz potencijalni gubitak od smanjenja vrijednosti
Financijska imovina raspoloživa za prodaju	Povećanje financijske imovine i kapitala	Smanjenje financijske imovine i kapitala	-

Izvor: Izrada autora prema Mijoč i Liović 2015.

Efekti naknadnog mjerenja na porezni učinak prema Mijoč i Liović (2015.) prikazani su u nastavku rada.

Naime, kod naknadnog mjerenja financijske imovine po fer vrijednosti kroz dobit ili gubitak specifična je stavka da su nerealizirani dobiti knjiženi kao prihodi i porezno su priznata stavka, dok svi nastali gubici su knjiženi kao rashodi i porezno su priznati tek kod prodaje iste financijske imovine. Također, gubitak će se porezno priznavati u visini prethodno nastalog nerealiziranog dobitka u svrhu oporezivanja. Nadalje, zajmovi i potraživanja u slučaju utvrđivanja manje nadoknadive svote (smatra se iznosom koji se uspoređuje s knjigovodstvenom vrijednosti, a dobije se kad se fer vrijednost imovine smanji za trošak prodaje ili njene vrijednosti u uporabi, a prilikom usporedbe iznos sredstava se mijenja onda kada je nadoknadiva vrijednost manja od knjigovodstvene, dok u obratnom slučaju, ono svoju vrijednost ne mijenja) kod naknadnog mjerenja od knjigovodstvene vrijednosti podliježe testu umanjenja vrijednosti. Nastali rashodi se također kao i kod financijske imovine po fer

vrijednosti kroz dobit ili gubitak su porezno priznati tek kod prodaje financijske imovine. Odbitna privremena razlika predstavlja rashod i ona se prikazuje kao odgođena porezna imovina koja nastaje onda kada financijska imovina nije prodana u poreznom razdoblju. Kod kategorije financijske imovine raspoložive za prodaju, efekt se bilježi na revalorizacijsku rezervu. Naime, prilikom povećanja fer vrijednosti, povećava se i revalorizacijska rezerva, a prilikom smanjenja fer vrijednosti, smanjuje se i revalorizacijska rezerva. Također, smanjenjem fer vrijednosti, privremena razlika iskazuje se kao odgođena porezna imovina, a povećanje kao odgođena porezna obveza. (Mijoč i Liović, 2015.)

Prema Guzić (2017.) prilikom naknadnog mjerenja prema MSFI 9 kod financijske imovine prema fer vrijednosti kroz račun dobiti i gubitka pojavljuju se efekti od naknadne procjene koji se bilježe kao prihod ili rashod u računu dobiti ili gubitka. Ako se naknadno mjeri financijska imovina čiji se učinci mjere kroz ostalu sveobuhvatnu dobit, onda se efekti knjiže kroz kapital. Ako se financijska imovina naknadno mjeri prema amortiziranom trošku, onda se procjenjuje uz pomoć efektivne kamatne stope gdje je amortizirani trošak – trošak stjecanja umanjen za otplatu glavnice i smanjenje vrijednosti metodom efektivne kamatne stope.

Metoda efektivnih kamatnih stopa - kamatna stopa koja je propisana od strane HNB-a (Hrvatske narodne banke) i koja prikazuje koliki je ukupni trošak kredita zove se *efektivna kamatna stopa*. Njezin naglasak je na tome što je pravi izvor informacije kada je u pitanju odluka gdje klijent mora odlučiti što je najbolje za njega, u okviru njegovih mogućnosti. Ona je jedna od metoda pomoću koje se izračunava amortizirani trošak. Razlog zbog kojeg EKS (efektivna kamatna stopa) je svojevrsni oslonac kod donošenja odluka zbog informacije koje pruži je to što raspoređuje sve kamatne prihode i rashode tijekom nekog određenog razdoblja, te dodatna stavka je u tome što ona točno diskontira sva procijenjena buduća i primanja i davanja dok je vijek određenog financijskog instrumenta. Također, u obzir uzima procijenjeni novčani tok (ne uzima buduće gubitke nastale od zajma) skupa sa svim primljenim ili plaćenim poenima te naknade. Odnosno, navedena kamatna stopa računa sadašnju vrijednost očekivanog novčanog toka financijske imovine ili nadoknativi iznos. (Žager i ostali, 2017.)

3.3.Reklasifikacija

Reklasifikaciju se može pobliže pojasniti kao pojavu kada zbog odluka dovedene temeljem različitih informacija i/ili svojevrsnih vlastitih interesa, financijsku imovinu početno vrednovanu i klasificiranu u jednu kategoriju financijske imovine reklasificira tu istu imovinu

u drugu kategoriju financijske imovine, odnosno mijenja model upravljanja tom imovinom. (Guzić, 2017.)

Prema MRS-u 39 reklasifikacija je moguća kod sve četiri kategorije financijske imovine, ali svaka za sebe ima svoj način reklasifikacije i određene uvjete za reklasifikaciju s kojim ispunjaju uvjete reklasifikacije iz jedne u drugu kategoriju financijske imovine, s naglaskom da reklasifikacija je ograničena na smjer njenog kretanja iz jedne u drugu kategoriju.

Reklasifikacija se tvori tako da prilikom reklasifikacije financijske imovine po fer vrijednosti kroz dobit ili gubitak u bilo koju u ostale tri kategorije je moguće, no reklasifikacija tih triju kategorija u financijsku imovinu po fer vrijednosti kroz dobit ili gubitak nije moguće.


Prilikom reklasifikacije financijske imovine po fer vrijednosti kroz dobit ili gubitak, ona postaje amortizirani trošak i ista se odvija na datum reklasifikacije. Ako je namjera navedene kategorije financijske imovine reklasificirati u kategoriju zajmova i potraživanja onda je ujedno i potrebno da ista ima uvjete prema definiciji zajmova i potraživanja i da se može držati do dospijeca ili dogledne budućnosti. Također, reklasifikacija kod ove kategorije financijske imovine u kategoriju ulaganja koja se drže do dospijeca moguća je kada se na datum reklasifikacije utvrđuje njena fer vrijednost i ista postaje amortizirani trošak, dok se nerealizirani dobitci/gubitci se ne ispravljaju. (Mijoč i Liović, 2015.)

U slučaju reklasifikacije ulaganja koja se drže do dospijeca kao jedan od dužničkih financijskih instrumenata, potrebno je opet vrednovati fer vrijednosti te razliku koja se dobije priznati kao revalorizacijsku rezervu za koju se smatra da su dio kapitala koje nastaju ponovnom procjenom imovine iznad troškova nabave (dugotrajne materijalne i nematerijalne imovine) prema Zakonu o računovodstvu (NN 86/15).

Za financijska ulaganja u zajmove koja se mjere po amortiziranom trošku, vrijedi da njihova reklasifikacija moguća je samo u imovinu raspoloživu za prodaju i to samo pod uvjetom ako je moguće kod financijske imovine i obveze utvrditi fer vrijednost.

Kod financijske imovine raspoložive za prodaju reklasifikacija se odvija u kategorije zajmova i potraživanja i ulaganja koja se drže do dospijeca. U slučaju reklasifikacije utvrđuje se fer vrijednost na datum reklasifikacije i postaje amortizirani trošak. Reklasifikacija financijske imovine raspoložive za prodaju u zajmove i potraživanja ima jednake uvjete kao i kod reklasifikacije financijske imovine po fer vrijednosti kroz dobit ili gubitak u zajmove i potraživanja. U slučaju da se ista kategorija financijske imovine ima namjeru reklasificirati u financijsku imovinu koja se drži do dospijeca onda je potrebno da ispunjava uvjet da ima namjeru držanja do dospijeca. (Mijoč i Liović, 2015.)


U slučaju MSFI-a 9, prema Guzić (2017.) ako društvo reklasificira financijsku imovinu, ono je obvezno primijeniti reklasifikaciju od datuma reklasifikacije, a različite kombinacije reklasifikacije prema MSFI-u 9 pojašnjene su u sljedećim prikazima:



Slika 6: Reklasifikacije financijske imovine prema amortiziranom trošku i mjerene prema fer vrijednosti kroz dobit ili gubitak

Izvor: izrada autora prema


U prvom slučaju reklasifikacije iz financijske imovine prema amortiziranom trošku u financijsku imovinu mjerenu prema fer vrijednosti kroz račun dobiti ili gubitka, fer vrijednost se procjenjuje na datum reklasifikacije, dok su dobit ili gubitak nastali kao razlika između amortiziranog troška i fer vrijednosti priznat kroz račun dobiti ili gubitka. U obratnom slučaju reklasifikacije fer vrijednost jednaka je njenoj bruto knjigovodstvenoj vrijednosti. S obzirom na to da se u ovom slučaju ne pojavljuje razlika – nema dobiti niti gubitka.



Slika 7: Reklasifikacija financijske imovine prema amortiziranom trošku i po fer vrijednosti kroz OSD

Izvor: izrada autora prema

Kada se financijska imovina prema amortiziranom trošku reklasificira u financijsku imovinu po fer vrijednosti kroz ostalu sveobuhvatnu dobit, fer vrijednosti se procjenjuje na datum reklasifikacije, dok se dobit ili gubitak od razlike između amortiziranog troška i utvrđene fer vrijednosti prikazuje u ostaloj sveobuhvatnoj dobiti u bilanci društva. Iz svega navedenog zaključuje se kako ovakva reklasifikacija ima utjecaj na veličinu kapitala. Prilikom reklasifikacije financijske imovine po fer vrijednosti kroz OSD u financijsku imovinu prema amortiziranom trošku, fer vrijednost se također procjenjuje na datum reklasifikacije, a dobitak ili gubitak od reklasifikacije se usklađuje s fer vrijednosti financijske imovine na datum reklasifikacije, a iz vlasničkog kapitala se isključuje.



Slika 8: Reklasifikacija financijske imovine mjerene prema fer vrijednosti kroz dobit ili gubitak i po fer vrijednost kroz OSD

Izvor: izrada autora prema

U gore navedenom slučaju reklasifikacije financijska imovina mjerena prema fer vrijednosti kroz dobit ili gubitak u financijska imovina po fer vrijednosti kroz ostalu sveobuhvatnu dobit, imovinu se procjenjuje prema fer vrijednosti što dalje pomaže prilikom zaključka da navedena reklasifikacija nema utjecaja na račun dobiti i gubitka niti na ostalu sveobuhvatnu dobit. U obratnom smjeru reklasifikacije se imovina također procjenjuje prema fer vrijednosti, no svi dobitci ili gubitci od kapitala što su priznati u ostaloj sveobuhvatnoj dobiti postaju reklasifikacijsko usklađenje na datum reklasifikacije reklasificirajući se u računu dobiti i gubitka.

4. EMPIRIJSKO ISTRAŽIVANJE

4.1.Prikupljanje podataka za potrebe istraživanja

U ovome dijelu rada analizirat će se utjecaj promjena udjela fer vrijednosti imovine i promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu, uz kontrolne varijable (gubitak od zajmova u bruto zajmovima, kapital u ukupnoj imovini i profitabilnost). Uzorak se sastoji od 291 europske banke, a godine promatranja su od 2014. – 2016.

Podaci su uzeti iz baze BankFocus koji su obrađeni u Microsoft Office Excelu i uvedeni u SPSS (Statistical Package for the Social Sciences) kako bi prikazali rezultate ispitivanja. Zbog nedostatka podataka u izvještajima banaka, uzorak je smanjen sa 627 na 310 banaka. Nedostajali su podaci pojedinih banaka o njihovom udjelu financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini u 2016. i 2015. godini, te podaci o promjeni udjela fer vrijednosti imovine u 2016. i 2015. godini. Zatim se uzorak smanjio i zbog nedostatka podataka o neto dobiti i gubitku imovine i obveza zbog kojeg nije bilo moguće izračunati promjenu fer vrijednosti dobitka u odnosu na prethodnu godinu 2016. i 2015. godine. Također, u izvještajima pojedinih banaka nije bilo informacija o gubitku od zajmova u bruto zajmovima 2016. godine. Nadalje, kada se uzorak smanjio na 310 banaka, provedena je analiza podataka kroz deskriptivnu statistiku gdje su uočena velika odstupanja kod promjene fer vrijednosti dobitaka u 2015. i 2016.godini, gdje je uzorak smanjen za još 6% uzorka minimalnih i maksimalnih vrijednosti te varijable.

Očekuje se pozitivan utjecaj promjene fer vrijednosti dobitaka u odnosu na prethodnu godinu na varijablu promjene udjela fer vrijednosti financijske imovine. Smatra se da ako banka ostvaruje dobitke, da će ista udio imovine vrednovan po fer vrijednosti povećavati kako bi nastavila ostvarivati dobit. Odnosno, smatra se da ako banka ostvaruje gubitke, da će ista smanjivati udio imovine fer vrijednosti imovine.

Također, očekuje se pozitivan utjecaj i u obratnom slučaju. Pretpostavka glasi, ako se povećá udio fer vrijednosti financijske imovine, povećat će se i fer vrijednost dobitaka u odnosu na prethodnu godinu. Temelj ove pretpostavke leži u činjenici da ako banke procijene rast tržišne vrijednosti financijske imovine u narednoj godini, da će se ujedno i povećavati udio financijske imovine u tekućoj godini.

4.2.Obrada podataka različitim metodama istraživanja

Svi izračuni korišteni su pomoću podataka uzetih iz BankFocus baze, a nalaze se u tablici ispod:

Tabela 3: Tablica varijabli korištenih u SPSS-u za potrebe ispitivanja i njihovi izračuni

VARIJABLA	NAZIV VARIJABLE U SPSS-U	IZRAČUN
Udio financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini u 2016. godini	Udiofinim2016	Financijska imovina po fer vrijednosti i za trgovanje 2016. godine/Ukupna financijska imovina 2016. godine
Udio financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini u 2015. godini	Udiofinim2015	Financijska imovina po fer vrijednosti i za trgovanje 2015. godine/Ukupna financijska imovina 2015. godine
Gubitak od zajmova u Bruto zajmovima 2016. godine	Zajmovi2016	Gubitak od zajmova u 2016. godini/Bruto zajmovi 2016. godine.
Kapital u ukupnoj imovini 2016. godine	Kapital2016	Kapital/Ukupna imovina 2016. godine
Profitabilnost u 2016.godini	Profitabilnost2016	Neto dobit 2016. godine/Ukupna imovina 2016. godine
Promjena udjela fer vrijednosti imovine u 2016.godini	Δ UdjelaFVimovine2016	(Udio financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini 2016. godine)-(Udio financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini 2015. godine)
Promjena udjela fer vrijednosti financijske imovine u 2015.godini	Δ UdjelaFVimovine2015	(Udio financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini 2015. godine) – (Udio financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini 2014. godine)
Promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu 2016.godine	Δ FVdobitaka2016	(Neto dobici i gubici od imovine i obveza po fer vrijednosti kroz profit i gubitke u 2016. godini - Neto dobici i gubici od imovine i obveza po fer vrijednosti kroz profit i gubitke u 2015. godini) / apsolutne vrijednosti (Neto dobici i gubici od imovine i obveza po fer vrijednosti kroz profit i gubitke u 2015. godini)
Promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu 2015.godine	Δ FVdobitaka2015	(Neto dobici i gubici od imovine i obveza po fer vrijednosti kroz profit i gubitke u 2015. godini - Neto dobici i gubici od imovine i obveza po fer vrijednosti kroz profit i gubitke u 2014. godini)/ apsolutna vrijednosti (Neto dobici i gubici od imovine i obveza po fer vrijednosti kroz profit i gubitke u 2014. godini)

Izvor: izrada autora

Za ispitivanje hipoteza korišten je program SPSS, u koji je uvedena baza iz BankFocus i uređena kroz Microsoft Office Excel, za banke iz Europe zbog opsežnosti podataka u odnosu na one iz Hrvatske. Korištena je ENTER metoda kod korištenja linearne regresije.

Regresija se koristi kod procjene međusobne ovisnosti promatranih varijabli, a u ovome radu korištena je multipla regresija, odnosno, vrsta regresije kod koje postoji jedna zavisna i više nezavisnih varijabli. (Pivac, 2010.)

Oblik modela multiple regresije glasi:

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_1 + \hat{\beta}_2 \cdot X_2 + \dots + \hat{\beta}_k \cdot X_k + e \quad (1)$$

Gdje su $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$ nepoznatne, a e je slučajna varijabla. Nezavisne varijable u ovom modelu su $X_1, X_2, \dots, X_k$.

U ovom radu navedeni regresijski model konkretno glasi:

- Za H1 hipotezu:

$$\Delta \text{Udjela FV imovine 2016} = \hat{\beta}_0 + \hat{\beta}_1 \cdot \Delta \text{ FV dobitaka 2015} + \hat{\beta}_2 \cdot \text{Gubitak od zajmova u bruto zajmovima 2016} + \hat{\beta}_3 \cdot \text{Kapital u ukupnoj imovini 2016} + \hat{\beta}_4 \cdot \text{Profitabilnost 2016} + e$$

- Za H2 hipotezu:

$$\Delta \text{ FV dobitaka 2016} = \hat{\beta}_0 + \hat{\beta}_1 \cdot \Delta \text{Udjela FV imovine 2015} + \hat{\beta}_2 \cdot \text{Gubitak od zajmova u bruto zajmovima 2016} + \hat{\beta}_3 \cdot \text{Kapital u ukupnoj imovini 2016} + \hat{\beta}_4 \cdot \text{Profitabilnost 2016} + e$$

Postoji pet modela korištenja varijabli kod multiple regresije: FORWARD, BACKWARD, STEPWISE, TEST i ENTER metoda koje je ujedno i korištena u radu. ENTER metoda je specifična po forsiranom ulazu varijabli.

4.3. Rezultati obrađenih podataka

Zavisno od različitih promjena u okolini i procjena reakcije na njih, postoji niz različitih odluka koje određene banke mogu poduzeti. Također, velike zasluge prilikom donošenja odluka imaju i informacije. Klasifikacija i reklasifikacija financijske imovine unutar svojih kategorija uvelike je određena gore navedenim utjecajima kao i vlastitim interesima pojedinaca. Na koji način re/klasifikacija djeluje na određene stavke financijske imovine, otkrit će se u nastavku rada gdje su prikazani rezultati ispitivanja.

4.3.1. Deskriptivna statistika

Uz inferencijalnu statistiku koja služi za generaliziranje populacije na temelju uzorka, postoji i deskriptivna statistika koja služi za opisivanje i zaključivanje. (Pivac, 2010.)

Tabela 4: Broj banaka prema zemljama

	Frekvencija	Postotak	Valjan postotak	Kumulativno
Valjano	4	1.4	1.4	1.4
AUSTRIA	7	2.4	2.4	3.8
BELGIJA	6	2.1	2.1	5.8
BOSNA I HERCEGOVINA	4	1.4	1.4	7.2
BUGARSKA	5	1.7	1.7	8.9
CIPAR	1	0.3	0.3	9.3
ČEŠKA	1	0.3	0.3	9.6
DANSKA	7	2.4	2.4	12
ESTONIJA	2	0.7	0.7	12.7
FINSKA	4	1.4	1.4	14.1
FRANCUSKA	13	4.5	4.5	18.6
HRVATSKA	6	2.1	2.1	20.6
IRSKA	1	0.3	0.3	21
ISLAND	3	1	1	22
ITALIJA	26	8.9	8.9	30.9
LETONIJA	5	1.7	1.7	32.6
LITVA	3	1	1	33.7
LUKSEMBURG	6	2.1	2.1	35.7
MAĐARSKA	1	0.3	0.3	36.1
MALTA	2	0.7	0.7	36.8
NIZOZEMSKA	4	1.4	1.4	38.1
NORVEŠKA	18	6.2	6.2	44.3
NJEMAČKA	1	0.3	0.3	44.7
POLJSKA	2	0.7	0.7	45.4
PORTUGAL	10	3.4	3.4	48.8
RUMUNJSKA	2	0.7	0.7	49.5
RUSIJA	102	35.1	35.1	84.5
SLOVAČKA	4	1.4	1.4	85.9
SLOVENIJA	3	1	1	86.9
SRBIJA	2	0.7	0.7	87.6
ŠPANJOLSKA	8	2.7	2.7	90.4
ŠVEDSKA	8	2.7	2.7	93.1
ŠVICARSKA	2	0.7	0.7	93.8
UKRAJINA	7	2.4	2.4	96.2
VELIKA BRITANIJA	11	3.8	3.8	100
Ukupno	291	100	100	

Izvor: izrada autora

Iz gore navedenih tablica, može se zaključiti da je uzorak veličine N=291.

Najviše banaka uzorka N=291 zabilježeno je u Rusiji, a najmanje u Cipru, Češkoj, Irskoj, Mađarskoj i Njemačkoj. Rusija čini 35% uzorka banaka.

U tablici 5 prikazana je aritmetička sredina, medijan, standardna devijacija, minimum, maksimum i kvartili, za varijable udio financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini u 2016. i 2015. godini, gubitak od zajmova u bruto zajmovima 2016. godine, kapital u ukupnoj imovini 2016. godine i profitabilnost u 2016. godini.

Tabela 5: Deskriptivna statistika

		Udiofinim 2016	Udiofinim 2015	Zajmovi 2016	Kapital 2016	Profitabilnost 2016
Uzorak	Valjano	291	291	291	291	291
	Nedostaje	0	0	0	0	0
Aritmetička sredina		0,433	0,434	0,108	0,128	0,005
Medijan		0,318	0,356	0,064	0,101	0,006
Standardna devijacija		0,4	0,394	0,15	0,101	0,024
Minimum		-0,005	0	0	-0,121	-0,249
Maksimum		1	1	1,257	0,884	0,091
	25	0,035	0,042	0,017	0,071	0,002
Percentili	50	0,318	0,356	0,064	0,101	0,006
	75	0,907	0,89	0,131	0,154	0,012

Izvor: izrada autora

Kao što je već navedeno, veličina uzorka iznosi N=291.

Aritmetička sredina udjela financijske imovine po fer vrijednosti u ukupnih financijskoj imovini u 2016. godini iznosi 0.433, odnosno 0.434 u 2015. godini, s odstupanjima od 0.4 u 2016. godini i 0.394 u 2015. godini.

Polovina od uzorka (291) ima veći udio financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini u 2016. godini od 0.318, a polovina manje od 0.318. Za istu varijablu u 2015. godini medijan iznosi 0.356, odnosno, pola uzorka ima vrijednosti veće od 0.356, dok druga polovina ima vrijednosti manje od 0.356. Minimalna vrijednost u 2016. godini iznosi -0.005 zbog greške u izvještaju za Aldemore bank Plc iz Velike Britanije, koja zbog navedene negativne financijske imovine kroz fer vrijednosti i za trgovanje u 2016. godine time ujedno zabilježila negativnu vrijednost kroz izračun udjela financijske imovine po fer vrijednosti u ukupnoj financijskoj imovini u 2016. godini. Maksimalna vrijednost je 1. U 2015. godini minimum je 0, a maksimum dijeli istu vrijednost s 2016. godinom.

Donji kvartil iznosi 0.035, što je zapravo iznos udjela financijske imovine u ukupnoj financijskoj imovini u 2016. godini, odnosno 25% uzorka ima vrijednost navedenog udjela manju ili jednaku iznosu od 0.035, a gornji kvartil glasi 0.907, što je iznos koji ima preostalih

75% uzroka. U 2015. godini donji kvartil iznosi 0.042, što je iznos koji poprima 25% uzorka, a gornji kvartil, odnosno 75% uzorka poprima vrijednost manju ili istu od 0.89.

Što se kontrolnih varijabli tiče, kapital u ukupnoj imovini u 2016. godini poprima najveću vrijednost aritmetičke sredine u iznosu od 0.128, a najmanju vrijednost bilježi profitabilnost i iznosi 0.005. Glede odstupanja od aritmetičke sredine, najveće odstupanje ima gubitak od zajmova u bruto zajmovima, dok najmanja ima profitabilnost.

Najmanja minimalna vrijednost iščitava se kod varijable profitabilnosti kao i najmanju maksimalnu vrijednost. A gubitak od zajmova u bruto zajmovima poprima najveću minimalnu i najveću maksimalnu vrijednost.

U nastavku rada prikazan je Pearsonov koeficijent korelacije kao najpoznatija mjera linearne korelacije između slučajnih varijabli koja služi za otkrivanje međusobne povezanosti i zavisnosti istih (Pivac, 2010.). U ovom radu prikazan je koeficijent korelacije između varijabli promjena udjela fer vrijednosti imovine u 2016. i 2015. godini, promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu u 2016. i 2015. godini, te gubitak zajmova u bruto zajmovima, kapital u ukupnoj imovini i profitabilnost 2016. godine za H1 i H2 hipoteze.

U tabeli 6 prikazan je koeficijent korelacije za H1 hipotezu.

Tabela 6: Pearsonov koeficijent korelacije za H1 hipotezu

		Δ UdjelaFVimovine2016	Δ FVdobitaka2015	Zajmovi2016	Kapital2016	Profitabilnost2016
Δ udjela FV Imovine 2016	Pearsonova korelacija	1	-0,059	-0,036	-0,072	0,089
	Signifikantnost (dvosmjerna)		0,318	0,543	0,220	0,130
	N	291	291	291	291	291
Δ FV dobitaka2015	Pearsonova korelacija	-0,059	1	0,055	0,056	0,038
	Signifikantnost (dvosmjerna)	0,318		0,346	0,345	0,521
	N	291	291	291	291	291
Zajmovi2016	Pearsonova korelacija	-0,036	0,055	1	0,268*	-0,309**
	Signifikantnost (dvosmjerna)	0,543	0,346		0	0
	N	291	291	291	291	291
Kapital 2016	Pearsonova korelacija	-0,072	0,056	0,268**	1	0,078
	Signifikantnost (dvosmjerna)	0,220	0,345	0		0,185
	N	291	291	291	291	291

Profitabilnost 2016	Pearsonova korelacija	0,089	0,038	- 0,309**	0,078	1
	Signifikantnost (dvosmjerna)	0,130	0,521	0	0,185	
	N	291	291	291	291	291

Izvor: izrada autora

Naime, u tablici 6 može se primijetiti korelacija kod varijabli gubitak zajmova u bruto zajmovima 2016. godini s kapitalom u ukupnoj imovini 2016. godine gdje je $\alpha \approx 0$, odnosno $\alpha^* < 5\%$, to jest $\alpha^* < 10\%$. Korelacija iznosi $\hat{r} = 0,268$ i označava slabu pozitivnu korelaciju, to jest, u slučaju povećanja gubitaka zajmova u bruto zajmovima, povećava se i kapital u ukupnoj imovini.

Također, gubitak zajmova u bruto zajmovima u 2016. godini povezani su s profitabilnosti u istoj godini, gdje α iznosi kao i u prethodnom slučaju ($\alpha \approx 0$). Korelacija iznosi $\hat{r} = -0,309$ i označava negativnu slabu korelaciju između gubitaka zajmova u bruto zajmovima i profitabilnosti u 2016. godini (ako se povećava gubitak zajmova u bruto zajmovima, smanjuje se profitabilnost).

U nastavku rada nalazi se analiza korelacije ali za H2 hipotezu:

Tabela 7: Pearsonov korefijent korelacije za H2 hipotezu

		Δ Udjela FV imovine 2015	Δ FV dobitaka 2016	Zajmovi 2016	Kapital 2016	Profitabilnost 2016
Δ Udjela FV Imovine 2015	Pearsonova korelacija	1	0,102*	0,092	0,072	-0,076
	Signifikantnost (dvosmjerna)		0,084	0,117	0,219	0,198
	N	291	291	291	291	291
Δ FV Dobitaka 2016	Pearsonova korelacija	0,102*	1	0,002	0,070	0,060
	Signifikantnost (dvosmjerna)	0,084		0,970	0,233	0,305
	N	291	291	291	291	291
Zajmovi 2016	Pearsonova korelacija	0,092	0,002	1	0,268*	-0,309**
	Signifikantnost (dvosmjerna)	0,117	0,970		0	0
	N	291	291	291	291	291
Kapital 2016	Pearsonova korelacija	0,072	0,070	0,268**	1	0,078
	Signifikantnost (dvosmjerna)	0,219	0,233	0		0,185
	N	291	291	291	291	291

Profitabilnost 2016	Pearsonova korelacija	-0,076	0,060	- 0,309**	0,078	1
	Signifikantnost (dvosmjerna)	0,198	0,305	0	0,185	
	N	291	291	291	291	291

Izvor: izrada autora

Naime i kod tablice 7 može se zamijetiti ponovna korelacija kod gubitaka zajmova u bruto zajmovima u 2016. godini s kapitalom u ukupnoj imovini i profitabilnosti u 2016. godini, ali i korelacija kod varijabli promjena udjela fer vrijednosti financijske imovine 2015. godine s promjenom fer vrijednosti dobitaka u odnosu na prethodnu godinu u 2016. godini pri razini značajnosti od $\alpha^* < 10\%$, gdje je $\alpha \approx 0,084$. Korelacija iznosi $\hat{r} = 0,102$ te označava slabu pozitivnu korelaciju, odnosno, smatra se da ako se poveća fer vrijednost dobitaka u odnosu na prethodnu godinu, povećat će se udio fer vrijednosti financijske imovine.

4.3.2. Regresija

U nastavku rada ispitat će se međusobna ovisnost promatranih varijabli.

Za ispitivanje međusobne ovisnosti promatranih varijabli, u ovom radu postavljene su dvije hipoteze koje su navedene na početku ovog diplomskog rada.

Prva hipoteza glasi:

H1: Promjena nerealiziranih dobitaka i gubitaka od promjene fer vrijednosti financijske imovine utječe na strukturu financijske imovine u narednoj godini

Kod prve hipoteze, za zavisnu varijablu postavljena je promjena udjela financijske imovine u 2016. godini, dok su za nezavisne postavljene promjena udjela fer vrijednosti dobitaka u odnosu na prethodnu godinu 2015., gubitak od zajmova u bruto zajmovima 2016. godine, kapital u ukupnoj imovini 2016. godine i profitabilnost u 2016. godine. Odnosno, varijabla promjene udjela financijske imovine u 2016. godini je varijabla na koju se utječe, što će se razmotriti u nastavku rada.

U tabeli 8 nalazi se deskriptivna statistika gdje se promatra aritmetička sredina i standardna devijacija varijabli koje ulaze u regresijski model za H1 hipotezu.

Tabela 8: Deskriptivna statistika za prvu hipotezu

	Aritmetička sredina	Standardna devijacija	Veličina uzorka
Δ UdjelaFVimovine2016	-0,002	0,147	291
Δ FVdobitaka2015	0,602	6,041	291
Zajmovi2016	0,108	0,15	291
Kapital2016	0,128	0,101	291
Profitabilnost2016	0,005	0,024	291

Izvor: izrada autora

Iz tablice deskriptivne statistike može se zaključiti kako je prosječna vrijednost promjene udjela fer vrijednosti imovine u 2016. godini negativna, odnosno iznosi -0.002 s odstupanjima od 0.147. Što se nezavisnih varijabli tiče, promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu ima prosječnu vrijednosti u iznosu od 0.602 s odstupanjem od 6.04.

Gubitak od zajmova u bruto u zajmovima zauzima prosječnu vrijednost od 0.108 s odstupanjem od 0.15., prosječna vrijednost kapitala u ukupnoj imovini iznosi 0.128 s odstupanjem od 0.101, a profitabilnost bilježi prosječnu vrijednost od 0.005, s odstupanjem od 0.25.

Iz navedenih varijabli formira se model koji glasi:

Promjena udjela fer vrijednosti imovine 2016.godine = f (promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu 2015. godine, gubitak od zajmova u bruto zajmovima 2016. godine, kapital u ukupnoj imovini u 2016.godini, profitabilnost 2016. godine)

U radu za izračun regresije korištena je ENTER metoda.

Iz dole navedene tablice mogu se saznati vrijednosti osnovnih pokazatelja višestruke regresije:

Tabela 9: Prikaz rezultata osnovnih pokazatelja kod H1 hipoteze

Model	Koeficijent korelacije	Koeficijent determinacije	Korigirani koeficijent determinacije	Standardna greška
1	0,133 ^a	0.018	0.004	0.147

a. Prediktori: (Konstanta), Profitabilnost2016, Δ FVdobitaka2015, Kapital2016, Zajmovi2016

Izvor: izrada autora

Iz navedenih vrijednosti, zaključuje se da 1.8% sume kvadrata odstupanja promjene udjela fer vrijednosti financijske imovine u 2016. godini protumačeno navedenim modelom, što upućuje na slabu reprezentativnost modela.

U tablici ANOVA prikazuju se svi protumačeni i neprotumačeni podaci, te ukupna odstupanja ocijenjena modela i F – test s empirijskom signifikantnošću.

Tabela 10: ANOVA tablica

ANOVAa						
Model		Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	F	Sig.
1	Regresija	0.113	4	0.028	1.307	0.267 ^b
	Rezidual	6.166	286	0.022		
	Ukupno	6.279	290			
a. Zavisna varijabla: Δ UdjelaFVimovine2016 b. Nezavisne varijable: (Konstanta), Profitabilnost2016, Δ FVdobitaka2015, Kapital2016, Zajmovi2016						

Izvor: izrada autora

Iz ANOVA tablice zaključuje se uz pomoć empirijske F vrijednosti koja iznosi 1.307 koju je potrebno usporediti s tabličnom vrijednosti uz signifikantnost od 10% $F_{tab}^{\alpha=1\%}[df_1=4;df_2=286]=3.338$, da je $F^* < F_{tab} \Rightarrow H_0$, da se odbacuje H_1 hipoteza, odnosno ocijenjeni regresijski model je statistički neznačajan i to se može potvrditi s razinom signifikantnosti iz tablice koja iznosi $\alpha=0,267>0.1$.

U idućoj tablici prikazane su vrijednosti ocijenjenih parametara, standardne greške, empirijska vrijednost t – omjera, te inflacija varijance i njena recipročna vrijednost.

Tabela 11: Rezultat regresije

	Nestandarizirani koeficijenti		Standardizirani koeficijenti	t	Sig.	90,0% Interval povjerenja za B		Kolinearna statistika	
	B	Stand. greška	Beta			Donja granica	Gornja granica	Tolerancija	VIF
(Konstanta)	0.009	0.014		0.634	0.527	-0.015	0.033		
Δ FVdobitaka 2015	-0.001	0.001	-0.059	-1.007	0.315	-0.004	0.001	0.993	1.008
Zajmovi 2016	0.021	0.064	0.022	0.338	0.736	-0.083	0.126	0.816	1.226

Kapital 2016	-0.120	0.090	-0.083	-1.341	0.181	-0.269	0.028	0.898	1.1 13
Profitabil nost 2016	0.629	0.378	0.104	1.665	0.097	0.006	1.253	0.875	1.1 43
a. Zavisna Varijabla: $\Delta Udjela FV imovine_{2016}$									

Izvor: izrada autora

U nastavku se otkriva kako model glasi:

promjena udjela fer vrijednosti financijske imovine = $0.009 - 0.001 \cdot \text{promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu} + 0.021 \cdot \text{gubitak od zajmova u bruto zajmovima} - 0.120 \cdot \text{kapital u ukupnoj imovini} + 0.629 \cdot \text{profitabilnost}$.

Iz navedenog modela može se zaključiti sljedeće:

- Varijabla promjene udjela fer vrijednosti financijske imovine ili regresant poprima vrijednost 0.009 ako sve regresorske varijable poprime vrijednost 0.
- Ako se poveća fer vrijednost dobitaka za 1% u odnosu na prethodnu godinu, fer vrijednost imovine smanjit će se za 0,001 c.p. (ceteris paribus – uvjet da se ne mijenjaju ostale varijable u modelu)
- Povećanjem gubitka od zajmova u bruto zajmovima za 1%, povećat će se i udio fer vrijednosti imovine za 0.021 c.p.
- Ako se kapital u ukupnoj imovini poveća za 1%, udio fer vrijednosti smanjit će se za 0.120 c.p.
- Fer vrijednosti imovine će se povećati za 0.629, ako se profitabilnost poveća za 1% c.p.

Nadalje, iz navedenog modela, može se zaključiti kako je jedino profitabilnost statistički značajna na varijablu promjene udjela fer vrijednosti financijske imovine i to zbog iduće navedenih razina signifikantnosti gdje je empirijska p vrijednosti manja od 0.1 i to je vrijednost na granici značajnost (inače se uzima 5%). Također, profitabilnost ima pozitivan utjecaj. U gore procijenjenom modelu VIF ne prelazi vrijednost 5 što dovodi do zaključka da model nema problem multikolinearnosti, što znači da nema regresorskih varijabli koje su međusobno linearno zavisne.

Druga hipoteza glasi:

H2: Promjena u udjelu financijske imovine vrednovane po fer vrijednosti je povezana s nerealiziranim dobitcima/gubitcima od promjene fer vrijednosti u narednoj godini.

U tablici 12 prikazane su aritmetička sredina i standardna devijacija varijabli koje ulaze u regresijski model za H2 hipotezu:

Tabela 12: Deskriptivna statistika za drugu hipotezu

	Aritmetička sredina	Standardna devijacija	Uzorak
$\Delta FV_{\text{dobitaka2016}}$	0.49	3.315	291
$\Delta U_{\text{djelaFVimovine2015}}$	-0.011	0.172	291
Zajmovi2016	0.108	0.15	291
Kapital2016	0.128	0.101	291
Profitabilnost2016	0.005	0.0244	291

Izvor: izrada autora

Promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu 2016. godine bilježi aritmetičku sredinu u iznosu od 0.49 s prosječnim odstupanjem od 3.315. Također, pri uzorku od 291, aritmetička sredina promjene udjela fer vrijednosti financijske imovine u 2015. godini iznosi -0.011 s prosječnim odstupanjem od 0.172. Ostale nezavisne, kontrolne varijable objašnjene su na stranici 35.

Također, korištena je ENTER metoda za procjenu regresijskog modela H2 hipoteze.

U nastavku će se prikazati tablica vrijednosti osnovnih pokazatelja višestruke regresije:

Tabela 13: Prikaz rezultata osnovnih pokazatelja za H2 hipotezu

Model	Koeficijent korelacije	Koeficijent determinacije	Korigirani koeficijent determinacije	Standardna greška
1	0,134 ^a	0.018	0.004	3.302
a. Prediktori: (Konstanta), Profitabilnost2016, $\Delta FV_{\text{dobitaka2015}}$, Kapital2016, Zajmovi2016				

Izvor: izrada autora

Iz tablice 13 zaključuje se kako je protumačeno 1.8% sume kvadrata odstupanja navedenog modela promjene fer vrijednosti dobitaka u odnosu na prethodnu godinu 2016. godine.

U nastavku prikazana je tablica ANOVA:

Tabela 14: ANOVA

ANOVAa						
Model		Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	F	Sig.
1	Regresija	58.255	4	14.564	1.332	0,258 ^b
	Rezidual	3127.723	286	10.936		
	Ukupno	3185.978	290			

a. Zavisna varijabla: $\Delta FV_{dobitaka2016}$
b. Nezavisne varijable: (Konstanta) Profitabilnost2016, Kapital2016, $\Delta UdjelaFV_{imovine2015}$, Zajmovi2016

Izvor: izrada autora

Iz navedene tablice zaključuje se iduće:

Ocijenjeni regresijski model je statistički neznačajan pri razini signifikantnosti od 10%, a to se može dokazati na dva načina.

Prvi način temelji se na usporedbi tablične i empirijske F vrijednosti - $F_{tab[df_1=4;df_2=286]}^{\alpha=1\%}=3,338$, a empirijska iznosi 1.332, što znači da je $F^* < F_{tab} \Rightarrow H_0$.

Drugi način koji potvrđuje gore navedeni zaključak se odnosi se na iščitavanje razine signifikantnosti iz tablice koja iznosi $\alpha=0.258>0.1$.

Iduća tablica pruža informacije ocijenjenih parametara, standardne greške, empirijske vrijednosti t – omjera, i tako dalje.

Tabela 15: Rezultat regresije za drugu hipotezu

	Nestandarizirani koeficijenti		Standardizirani koeficijenti	t	Sig.	90,0% Interval povjerenja za B		Kolinearna statistika	
	B	Stand. greška	Beta			Donja granica	Gornja granica	Tolerancija	VIF
(Konstanta)	0.231	0.327		0.706	0.481	-0.309	0.771		
$\Delta udjela FV_{imovine2015}$	1.972	1.137	0.102	1735	0.084	-0.097	3.848	0.986	1.015
Zajmovi 2016	0.084	1.431	-0.004	-0.059	0.953	-2.445	2.2276	0.816	1.225
Kapital 2016	1.928	2.025	0.059	0.952	0.342	-1.413	5.269	0.896	1.116
Profitabilnost 2016	8.457	8.514	0.062	0.993	0.321	-5.592	22.507	0.874	1.145
a.Zavisna varijabla: $\Delta FV_{dobitaka2016}$									

Izvor: izrada autora

Na temelju rezultata iz tablice, model glasi:

promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu 2016. godine = $0.231 + 1.972 \cdot \text{promjena udjela fer vrijednosti financijske imovine u 2015. godini} + 0.084 \cdot \text{gubitak od zajmova u bruto zajmovima 2016. godine} + 1.928 \cdot \text{kapital u ukupnoj imovini 2016. godine} + 8.457 \cdot \text{profitabilnost u 2016. godini}$.

Iz gore navedenog modela, interpretacija glasi sljedeće:

- Ako sve regresorske varijable poprime vrijednost 0, varijabla promjene fer vrijednosti dobitaka u odnosu na prethodnu godinu će poprimiti vrijednost u iznosu od 0.231.
- Ako se promjena udjela fer vrijednosti financijske imovine u 2015. godini poveća za 1% očekuje se povećanje fer vrijednosti dobitaka u odnosu na prethodnu godinu za 1.972 c.p.
- Fer vrijednost dobitaka u odnosu na prethodnu godinu će se također povećati ali za 0.084 ako se gubitak od zajmova u bruto zajmovima poveća za 1% c.p.
- Ako se kapital u ukupnoj imovini poveća za 1%, fer vrijednost dobitaka u odnosu na prethodnu godinu će iznositi 1.928 c.p.
- Kod povećanja za 1% varijable profitabilnosti, fer vrijednost dobitaka u odnosu na prethodnu godinu će rasti za 8.457 c.p.

Iz gore navedene tablice zaključuje se kako je jedini statistički značajan utjecaj varijable promjena udjela fer vrijednosti financijske imovine u 2015. godini na varijablu promjena fer vrijednosti dobitaka u odnosu na prethodnu godinu 2016. godine pri razini signifikantnosti od 10%, te ima pozitivan utjecaj.

Temeljem rezultata u procijenjenom model VIF, ni jedna varijabla ne prelazi vrijednost od 5, te se zaključuje kako model nema problem multikolinearnosti.

4.4. Analiza rezultata obrađenih podataka

Iz provedene analize može se zaključiti sljedeće:

Kod ispitivanja prve hipoteze, utjecaj na povećanje udjela fer vrijednosti financijske imovine ima profitabilnost. Utjecaj je pozitivan. Pretpostavka leži u činjenici da prilikom ostvarivanja profitabilnosti, donosioci odluka će težiti povećavanju udjela fer vrijednosti financijske imovine u ukupnoj imovini kako bi nastavili ostvarivati profitabilnost u sljedećoj godini.

Međutim, odbacuje se hipoteza utjecaja promjene nerealiziranih dobitaka i gubitaka od promjene fer vrijednosti financijske imovine na strukturu financijske imovine.

Također, povećanjem udjela fer vrijednosti financijske imovine u prethodnoj godini utječe na povećanje fer vrijednosti dobitka u odnosu na prethodnu godinu, što ujedno i potvrđuje pretpostavku kako prilikom procjene analitičara o povećanju rasta tržišne vrijednosti financijske imovine, onda će povećavati i udio tih kategorija u idućoj godini. Potvrđuje se pozitivan utjecaj fer vrijednosti imovine u ukupnoj imovini na fer vrijednost dobitaka u odnosu na prethodnu godinu.

ZAKLJUČAK

Svako poslovanje kreće od kvalitetno donošenih odluka, a svaka odluka se temelji na informacijama koje su trenutno dostupne. Različiti izvori tvore različite baze informacija za različite korisnike. Dakako, iako se temelj odluke naslanja na informacije, stavovi i različiti interesi su ti koji je su zaključni. S obzirom kolika je važnost informacija, njihovo prezentiranje je od ključne važnosti, a reguliraju ih standardi.

Utjecaj i važnost informacija može se sagledati kroz donošenje odluka o klasifikaciji, odnosno reklasifikaciji financijske imovine unutar četiri prema MRS-u 39 ili tri prema MSFI-u 9 kategorije. Svaka od kategorija financijske imovine može se početno, a zatim i naknadno vrednovati. Re/klasifikacija financijske imovine moguća je u određene kategorije prema unaprijed postavljenim uvjetima i prema saznanjima o istoj. Reklasifikacije je uglavnom rezultat različitih kretanja na tržištu gdje financijske institucije poduzimaju različite radnje kako ne bi imale gubitke.

U ovom radu korištena je baza podataka iz cijele Europe zbog veće baze banaka. Početni uzorak promatranja bio je veličine $N=627$, no zbog nedostataka podataka i velikih prosječnih odstupanja, smanjen je na 291. Korišten je program SPSS kako bi se mogla provesti analiza i donijeti zaključak, ali prije samog korištenja podataka u SPSS-u bilo je potrebno obraditi iste kroz Microsoft Office Excel. Za ovaj rad korištena je BankFocus baza. Godine koje su promatrane kroz rad su od 2014.-te do 2016.-te godine.

Kroz rad je ispitan utjecaj promjene fer vrijednosti dobitaka skupa s kontrolnim varijablama kapitala u ukupnoj imovini, gubitkom od zajmova u bruto zajmovima te profitabilnost na promjenu udjela fer vrijednosti financijske imovine. Rezultat ispitivanja ukazuje na nepovezanost utjecaja promjene fer vrijednosti dobitaka u odnosu na prethodnu godinu na promjenu udjela fer vrijednosti financijske imovine kao što je postavljeno očekivanje da će banka ako ostvaruje dobitke, povećavati udio fer vrijednosti kako bi nastavila ostvarivati i dalje dobitke. Naime, jedino je profitabilnost iskazala kako ima utjecaj na promjenu udjela fer vrijednosti imovine.

Također, ispitan je utjecaj promjene udjela fer vrijednosti financijske imovine uz iste kontrolne varijable kao i kod ispitivanja prve hipoteze na promjenu fer vrijednosti dobitaka u odnosu na prethodnu godinu, gdje je očekivanje da ako se poveća udjel fer vrijednosti financijske imovine da će se povećavati i fer vrijednost dobitaka u odnosu na prethodnu godinu, odnosno, smatra se da će se povećavati udio financijske imovine u tekućoj godini ako se procijeni da će se u narednoj godini desiti rast tržišne vrijednosti financijske imovine.

Rezultat ovakvog ispitivanja ukazuje na povezanost utjecaja promjene udjela fer vrijednosti imovine na promjenu fer vrijednosti dobitaka.

SAŽETAK

U ovom radu se provela analiza različitih utjecaja na udio fer vrijednosti financijske imovine i na fer vrijednost dobitka u odnosu na prethodnu godinu. Analiza se provela na uzorku od 291 europske banke za razdoblje od 2014.-2016. godine.

Rezultati analize utvrđuju kako na udio fer vrijednosti financijske imovine utječe profitabilnost s pozitivnim predznakom, dok na fer vrijednost dobitka u odnosu na prethodnu godinu pozitivno utječe udio fer vrijednosti financijske imovine. Međutim varijable kapital u ukupnoj imovini, promjena fer vrijednosti dobitka u odnosu na prethodnu godinu i gubitak od zajmova u bruto zajmovima nemaju utjecaj na promjenu udjela fer vrijednosti financijske imovine, a kapital u ukupnoj imovini skupa s gubitkom od zajmova u bruto zajmovima i profitabilnošću, također nemaju utjecaj ali na varijablu promjenu fer vrijednosti dobitka u odnosu na prethodnu godinu.

U konačnici, rezultat istraživanja ukazuje na to da banke neovisno ostvarivale dobitke ili gubitke neće ovisno o tome povećavati ili smanjivati udio fer vrijednost imovine, dok ako banka ima informaciju s kojom mogu procijeniti rast tržišne vrijednosti ona će povećavati udio tih kategorija financijske imovine.

Ključne riječi: europske banke, udio fer vrijednost financijske imovine, fer vrijednost dobitaka u odnosu na prethodnu godinu

SUMMARY

This paper analyses different influence on fair value share on assets and on fair value of gains comparing previous year. Analyse has been provided on sample size of 291 European banks in the period of 2014.-2016.

The results of mentioned analyse determine that profit has positive effect on the fair value share of financial assets, and that also positive effect has fair value share of financial assets on the fair value of gains. However, variables equity in total assets, fair value change of gain or loss, loan loss in gross loans don't have influence on change of fair value share of financial assets, and equity in total assets, loan loss in gross loans and profitability also has no influence but on variable change of fair value of gains comparing the last year.

For the end, the result of this research indicates that independently if banks expect gains or losses, the same one will not increase or reduce the fair values share of assets, but if bank has information that can estimate growth of market value she will increase share of that financial assets categories.

Key words: European banks, fair value share of financial assets, fair values of gains

LITERATURA

1. Abramović K. i ostali (2008.): Primjena hrvatskih standarda financijskog izvještavanja, Sveučilišna tiskara d.o.o. Zagreb str. 47-72, 289-489
2. Akerlof, G. A. (1970.): The market for "lemons": Quality and the market mechanism, Quarterly Journal of Economics, 84, str. 488 – 500.
3. Belak, V. (2008.): Kreativno računovodstvo i njegov utjecaj na financijske izvještaje, Računovodstvo, revizija i financije, broj 8, str. 13-23.
4. Belak, V. (2010.): Računovodstvo financijske imovine raspoložive za prodaju (kod svih poduzetnika), Računovodstvo, revizija i financije, broj 9, str. 17-24.
5. Belak V. (2006.): Profesionalno računovodstvo, Zgombić & Partneri Zagreb, 15-28, 308.
6. Bischof, J., Brüggemann, U., Daske, H., (2012): Fair Value Reclassifications of Financial Assets during the Financial Crisis, Humboldt-Universität zu Berlin, Internet, dostupno na : <https://edoc.hu-berlin.de/handle/18452/5037>. [04.05.2018.]
7. Cingula, M. I Klačmer Čalopa M. (2009): Financijske institucije i tržište kapitala, TIVA Tiskara Varaždin, str. 1-18, 31-42.
8. Fiechter, P. (2011.): Reclassification of Financial Assets under IAS 39: Impact on European Banks Financial Statements, Accounting in Europe, 8:1, 49-67, Internet, dostupno na: <https://www.tandfonline.com/doi/full/10.1080/17449480.2011.574409?scroll=top&needAccess=true>. [04.05.2018.]
9. Filipović, I. (2008.): Financijska izvješća banaka, Računovodstvo, Revizija i financije, broj 3, str. 130-138.
10. Filipović, I. (2016.): Računovodstvo financijskih institucija, Ekonomski fakultet Split str. 5-10.
11. Goić, S. (1995.): Teorija agencije kao temeljni koncept odnosa u suvremenom poslovanju, Računovodstvo i financije, broj 11., str 83-94.
12. Guzić Š.(2017.): MSFI – 9 Financijski instrumenti, Računovodstvo, Revizija i financije, broj 12/2017, str. 58 – 67.
13. Hladika, M. i Perčević, H (2012.): Utjecaj računovodstvenog tretmana naknadnog mjerenja financijskih instrumenata na financijski položaj i profitabilnosti hrvatskog bankarskog sektora, Ekonomska misao i praksa, Internet, dostupno na:

<https://search.proquest.com/openview/6147b3b51f14907b7d32e96769f58c34/1?pq-origsite=gscholar&cbl=196177>. [04.05.2018.]

14. Kramar K. i Pretnar Abičić S. (2018.): Financijska imovina (HSFI 9 i MRS 32, MSFI 9), dostupno na: <https://www.racunovodja.hr/33/financijska-imovina-hsfi-9-i-mrs-32-i-mrs-39-uniqueidmRRWSbk196E4DjKFq6pChBZsCk8bXzARdeJ4z5ar7GQmMG7vkyk7Nw/> [05.03.2019.]
15. Leko, V. (2002.): Financijske institucije i tržišta, pomoćni materijal za izučavanje, Ekonomski fakultet Zagreb str. 3-32.
16. Liović, D. i Mijoč, I. (2015.): Računovodstveni učinci reklasifikacije financijske imovine, Računovodstvo, revizija i financije, broj 10., str. 70-78.
17. Mamić Sačer, I., Sever, I., (2013.): Primjena međunarodnih standarda financijskog izvještavanja, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb, str. 1-7, 169-179.
18. Mrša J. (2010.): Klasifikacija i mjerenje financijske imovine, RRIF, Zagreb, broj 1, str. 203-204.
19. Mrša J. (2019.): MSFI 9 – Financijski instrumenti – primjena na financijske izvještaje za razdoblja koja počinju od 1. Siječnja 2018. godine i poslije, RRIF, Zagreb, br.1, str. 146-147.
20. Narodne novine (2013.): Odluka o izmjenama i dopunama odluke o objavljivanju međunarodnih standarda financijskog izvještavanja, Narodne novine d.d., Zagreb, broj. 45/2013.
21. Narodne novine (2017.): Odluka o klasifikaciji izloženosti u ružične skupine i načinu utvrđivanja kreditnih gubitaka, Narodne novine d.d., Zagreb, br. 114/2017
22. Narodne novine (2015.): Odluka o objavljivanju hrvatskih standarda financijskog izvještavanja, Narodne novine d.d., Zagreb broj 86/2015.
23. Narodne novine (2009): Odluka o objavljivanju međunarodnih standarda financijskog izvještavanja, Narodne Novine d.d., Zagreb, broj 136/2009.
24. Pivac S., (2010.): Statističke metode, Sveučilište u Splitu, Ekonomski fakultet Split
25. Ramljak, B., (2011.): Računovodstvene politike – utjecaj na izgled financijskih izvještaja, Sveučilište u Splitu, Ekonomski fakultet Split
26. Tipurić, D. (2008.): Korporativno upravljanje, Sinergija nakladništvo d.o.o., Zagreb, str. 115-138, 471-485.

27. Toth K., (2009.): Financijski instrumenti – priznavanje i mjerenje, FiP 5/2009, str.11-19
28. Vidučić, Lj. (2012.): Financijski menadžment, RRIF-plus, Zagreb, str. 9-109, 223-259, 423-459.
29. Žager, L. (2007.): Osnove računovodstva, Hrvatska zajednica računovođa i financijskih djelatnika, str. 3-72, 202-214.
30. Žager, K., Mamić Sačer, I., Sever Mališ, S., Ježovita, A., Žager, L. (2017): Analiza financijskih izvještaja, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb, str. 14-41, 44-58, 224-326.
31. Žager, K., Mamić Sačer I., Sever S., Žager L. (2008.): Analiza financijskih izvještaja, Masmedia, Zagreb, str. 2-43, 84-134, 148-162, 224-227.

POPIS TABLICA

Tabela 1: Usporedba MRS-a 39 i MSFI-a 9	17
Tabela 2: Naknadno mjerenje financijske imovine	22
Tabela 3: Tablica varijabli korištenih u SPSS-u za potrebe ispitivanja i njihovi izračuni	28
Tabela 4: Broj banaka prema zemljama	30
Tabela 5: Deskriptivna statistika	31
Tabela 6: Pearsonov koeficijent korelacije za H1 hipotezu	32
Tabela 7: Pearsonov koeficijent korelacije za H2 hipotezu	33
Tabela 8: Deskriptivna statistika za prvu hipotezu	35
Tabela 9: Prikaz rezultata osnovnih pokazatelja kod H1 hipoteze	35
Tabela 10: ANOVA tablica	36
Tabela 11: Rezultat regresije	36
Tabela 12: Deskriptivna statistika za drugu hipotezu	38
Tabela 13: Prikaz rezultata osnovnih pokazatelja za H2 hipotezu	38
Tabela 14: ANOVA	38
Tabela 15: Rezultat regresije za drugu hipotezu	39

POPIS SLIKA

Slika 1: Struktura računovodstva	8
Slika 2: Vrsta računovodstva prema podjeli korisnika informacija	9
Slika 3: Nastanak računovodstvenih standarda	15
Slika 4: Podjela financijskog instrumenta	18
Slika 5: Kategorije financijske imovine prema MRS-u 39	20
Slika 6: Reklasifikacije financijske imovine prema amortiziranom trošku i mjerene prema fer vrijednosti kroz dobit/gubitak	25
Slika 7: Reklasifikacija financijske imovine prema amortiziranom trošku i po fer vrijednosti kroz OSD	25
Slika 8: Reklasifikacija financijske imovine mjerene prema fer vrijednosti kroz dobit ili gubitak i po fer vrijednost kroz OSD	26

GRAFIKONI

Grafikon 1: Asimetrična informacija	11
Grafikon 2: Analiza oportunističkog ponašanja	12