Procjena financijskih frikcija u investicijskim tokovima u Republici Hrvatskoj

Šagovac, Mislav

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:148:349095

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

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

Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb

Sveučilište u Zagrebu

Ekonomski fakultet

Mislav Šagovac

PROCJENA FINANCIJSKIH FRIKCIJA U INVESTICIJSKIM TOKOVIMA U REPUBLICI HRVATSKOJ

DOKTORSKI RAD

Zagreb, 2019.

Sveučilište u Zagrebu

Ekonomski fakultet

Mislav Šagovac

PROCJENA FINANCIJSKIH FRIKCIJA U INVESTICIJSKIM TOKOVIMA U REPUBLICI HRVATSKOJ

DOKTORSKI RAD

Mentor:

prof. dr. sc. Josip Tica

Zagreb, 2019.

Sveučilište u Zagrebu

Faculty of Economics and Business

Mislav Šagovac

ESTIMATION OF THE INVESTMENT CHANNEL OF FINANCIAL FRICTIONS IN THE REPUBLIC OF CROATIA

DOCTORAL THESIS

Supervisor:

prof. dr. sc. Josip Tica

Zagreb, 2019

_MISLAV ŠAGOVAC__ _____

Ime i prezime doktoranda/ice

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,_____ godine _____

(vlastoručni potpis)

SAŽETAK

Stagnacija investicija nefinancijskih poduzeća u razvijenim zemljama i nekim nerazvijenim zemljama Europske unije zbog svjetske financijske krize vratila je pitanje odrednica investicija u središte zanimanja znanstvenih i stručnih krugova. Ekonomska teorija i empirija postavljaju aktualna pitanja o tome čime su određeni tokovi investicija, kako povećati investicije nefinancijskih poduzeća i kolika je efikasnost domaće ekonomske politike u poticanju investicija. Temeljni je cilj ove doktorske disertacije istražiti osnovne determinante investicija u Republici Hrvatskoj, a posebno investicijskog kanala financijskih frikcija. Pri tome se posebno testira hipoteza o postojanju financijskog, a posebno hipoteza o postojanju likvidnog ograničenja kao značajki financijskih frikcija. Uporabom panel *threshold* regresije, novih varijabli za kontroliranje agregatne potražnje i gotovo cijele populacije poduzeća u Republici Hrvatskoj odbačena je hipoteza o značajnijem stupnju financijskog ograničenja kada se primijeni poznati pristup Fazzarija i dr. (1988). Istraživanjem je prihvaćena hipoteza o postojanju likvidnog ograničenja poslovnih subjekata, odnosno potvrđena je nelinearnost u osjetljivosti investicija na novčane tokove kao funkcija stanja likvidnosti. Empirijsko je istraživanje potvrdilo i postojanje heterogenosti na nesavršenim tržištima kapitala s obzirom na oblik vlasništva i podrijetlo kapitala. Posljednja je hipoteza pokazala ograničenost politike oprosta i odgode dugova nefinancijskih poduzeća u poticanju investicija i rastu zaposlenosti. Posljednja hipoteza ima karakteristike kvaziprirodnih eksperimenata što omogućuje nadilaženje problema endogenosti u procjeni investicijske jednadžbe. Dobiveni rezultati ističu važnost osmišljavanja domaće ekonomske politike na način da uvažava ulogu heterogenosti u ponašanju investicija, posebno s aspekta nesavršenosti na tržištima kapitala.

Ključne riječi: financijske frikcije, tokovi investicija, Hrvatska, panel *threshold* regresija, efekti tretmana, Zakon o financijskom poslovanju i predstečajnoj nagodbi

EXTENDED SUMMARY

Stagnation of investment of non-financial firms in developed and underdeveloped EU countries, after the global financial crisis, has returned the issue of investment in the centre of interest of scientific and professional community. What are the main determinants of investments, how to increase the investment of non-financial corporations, and how effective the domestic economic policy is in stimulating investment, are the current issues posed by economic theory and empiricism. Drop investments through net worth channel contributed to amplification and persistence of financial shock in Great recession.

The main goal of this doctoral dissertation is to explore the fundamental determinants of investments in the Republic of Croatia, and in particular the investment channel of financial frictions. Two types of financial frictions are analysed: the hypothesis of the existence of a firm financial constraints, and in particular, the hypothesis of the existence of the firm liquidity constraint. The heterogeneity of financial fristions with respect to ownership type and capital source is discussed. In last part of dissertation explains effect of debt forgiveness on investment and employment.

For first two hypothesis panel threshold regression is used. The new variables to control aggregate demand I added to threshold regression and the sample include almost the entire population of companies in the Republic of Croatia. First two hypothesis was tested by assessing investment cash flow sensitivities fot various degree of financial and liquidity contraints. The hypothesis of a significant degree of financial constraint was rejected when applying approach of Fazzaria et al. (1988). On contrary, the hypothesis of the existence of liquidity constraints was confirmed: there is nonlinearity in the sensitivity of investments to cash flow, as a function of liquidity. Inliquid firms hve precutionry demand for cash, so additional cash is used as a buffer to liquidity shock. Firms at margin (liquid firms) shows highest sensitivity of investment to cash flows, while highly liquid firms show low sensitivities. Empirical research has also confirmed the existence of heterogeneity in imperfect capital markets with regard to the form of ownership and the origin of capital. Both group didn't experience financial and liquidity constraint problems.

The last hypothesis has shown the limited effect of the forgiveness policy and the prolongation of debts of non-financial corporations on boosting investment and employment growth. The last hypothesis has the characteristics of quasi-natural experiments which allow overcoming

endogenous problems in estimating the investment equation. The results obtained emphasize the importance of designing domestic economic policy in a way that takes into account the significant role of heterogeneity in investment on imperfection of capital markets.

Key words: financial frictions, investment flows, Croatia, panel threshold regression, treatment effects

SADRŽAJ

SAŽETAK 1

EXTENDED SUMMARY 1

1. UVOD 1

1.1 Područje, predmet i problem istraživanja 1

1.2 Ciljevi istraživanja 6

1.3 Hipoteze istraživanja 7

1.4 Metode istraživanja 11

1.5 Očekivani znanstveni doprinos 13

1.6 Struktura disertacije 15

2 ZNAČAJKE INVESTICIJSKOGA KANALA FINANCIJSKIH FRIKCIJA U MODELIMA RACIONIRANJA KREDITA I PREVENTIVNE POTRAŽNJE ZA LIKVIDNOŠĆU 18

2.1 Dinamika investicijskih i kreditnih tokova u Republici Hrvatskoj i Europskoj uniji 18

2.1.1 Komparativna analiza dinamike investicija u Hrvatskoj i Europskoj uniji 18

2.1.2 Agregatna investicijska i kreditna aktivnost u Republici Hrvatskoj 23

2.1.3 Pregled istraživanja o dinamici i interakciji kreditne i realne aktivnosti 28

2.2 Modeli investicija bez financijskih frikcija 31

2.2.1 Keynesova teorija investicija 31

2.2.2 Neoklasična teorija potražnje za investicijama 33

2.2.3 Q-teorija investicija 37

2.2.4 Utjecaj nesigurnosti i ireverzibilnosti na investicije: realne opcije 42

2.2.5 Q-teorija investicija u uvjetima nesigurnosti s proširenom funkcijom prilagođavanja 46

2.2.6 Modigliani-Millerova teorija irelevantnosti strukture kapitala 48

2.3 Značajke financijskog ograničenja kao problema financijskog ugovaranja 50

2.3.1 Heuristički opis pojma financijskog ograničenja 50

2.3.2 Tiroleov model racioniranja kredita 53

2.3.3 Trošak verifikacije stanja 63

2.3.4 Teorija hijerarhije financijskih izbora 65

2.4 Značajke likvidnog ograničenja poduzeća 67

2.4.1 Heuristički opis likvidnog ograničenja 67

2.4.2 Holmstrom-Tiroleov model potražnje za likvidnošću 73

2.5 Makroekonomski modeli s financijskim frikcijama 78

2.5.1 Kratak pregled povijesnih radova 78
2.5.2 Kanal zaduživanja poduzeća 81
2.5.3 Odnos financijske intermedijacije i investicijske aktivnosti poduzeća 89

3 EMPIRIJSKI PRISTUPI PROCJENJIVANJA FINANCIJSKOG I LIKVIDNOG OGRANIČENJA KAO ZNAČAJKI INVESTICIJSKOGA KANALA FINANCIJSKIH FRIKCIJA 93

3.1 Sistematizacija empirijskih istraživanja o investicijskom kanalu financijskih frikcija 93

3.2 Analiza financijskog ograničenja procjenom osjetljivosti investicija na novčane tokove za poduzeća različita financijskog položaja 95
3.2.1 Utjecaj financijskih frikcija na razinu novčanih sredstava 101
3.2.2 Problem endogenosti i ostale kritike u procjenjivanju osjetljivosti investicija na novčane tokove 103
3.2.3 Problem apriorne klasifikacije tvrtki 110
3.2.4 Analiza financijskog ograničenja poduzeća primjenom *threshold* regresije 112

3.3 Analiza financijskog ograničenja primjenom metode efekta tretmana 114

3.4 Ostali metodološki pristupi identificiranja financijskog ograničenja 117
3.4.1 Analiza financijskih frikcija pomoću strukturnih ekonometrijskih modela 117
3.4.2 Analiza financijskog ograničenja primjenom anketnih podataka 120
3.4.3 Kolateralni kanal i tvrtkin kanal bilance stanja 122

3.5 Međuovisnost potražnje za likvidnošću i investicijske aktivnosti poduzeća 124

3.6 Financijske frikcije i ponuda kapitala (bankovni kanal zaduživanja) 128

4 ANALIZA ZNAČAJKI INVESTIRANJA I FINANCIRANJA PODUZEĆA U REPUBLICI HRVATSKOJ 132

4.1 Definicija varijabli i pokazatelja poslovanja poslovnih subjekata 132

4.2 Analiza općeg stanja i položaja poslovnih subjekata 135

4.3 Struktura i dinamika investicija poslovnih subjekta 141

4.4 Međuovisnost strukture financiranja i investicija poslovnih subjekata 159

4.5 Međuodnos investicija i likvidnosti poslovnih subjekata 173

5 EMPIRIJSKI MODEL UTJECAJA FINANCIJSKIH FRIKCIJA NA INVESTICIJSKU AKTIVNOST POSLOVNIH SUBJEKATA U REPUBLICI HRVATSKOJ 182

5.1 Metodološki okvir analize 182

5.2 Pregled podataka i izbor varijabli upotrijebljenih u analizi 186
5.2.1 Prilagodba podataka za analizu financijskog i likvidnog ograničenja 187
5.2.2 Sažetak osnovnih statističkih veličina 192

5.3 Specifikacija *threshold* regresijske investicijske jednadžbe 193

5.4 Rezultati analize investicijskoga kanala financijskih frikcija mjerenjem osjetljivosti investicija na novčane tokove 198
5.4.1 Rezultati analize financijskog ograničenja poslovnih subjekta 198
5.4.2 Rezultati analize likvidnog ograničenja poslovnih subjekta 213
5.4.3 Analiza heterogenosti u stupnju financijskog i likvidnog ograničenja poslovnih subjekata 218

5.5 Analiza robusnosti 223
5.5.1 Izbor različitih specifikacija modela 223
5.5.2 Osjetljivost na ekstremne vrijednosti, izbor nezavisnih varijabli, korištenje novčanih tokova u tekućem razdoblju i korištenje režimski ovisnih zavisnih varijabli 229

5.6 Analiza financijskog i likvidnog ograničenja na nebalansiranu panel-uzorku 245
5.6.1 Opis varijabli 245
5.6.2 Opis ekonometrijskog pristupa 248
5.6.3 Rezultati analize financijskog i likvidnog ograničenja na nebalansiranu uzorku 249

6 UČINAK ZAKONA O FINANCIJSKOM POSLOVANJU I PREDSTEČAJNOJ NAGODBI NA INVESTICIJE PODUZEĆA 259

6.1 Efekti tretmana i *difference-in-differences* procjenitelj uparivanja 259

6.2 Predstečajne nagodbe kao egzogeni tretman na financijsku situaciju 266
6.2.1 Opis Zakona o financijskom poslovanju i predstečajnoj nagodbi 266
6.2.2 Uparivanje poduzeća iz kontrolne skupine 268

6.3 Opis podataka upotrijebljenih u analizi 272
6.3.1 Podaci o predstečajnim nagodbama 272
6.3.2 Prilagodba podataka za primjenu metode efekta tretmana 279

6.4 Prikaz modela 287

6.5 Rezultati analize 288
6.5.1 Rezultati osnovnog modela 289
6.5.2 Utjecaj tretmana na zaposlenost poslovnih subjekata 292

6.6 Analiza robusnosti osnovnog modela 293
6.6.1 Promjena investicija za različita razdoblja 294
6.6.2 Uparivanje prema pokazateljima likvidnosti i zaduženosti 295

6.7 Analiza efekta tretmana metodom panel-fiksnih efekata 299

7 . ZAKLJUČAK 302

7.1 Investicijski tokovi u Republici Hrvatskoj i Europskoj uniji 302

7.2 Odrednice investicija s naglaskom na investicijski kanal financijskih frikcija 304

7.3 Razmatranje utjecaja financijskog ograničenja na investicije tvrtki u Republici Hrvatskoj 306

7.4 Utjecaj politike upravljanja novčanim sredstvima na investicije poduzeća 307

7.5 Učinak predstečajnih nagodbi kao egzogenog instrumenta na financijsku situaciju 309

POPIS LITERATURE 311

POPIS TABLICA I SLIKA 323

ŽIVOTOPIS 326

POPIS OBJAVLJENIH AUTOROVIH RADOVA 327

1. UVOD

1.1 Područje, predmet i problem istraživanja

Ova se doktorska disertacija, u širem smislu, smješta u područje društvenih znanosti i znanstveno polje ekonomije. U užem smislu, područje joj je empirijska makroekonomija s financijskim frikcijama, odnosno ekonometrijsko modeliranje međuovisnosti investicija i financijskih varijabli. Predmet je istraživanja empirijska procjena investicijskog kanala financijskih frikcija, odnosno istraživanje problema financijskog i likvidnog ograničenja kao značajki financijskih frikcija na razini poduzeća.

Frikcije općenito označavaju djelomično odstupanje od teorijskog modela savršenog tržišta. Financijske frikcije označavaju odstupanje od savršenih tržišta kapitala zbog fenomena asimetričnosti informacija između investitora i ekonomskih agenata. Bez financijskih frikcija kapital se usmjerava projektima s najvećom profitabilnošću bez ograničenja. U modelima s financijskim frikcijama, s druge strane, heterogenost ekonomskih agenata s obzirom na likvidnost, zaduženost i ostale financijske varijable postaje ključan za objašnjenje dinamike investicija i potrošnje na mikro i na makrorazini. Investicijski kanal financijskih frikcija objašnjava međuovisnost investicijske dinamike i financijskih faktora poduzeća (strukture kapitala, neto vrijednosti, likvidnosti), a očituje se u financijskom *ili* likvidnom ograničenju poduzeća zbog asimetričnosti informacija. Financijsko ograničenje ili racioniranje kredita označava stanje kreditne nesposobnosti poslovnog subjekta u kojem tvrtka ima investicijsku priliku i istodobno: 1) nema dovoljno interno prikupljenih sredstava za financiranje projekta, 2) nema dostatnu razinu neto vrijednosti (novca, kolaterala) kao zaloga za vanjsko financiranje (Tirole, 2006). Likvidno ograničenje odražava stanje u kojem tvrtke odustaju od već započetih investicijskih poslova zbog šokova likvidnosti jer nakon šoka novi novčani tok služi za uspostavljanje optimalne likvidnosti, a ne investicija. Empirijskim procjenjivanjem investicijskog kanala financijskih frikcija verificiraju se teorijski mikroekonomski modeli o ponašanju investicija s jedne strane te makroekonomski modeli opće ravnoteže s investicijskim kanalom kao mikroekonomskom osnovom s druge strane.

Ekonomska je literatura prepoznala važnost međuovisnosti investicija i financijskih varijabli, posebno nakon Velike recesije. Prijašnji modeli nisu mogli objasniti amplifikaciju i perzistentnost ekonomskih šokova, pa su preispitivane ključne pretpostavke ekonomskih

modela. Brojni radovi iz makroekonomije s financijskim frikcijama uključuju frikcije unutar jednadžbe investicija radi analize amplifikacije i perzistentnosti ekonomskih šokova (Fisher, 1933; Minsky, 1986; Benanke i Gertler; 1986, Calstrom i Fuerst, 1997; Kiyotaki i Moore, 1997; Bernanke, Gertler i Gilchrist, 1999; pregled radova dan je u Brunnermeier, Eisenbach i Sannikov, 2012). Perzistentnost šokova označuje potrebno vrijeme za obnovu neto vrijednosti poduzeća zadržavanjem zarada, a amplifikaciju uglavnom stvara proces prodaje imovine iz nužde (engl. *fire sells*) (Brunnermeier, Eisenbach i Sannikov, 2012). Empirijskom procjenom investicijskoga kanala verificiraju se navedeni ekonomski modeli i važnost financijskih frikcija za razumijevanje investicijske dinamike na mikrorazini i poslovnih ciklusa na makrorazini.

Osim u objašnjenju poslovnih ciklusa, uloga je investicija i u poticanju ekonomskog rasta jer one odražavaju potencijale dugoročna uspjeha poduzeća i potencijale općeg ekonomskog rasta. Zna se da je u Solowljevu modelu rasta (Solow, 1956) osnovni faktor konvergencije, uz rast produktivnosti, akumulacija kapitala. Investicije su stoga ključan element dugoročna rasta nacionalnih ekonomija i izrazito su važna komponenta agregatnog dohotka u Republici Hrvatskoj. One čine najvolatilniju komponentu agregatne potražnje domaće ekonomije te je pad vrijednosti investicija u odnosnu na BDP ključan za razumijevanje dugoročne recesije i slab oporavak gospodarstva poslije izbijanja ekonomske krize. Niske stope rasta investicija zabilježene su i u razvijenim zemljama, pa se privatne investicije prepoznaju kao važan faktor objašnjenja sekularne stagnacije u razvijenim zemljama (MMF, 2015).

Investicije su u središtu pozornosti mikroekonomske i makroekonomske teorije. U prvom neoklasičnom modelu investicija, koji je izveden iz problema optimizacije tvrtki, kapital se prilagođava tako da granični troškovi korištenja budu jednaki graničnom proizvodu kapitala (Jorgenson, 1967). Zbog restriktivnih pretpostavki takvog modela koje se odnose na trenutačno prilagođavanje ravnoteži, model je proširivan različitim oblicima nesavršenosti (frikcije) koji stvaraju realniju sliku ponašanja investicija. Glavni teorijski pristupi objašnjenja ponašanja investicija jesu varijacije q-teorije investicija (Hayashi, 1982, Brainard i Tobin, 1968) i Modigliani-Millerova teorija irelevantnosti strukture kapitala (Modigliani, Miller, 1958). U standardnoj neoklasičnoj funkciji investicija s troškovima prilagođavanja (q-teorija investicija), jedina su odrednica ponašanja investicija očekivani budući profiti i troškovi kapitala (engl. *user costs fo capital*). Poznata q-teorija investicija i iz nje izvedena reducirana empirijska funkcija investicija proširena je tako da uračunava ireverzibilnost, nesigurnost glede novčanih tokova i fiksne troškove investiranja. U literaturi su se sve ove karakteristike investicija analizirale unutar problema vrednovanja američkih (europskih) „call“ opcija (Dixit i Pyndrick, 1994) u

kojima je optimalna investicijska politika izvedena iz problema optimalna zaustavljanja (engl. *optimal stoping problems*) (Decamp, Villeneuve, 2013).

Navedeni su modeli vrlo koristan okvir za razumijevanje ponašanja investicija, ali nisu empirijski uspješni u objašnjenju investicijske dinamike, posebno pri pojavi velikih šokova. Alternativan pristup objašnjenju investicija razvio se unutar teorijskih i empirijskih radova iz teorije ugovora i korporativnih financija (pregled u Tirole, 2006; Bernard, 2005). Unutar takvih modela dinamika investicija rezultat je informacijskih nesavršenosti na kreditnom tržištu. S jedne su strane poduzeća koja raspolažu projektima s pozitivnom neto sadašnjom vrijednosti, ali nemaju dovoljno novčanih sredstava za pokrivanje investicijskih troškova, dok s druge strane postoje investitori i financijske institucije (banke) koje raspolažu novčanim sredstvima (štednjom). Asimetričnost informacija između dužnika i vjerovnika stvara jaz između troškova eksternog i internog financiranja i utječe na investicije poduzeća (Townsend, 1979; Mayers i Myluf, 1984; Stiglitz i Weiss, 1981; Gale i Hellwig, 1985; Tirole, 2006). Takvi modeli iz teorije ugovora i korporativnih financija čine mikroekonomske osnove makroekonomskih modela s financijskim frikcijama, pa se empirijskim procjenjivanjem investicijskoga kanala testiraju mikroekonomski modeli o ponašanju investicija s jedne strane i makroekonomski modeli s investicijskom jednadžbom u konceptu opće ravnoteže s druge strane.

Empirijska literatura o utjecaju financijskih frikcija na investicije može se podijeliti na makroekonomsku (djelovanje financijskih frikcija kroz kreditni kanal) i mikroekonomsku literaturu (istraživanja iz područja empirijskih korporativnih financija)[1]. Kreditni se kanal može dodatno raščlaniti na tri kanala utjecaja financijskih frikcija na investicijsku aktivnost: kanal bilance stanja dužnika (poduzetnika), kanal zaduženja tvrtke (bankovni kanal) i kanal likvidnosti (Banka za međunarodna izravnanja, 2011). Uvažavajući navedenu sistematizaciju, doktorski je rad pretežito usmjeren na analizu kanala bilance stanja poduzeća.

Empirijska istraživanja iz korporativnih financija o financijskom ograničenju uglavnom su se svodila na odbacivanje neoklasične teorije investicija potvrđivanjem povezanosti financijskih faktora poduzeća i investicija. Najveća poteškoća u ovom području istraživanja odnosi se na problem identifikacije ponude i potražnje za kreditima, odnosno poteškoću određivanja je li pad (rast) kreditne aktivnosti pod utjecajem pada (rasta) potražnje za kreditima ili ograničenja

[1] Osim kreditnoga kanala, makroekonomska empirijska literatura o ponašanju investicija najčešće prepoznaje dvije odrednice investicija: neizvjesnost (Bloom, 2009; Gilchrist. S., Sim, J. W. & Zakrajšek E., 2014) i agregatnu potražnju (MMF, 2015; Krugman 2011). Iako je u ovom radu naglsak na kredintom kanalu, poštuje se utjecaj ostalih dvaju faktora na inveticije.

(ekspanzije) ponude za kreditima. Ovaj se problem nastoji riješiti na dva načina. Prvi se način odnosi na testiranje financijske ograničenosti poduzeća mjerenjem osjetljivosti investicija na novčane tokove kao funkcije zaduženosti[2] (Fazzari, Hubbard i Petersen, 1988; pregled literature dan u Hubbard, 1988. i Stein, 2003). Tvrtke se apriorno dijele na financijski ograničene i neograničene ili se primjenom nelinearnih ekonometrijskih metoda utvrđuju endogene granice koje dijele financijski ograničene od neograničenih poduzeća. Potom se testira hipoteza o signifikantnoj pozitivnoj vezi novčanih tokova i investicija za svaku skupinu poduzeća. Glavni je problem ove vrste istraživanja endogenost. Pozitivna veza novčanih tokova i investicija može biti odraz većih investicijskih prilika, a ne financijskih ograničenja (Kaplan i Zingales, 1997; Erickson i Whited, 2000; Gomes 2001; Alti 2003). Drugi način analize financijskog ograničenja odnosi se na rješavanje problema endogenosti korištenjem efektima tretmana kako bi se testirao kauzalni odnos između financijskih varijabli i investicija (Calomiris i Hubbard, 1995; Blanchard, Lopez-de-Silanes i Schleifer, 1994; Lamont, 1997; Rauh, 2006; Almeida et al., 2012; Lemmon i Roberts, 2007). U ovoj će se disertaciji analizirati posljedice obaju pristupa. Prvo se primjenom nelinearnih ekonometrijskih metoda na uzorku malih i velikih poduzeća testira hipoteza o postojanju financijskog i likvidnog ograničenja, a potom se primjenom predstečajne nagodbe kao pozitivnog šoka na financijsku situaciju testira utjecaj poboljšanja financijske situacije (oprosta i odgode dugova) na investicijsku aktivnost.

S obzirom na to da se u postojećoj literaturi pojmovi financijskog i likvidnog ograničenja najčešće promatraju kao sinonimi, empirijska literatura o likvidnom ograničenju znatno je oskudnija. Izuzetak su teorijsku pristupi Holmstroma i Tirolea (2011), te empirijski radovi Cleary, Povel i Raitha (2007) i Guarigliae (2007).

Uzevši u obzir sve navedeno, temeljna su problemska pitanja na koja će se u ovoj disertaciji pokušati dati odgovor sljedeća: Mogu li financijske frikcije objasniti dinamiku ponašanja investicija prije i nakon financijske krize? Koja bilančna varijabla najbolje odražava razlikovanje financijski ili likvidno ograničenih i neograničenih poduzeća? Utječe li poboljšanje financijskog položaja (sklopljena predstečajna nagodba), zbog stalnih investicijskih prilika, na rast investicija, kako u poduzećima, tako i u cijelom gospodarstvu? Kakav je bio udio ograničenih i neograničenih poduzeća tijekom promatrana razdoblja? Kakav je utjecaj

[2] S obzirom na važnost termina „osjetljivost investicija na novčane tokove“ za predmetno istraživanje i empirijsku literaturu o financijskim frikcijama općenito, važno je odmah istaknuti da termin podrazumijeva vrijednost koeficijenta uz novčane tokove u investicijskoj (regresijskoj) jednadžbi, gdje se kao zavisna varijabla pojavljuje stopa investicija, a kao ključna nezavisna varijabla stopa novčanih tokova.

politike likvidnosti na investicije poduzeća? Utječe li agregatna ponuda likvidnih instrumenata na likvidnost?

Radi razvijanja intuicije i odgovora na prethodna pitanja, može se heuristički opisati kako nesavršena tržišta kapitala utječu na investiranje u poduzećima i poslovne cikluse, na agregatnoj razini. Poduzeća na tržištu zauzimaju određeni financijski položaj. U modelima je položaj najčešće određen neto vrijednošću poduzeća (Benanke i Gertler, 1986.; Calstrom i Fuerst, 1997; Tirole, 2006) ili vrijednošću kolaterala (Kiyotaki, Moore,1997). Poduzeća mogu financirati (profitabilne) projekte iz internih i eksternih izvora financiranja. Eksterno financiranje skuplje je od internog financiranja putem zadržanih zarada jer su eksterni izvori financiranja ograničeni vrijednostima kolaterala ili troškovima agenata (poduzetnici ne mogu založiti ukupne prinose na projekt (Tirole, 2006)). Zbog moralnog hazarda ili nekog drugog oblika asimetričnosti informacija moguće je da i u ravnoteži nastane racioniranje kredita (Stigliz i Weiss, 1981) te da poduzeća ne mogu financirati projekt čak i ako ima pozitivnu neto sadašnju vrijednost. Također, zaduženje povećava financijsku polugu poduzeća te ona s visokim dugom u odnosu prema neto vrijednosti postaju ranjiva na ekonomske šokove (Koo, 2009). Rizik se dodatno povećava rastom troška zaduženja jer se povećava vjerojatnost bankrota i trošak nadzora (engl. *debt overhang*).

U makroekonomskim modelima dinamiku pokreće određeni šok, najčešće šok produktivnosti, što implicira da su modeli najčešće proširenje standardnih modela realnih poslovnih ciklusa (RBC). Temporalni je šok perzistentan jer može proći mnogo vremena dok poduzeća ne uspiju obnoviti svoj financijski položaj (neto vrijednost) stvaranjem profita (Benanke i Gertler, 1986). Dakle, zbog šoka na neto vrijednost poduzeća smanjuju se investicije jer se aktiviraju financijske frikcije. Drugo je važno svojstvo šokova, osim perzistentnosti je amplifikacija (Brunnermeier i ostali, 2012). Šok može biti pojačan ako su produktivna poduzeća prisiljena prodavati kapital iz nužde (engl. *fire-sell*s). Kako prodaja imovine iz nužde smanjuje vrijednost kapitala, dodatno se narušava neto vrijednost poduzeća (spirala gubitaka). Dodatno, kolateralne margine mogu rasti, a to može prisiliti agente na smanjenje hipotekarne poluge (Geanokoplos, 2011). Sve smanjuje cijenu imovine, što dodatno narušava neto vrijednost poduzeća i donosi dodatne prodaje iz nužde. U potonjem opisu ponašanje investicija ima presudnu ulogu u amplifikacijskom procesu.

Ukratko, u radu se istražuje utjecaj promjene neto vrijednosti i/ili financijskih varijabli (zaduženosti, premije rizika, pokazatelja financiranja) na ponudu kapitala u uvjetima

asimetričnih informacija (financijsko ograničenje), s jedne strane, te utjecaj likvidnosti i politike upravljanja njome, kao ublaživača šokova, na investicije nefinancijskih poduzeća, s druge strane.

1.2 Ciljevi istraživanja

Iz opisa predmeta i dispozicije rada proizlazi osnovni cilj istraživanja: empirijski ispitati mogući utjecaj financijske i likvidne situacije, kao pokazatelja financijskih frikcija na investicijske odluke poduzeća s jedne strane, te analizirati utjecaj predstečajne nagodbe, kao pozitivnog šoka na financijsku situaciju, na investicije poduzeća s druge strane. Cilj je utvrditi postoje li nesavršenosti na financijskom tržištu i ako postoje, da li je njihov utjecaj značajan s obzirom na ostale determinante investicija, posebno agregatne potražnje.

Glavni se cilj može raščlaniti na znanstvene i aplikativne ciljeve. Znanstveni su ciljevi doktorskog rada:

1. Ustanoviti intenzitet utjecaja financijskog ograničenja na investicije poduzeća.
2. Odrediti karakteristike likvidnog i financijskog ograničenja te utvrditi utjecaj likvidnog ograničenja na investicije poduzeća
3. Ispitati heterogenosti financijskog ograničenja s obzirom na oblik vlasništva i podrijetlo kapitala.
4. Utvrditi utjecaj olakšanja budžetskog ograničenja (povećanja neto vrijednosti) na investicije poduzeća primjenom efekta tretmana.

Osim znanstvenih spoznaja, ova disertacija može pridonijeti efikasnijim ekonomskim politikama, a njezina se praktična primjenjivost ogleda u sljedećim aplikativnim ciljevima:

1. ustanoviti efikasnost predstečajnih nagodbi u poticanju investicija u Republici Hrvatskoj
2. Utvrditi opravdanost opraštanja dugova za prezadužena i nelikvidna poduzeća.
3. razjasniti utjecaj financijskih i likvidnih šokova na investicije poduzeća kako bi se utvrdili efekti ekonomskih mjera za ublažavanje šokova.
4. predložiti mjere za povećanje stupnja financijske uključivosti.

1.3 Hipoteze istraživanja

Prema neoklasičnoj teoriji investicija (q-teorija investicija), kompletna informacija o investiranju sadržana je u varijabli q, dok ostale varijable nemaju utjecaja na ponašanje investicija. Dakle, na savršenim tržištima kapitala varijable poput neto vrijednosti poduzeća ili kolaterala ne bi trebale objašnjavati ponašanje investicija. Rezultat takva shvaćanja bilo je zanemarivanje financijskih faktora u empirijskim modelima investicija. Podrazumijevalo se postojanje reprezentativnog agenta (tvrtke), što je impliciralo primjenu istoga empirijskog modela za sve tvrtke (Hubbart, 1988).

Jedan od prvih pokušaja empirijskog testiranja financijskog ograničenja jest rad Fazzarija, Hubbarda i Petersena (1988) - FHP. Autori su pokušali riješiti problem identifikacije financijskog ograničenja uspoređujući osjetljivost investicija na novčane tokove unutar grupe tvrtki različitih financijskih karakteristika (a priori ograničenih i neograničenih)[3]. Najčešće se uzorak dijelio na tri grupe poduzeća prema određenom bilančnom pokazatelju (stupanj zaduženosti, veličina i dr.), nakon čega se procjenjivala investicijska jednadžba za svaku grupu poduzeća. Poduzeća koja su financijski ograničena (grupa s najvišim koeficijentom zaduženosti) trebala bi imati najveću osjetljivost investicija na novčane tokove. Drugim riječima, ta se poduzeća novčanim tokom koriste za projekte koje nisu mogla financirati zbog financijskog ograničenja. Nezadužena će poduzeća imati vrlo malu ili nultu osjetljivost (koeficijent uz novčane tokove) jer ona ionako mogu financirati projekte novim kreditom, pa im nova novčana sredstva nisu bitan faktor za odluke o investicijama. Jedan od osnovnih razloga potonjeg ponašanja investicija čini različita financijska hijerarhija izvora financiranja: interna su sredstva jeftinija od eksternih izvora financiranja (duga i kapitala) jer se ne zahtijeva plaćanje rizične premije. Zato bi dostupnost likvidnih sredstava (novca) trebala utjecati na investicije iznad q-a. Drukčije rečeno, dostupnost izvanjskog financiranja zbog veće neto vrijednosti pozitivno utječe na investicijsku aktivnost. To je suprotno standardnoj neoklasičnoj teoriji investicija koja pretpostavlja savršena tržišta kapitala, a prema kojoj fluktuacije u novčanim tokovima za različit stupanj zaduženosti ne bi trebale utjecati na investicije.

Hubbard (1998) i Stein (2003) daju pregled mnogih radova koji su nakon FHP (1988) empirijski testirali utjecaj novčanih tokova na investicije. Provedeno je mnogo takvih testova i može se zaključiti da regresiranje investicija na Tobinov q i novčane tokove tipično rezultira malim

[3] Ovdje i u nastavku rada osjetljivost investicija na novčane tokove označava razinu koeficijenta uz novčane tokove u investicijskoj jednadžbi.

pozitivnim koeficijentom uz q i signifikantnim pozitivnim koeficijentom uz novčane tokove. Mali koeficijent uz q obično se objašnjava velikim konveksnim troškovima prilagođavanja, a veliki koeficijent uz novčane tokove za različite razine zaduženosti uzima se kao dokaz postojanja financijskog ograničenja tvrtki.

Slijedeći potonja istraživanja, prvi dio rada je usmjeren na procjenu osjetljivosti investicija na novčane tokove kako bi se testirala hipoteza o postojanju financijskog ograničenja poduzeća. Pri tome se pokušava minimizirati probleme koji se pojavljuju u prijašnjim istraživanjima upotrebom primjerene ekonometrijske metode, uzorka, specifikacije modela i korištenjem novom potražnom varijablom. U skladu s dosadašnjim istraživanjima, očekuje se pozitivna, monotono rastuća osjetljivost investicija na novčane tokove kao funkcija rasta zaduženosti. Povećanjem stupnja zaduženosti raste i osjetljivost investicija na novčane tokove, jer poduzeća, zbog vezanog budžetskog ograničenja, mogu investirati samo stvaranjem novčanog toka (iz internih izvora). Iz svega navedenog proizlazi prva hipoteza koja glasi:

H1: Dinamika investicijske aktivnosti poslovnih subjekata u Republici Hrvatskoj ukazuje na postojanje financijskog ograničenja što potvrđuje postojanje tržišnih nesavršenosti (frikcija) na tržištima kapitala.

Drugi dio empirijskog dijela rada odnosi se na procjenu likvidnog ograničenja. U teorijskim se radovima problem likvidnosti najčešće proučava unutar modela potražnje za likvidnošću ili optimalna upravljanja novčanim sredstvima (Tirole, 2011; Bolton, Cheng i Wang, 2011; Villeneuve i Warin, 2014). Poduzeća se mogu štititi od budućih rizika gomilanjem likvidnosti, što je *ex ante* njihov trošak. S druge strane, osiguranje likvidnosti pošto je nastupio šok likvidnosti može biti otežano jer se sužava ponuda kredita. Stoga bi poduzeće trebalo uspostaviti primjerenu razinu likvidnosti uvažavajući troškove nelikvidnosti i troškove likvidnosti. Stupanj likvidnosti kao značajka financijske situacije stoga utječe na investicijsku aktivnost poduzeća. Pri tome je važno istaknuti da postoji heterogenost u smislu nesavršenosti proizišlih iz likvidnog i financijskog ograničenja. Nelikvidna bi se poduzeća (likvidno ograničena) trebala drukčije ponašati (osjetljivost investicija na novčane tokove) od financijski ograničenih (prezaduženih) poduzeća (Cleary, Povel i Raith, 2007; Guariglia, 2007). Očekuje se nelinearan odnos investicija i novčanih tokovova. Nelikvidna bi poduzeća trebala pokazivati nulti ili negativan utjecaj novčanih tokova na investicije jer poduzeća novi novčani tok neće upotrebljavati za investicije, nego za uspostavljenje primjerene likvidnosti. Poduzeća koja su na granici likvidnosti ili likvidna pokazivat će pozitivne koeficijente uz novčane tokove.

Drugim riječima, riječ je o poduzećima koja nova novčana sredstva (nakon isplate dobiti) mogu upotrijebiti za nove investicije. Nakon određene, visoke likvidnosti osjetljivost se opet smanjuje jer poduzeća već ionako trpe previsoke troškove likvidnosti. Druga hipoteza glasi:

H2: Kretanje investicija poslovnih subjekata u Republici Hrvatskoj sadržajno je heterogeno u smislu tržišnih nesavršenosti (frikcija) proizišlih iz likvidnog i financijskog ograničenja kao čimbenika investicijske aktivnosti.

Stupanj financijskog ograničenja ovisi o raznim čimbenicima. Tirole (2006) ističe kako se glavni čimbenici odnose na iznos neto vrijednosti poduzeća, veličinu privatne koristi koju može uživati investitor ako „iskorištava“ (engl. *missbehave*), mogućnost smanjenja privatne koristi tehnologijama nadzora te ugled poduzeća. Poduzeća se razlikuju s obzirom na spomenute dimenzije, pa se za određene grupe njih može očekivati manji stupanj financijskog i likvidnog ograničenja. U radu je posebna pozornost obraćena poduzećima u većinskom javnom ili stranom vlasništvu. Za ove se dvije grupe očekuje konstantna neosjetljivost investicija na novčane tokove kao funkcija pokazatelja zaduženosti i likvidnosti. Politički utjecaji i priljev kapitala od društva majki u inozemstvu omogućuju ovim poduzećima fleksibilnost u financiranju željenih projekata. Treća hipoteza glasi:

H3. Postojanje heterogenosti u stupnju financijskog i likvidnog ograničenja poslovnih subjekata u Republici Hrvatskoj uvjetovano je i udjelom javnog vlasništva i stranog kapitala u poslovnim subjektima u RH.

Glavni prigovor analizi financijskog ograničenja mjerenjem osjetljivosti investicija na novčane tokove odnosi se na problem endogenosti (Kaplan i Zingales, 1997; Erickson i Whited, 2000; Gomes 2001; Alti 2003; Cleary, Povel i Raith 2007). Novčani tokovi vrlo vjerojatno snažno koreliraju s budućom profitabilnošću. Dapače, potonji su radovi primjenom strukturnog ekonometrijskog modela pokazali da osjetljivost investicija na novčane tokove raste s rastom financijskog ograničenja. Dodatno, financijske su frikcije samo jedan od brojnih faktora koji utječu na osjetljivost investicija na novčane tokove.

Rješenje za problem endogenosti implicira pronalaženje šoka na neto vrijednost (novčane tokove) koji je egzogen na investicijske prilike. Drugim riječima, ključ je identificirati šok koji utječe na neto vrijednost, ali ne i na potražnju tvrtke za kreditima, kako bi se ispitao utjecaj ponude kredita na investicije. U kontekstu regresijske jednadžbe investicija velik dio literature usmjerio se na pronalaženje savršena egzogenog instrumenta za novčane tokove. Ova grupa

radova metodološki pripada kategoriji kvaziprirodnih eksperimenata (engl. *quasi-Natural experiments*), a glavni im je cilj izoliranje šoka na tvrtkinu financijsku poziciju koji je nekoreliran s investicijskim prilikama kako bi se procijenio efekt tretmana na investicijsko ponašanje poduzeća.

Autori su se koristili različitim egzogenim šokovima na neto vrijednost. Calomiris i Hubbard (1995) su kao šok upotrijebili promjenu porezne politike vlade SAD-a 1935. godine. Blanchard, Lopez-de-Silanes i Schleifer (1994) su kao instrument novčanih tokova upotrijebili novac zarađen nepredviđenim pozitivnim ishodima u sudskim sporovima. Lamont (1997) je analizirao investicije naftnih i nenaftnih sektora istog poduzeća nakon naftnog šoka 1986. godine (pad cijena nafte od 50 %). Rauh (2006) je proučavao tvrtke koje imaju obvezu uplate sredstava u mirovinski fond radi ispunjenja obveza po mirovinskim planovima zaposlenika, kada je imovina mirovinskog fonda veća od obveza. Almeida i ostali (2012) proučavali su utjecaj šoka ponude eksternog financiranja u kolovozu 2007. godine na investicije poduzeća. Lemmon i Roberts (2007) procjenjivali su utjecaj promjena u ponudi kapitala na financijsku i investicijsku politiku poduzeća koristeći se trima odvojenim egzogenim šokovima na ponudu kredita u 1989. godini (propast Drexel Burnham Lambert, Inc, prihvaćanje Zakona o reformi financijskih institucija, restrukturiranju i prisilnoj naplati (FIRREA) te promjenom u smjernicama o kreditnom rejtingu Nacionalne udruge osiguravajućih društava).

U ovom se doktorskom radu kao egzogeni šok poboljšanja financijske situacije poduzeća upotrebljava instrument predstečajne nagodbe. U Hrvatskoj je 2012. godine donesen Zakon o financijskom poslovanju i predstečajnoj nagodbi koji omogućuje djelomičan oprost i refinanciranje dugova. Tako se može ispitati razlika u ponašanju dviju grupa poduzeća – onih koja su popravila financijsku situaciju postupkom predstečajne nagodbe i sličnih poduzeća koja nisu pokrenula postupak predstečajne nagodbe. Glavni je fokus na međuovisnosti pada zaduženja, odnosno poboljšanja financijske i likvidne situacije poduzeća i investicija. U radu se pretpostavlja da primjena instrumenta neće povećavati investicije tretiranih poduzeća u odnosu prema onima iz testne grupe zbog nemonotona odnosa novčanih tokova i investicija za različite režime zaduženja i stanja likvidnosti: *uz danu razinu stope novčanih tokova* tvrtke koje iz stanja nelikvidnosti i prezaduženosti prijeđu u stanje granične likvidnosti, ne povećavaju investicije, ceteris paribus.

H4: Oprost i odgoda dugova zbog uspješno sklopljene predstečajne nagodbe ne utječu na ublažavanje posljedica tržišnih nesavršenosti (frikcija), odnosno na relativno povećanje investicijske aktivnosti poslovnih subjekata koji sudjeluju u predstečajnim nagodbama.

1.4 Metode istraživanja

U pregledu literature koristit će se uobičajenim metodama analize, sinteze, apstrakcije, konkretizacije i deskripcije kako bi se dobila spoznaja o problemu istraživanja i prikazale dosadašnje spoznaje ekonomske teorije i empirije. Ipak, u testiranju hipoteza u doktorskom će se radu primjenjivati pretežito kvantitativne istraživačke metode. To su metode deskriptivne statistike kojom će se opisivati vremenske serije ključnih varijabli, kako na agregatnoj, tako i na mikrorazini, ali i struktura varijabli radi dobivanja uvida u udjele pojedinih sastavnica. Također, koristit će se složenijim linearnim i nelinearnim ekonometrijskim metodama kako bi se pokušala identificirati kauzalna povezanost između varijabli od interesa.

Za dokazivanje prvih triju hipoteza upotrijebit će se *threshold* regresija prema Hansen (1999) i Hansen (2000) i metoda panel-fiksnih efekata (Cameron i Triviedi, 2009; Hsiao, 2014). Metoda *threshold* regresije primjenjuje se kada različiti poduzorci ukupnog uzorka mogu pokazivati različite procijenjene koeficijente. Primjerice, različita veličina tvrtke može upozoravati na različite osjetljivosti investicija na novčane tokove. *Threshold* regresija nastoji identificirati granicu koja dijeli uzorak. Tako se uvodi dodatna dimenzija u objašnjavanju heterogenosti. Klasični modeli s fiksnim efektima odražavaju samo heterogenost u odsječcima (engl. *intercept*), a *threshold* regresija proširuje i za promjenu u parametrima za različite vrijednosti *threshold* varijable. Threshold regresija kao metoda je adekvatna za procjenu financijske ograničenosti iz dva razloga. Prvi je što omogućuje izbor kriterija i granica za svaki kriterij na temelju podataka (engl. *data-driven approach*). Drugo, svrstavanje poduzeća u određene režime nije fiksno, već se omogućuje prelazak iz jednog režima u drugi.

Ukratko, *threshold* regresija omogućuje endogeno grupiranje poduzeća na financijski ograničena i neograničena prema određenim financijskim kriterijima *(threshold* varijablama). Ako se pokaže da granice postoje, metoda omogućuje procjenu regresijskih koeficijenata uz novčane tokove za svaki režim, što u konačnici omogućuje testiranje prethodno opisanih triju hipoteza.

Metoda *threshold* regresije zahtijeva balansirani uzorak (Hansen 1999, str. 347) što može uzrokovati problem pristranosti preživljavanja. Stoga će se u analizi robusnosti prvih triju hipoteza, uz threshold regresiju koja zahtijeva korištenje balansiranim panelom, koristiti i uobičajenom metodom panel-fiksnih efekata, koja ne zahtijeva balansirani panel. Metoda panel-fiksnih efekta sadržavat će efekte tvrtki i efekte vremena, odnosno panel-model promjenjiva odsječka s fiksnim efektima.

Za dokazivanje četvrte hipoteze poslužit će metoda efekta tretmana u kojoj je cilj procijeniti kauzalni efekt binarne varijable na varijablu ishoda (Roberts i Whited, 2013). Binarna varijabla ima vrijednost 1, ako je primljen tretman, odnosno 0, ako nije primljen. Poduzeća na koja je primijenjen tretman tretirana su grupa, a poduzeća koja nisu primila tretman kontrolna su grupa. Vrijednost varijable ishoda ovisi o tome je li tvrtka primila tretman. Efekt tretmana razlika je očekivane vrijednosti ishoda. Važno je napomenuti da jednostavna usporedba prosjeka tretirane i kontrolne grupe ne odgovara efektu tretmana zbog pristranosti izbora (engl. *selection bias*). Pristranost izbora odražava mogućnost povezanosti tretmana i ishoda. Upravo je mogućnost povezanosti tretmana i mogućih ishoda glavni problem procjene kauzalnog efekta binarne varijable.

Problem pristranosti izbora može se riješiti na različite načine. Najjednostavnije rješenje uključuje slučajnu primjenu tretmana na pojedina poduzeća. Međutim, u praksi, posebice u primjeni ekonomskih politika, takvo je rješenje neprimjenjivo. U doktorskom se radu stoga za procjenu efekta tretmana upotrebljava procjenitelj *difference-in-differences* (DD). Metoda DD sadržava tretmansku i vremensku varijablu. Tertmanska bi varijabla trebala kontrolirati permanentne (vremenski invarijantne) razlike između kontrolne i tretirane grupe, a vremenska bi varijabla trebala kontrolirati trendove zajedničke tretiranoj i kontrolnoj grupi. Preostala varijacija odražava učinak tretmana (DD procjenu).

Za identificiranje kontrolne grupe u radu se primjenjuje metoda uparivanja (engl. *matching method*) prema Abadie i Imbens (2002). Metoda uparivanja svodi se na identificiranje subjekta u kontrolnoj grupi sličnih subjektima u tretiranoj grupi. Ishodi sličnih subjekata poslije tretmana aproksimiraju protučinjenične ishode (engl. *contrafactual outcomes*) subjekata iz tretirane grupe. Primjerice, ako se želi procijeniti utjecaj tretmana na investicije, prvo se među poduzećima koja nisu primila tretman pronalaze ona koja su po određenim karakteristikama (kovarijablama) slična poduzećima koja su ga primila. Razlika između investicija ovih dviju grupa, u razdoblju nakon tretmana, označava efekt tretmana. Procjenitelj se uparivanja može

koristiti u prostornim i panel-podacima. U panel-podacima je riječ o DD procjenitelju uparivanja (engl. *difference-in-defferences matching estimator*). Zaključno, za svaku varijablu treba pronaći najbolji par i usporediti opažene vrijednosti s procijenjenim prosječnim vrijednostima para.

Primarni je izvor podataka repozitorij računovodstveno-financijskih izvještaja Financijske agencije te dodatnih podataka financijskih izvještaja (obrazac POD-DOP), koji prikuplja Državni zavod za statistiku. Podaci se odnose na sve pozicije iz računovodstveno-financijskih izvještaja (bilanca, račun dobiti i gubitka, procijenjeni izvještaj o novčanom toku) od 2000. do 2014. godine. Uzorak sadržava ukupno oko 1,5 milijuna financijskih izvještaja. Primjena *threshold* regresije i panel-fiksnih efekata podrazumijeva različite postupke, pa će i konačan uzorak ovisiti o izboru sektora, načinu eliminiranja ekstremnih vrijednosti i izboru balansiranog ili nebalansiranog uzorka.

U radu će se upotrijebiti još dva izvora podataka. U deskriptivnoj će se analizi upotrijebiti agregatni podaci o investicijskoj i kreditnoj aktivnosti iz baze podataka Eurostata. Za analizu posljednje hipoteze, uz podatke iz financijskog izvještaja, koristit će se podacima o pokrenutim i sklopljenim predstečajnim nagodbama. Ova baza podataka uključuje 1.319 poslovnih subjekata koji su uspješno sklopili predstečajnu nagodbu sa svojim vjerovnicima od 23. travnja 2013. do 1.rujna 2014.

1.5 Očekivani znanstveni doprinos

Najveći doprinos ovog rada očituje se u razgraničavanju financijskog i likvidnog ograničenja poduzeća. Prema autorovoj spoznaji, ne postoji rad koji je primjenom *threshold* regresije ispitivao različito ponašanje likvidnog i financijskog ograničenja za velika, srednja i mala poduzeća. Izuzetak je rad Cleary, Povel, Rait (2007), koji uvodi sličnu, ali ipak različitu distinkciju internog i eksternog ograničenja.

Očekivani znanstveni doprinos sastoji se u kombinaciji različitih segmenata istraživanja, koji su primjenjivani u prijašnjim radovima. Prvo, istraživanje je provedeno nad uzorkom svih tvrtki u RH (mala, srednja i velika poduzeća), a glavnina se istraživanja, uz rijetke izuzetke, temeljila na uzorku velikih tvrtki koje posluju na organiziranim tržištima kapitala. Drugo, primjenjuje se metoda *threshold* regresije, koja omogućuje svrstavanje poduzeća u različite režime prema

određenim kriterijima, a u većini su se drugih radova u razvrstavanju poduzeća primjenjivali apriorni kriterije i linearne regresijske tehnike. Treće, u analizi se upotrebljava skup više bilančnih varijabli kako bi se usporedili rezultati svake pojedine specifikacije modela. Prema dosadašnjem opisu, rad je po svojem sadržaju i strukturi najsličniji radu u nastajanju Tarrasowa (2015). Ipak, najveći se doprinos očituje u razgraničavanju financijskog i likvidnog ograničenja poduzeća kao značajki financijskih frikcija, što je prema autorovim spoznajama, prvi takav pokušaj u empirijskoj literaturi koja se bavi ovom problematikom. U prijašnjim se radovima o testiranju financijskog ograničenja između ovih dvaju pojmova stavlja znak jednakosti. Likvidno je ograničenje jednostavno drugi naziv za financijsko ograničenje. Prema autorovoj spoznaji, prvi rad u kojem se uvodi slična distinkcija onaj je Cleary, Povel, Raith (2007). Autori razlikuju interno i eksterno financijsko ograničenje. Međutim, teorijsko se objašnjenje ove distinkcije razlikuje od objašnjenja pružena u ovom radu. Također, autori su svoju teorijsku hipotezu testirali pomoću linearnih regresijskih metoda koristeći se različitim bilančnim varijablama. Ukratko, prema autorovoj spoznaji, ne postoji rad koji je primjenom *threshold* regresije ispitivao različito ponašanje likvidnog i financijskog ograničenja za velika, srednja i mala poduzeća. Prema autorovoj spoznaji također se prvi put na ovaj način ispituje monotonost osjetljivosti investicija na novčane tokove za različit stupanj likvidnosti i zaduženosti poduzeća. Valja napomenuti da su za Hrvatsku pitanja postavljena u ovom pasusu posve neistražena.

Ovo će istraživanje popuniti i određenu prazninu u postojećoj literaturi o odrednicama investicija. U ovom se radu prvi put u investicijsku jednadžbu uvrštava pokazatelj stope nove dodane vrijednosti kao aproksimacija agregatne potražnje u poduzeću te se pokazuje da dodavanje ove varijable utječe na razinu procijenjenih parametara u modelu. Do sada se ona aproksimirala veličinom ukupnih prihoda. U radu se također pruža detaljna deskriptivna analiza o morfologiji i strukturi investicija u RH, pri čemu se koristilo gotovo svim poduzećima u RH, što je, koliko autor zna, prvi pokušaj da se raščlani narav investicija u dugom razdoblju u RH služeći se mikropodacima iz računovodstveno-financijskih izvještaja i ostalih javno dostupnih izvora.

U drugom dijelu empirijske analize uvodi se novi tretman kao pozitivan šok na financijsku situaciju, a koji je ortogonalan na investicijske prilike – Zakon o financijskom poslovanju i predstečajnoj nagodbi. Ispitivanjem međuovisnosti financijske situacije i investicija primjenom efekta tretmana (sklapanjem nagodbe) posredno se analizira ispunjenje aplikativnih ciljeva Zakona. Prema autorovoj spoznaji, u ovom se radu prvi put istražuje utjecaj predstečajnih nagodbi na investicije poduzeća primjenom efekta tretmana. Tomu je uz ostalo tako što Zakon

o financijskom poslovanju i predstečajnoj nagodbi, u malo drukčijem obliku, postoji u tek nekoliko zemalja. Osim uspostavljanja likvidnosti i solventnosti dužnika, konačan učinak Zakona trebao bi se očitovati u „ponovnom pokretanju održive poslovne aktivnosti i čuvanja zaposlenosti“ (Hrvatski sabor, 2013). Doprinos je ovog rada upravo u rasvjetljavanju utjecaja Zakona o financijskom poslovanju i predstečajnoj nagodbi na investicije poduzeća i zaposlenost.

Istraživanje ima dodatne doprinose u obliku preporuka nositeljima ekonomskih politika. Moći će se ustanoviti koliko djelomičan oprost i odgoda dugova utječu na investicije i zaposlenost. Nositelji politika mogu steći spoznaju o postojanju financijskog i likvidnog ograničenja poduzeća u RH tijekom duljeg razdoblja. Odgovora se na pitanje jesu li poduzeća financijski ograničena i koliko je to važno za odluke o poticanju investicija. Akumulacija kapitala ključan je element konvergencije i rasta gospodarstva, pa je za ekonomsku politiku vrlo važno razumjeti koliko financijske frikcije utječu na stvaranje kapitala. Može se procijeniti utjecaj politika usmjerenih na lakši pristup financiranju ili zakona koji utječu na platnu disciplinu na ponašanje investicija.

Razjašnjavanje utjecaja financijskih i potražnih faktora na investicije pridonijet će ekonomskoj znanosti boljim razumijevanjem ponašanja investicija i potencijalnih ekonomskih ranjivosti vezanih uza šokove na neto vrijednost poduzeća. Također, sposobnost identificiranja odrednica investicija poslužit će kao pomoć nositeljima ekonomskih politika u Republici Hrvatskoj pri osmišljavanju politike poticanja investicijske aktivnosti.

1.6 Struktura disertacije

U nastavku se opisuje sadržaj doktorskog rada. Na početku drugog poglavlja pruža se motivacija za izučavanje financijskog i likvidnog ograničenja kao predmeta istraživanja. Prvo se deskriptivnom statistikom upozorava na važnost ponašanja investicija za agregatnu ekonomsku aktivnost te se pruža komparativan pregled investicijske aktivnosti za članice Europske unije. Potom se opisuje kreditna aktivnost banaka u pretkriznom i kriznom razdoblju, s naglaskom na odnos kreditne i investicijske aktivnosti, kako bi se dobila početna predodžba o međuovisnosti realne (investicijske) i financijske (kreditne) aktivnosti. Na kraju se prikazuju ključni nalazi empirijskih radova o međuovisnosti financijske i realne ekonomije, s naglaskom na investicijski kanal financijskih frikcija. Nakon dobivanja uvida o dinamici investicijske i

kreditne aktivnosti, od poglavlja 2.2. do kraja drugog poglavlja pruža se pregled teorijskih radova o ponašanju investicija u modelima bez financijskih frikcija te modelima racioniranja kredita i preventivne potražnje za likvidnošću. Prvo se izvodi standardna neoklasična investicijska jednadžba te se objašnjavaju determinante ponašanja investicija prema neoklasičnoj paradigmi. Potom se neoklasičnoj teoriji dodaju troškovi prilagođavanja (potpoglavlje 2.2.3.) te nesigurnost glede novčanih tokova (potpoglavlja 2.2.4. i 2.2.5.). Potpoglavlje 2.2.6. prikazuje osnovne nalaze Modigliani-Millerove teorije strukture kapitala. U poglavlju 2.3.prikazani su modeli racioniranja kredita i financijskog ograničenja kao posljedice postojanja moralnog hazarda ili troškova verifikacije stanja na tržištu kapitala te se posebno analizira utjecaj prezaduženosti na investicije. U poglavlju 2.4. opisuju se modeli koji objašnjavaju odnos likvidnosti (potražnje za likvidnošću) i investicija te se uvodi razlikovanje likvidnog i kreditnog (financijskog) ograničenja. U petom dijelu drugog poglavlja prikazuju se makroekonomski modeli koji u sebi integriraju principal-agent odnose. Riječ je o makroekonomskim modelima s financijskim frikcijama, koji nastoje objasniti amplifikaciju i perzistentnost poslovnih ciklusa. U potpoglavlju 2.5.1. daje se kratak pregled povijesnih radova o međuovisnosti financijskih varijabli i poslovnih ciklusa. U potpoglavlju 2.5.2. pozornost se obraća tvrtkinu kanalu financijskih frikcija, a u potpoglavlju 2.5.3. prikazuju se modeli koji izravno uključuju bankarski sektor.

Poslije teorijskog pregleda, u trećem je poglavlju pružen pregled empirijske literature. Prvo se prikazuju radovi koji su financijsko ograničenje testirali osjetljivošću investicija na novčane tokove za različite, najčešće apriorno određene, grupe poduzeća. Detaljno se analizira empirijski oblik ove grupe istraživanja te se navode problemi takva pristupa. Potom se prikazuju empirijski radovi koji su primjenom efekta tretmana nastojali prebroditi osnovne nedostatke prve grupe istraživanja: problem endogenosti novčanih tokova i pogreške u mjerenju q-a. Ovi se radovi razlikuju s obzirom na način mjerenja efekta tretmana i izbora egzogenog šoka na ponudu kapitala banke ili neto vrijednosti poduzeća. U poglavlju 3.4. prikazuju se i ostali, rjeđe primjenjivani metodološki pristupi testiranja financijskog ograničenja poput anketiranja menadžera poduzeća, strukturnih ekonometrijskih modela te kolateralnoga kanala. Poslije pregleda radova o financijskom ograničenju u poglavlju 3.5. osobita je pozornost obraćena odnosu likvidnosti i investicija, koji je u empirijskoj literaturi manje zastupljen. Objašnjavaju se empirijski pristupi za razgraničavanje financijskog i likvidnog ograničenja. Na kraju četvrtog poglavlja pruža se prikaz empirijskih radova o bankarskom kanalu financijskih frikcija. Objašnjava se kako šok na kapital banke može uzrokovati kontrakcije u ponudi kredita.

Nakon pregleda teorijskih i empirijskih radova slijedi pregled mikropodataka kojima se koristi u doktorskom radu. To znači definiranje uzorka i varijabli kojima se koristi u analizi. Potom se primjenjuju metode deskriptivne analize nad definiranim uzorkom kako bi se opisalo ponašanje investicija te međuovisnost investicija i financijskih varijabli. Poglavlje 4.2. opisuje ključne agregatne i rezidualne indikatore poslovanja poduzeća te morfologiju i strukturu investicija u Republici Hrvatskoj. Poglavlje 4.3. proučava financijsku strukturu poslovnih subjekata, izvore financiranja investicija i međuovisnost financijske situacije i investicijske aktivnosti. Poglavlje 4.4. analizira likvidnu poziciju poduzeća i odnos obrtnih sredstava i investicija.

Poglavlja 5. i 6. najvažniji su dio istraživanja Peto poglavlje započinje iznošenjem metodološkog okvira *threshold* regresije te se objašnjava zašto je upravo ta metoda odabrana u istraživanju financijskog ograničenja poduzeća. U poglavljima 5.2., 5.3. i 5.4. objašnjava se odabir varijabli u modelu, navode izvori podataka, pripremaju se za kvantitativnu analizu te se iznose ograničenja modela. U poglavlju 5.5. prikazuju se rezultati istraživanja o jačini i smjeru povezanosti investicija i novčanih tokova za različite, endogeno utvrđene grupe poduzeća, pri čemu *threshold* varijable čine pokazatelji likvidnosti i pokazatelji financiranja. Posebno se testira financijsko i likvidno ograničenje za poduzeća u većinskom javnom i stranom vlasništvu. Na kraju šestog poglavlja analizira se robusnost kako bi se testirala osjetljivost rezultata na izbor pojedinih nezavisnih varijabli, ekonometrijskog modela i strukture uzorka.

Šesto poglavlje ima sličnu strukturu kao i peto poglavlje. Prvo se iznosi metodološki okvir efekta tretmana, *difference-in-differences* procjenitelja i metode uparivanja (engl. *matching method*). Potom se upoznaje sa Zakonom o financijskom poslovanju i predstečajnoj nagodbi kao egzogenim tretmanom. U poglavljima 6.3. i 6.4. opisuju se podaci te sadržaj tretmanske i kontrolne grupe. U poglavlju 6.5 izlažu se rezultati analize s komentarom dobivenih rezultata te analiziraju njihove posljedice sa znanstvenog i provedbenog aspekta.

U sedmom, posljednjem, poglavlju sistematiziraju se najvažniji zaključci proizišli kao rezultat teorijske i empirijske analize, razmatra se jesu li i koliko ostvareni postavljeni istraživački ciljevi te se iznose završna razmatranja i preporuke za buduća istraživanja.

2 ZNAČAJKE INVESTICIJSKOGA KANALA FINANCIJSKIH FRIKCIJA U MODELIMA RACIONIRANJA KREDITA I PREVENTIVNE POTRAŽNJE ZA LIKVIDNOŠĆU

2.1 Dinamika investicijskih i kreditnih tokova u Republici Hrvatskoj i Europskoj uniji

Osnovni je cilj ovog poglavlja pružanje motivacije za izbor investicija, odnosno investicijskog kanala financijskih frikcija kao objekta istraživanja. Prvo se pruža deskriptivna analiza agregatne investicijske aktivnosti u RH i EU. Potom se opisuje kreditna aktivnost banaka u pretkriznom i kriznom razdoblju s naglaskom na odnos kreditne i investicijske aktivnosti, kako bi se dobila početna predodžba o međuovisnosti realne (investicijske) i financijske (kreditne) aktivnosti. Na kraju se prikazuju ključni nalazi empirijskih radova o međuovisnosti financijske i realne ekonomije s naglaskom na investicijski kanal financijskih frikcija.

2.1.1 Komparativna analiza dinamike investicija u Hrvatskoj i Europskoj uniji

U ovom se poglavlju pruža početna deskriptivna analiza ključnih agregatnih varijabli. Cilj je stvoriti početan uvid o ponašanju investicija i ostalih varijabli agregatne potražnje od 2000. do 2015. Analiza strukture agregatne potražnje može indicirati važnost pojedine komponente u razumijevanju rasta ekonomske aktivnosti prije krize i kontrakcije (stagnacije) poslije nje. Primjerice, Mian i Atif (2014) su u knjizi „Kuća od dugova“ kao ključnu varijablu za razumijevanje krize u SAD-u istaknuli korelaciju zaduženosti kućanstava s negativnim bogatstvom (zbog rasta kreditne ponude) i smanjenja njihove potrošnje. Visoka zaduženost kućanstava uzrokovala je snažan pad agregatne osobne potrošnje i ekonomske aktivnosti. Dakle, ključna je varijabla pad osobne potrošnje, odnosno potrošni kanal financijskih frikcija. Kako bi se utjecaj osobne potrošnje i ostalih komponenti analizirao na primjeru Hrvatske, primjereno je na početku analizirati kretanje komponenti bruto domaćeg proizvoda da bi se dobila predodžba o dinamici potrošnje, investicija i ostalih komponenti bruto domaćeg proizvoda.

Slika 2-1 opisuje vremenska kretanja pojedine komponente BDP-a u postotku od agregatnog BDP-a. Dok su osobna i državna potrošnja, kao omjer BDP-a, relativno stabilni u cijelom razdoblju, investicije pokazuju značajnu volatilnost. Od 2000. do 2008. godine rasle su s 18 % na čak 30 % BDP-a, a u samo jednoj godini pale su na 24 % BDP-a. Pad je nastavljen i nakon

Velike recesije, pa su se 2014. godine investicije vratile na razine BDP-a na kojima su bile 2000. godine. Riječ je o velikim fluktuacijama investicija. Zanimljivo je da neto izvoz i ukupne investicije izgledaju kao zrcalne funkcije u odnosu prema horizontalnoj osi. Može se reći da je rast investicija bio financiran priljevom inozemnog viška štednje. To potvrđuju i podaci HNB-a, prema kojima poduzeća tijekom cijeloga pretkriznog razdoblja imaju rast inozemnog zaduživanja u postotku od BDP-a (HNB, 2015). Dugovi nefinancijskog sektora rastu s 38 % BDP-a 2001. godine na 81,3 % BDP-a 2010. godine. Međutim nakon 2010. godine poduzeća se razdužuju i na stranom i na domaćem tržištu, pa u prvom tromjesečju 2016. godine ukupan je dug 72% BDP-a. Iz slike se izvodi jednostavan zaključak. Za ekonomsku (financijsku) krizu u Hrvatskoj presudno je objasniti šokove investicija. Potrebno je objasniti poremećaje koji utječu na transformaciju domaće i strane štednje u budući kapital. S druge strane, državna i osobna potrošnja imaju stabilan udio u BDP-u. Naravno, moguće je da apsolutne promjene osobne i državne potrošnje znatno utječu na relativnu promjenjivost investicija. Upravo je utvrđivanje smjera kauzalnosti utjecaja između agregatne potražnje i investicija jedan od glavnih ciljeva empirijskih radova o investicijskoj dinamici.

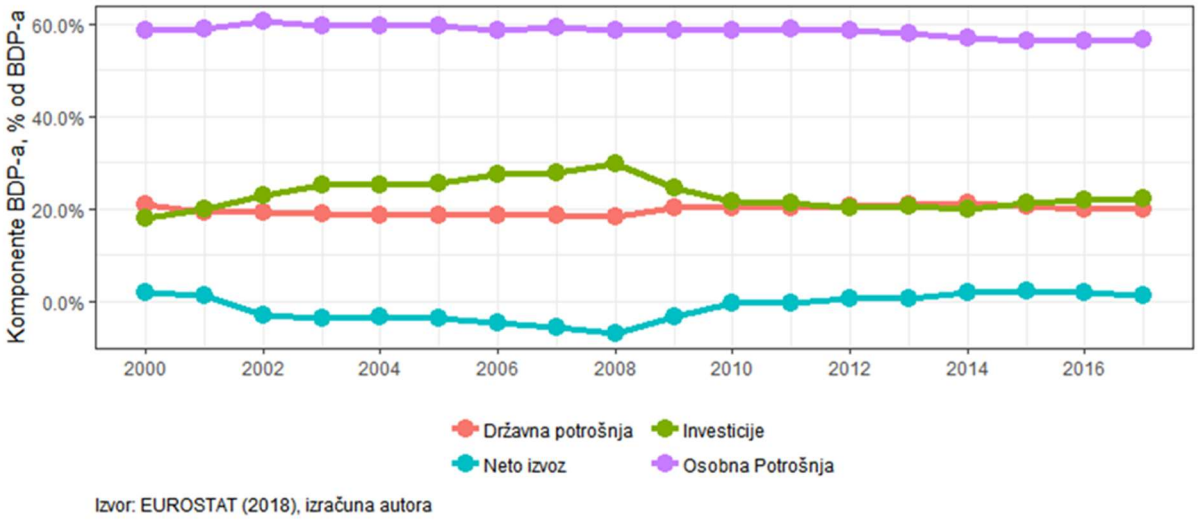

Slika 2-1: Osobna potrošnja, državna potrošnja, investicije i neto izvoz od 2000. do 2017. u postotku od agregiranog BDP-a; cjenovni indeks 2010 =100.

Na slici 2-2 prikazana je dinamika bruto kapitalne formacije u 28 zemalja EU od 1995. do 2017, u cijenama 2010. godine. Crvena krivulja prikazuje pretkrizni trend, od prvog tromjesečja 1995. godine do drugog tromjesečja 2008. godine. Jaz između dviju krivulja nakon Velike recesije gubitak je investicija u EU. Izvještaj ECB-a (2013) navodi da je gubitak investicija u vrijeme kontrakcijske faze u EU iznosio 14 %, pri čemu se on mjeri kao razlika između stvarne razine investicija i razine investicija koja bi bila postignuta da je nastavljen pretkrizni trend.

Takva situacija s investicijama osporava opravdanost cijele skupine modela koji pretpostavljaju vraćanje investicija i ostalih komponenti agregatne potražnje na prethodni trend rasta. Ne samo da se nisu vratile na pretkrizni *trend* rasta nego u investicijama nisu ostvarene ni prijašnje *stope* rasta (vratile su se na trend usporedan s prijašnjim). Ukratko, iz slike je jasno vidljivo da investicije stagniraju nakon recesije. Ne samo da se ne pokazuju znakovi vraćanja na prijašnju putanju rasta nego nisu postignute ni stope rasta iz pretkriznog razdoblja.

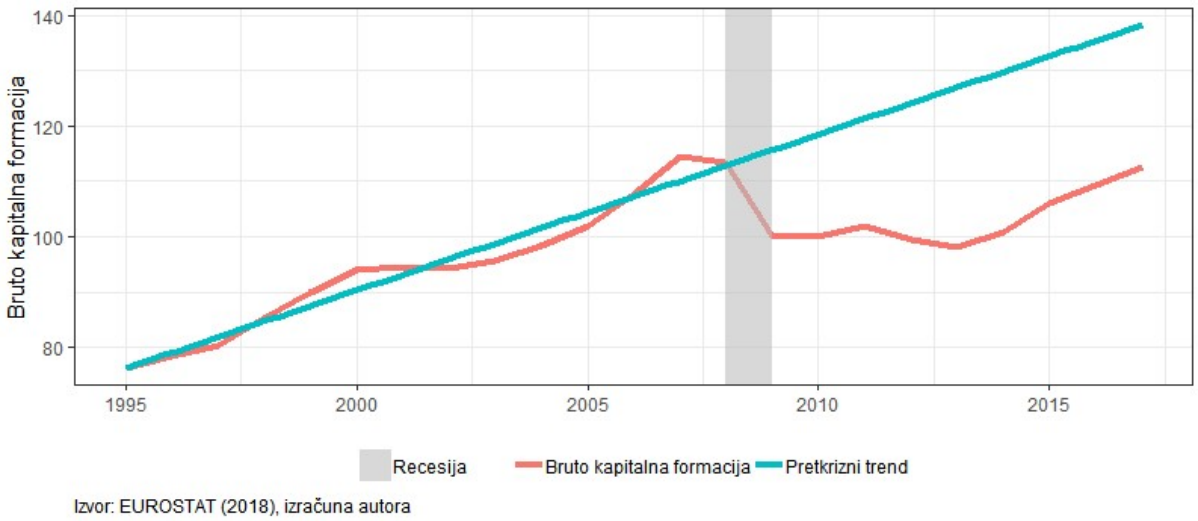

Slika 2-2: Bruto kapitalna formacija na razini EU 28 od 1995. do 2017; cjenovni indeks 2010 = 100

Spori oporavak investicija zabilježen je i u drugim razvijenim zemljama. Investicije su u njima imale manje stope rasta u usporedbi sa zemljama u razvoju (MMF, 2015). Razvijene zemlje bilježe negativan trend rasta čak i prije financijske krize (Morkunaite i Huefner, 2014). Smanjuju se sve vrste investicija: stambene investicije, državne investicije i investicije poduzeća. Spor oporavak investicija iznenađuje i zato što su se financijske performanse u poduzećima u razvijenim zemljama znatno oporavile od 2012. do 2014. To se posebno odnosi na rast štednje (operativnoga novčanog toka) poduzeća. Primjerice, u SAD-u je štednja kompanija rasla s 8 % na 10 % BDP-a (Morkunaite i Huefner, 2014). Neto zaduživanje poduzeća kao postotak BDP-a bilježi pozitivne vrijednosti i iznad je prosjeka prošlog desetljeća (Morkunaite i Huefner, 2014). Rast štednje i novčanih sredstava uz istodobnu stagnaciju investicija označuje fenomen gomilanja likvidnosti, koji je također važan segment proučavanja u ovom radu jer odražava odnos likvidne i investicijske aktivnosti poduzeća.

U tablici 2-1 iskustvo Hrvatske uspoređeno je s onim u odabranim zemljama Europske unije. Komparativna analiza prostornih podataka o stopama rasta bruto kapitalne formacije za zemlje članice EU pokazuju da je Hrvatska, poslije Grčke, Cipra i Slovenije od 2008. do 2015. imala

najveći pad bruto investicija. Hrvatska bilježi kumulativan pad investicija od 44 %. Najrazvijenije članice EU, Njemačka i Francuska, posve su se oporavile od investicijskog šoka, a neke zemlje poput Velike Britanije, Poljske i skandinavskih zemalja već ostvaruju pozitivne stope rasta bruto investicija u odnosu prema onima iz 2008 godine. Može se također primijetiti da su sjeverne, razvijene zemlje bolje prošle od južnih, perifernih članica Europske unije.

Tablica 2-1: Stopa rasta bruto kapitalne formacije za izabrana razdoblja (razdvojiti postotak)

Zemlja	1995–2007.	2007–2008.	2008–2009.	2009–2010.	2010–2015.
Njemačka	11,29%	0,66%	-17,44%	12,99%	4,10%
Austrija	25,73%	-0,71%	-10,26%	0,30%	9,70%
Belgija	53,24%	2,44%	-9,72%	1,52%	10,30%
Švicarska	19,01%	7,24%	4,47%	-4,94%	-1,50%
Cipar	42,11%	23,22%	-21,40%	5,15%	-43,10%
Češka	69,35%	1,21%	-18,05%	4,38%	10,80%
Danska	64,14%	-4,77%	-21,22%	-0,60%	17,30%
Estonija	391,97%	-20,38%	-41,74%	6,61%	37,90%
Grčka	119,79%	-9,18%	-26,88%	-10,79%	-49,20%
Španjolska	108,49%	-3,54%	-17,21%	-3,75%	-10,10%
Europska unija (15 zemalja)	43,35%	-2,34%	-15,97%	5,60%	4,20%
Europska unija (28 zemalja)	47,70%	-1,81%	-16,53%	5,37%	4,80%
Finska	86,27%	-1,84%	-20,56%	7,41%	-0,40%
Francuska	52,59%	-0,18%	-13,51%	3,41%	8,40%
Hrvatska	**195,14%**	**9,89%**	**-23,92%**	**-14,31%**	**-9,40%**
Mađarska	72,58%	0,56%	-23,86%	4,82%	2,00%
Irska	202,93%	-13,54%	-19,51%	-13,12%	79,50%
Italija	38,47%	-3,36%	-15,36%	5,49%	-19,00%
Litva	380,31%	3,38%	-54,56%	38,50%	33,50%
Letonija	582,14%	-15,42%	-41,19%	-19,03%	32,90%
Nizozemska	51,85%	2,61%	-10,80%	-1,57%	2,20%
Norveška	86,48%	0,54%	-13,09%	2,46%	15,00%
Poljska	147,09%	2,75%	-12,62%	9,41%	20,90%
Portugal	37,78%	0,73%	-12,25%	3,41%	-26,60%
Rumunjska	155,63%	11,54%	-24,35%	-1,57%	6,60%
Švedska	73,60%	-1,57%	-19,57%	16,41%	19,10%
Slovenija	134,78%	3,23%	-32,27%	-5,84%	-9,70%
Slovačka	102,34%	5,88%	-29,27%	18,91%	11,10%
Ujedinjeno Kraljevstvo	35,23%	-7,43%	-16,34%	15,61%	29,10%
Island	237,23%	-18,23%	-49,07%	-8,59%	65,00%

Izvor: EUROSTAT (2018), autorov izračun

Važno je napomenuti da ne postoji jasna korelacija između rasta investicija u razdoblju prije krize (1995–2007) i pada poslije nje. Primjerice, Hrvatska i Irska imale su vrlo sličan rast investicija prije krize (oko 200 %), ali je pad investicija u Hrvatskoj bio znatno veći od 2009.

do 2015. Očigledna je heterogenost između zemalja, pa se može zaključiti da je dinamika investicija uvelike određena domaćim ekonomskim faktorima, a ne samo vanjskim šokovima.

Pad agregatne bruto kapitalne formacije najčešće se objašnjava pomoću triju varijabla: rastom neizvjesnosti (Bloom, 2009; Gilchrist. S., Sim, J. W. & Zakrajšek E., 2014), padom agregatne potražnje (MMF, 2015; Krugman 2011) i rastom stupnja financijskog ograničenja. Potonju tvrdnju vjerno odražava citat iz ekonomskog biltena ECB-a (2015, str. 9): „Investicije se trenutno nalaze na razinama, koje su 15% niže od predkriznih razina u 2008., što se u velikoj mjeri može objasniti snažnim padom strane i domaće potražnje, niskom profitabilnošću tvrtki, dugim periodom nepovoljnih uvjeta financiranja i povišenoj ukupnoj nesigurnosti, kao i nižim javnim investicijama te, u nekim zemljama, prilagodbom na tržištima nekretnina.“ Kao mogući ograničavajući faktor u budućnosti ističe se proces razduživanja poduzeća i smanjenja očekivanja dugoročna rasta. Istraživanje MMF-a (2015) također ističe važnost tih triju faktora, ali posebno identificira agregatnu potražnju kao ključnu varijablu za objašnjenje agregatnih investicija. Kako bi riješili problem simultanosti između investicija i agregatne potražnje, autori su se služili regresijskom analizom s instrumentalnom varijablom. Analizirane su samo kontrakcije u outputu, koje su rezultat restriktivne fiskalne politike. Rezultati pokazuju da je agregatna potražnja presudna za objašnjenje investicijske dinamike. Neizvjesnost i nepovoljna financijska situacija imaju signifikantan, ali manji utjecaj na investicije.

Osim triju ključnih varijabla, razlozi pada investicija mogu biti razni makro- i mikrofaktori. Makroekonomski razlozi mogu biti demografski trendovi, slab očekivan rast gospodarstva i nedostatak tehnoloških inovacija. Na mikrorazini razlozi mogu biti nesigurnost, kratkoročna usmjerenost menadžmenta i nedostatak izvanjskih izravnih stranih investicija. Postoje i mnogi drugi, strukturni faktori, koji utječu na poslovne investicije. Međutim, oni su važniji za dugoročan, stalan trend investicija. Oscilacije u kratkom razdoblju uglavnom se objašnjavaju pomoću triju navedenih faktora.

Ovaj kratak uvod pokazuje da je glavni pokretač ekonomske kontrakcije i slabog ekonomskog oporavka velik pad i slab oporavak investicija. To vrijedi za napredne zemlje, za EU i RH. Unatoč brojnim radovima koji su objašnjavali dinamiku investicija, može se zaključiti da dosadašnji teorijski i empirijski modeli nisu uspjeli posve objasniti ponašanje investicija, posebno velike promjene pri snažnim šokovima. Neobjašnjivi šokovi investicija ključni su za objašnjenje poslovnih ciklusa, pa su one osnovni objekt utjecaja ekonomskih politika putem fiskalne politike stimulansa, ali i kao dio transmisijskog mehanizma monetarne politike. Ako

se tome doda važnost investicija za dugotrajan ekonomski rast i razvoj konkurentnosti, jasna je motivacija za njihov izbor kao predmet istraživanja u ovom radu.

2.1.2 Agregatna investicijska i kreditna aktivnost u Republici Hrvatskoj

Poslije financijske krize u makroekonomskoj literaturi pojavila su se brojna istraživanja o utjecaju financijskih frikcija na opću ekonomsku aktivnost (pregled dan u Brunnermeier, Eisenbach i Sannikov, 2012). Modeli s financijskim frikcijama amplifikaciju i perzistentnost poslovnih ciklusa objašnjavaju određenim oblikom nesavršenosti na tržištu kapitala. Riječ je o modelima koji u prevladavajuće modele (realni poslovni ciklusi i neokenezijanski modeli) uključuju modele razvijene unutar teorije ugovora i korporativnih financija. U većini modela osnovni je kanal utjecaja investicijski kanal financijskih frikcija: kontrakcija ponude kredita financijskih institucija uzrokuje kontrakciju u investicijama. U ovom se poglavlju pruža sažet pregled međuovisnosti investicijskih i financijskih tokova u Republici Hrvatskoj, odnosno traži se odgovor na pitanje: postoji li i kakva je priroda veze investicijske i financijske (kreditne) aktivnosti? Kako bi se pružila motivacija za važnost ovog pitanja, u nastavku se opisuje dinamika agregatnih financijskih varijabli i investicija.

Na slici 2-3 prikazana je dinamika stope rasta kvartalnih vrijednosti bruto investicija u fiksni kapital i kredita nefinancijskim društvima u odnosu prema istom kvartalu prethodne godine. Slika pokazuje kongruenciju vremenskih odsječaka prije krize i djelomično razdvajanje poslije nje. Usporavanje stope rasta kreditiranja podudara se s usporavanjem investicijske aktivnosti, *vice versa.* Točnije, stopa rasta kredita od 2001. do 2008. godine iznosi 206 %, a stopa rasta investicija u istom razdoblju iznosi 201 %. Nakon krize, od 2008. do 2014., stopa rasta kredita iznosi -5 %, a stopa rasta ukupnih investicija -45 %. Ovakva dinamika upućuje na snažnu procikličnost kreditne aktivnosti, fenomen opažen i u drugim zemljama (Quadrini, 2011). Međutim, iz grafa se ne može implicirati kauzalna veza kreditne aktivnosti na investicije. Moguće je da su investicije pod utjecajem realnih varijabli poput produktivnosti, a smanjenje kredita i duga rezultat je manje potražnje za likvidnim sredstvima (kreditima). Moguće je i da je kreditna kontrakcija rezultat financijskih šokova ili samo dio amplifikacijskog mehanizma. Točno utvrđivanje uzroka zahtijevalo bi provođenje testa kauzalnosti na frekventnijem skupu podataka i na duljim vremenskim serijama. Ipak može se implicirati određena korelacija kreditne aktivnosti banaka i investicija poduzeća.

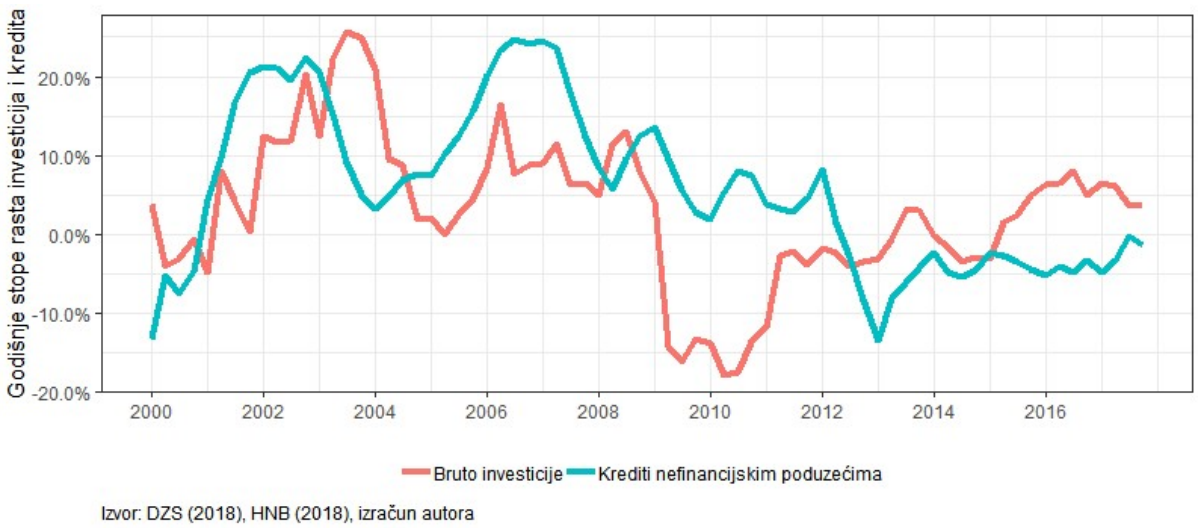

Slika 2-3: Postotna promjena bruto investicija u fiksni kapital i ukupnih kredita nefinancijskim institucijama, u nominalnim iznosima

Promjena aktive banke može biti rezultat promjene kapitala i promjene duga. Literatura o financijskim frikcijama često ističe važnost kapitala banke za kreditnu aktivnost (adekvatnost kapitala). Međutim, Adrian i Shin (2013) pokazali su da je promjena kreditne aktivnosti rezultat promjene duga banke, a vrlo rijetko rezultat promjene kapitala. Slika 2-4 pokazuje promjene duga i kapitala poslovnih banaka u RH u odnosu prema promjenama ukupne knjigovodstvene vrijednosti imovine. Promjena imovine banaka rezultat je promjene duga, a u manjem stupnju promjene kapitala. Ovakva se dinamika najčešće objašnjava fenomenima moralnog hazarda, ograničene odgovornosti banaka i stupnjem nesigurnosti (Nuno i Thomas, 2013). Sve potonje donosi fenomen bankovnog ciklusa poluge (engl. *Bank liquidity cycles*). Dakle, kreditna je aktivnost prociklična i uglavnom je rezultat promjene duga. Bankovna percepcija rizika može znatno utjecati na ponudu kredita i, posljedično, investicijsku aktivnost.

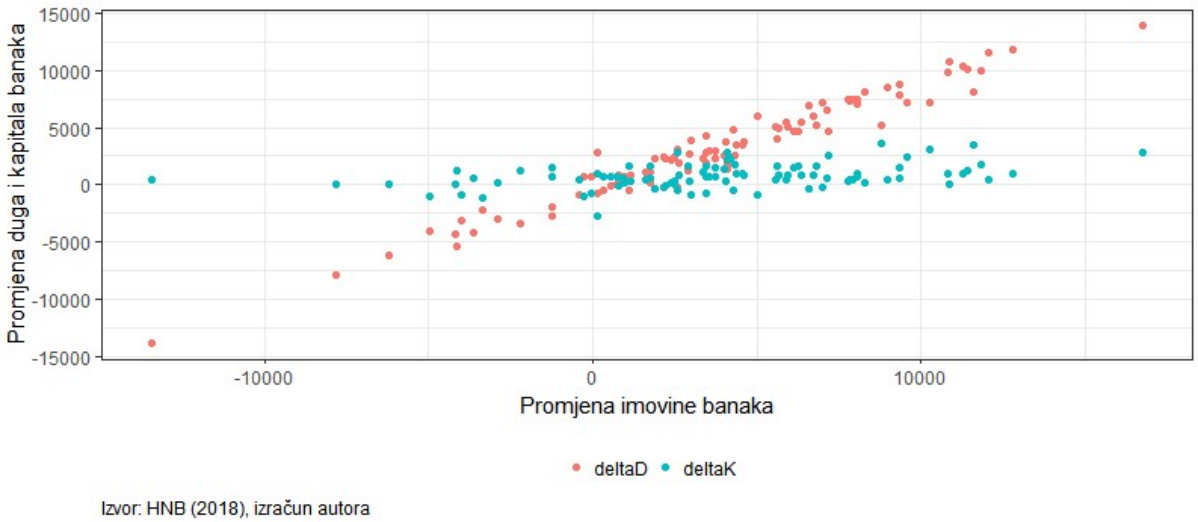

Slika 2-4: Promjene duga i kapitala poslovnih banaka prema promjeni imovine od 1995. do 2018.

Makroekonomska literatura o financijskim frikcijama prepoznaje tri kanala djelovanja financijskih frikcija: 1) bankovni kanal, 2) kanal bilance stanja poduzeća i 3) kanal likvidnosti. Bankovni kanal podrazumijeva negativan šok na kapital banke, koji uzrokuje kontrakciju ponude kredita. Primjerice, šok likvidnosti uzrokuje veću neusklađenost sredstava i obveza banke, pa ona smanjuje financijsku polugu. Postavlja se pitanje utjecaja bankovnog kanala u Republici Hrvatskoj. Slika 2-5, preuzeta iz prezentacijskog formata HNB-a, pokazuje da poslovne banke imaju na raspolaganju velike iznose likvidnosti. Postoji višak likvidnosti koji banke imaju na raspolaganju na računima centralne banke. Uzevši u obzir potonji višak likvidnosti, teško je poduprijeti hipotezu o dugoročnom, stalnom padu ponude kredita zbog šoka narušavanja bilance banaka. Može se indicirati da je važniji kanal utjecaja financijskih frikcija kanal bilance stanja poduzeća. Drugim riječima, smanjenje neto vrijednosti poduzeća (npr. smanjenje vrijednosti kolaterala) smanjuje založeni dohodak, što posljedično smanjuje i investicije. Ovaj je rad ponajprije orijentiran na kanal bilance stanja poduzeća, s time da se u raspravu uvodi i važnost politike upravljanja likvidnosti na investicijsku dinamiku nefinancijskih poduzeća.

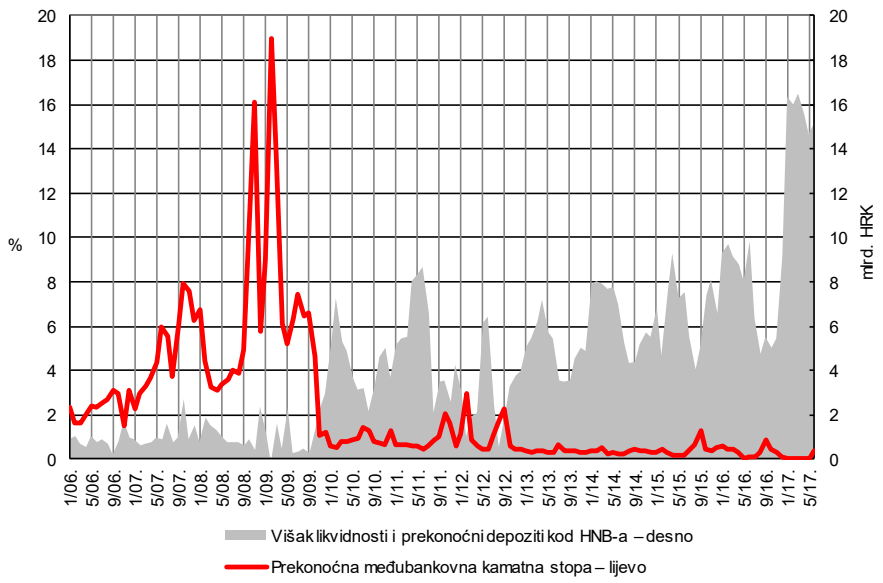

Izvor: HNB (2018)

Slika 2-5: Višak likvidnosti bankarskog sektora u Republici Hrvatskoj

U standardnom makroekonomskom modelu (IS-LM model) najvažnija je determinanta ponašanja investicija kamatna stopa. Pad kamatne stope smanjuje trošak investiranja i time potiče rast poslovnih investicija te obrnuto. Međutim, kamatne stope na kredite nefinancijskim poduzećima smanjuju se poslije krize, a investicije konstantno bilježe negativne stope rasta. Dinamiku kamatnih stopa i ukupne kapitalne formacije u RH prikazuje slika 2-6. Od 2000. do 2005. kamatne stope padaju s 10 % na 6 % što istodobno prati i rast investicija. Nakon 2005. godine kamatne stope rastu otprilike 2 postotna boda, a u istom razdoblju rastu i investicije. Nakon Velike recesije, od 2009. do 2014., kamatne su stope pale na povijesno niske razine, a ulaganja u fiksni kapital istodobno uvelike opadaju. Na temelju kretanja vremenskih serija na slici teško je prihvatiti hipotezu o jakoj pozitivnoj korelaciji između kamatnih stopa i investicija.

Fenomen niskih troškova financiranja još je izraženiji u međunarodnom financiranju. Mnoga su se poduzeća u pretkriznom razdoblju zaduživala u inozemstvu pa je referentna kamatna stopa za njih određena stanjem na tržištu kapitala i mjerama ekonomskih politika u EU. Prema ekonomskom biltenu ECB-a (2015), kompozitne su bankovne kamatne stope pale s 5,5 % pri kraju 2008 godine na 2,15 % sredinom 2015. godine. Dakle poduzeća koja se zadužuju u inozemstvu imaju još povoljnije uvjete financiranja. U inozemstvu su referentne kamatne stope nakon krize oko 0 %. U takvim je uvjetima poseban makroekonomski problem fenomen nulte

niske granice (engl. *zero lower bond*), prema kojem centralna banka ne može politikama kratkoročne kamatne stope poticati rast investicija jer su kamatne stope već na nultim razinama.

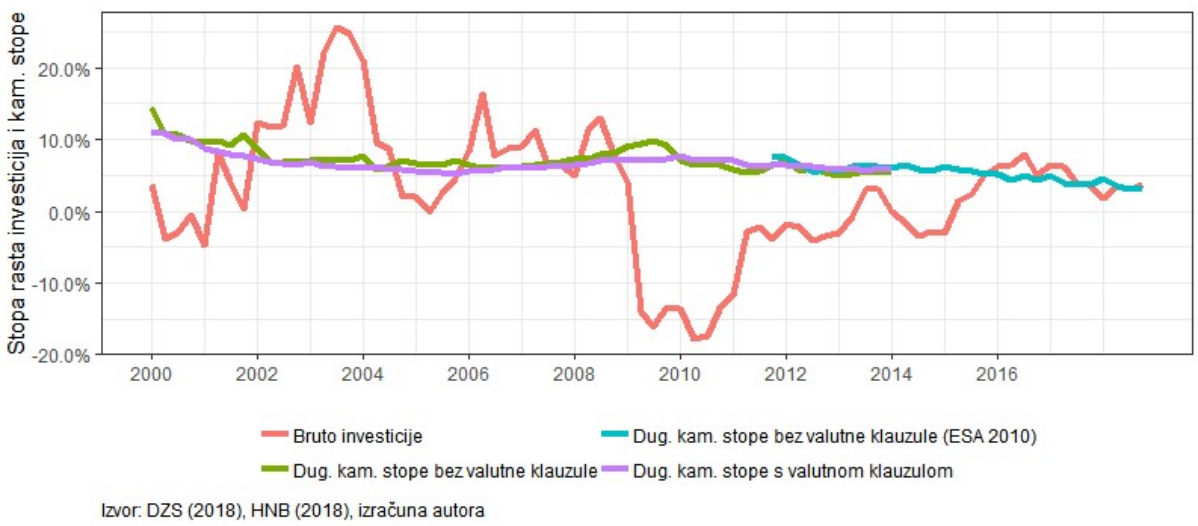

Slika 2-6: Dinamika bruto investicija u fiksni kapital i dugoročnih kamatnih stopa za trgovačka društva od 2000. do 2014.

Manju važnost kamatnih topa potvrđuje i istraživanje Sharpa i Suareza (2013), koji se koriste podacima iz anketnog upitnika, u kojima se od korporativnih izvršnih direktora 900 američkih kompanija tražilo da odrede ključne faktore koji utječu na investicijske planove tvrtke. Rezultati ankete pokazuju da bi samo 8 % tvrtki povećalo investicije uz 1 postotni bod smanjenja kamatnih stopa. Dodatnih 8 % povećalo bi investicije uz 2 % smanjenje kamatnih stopa. U čak 68 % ispitanika kamatna stopa nije imala nikakva utjecaja na odluke o investicijama. Pri povećanju kamatnih stopa veza je malo jača: 16 % poduzeća smanjilo bi investicije uz rast kamatnih stopa jedan postotni bod i dodatnih 15 % uz rast kamatnih stopa od dva postotna boda. Osnovni razlozi neosjetljivosti po važnosti jesu: dostatan iznos novčanih rezervi, trenutačno niske kamatne stope te to što su investicijski planovi rađeni na temelju buduće potražnje.

Može se zaključiti da postoji pozitivna korelacija između kreditne aktivnosti i investicija te da kamatna stopa ne može biti isključiv indikator njihova ponašanja. Osnovni je zadatak ovog rada ustanoviti smjer kauzalnosti: utječe li kontrakcija ponude kredita na investicije ili smanjenje potražnje za investicijama utječe na pad ponude kredita.

2.1.3 Pregled istraživanja o dinamici i interakciji kreditne i realne aktivnosti

U uvodu je naznačeno da u makroekonomskoj teoriji postoje suprotna gledišta o međuovisnosti financijskih varijabli i ekonomske aktivnosti. Jedna skupina ekonomista smatra da su dugovi „novac koji dugujemo samima sebi“ (Krugman, 2011), pa ne bi trebali imati utjecaja na opću ekonomsku aktivnost, pa tako ni na investicije. Ekonomisti suprotna gledišta smatraju da je rast dugova osnovni pokazatelj financijskih kriza. Iako su i prije krize postojali radovi koji su fluktuacije u ekonomskoj aktivnosti objašnjavali financijskim faktorima (Benanke i Gertler; 1986, Calstrom i Fuerst, 1997; Kiyotaki i Moore, 1997; Bernanke, Gertler i Gilchrist, 1999), većina se modela temeljila na prvom gledištu, prema kojem su financijske institucije samo intermedijari koji prenose kupovnu moć s jednog agenta na drugog, a investicije funkcija agregatne potražnje. Prije prikaza kompleksnijih modela o međuovisnosti financijskih frikcija i investicijske aktivnosti u ovom se poglavlju pruža pregled radova koji su potvrdili važnost financijskih tržišta u objašnjavanju poslovnih ciklusa.

Schularick, Moritz i Taylor (2012) proučavali su utjecaj kreditne ekspanzije na poslovne cikluse u 14 razvijenih zemalja u 140 godina. Izdvojili su dva „razdoblja financijskoga kapitalizma“ [4]. Prvo je razdoblje od 1870. do 1939. kada novac i kredit u dugom roku održavaju stabilan odnos prema BDP-u, što je donijelo novčarski pogled na kreditnu aktivnost (doba novca). Drugo razdoblje započinje 1945. godine kada se kreditni udjeli u BDP-u oporavljaju i 1970-ih dostižu razine iz 1940-ih te nastavljaju rasti sve do danas (doba kredita). Prosječna godišnja stopa rasta širokog novca (M2 i M3) u prvom razdoblju (1870–1945) iznosila je 3,57 % , kredita 3,96 % i imovine 4,11 %. U poslijeratnom su razdoblju iste varijable rasle po stopama 8,61 %, 10,92 % i 10,48 %. Trendovi su jednaki za sve proučavane zemlje[5]. Dakle agregatna financijska poluga neprekidno raste nakon Drugoga svjetskog rata u svim razvijenim zemljama. Ovaj fenomen autori nazivaju „financijski hokejski štap“ (engl. *financial hockey stick*). Snažan rast poluge

[4] Autori su dodatno izdvojili i tri povijesno različita gledišta o dinamičkoj međuovisnosti novca, kredita i makroekonomije: 1) Novčarski pogled (engl. *money view*) prema kojem novac ima važan kratkoročan utjecaj na output, ali kreditnoj se aktivnostine pridaje važnost. 2) Irelevantan pogled (engl. *irrelevance view*) slijedi Modigliani-Millerovu hipotezu o nevažnosti strukture financiranja za vrijednost poduzeća. Ovaj pogled imao je najjači utjecaj u drugoj polovici 20. stoljeća pa su u tom razdoblju modeli s novcem i financijskim frikcijama bili rijetki. 3) Kreditni pogled počinje 1980-ih godina s radovima Mishkina (1978), Bernankea i Gertlera (1983), Kiyotakia(1997) i drugih, a vodi se još starijom Fisherovom razradom (1933), pri čemu se analizira utjecaj strukture kredita banaka, poduzeća i kućanstva na ekonomsku aktivnost.

[5] Stopa rasta kredita u kasnijoj, poslijeratnoj fazi, vjerojatno je i podcijenjena zbog razvoja „bankarstva u sjeni“ (engl. *shadow banking*).

najviše je pod utjecajem rasta duga kućanstava, posebno hipotekarnih kredita. Primjerice, odnos hipotekarnih kredita i BDP-a za 17 razvijenih zemalja iznosio je 20% na početku 20 stoljeća te 70 % u 2010. godini.

Autori su pokazali da su recesije u prijeratnom razdoblju bile teže u smislu pada realnih varijabli pet godina nakon krize. Kreditnu ekspanziju u poslijeratnom razdoblju pripisuju aktivnijoj monetarnoj i fiskalnoj politici (osiguranje depozita, podrška bankarske likvidnosti i td.) koja je pogodovala razvoju financijskog sektora. Na kraju, autori su testirali svoju hipotezu o važnosti kredita za poslovne cikluse primjenom logit-modela. Uvažavajući različite specifikacije modela, kontrolne varijable i uzorke, autori su otkrili signifikantnu vezu između vjerojatnosti nastanka financijske krize i rasta realnih godišnjih kredita pet godina prije krize. Podaci uključuju gotovo sve krize u modernoj ekonomiji i pokazuju jasnu uzročnu vezu između snažna rasta privatnog duga prije krize i jačine recesija. Bankovna kriza bez prethodna snažna rasta privatnog duga ima sličnu dinamiku kao i normalne recesije (recesije bez bankarske krize).

Empirijski podaci o međuovisnosti kreditne i realne aktivnosti potaknuli su neka novija istraživanja o financijskim (kreditnim) ciklusima. Financijski ciklusi pokazuju veći stupanj inertnosti i veće amplitude od poslovnih ciklusa. Za razliku od klasičnih modela s financijskim frikcijama, koje nastoje objasniti amplifikaciju i perzistentnost nakon šoka, teorija financijskog ciklusa nastoji objasniti teoriju endogeno stvorenih financijskih kriza. Primjeri su istraživanja iz ovog područja već prikazano istraživanje Schularicka, Moritza i Taylora (2012) te skupina radova što ju je objavila Banka za međunarodna izravnanja (primjerice Drehmann, Borio i Tsatsaronis, 2012; Drehman i Tsatsaronis, 2014).

Globalni rast kreditne poluge potvrđuju i druga istraživanja. Ženevsko izvješće o svjetskoj ekonomiji daje pregled dinamike kreditne poluge nakon financijske krize. Rezultati su sljedeći (Buttiglionie i dr., 2014):

- stalan rast poluge, mjerene kao odnos duga i BDP-a na globalnoj razini, čak i nakon financijske krize
- u anglosaksonskim zemljama (SAD i VB) zabilježeno je razduživanje kućanstava i financijskog sektora, ali je istodobno povećan dug konsolidirane države. Sve razvijene zemlje imaju snažan rast duga države poslije 2008. godine (35 % u prosjeku, pri čemu je rast u SAD-u i UK veći nego u eurozoni), što implicira prijenos obveza od privatnog prema javnom sektoru.

- od krize 2008 godine stopa rasta zaduženja u zemljama u razvoju (posebno u Kini) ubrzava se u odnosu prema razvijenim zemljama, koje su kroz povijest uvijek imale veće dugove (prosječno 212 % BDP-a prema 151 % BDP-a u zemljama u razvoju).

Kreditna kontrakcija različito utječe na velika i mala poduzeća. Adrian, Colla i Shin (2012) s pokazali su da agregatni kreditni plasmani opadaju nakon krize (prema svim tvrtkama), s time što velike tvrtke nadomještaju pad kreditne ponude intermedijara povećanom emisijom korporativnih obveznica. Rast emisije korporativnih obveznica zabilježen je i u zemljama EU (ECB, 2013).

Izvještaj ECB-a (2013) potvrđuje prijašnje nalaze o rastu dugova prije krize. Većinom je riječ o bankovnom dugu. Međutim, velika je heterogenost među zemljama. Najveći rast korporativnih dugova zabilježen je u Španjolskoj i Irskoj, a Njemačka, Belgija i Finska imale su manji rast dugova. Zemlje s većim rastom dugova imale su i veći rast investicija. U Španjolskoj i Irskoj rast se dugova ponajprije odnosio na rast tržišta nekretnina. Sljedeći su faktori pridonijeli rastu poluge u EU (ECB, 2013):

- niska volatilnost na financijskim tržištima
- relativno niske kamatne stope na bankovne kredite
- olakšanje bankovnih standarda kreditiranja.

ECB provodi i ankete o dostupnosti eksternog financiranja za mikro, mala, srednja i velika poduzeća. Trinaesta je anketa provedena u rujnu i listopadu 2015. U uzorku je bilo 11.226 poduzeća, od kojih 91 % s brojem zaposlenih manjim od 250. Poduzeća u uzorku trebaju identificirati najvažniji problem s kojim se susreću u svom poslovanju. U spomenutoj anketi „dostupnost financiranja“ smatra važnim samo 11 % poduzeća, pri čemu s vremenom postoji jasan trend pada važnosti ovog faktora. Najvažnijim faktorom investiranja odgovorne osobe smatraju „traženje kupaca“ (25 %), a ostali su faktori otprilike jednako važni („dostupnost kvalificirane radne snage“., „konkurencija“, „regulacija“, „troškovi rada“). Velika je heterogenost među zemljama. U Grčkoj, 30 % poduzeća navodi „dostupnost financiranja“ kao ograničenje (najvažniji faktor), a u Austriji, Finskoj i Njemačkoj samo 7 %. Eksterno financiranje pretežito služi za fiksne investicije (37 %) i ulaganja u zalihe i radni kapital (33 %). Stoga je važno pri analizi financijskog ograničenja uvažiti dva temeljna oblika investicija te ukupnu investicijsku aktivnost.

ECB anketa pokazuje i da financijski jaz, koji se računa kao razlika između potrebnih i dostupnih sredstava, prvi put poprima negativne vrijednosti od 2009. godine. Ključni faktor koji objašnjava pad financijskog ograničenja rast je spremnosti banaka da financiraju nove investicije. Velike kompanije imaju znatno manji postotak odbijenih kreditnih zahtjeva (1 %) od malih i srednje velikih tvrtki (9 %).

Istraživanje ECB-a o dostupnosti financiranja upućuje na postojanje financijskog ograničenja tijekom kriznih godina i postupan oporavak s odmakom od krize. Posljednji podaci pokazuju da je udio financijski ograničenih poduzeća u prosjeku bio nizak na kraju 2015. godine. Istraživanje dakle potvrđuje fluktuacije u ponudi kredita financijskih institucija: jači stupanj racioniranja kredita u vrijeme krize i otpuštanje kolateralnih i ostalih kreditnih ograničenja poslije nje.

Podaci općenito upućuju na rast poluge kućanstava i poduzeća na globalnoj razini. Često se relativan rast dugova tumači kao rast rizika i ranjivosti gospodarstva. Međutim, rast dugova može pozitivno djelovati na rast, zbog mogućeg izglađivanja funkcije potrošnje i investicija. Ipak, pretjerana ekspanzija dugova i financiranje neprofitabilnih projekata mogu uzrokovati financijske nestabilnosti upravo kroz investicijski kanal financijskih frikcija.

2.2 Modeli investicija bez financijskih frikcija

U ovom se poglavlju daje pregled teorije investicija bez financijskih frikcija. Prvo se pruža analiza neoklasične teorije investicija, koja je razvijena 60-ih godina (Jorgenson, 1963; Jorgenson, 1967). Potom se prikazuje Q-teorija investicija (Hayashi, 1982). Osnovna je pretpostavka ovog modela postojanje troškova prilagođavanja stoka kapitala. Potom se u model uključuju fenomeni neizvjesnosti i ireverzibilnosti investicija (modeli realnih opcija). Svi modeli pretpostavljaju postojanje savršenih tržišta kapitala.

2.2.1 Keynesova teorija investicija

U Keynseovoj teoriji ulaganje u kapitalnu imovinu određeno je graničnom efikasnosti kapitala (engl. *marginal efficiency of capital*). Granična efikasnost kapitala jednaka je „diskontnoj stopi koja izjednačuje sadašnju vrijednost anuiteta (potencijalne prinose, engl. *prospective yield*) i

cijenu ponude kapitala (engl. *supply price*)“ (Keynes, 1936, str. 135). Cijena ponude kapitala nije tržišna cijena po kojoj se mogu kupiti kapitalna dobra, nego zamjenska vrijednost kapitala. Uočljivo je da je granična efikasnost kapitala određena očekivanim prinosom i aktualnom cijenom njegove ponude. U modernoj financijskoj teoriji umjesto pojma granične efikasnosti kapitala upotrebljava se pojam interne stope profitabilnosti. Riječ je o stopi uz koju je čista sadašnja vrijednost projekta jednaka nuli (Orsag, 2002). Ako je interna stopa profitabilnosti veća od troška kapitala, projekt je profitabilan i tvrtka bi trebala investirati u projekt. U kontekstu Keynsove terminologije aktualne će se investicije povećavati do točke u kojoj ne postoji ni jedan oblik kapitalne imovine, za koji je granična efikasnost kapitala veća od tržišne kamatne stope. Drugim riječima, stopa će investicija rasti do točke na kojoj je granična efikasnost kapitala jednaka tržišnoj kamatnoj stopi. Valja također napomenuti da rast investicija u određeni oblik kapitala u određenom razdoblju smanjuje graničnu efikasnost tog tipa kapitala zbog: 1) smanjenja prinosa povećanjem ponude kapitala i 2) rasta cijene kapitala za predmetno kapitalno dobro.

Potonja analiza implicira četiri bitne značajke modela investicija u Keynesovoj teoriji (Leijonhufvud, 1968):

1. Visoka elastičnost cijena kapitalnih dobara, za danu razinu diskontne stope, u odnosu prema stopi rasta stoka kapitala.
2. Tržište kapitalnih dobara i obveznica savršeni su supstituti. Drugim riječima, elastičnost je supstitucije prihoda od kapitala i obveznica beskonačna.
3. Visoka elastičnost kapitalnih dobara s obzirom na diskontnu stopu (zahtijevanu stopu prinosa).
4. Visoka elastičnost ponude kapitalnih dobara s obzirom na cijenu kapitalnih dobara.

U Keynesovoj teoriji očekivanja su ključan faktor investicija jer utječu na graničnu efikasnost kapitala, što je temeljni faktor investicija. Očekivanja su uvjetovana pouzdanjem investitora u buduće prinose od projekta. Stupanj pouzdanosti uglavnom je funkcija bihevioralnih faktora i tržišne psihologije (engl. *animal spirits*). Općenito, moć pojedinca u predviđanju budućih novčanih tokova vrlo je ograničena. Čak i kada bi postojali investitori koji bi mogli prilično točno predvidjeti koristi od projekta, bilo bi ih vrlo malo i ne bi mogli utjecati na tržište. Bihevioralni su faktori stoga važniji od točnih matematičkih kalkulacija.

Keynes u svojoj analizi na pojedinim mjestima ističe važnost financijskih faktora (frikcija) na investicije poduzeća. U petom potpoglavlju dvanaestog poglavlja ističe se važnost povjerenja

na financijskim tržištima. Visoko povjerenje poduzetnika oko profitabilnosti investicijske prilike nije dovoljan uvjet za rast investicija jer poduzetnik nema neograničenu moć raspolaganja novčanim sredstvima (likvidnošću). Osim stupnja povjerenja poduzetnika važan je i stupanj povjerenja financijskih institucija, koje osiguravaju likvidna sredstva za projekt. Iako kriza može biti posljedica pada povjerenja u jednom od tržišta, oporavak zahtijeva stupanj povjerenja na oba tržišta (povjerenje dužnika i kreditora). Drugim riječima, rast je stupnja povjerenja kreditnih institucija nužan, ali ne i dovoljan uvjet oporavka investicija nakon financijskih kriza.

Keynes je važan dio analize posvetio i jednakosti štednje i investicija. Najjednostavnije rečeno, jednakost proizlazi iz definicije investicija. Naime, investicijom se smatra sve što nije potrošnja. Investicije nisu samo ulaganja u fiksnu imovinu već i u financijske i rezidencijalne investicije. Primjerice, ako se ulaganje u zalihe ne označi kao investicija, jasno je da više neće vrijediti jednakost štednje i investicija, već je njihova razlika upravo jednaka ulaganjima u zalihe. Iako se nužna jednakost investicija i štednje u nekim analizama označuje kao „tautologija bez kauzalne značajnosti“, ona je vrlo bitan dio Keynesove teorije (Leijonhufvud, 1968).

2.2.2 Neoklasična teorija potražnje za investicijama

Neoklasična teorija kapitalne akumulacije prikazuje se prema radovima Jorgensona (1963, 1967), uz određene preinake dane u novijim razmatranjima (Xavier Sala-i-Martin, 2005; Eklund, 2013). Prema neoklasičnoj teoriji, osnovni je cilj tvrtke maksimiranje budućih profita ili sadašnje njezine vrijednosti uz ograničenje koje opisuje tehnološke mogućnosti, a prema kojem output u svakom razdoblju ovisi o tokovima rada i kapitalnih usluga u tom razdoblju. Tok kapitalnih usluga i zamjene proporcionalan je stoku kapitala.

Formalno, prvo se opisuje funkcija cilja, koja je jednaka toku neto primitaka u razdoblju t:

$$R(t) = p(t)Y(t) - w(t)L(t) - p(t)I(t) \qquad (1)$$

gdje Q, L i I označavaju output, varijabilni input (rad) i investicije u trajna dobra, dok p i w označavaju njihove cijene.

Sadašnja vrijednost tvrtke$V$ jednaka je integralu diskontirnaih neto primitaka:

$$V = \int_0^\infty e^{-rt} R(t)dt \tag{2}$$

Sadašnja vrijednost tvrtke maksimizira se s obzirom na dva ograničenja. Prvo je ograničenje dano proizvodnom funkcijom:

$$Y(t) = A(t)F(K(t), L(t)) \tag{3}$$

gdje je $K(t)$ stok kapitala. Funkcija $F()$dva je puta diferencijabilna te zadovoljava:

a) konstantne prinose na opseg: $F\big(\beta K(t), \beta L(t)\big) = \beta\, F(K(t), L(t))$
b) konkavnost: $F_K > 0, F_L > 0, F_{KK} < 0, F_{LL} < 0$
c) Inada uvjete: $\lim_{K\to 0} F_K = \infty$ i $\lim_{K\to\infty} F_K = 0$

Važno je istaknuti da tvrtka može prodavati i kupovati neograničene količine kapitala (investirati i dezinvestirati) po cijeni $p(t)$.

Drugo je ograničenje dano diferencijalnom jednadžbom neto investicija, odnosno razlike bruto investicija i troškova zamjene:

$$\dot{K}(t) = I(t) - \delta K(t) \tag{4}$$

gdje je $\dot{K}(t)$ stopa promjene toka kapitalnih usluga u razdoblju t.

Tvrtke biraju rad L, kapital K i investicije I kako bi maksimirale sadašnju vrijednost budućih novčanih primitaka (2) s obzirom na ograničenja (3) i (4). Također pretpostavljaju se dva dodatna ograničenja:

1. pozitivan kapital u inicijalnom razdoblju $K_0 > 0$.
2. nepostojanje Ponzijevih uvjeta: $\lim_{t\to\infty} e^{-rt} K_t \geq 0$

Radi preglednosti, još se jednom daje pregled optimizacijskog problema:

$$\max \int_0^\infty e^{-rt}\, [p(t)A(t)F(K(t), L(t)) - w(t)L(t) - p(t)I(t)]dt$$

uz ograničenja:

$$\dot{K}(t) = I(t) - \delta K(t)$$

$$K(0) > 0 \; i \; \lim_{t \to \infty} e^{-rt} K(t) \geq 0$$

Radi rješenja problema optimiranja konstruira se Hamiltonianova funkcija (u nastavku se radi preglednosti izostavlja t iz notacije):

$$H = e^{-rt}(pAF(K, L) - wL - pI) + \lambda(I - \delta K) \tag{5}$$

gdje je λ cijena u sjeni za kapitalnu akumualciju u vremenu t. Ova varijabla mjeri doprinos rasta jedne jedinice kapitala u vremenu t vrijednosti tvrtke mjerene u nultom vremenu. Ako se λ želi izraziti kao tekuća vrijednost cijene u sjeni, potrebno je λ pomnožiti s faktorom e^{rt}. Odnosno, trenutačna vrijednost cijene u sjeni iznosi $q = e^{rt}\lambda$ (Xavier Sala-i-Martin, 2005).

Uvjeti su prvog reda:

$$AF_L(K, L) = \frac{w}{p} \tag{6}$$

$$-e^{-rt}p + \lambda = 0 \;\rightarrow\; -p + q = 0 \tag{7}$$

$$-\dot{\lambda} = -e^{-rt}pAF_K(K, L) + \lambda\delta \rightarrow -\dot{q} + rq = pAF_K(K, L) + q\delta \tag{8}$$

$$\lim_{t \to \infty} \lambda K = 0 \tag{9}$$

Prvi uvjet govori da će tvrtka zapošljavati radnike do točke na kojoj je granična produktivnost rada jednaka realnoj plaći. Riječ je o standardnoj jednadžbi potražnje za radom. Sve su varijable funkcija vremena, odnosno jednadžba (6) vrijedi u svakoj vremenskoj točki. Drugi uvjet kaže da je u optimumu vrijednost jedne jedinice investicija (cijena u sjeni za kapital) upravo jednaka trošku investicija (oportunitetnom trošku kapitala). Dakle, tvrtke će investirati dokle god se tržišni trošak dodatne jedinice kapitala ne izjednači s graničnim prihodima. Za objašnjenje trećeg uvjeta poželjno je preoblikovati jednadžbu (8):

$$AF_K(K, L) = \frac{-\dot{q} + rq}{p} \tag{10}$$

Ako se pretpostavi da je cijena p *numeraire* u svim razdobljima te ako se primijeni jednadžba (7), dobiva se relacija:

$$AF_K(K, L) = r + \delta = c \tag{11}$$

Tvrtka tako investira do točke u kojoj je granični proizvod kapitala jednak sumi povrata na alternativnu imovinu (realna kamatna stopa) i stopi amortizacije. U izvornom radu Jorgensona (1967), u jednadžbi (1) se pretpostavljaju različite cijene kapitalnih dobara (s) i outputa (p), pa jednadžba (11) ima oblik:

$$F_K(K,L) = \frac{s(r+\dot{\delta}) - \dot{s}}{p} = \frac{c}{p} \tag{12}$$

gdje je c implicitna vrijednost najma kapitalnih usluga.

Iz jednadžbe (10), odnosno (11), moguće je odrediti željene vrijednosti kapitala. Primjerice, ako se pretpostavi Cobb-Douglasova proizvodna funkcija, granična je produktivnost kapitala jednaka:

$$F_K(K,L) = A\alpha K^{\alpha-1}L^{1-\alpha} \rightarrow F_K(K,L) = \frac{\alpha Y}{K} = \frac{c}{A} \tag{13}$$

Rješenje po K daje optimalnu razinu kapitala:

$$K^* = \frac{A\alpha Y}{c} \tag{14}$$

Jednadžba (11) implicitno opisuje željene vrijednosti kapitala (Xavier Sala-i-Martin, 2005), a investicije su jednake razlici željene i aktualne vrijednosti kapitala:

$$I = \frac{A\alpha Y}{c} - K^* \tag{15}$$

Prema opisanom neoklasičnom modelu investicija, tvrtke unajmljuju kapital i rad sve dok se granični proizvodi ne izjednače s relativnim cijenama. Diskretne promjene cijena kapitala i rada (ili amortizacije) donose diskretne promjene u radu i kapitalu (Xavier Sala-i-Martin, 2005). Dakle, svaka promjena realne kamatne stope ili amortizacije donosi beskonačno pozitivnih ili negativnih investicija. Drugim riječima, u realnosti bismo trebali opažati samo nulte, beskonačno pozitivne ili negativne vrijednosti investicija (Xavier Sala-i-Martin, 2005).

Važno je također primijetiti da buduće, očekivane promjene graničnih proizvoda kapitala nemaju utjecaja na sadašnje investicije. Iako bi tvrtka znala da će u budućnosti porasti granični proizvod kapitala, neće preventivno povećavati kapital, nego će čekati razdoblje u kojem će se povećati granični proizvod kapitala kako bi diskretno povećala kapital. Takvo je ponašanje u suprotnosti s modernom ekonomskom teorijom u kojoj ponašanje ekonomskih agenata ovisi o

budućim očekivanjima, a koja najčešće rezultiraju glađom krivuljom investicija (potrošnje). U sljedećem se poglavlju opisuje kako uključivanje troškova prilagođavanja donosi realniju sliku ponašanja investicija.

2.2.3 Q-teorija investicija

2.2.3.1 Model internih troškova prilagođavanja

U prošlom je poglavlju pokazano da neoklasični model investicija bez frikcija stvara nezanimljivu situaciju u kojoj se kapital u svakom razdoblju prilagođava tako da granični troškovi korištenja budu jednaki graničnom proizvodu kapitala. Zbog očitih ograničenja takvog modela (trenutačno prilagođavanje), s radovima Lucasa (1967) i Goulda (1968), o problem optimizacije proširuje se za troškove prilagođavanja kako bi se stvorila realnija slika ponašanja investicija. Model investicija s troškovima prilagođavanja (engl. *adjustment cost model*) i q-teorija investicija dio su standardne neoklasične teorije koja pokušava objasniti potražnju za investicijama proširenjem početnog modela za troškove prilagođavanja. U nastavku se pruža pregled prema Hayashi (1982) i novijim pregledima u Xavier Sala-i-Martin (2005) i Eklund (2013).

Tvrtke moraju platiti instalacijske troškove ako žele instalirati novu jedinicu kapitala. Instalacijski troškovi nataloženi su troškovi, to jest resursi potrošeni za instaliranje kapitalne jedinice i ne mogu se povratiti. Troškovi instaliranja jedne jedinice kapitala označeni su s $\Phi(t)$. Slijedeći Xavier Sala-i-Martin (2005), pretpostavlja se da su troškovi prilagođavanja funkcija investicija po kapitalu. Troškovi prilagođavanja rastuća su funkcija željenih investicija po kapitalu i negativna funkcija aktualne razine kapitala. Dodatno, vrijedi: $\Phi(0) = 0$ (ako nema investicija, nema ni troškova prilagođavanja), $\Phi'\left(\frac{I}{K}\right) > 0$ i $2\Phi' + \left(\frac{I}{K}\right)\Phi'' \geq 0$ (tehnička pretpostavka radi lakšeg izvođenja analitičkog rješenja).

Optimizacijski problem sličan je onom iz prošlog poglavlja. Razlika je u dodanim troškovima prilagođavanja:

$$\max \int_0^\infty e^{-rt}\left[p(t)A(t)F(K(t),L(t)) - w(t)L(t) - p(t)I(t)\left(1 + \Phi\left(\frac{I(t)}{K(t)}\right)\right)\right]dt$$

uz ograničenja:

$$\dot{K}(t) = I(t) - \delta K(t)$$

$$K(0) > 0 \; i \; \lim_{t\to\infty} e^{-r} \; K(t) \geq 0$$

Ukupni troškovi investiranja jednaki su troškovima kupovine kapitalnog dobra, $p(t)I(t)$ uvaćenima za instalacijske troškove, $p(t)I(t)\Phi\left(\frac{I(t)}{K(t)}\right)$.

Kao i u prošlom poglavlju, konstruira se Hamiltonianova funkcija (cijene p su normalizirane):

$$H = e^{-rt}\left[AF(K,L) - wL - I\left(1 + \Phi\left(\frac{I}{K}\right)\right)\right] + \lambda(I - \delta K) \tag{16}$$

Uvjeti su prvog reda:

$$AF_L(K,L) = w \tag{17}$$

$$e^{-rt}\left(-\left(1 + \Phi\left(\frac{I}{K}\right) + \left(\frac{I}{K}\right)\Phi'\left(\frac{I}{K}\right)\right)\right) = \lambda \;\rightarrow\; \left(1 + \Phi\left(\frac{I}{K}\right) + \left(\frac{I}{K}\right)\Phi'\left(\frac{I}{K}\right)\right) = q \tag{18}$$

$$-\dot{\lambda} = -e^{-rt}\left(AF_K(K,L) + \left(\frac{I}{K}\right)^2 \Phi'\left(\frac{I}{K}\right)\right) - \lambda\delta \rightarrow \; -\dot{q} + rq \tag{19}$$

$$= AF_K(K,L) + \left(\frac{I}{K}\right)^2 \Phi'\left(\frac{I}{K}\right) - q\delta$$

$$\lim_{t\to\infty} \lambda K = 0 \tag{20}$$

Uvjeti prvog reda odgovaraju uvjetima neoklasične teorije investicije, izuzev uvjeta (18) koji odražava troškove prilagođavanja. Jednadžba (18) pokazuje da je cijena u sjeni za investicije funkcija investicija po kapitalu. Bez investicija nema ni troškova prilagođavanja, što odgovara neoklasičnome modelu u prethodnom poglavlju. Kako je q monotona funkcija investicija, moguće je definirati inverznu funkciju od q (Xavier Sala-i-Martin, 2005):

$$\frac{I}{K} = \varphi(q) \tag{21}$$

Sve informacije nužne za donošenje odluke o investicijama dane su u varijabli q, koja mjeri vrijednost koju tvrtki daje dodatna jedinica kapitala (cijena u sjeni za investicije). Kada je q veći od jedan, stopa će investicija biti pozitivna, a kada je q manji od jedan, stopa će investicija biti negativna. Ako je tržišna vrijednost dodatne jedinice kapitala jednaka 1, a sadašnja

vrijednost jedne jedinice kapitala veća od 1 ($q > 0$), tvrtka će investirati i obrnuto. Drugim riječima, jednadžba (21) označava potražnju za investicijama kao odnos investicija i cijene u sjeni. U okviru financija i teorije vrednovanja imovine q se intepretira kao tržišna vrijednost jedinice kapitala, odnosno dodatna sadašnja vrijednost profita koju tvrtka zarađuje kupnjom dodatne jedinice kapitala.

Kako bi se definirale odrednice q-a, potrebno je primijeniti jednadžbu (19):

$$r + \delta = \frac{AF_K(K, L) + \left(\frac{I}{K}\right)^2 \Phi'\left(\frac{I}{K}\right) + \dot{q}}{q} \tag{22}$$

Na lijevoj je strani jednadžbe kamatna stopa uvećana za amortizaciju. Desna strana jednadžbe označava povrat na investiciju, koja je jednaka zbroju graničnog proizvoda kapitala (AF_K), promjeni cijene u cijeni za kapital, odnosno kapitalnim prinosima ($\dot{q}$) i smanjenju troškova prilagođavanja zbog većih razmjera (rasta tvrtke), $\left(\frac{I}{K}\right)^2 \Phi'\left(\frac{I}{K}\right)$. Rješenje jednadžbe dovodi do izraza za cijenu u sjeni u vremenu 0 (Xavier Sala-i-Martin, 2005):

$$q_0 = \int_0^\infty e^{-rt}\left(AF_K(K, L) + \left(\frac{I}{K}\right)^2 \Phi'\left(\frac{I}{K}\right)\right) dt \tag{23}$$

Tekuća cijena instaliranoga kapitala jednaka je sadašnjoj vrijednosti budućih graničnih doprinosa kapitala. Zaključno, za razliku od neoklasičnog modela investicija iz prošle točke, u q-teoriji investicija, q je ključna varijabla za objašnjenje dinamike investicija, pri čemu q ovisi o očekivanim graničnim doprinosima kapitala i, implicitno, realnoj kamatnoj stopi.

Budući da je jedan od ciljeva doktorskog rada opisati i objasniti dinamiku investicija, važno je analizirati odnos investicija i outputa te kamatne stope. Implikacije modela opisuju se prema Romer (2011). Rast outputa povećava potražnju za industrijskim proizvodima, a time i profite za dani stok kapitala. Drugim riječima, rast outputa pomiče funkciju profita prema gore, što rezultira rastom kapitala i q-a. Veća tržišna vrijednost kapitala povećava potražnju za investicijama. S vremenom se sustav vraća u ravnotežu ($\dot{K} = 0$). Ponašanje investicija ovisi o karakteru šoka. Permanentni rast outputa donosi temporalni rast investicija. Temporalni rast outputa također povećava investicije, ali za manji iznos jer se q povećava za manji iznos. Kada bi se q povećao za isti iznos kao i pri stalnom rastu outputa, tvrtka bi u idućim razdobljima

iskusila velike troškove prilagođavanja kapitala na novu točku ravnoteže. Dakle, tvrtke uzimaju u obzir cijelo buduće razdoblje prilagođavanja.

Pad kamatne stope ima slične učinke kao i rast outputa, profitna se funkcija pomiče udesno, investicije rastu. Permanentni pad kamatne stope pridonosi temporalnom rastu investicija dok se industrija kreće prema novoj, permanentno višoj razini kapitala. Za ponašanje investicija bitnije su dugoročne kamatne stope od kratkoročnih kamatnih stopa (za detalje pogledati Romer, 2011, poglavlje 9).

2.2.3.2 Hayashijev teorem

U prethodnom je poglavlju pokazano da odluke o investicijama ovise samo o vrijednosti varijable q, koja označuje cijenu u sjeni za kapital (Lagrangov multiplikator u diskretnom vremenu). Drukčiju interpretaciju q-a dali su Brainard i Tobin (1968), a prema njoj je q odnos tržišne vrijednosti dodatne jedinice kapitala i zamjenskih troškova. Tu su interpretaciju preuzeli od Keynesa (1936), koji je tvrdio da je kapital to privlačniji što mu je vrijednost veća u odnosu prema troškovima njegova pribavljanja (Abel i Eberly, 2010). Drugim riječima, q iznad 1 (trošak kapitala) implicira pozitivnu neto sadašnju vrijednost projekta.

Hayashi (1982) je pokazao da je pod određenim uvjetima granični q (definiran u prethodnom potpoglavlju) jednak Tobinovu prosječnom q-u. Razlika graničnog i prosječnog q ovisi o prepotstavkama neoklasičnog modela investicija. Konkretnije, prosječni i granični q jednaki su ako su ispunjene tri pretpostavke: 1) funkcija proizvodnje i funkcija troškova prilagođavanja pokazuju konstantne prinose na opseg (funkcije su homogene stupnju homogenosti jedan), 2) kapitalna dobra su homogena i identična i 3) tržišta kapitala su efikasna.

Formalni prikaz Hayashijeva teorema prikazujemo prema Xavier Sala-i-Martin (2005). Produkt kapitala K i varijable q je jednak:

$$\frac{d(qK)}{dt} = \dot{q}K + q\dot{K} \tag{24}$$

Koristeći se jednadžbom $q = g(\frac{I}{K})$, (19) i (18), dobiva se:

$$\frac{d(qK)}{dt} = K\left[(r+\delta)q - AF_K - \left(\frac{I}{K}\right)^2 \Phi'\left(\frac{I}{K}\right)\right] + \tag{25}$$

$$(I-\delta K)\left[1+\Phi\left(\frac{I}{K}\right)+\left(\frac{I}{K}\right)\Phi'\left(\frac{I}{K}\right)\right]$$

$$\frac{d(qK)}{dt} = Kqr + Kq\delta - KAF_K - K\left(\frac{I}{K}\right)^2 \Phi'\left(\frac{I}{K}\right) + I + I\Phi\left(\frac{I}{K}\right) + I\left(\frac{I}{K}\right)\Phi'\left(\frac{I}{K}\right) \tag{26}$$

$$- \delta Kq$$

$$\frac{d(qK)}{dt} = Kqr - KAF_K + I\left(1+\Phi\left(\frac{I}{K}\right)\right) \tag{27}$$

$$\frac{d(qK)}{dt} = Kqr - \left[AF(K,L) - wL - I\left(1+\Phi\left(\frac{I}{K}\right)\right)\right] \tag{28}$$

Posljednja je jednadžba e dobivena korištenjem Eulerovim teorema, prema kojem za homogene funkcije, stupnja homogenosti jedan, vrijedi: $KAF_K + LAF_L = AF(K,L)$. Dobivena je jednadžba obična diferencijalna jednadžba prvog reda u varijabli qK. Rješenje diferencijalne jednadžbe daje:

$$q_0K_0 = \int_0^\infty e^{-rt}\left[AF(K,L) - wL + I\left(1+\Phi\left(\frac{I}{K}\right)\right)\right]dt \tag{29}$$

Desna strana jednadžbe označuje sadašnju vrijednost budućih novčanih primitaka (dividendi). „Ako vrijedi pretpostavka savršenih tržišta kapitala, ova će vrijednost odgovarati tržišnoj vrijednosti tvrtke“ (Xavier Sala-i-Martin, 2005, str. 29). Jednadžba se može napisati i kao:

$$q_0 = \frac{V_0}{K_0} \tag{30}$$

što daje rezultat Hayashijeva teorema: granični q jednak je prosječnom Tobinovu q.

Velik dio literature o investicijama pretpostavlja postojanje triju pretpostavki iz Hayashijeva teorema. Ova pretpostavka olakšava izračun q pokazatelja jer se granični q u realnosti ne može opaziti, a prosječni se q može izračunati kao odnos tržišne vrijednosti tvrtke i zamjenskih troškova kapitala. Tržišna je vrijednost tvrtke jednaka zbroju tržišne vrijednosti kapitala i tržišne vrijednosti dugova, a zamjenski se troškovi kapitala u empirijskim radovima aproksimiraju knjigovodstvenom vrijednosti imovine. Međutim, kao što će biti pokazano u pregledu empirijskih radova, neki su autori pokazali da pogreška u mjerenju q-a može biti

važna (npr. Gomes, 2001; Bond i dr., 2004), što donosi pristranost procijenjenih parametara investicijske jednadžbe. Ako prosječni q ne odgovara graničnom q, tada se prosječni q ne može upotrijebiti kao mjera investicijskih prilika.

Iako većina empirijskih radova pretpostavlja jednakost prosječnog i graničnog q-a, postoje pokušaji izravna mjerenja graničnog q-a. Primjer je istraživanje Abela i Blancharda (1986), koji su nastojali procijeniti vrijednost graničnog q-a koristeći se pomoćnim ekonometrijskim modelima (engl. *auxiliary econometric model*). Pristup obuhvaća specifikaciju graničnog proizvoda kapitala pomoću opservacijskih varijabli te stvaranje prediktivnog modela na temelju tih varijabli. Diskontiranjem na sadašnje razdoblje dobiva se vrijednost cijene u sjeni, λ. Cijena u sjeni služi kao mjera graničnog q-a u jednadžbi investicija, umjesto prosječnog q-a. Valja istaknuti da je potonji pristup vrlo teško provesti pomoću uobičajeno dostupnih podataka.

2.2.4 Utjecaj nesigurnosti i ireverzibilnosti na investicije: realne opcije

U dosadašnjim modelima osnovni kriterij investicijskog odlučivanja jesu kriteriji granične efikasnosti kapitala u Keynesa i očekivani budući granični doprinosi kapitala u q-teoriji investicija. U ovom poglavlju model se proširuje trima važnim karakteristikama investicija. Prvo, investicije su djelomično ili posve ireverzibilne, što znači da se vrijednost troškova može povratiti samo uz velike diskonte. Drugim riječima, inicijalni investicijski troškovi u velikom su dijelu nataloženi troškovi (engl. *sunk costs*). Drugo, ishodi su investicijskog projekta neizvjesni. Najbolje što tvrtka može učiniti jest procijeniti vjerojatnosti očekivanih alternativnih ishoda, s većom ili manjom stopom profitabilnosti. Treće, odluka o investicijama može se odgoditi. Tvrtka može čekati nove informacije o cijenama, troškovima i ostalim promjenama tržišnih uvjeta. Modeli s navedenim karakteristikama označuju se kao modeli realnih *call* opcija[6]. Uvođenje ovih karakteristika mijenja ponašanje investicija. Za investiranje nije bitna samo neto sadašnja vrijednost projekta prema principu uzmi ili ostavi, nego i vrijednost opcije čekanja. Opcija čekanja je vrijedna jer se u budućnosti mogu otkriti nove informacije važne za projekt (npr. cijena proizvoda). Tvrtka se suočava s izborom između minimiziranja utjecaja loših vijesti i gubitka sadašnje vrijednosti novčanih tokova. Dakako, oportunitetni troškovi

[6] Pojam „realne“ podrazumijeva investicijeske umjesto financijskih odluka.

izvršenja opcije u tekućem razdoblju mogu se uključiti u ukupne troškove projekta, pa neto sadašnja vrijednost ostaje ključan kriterij investicijske odluke.

U nastavku se pruža matematička analiza teorije realnih opcija u kojem je investicijska politika određena traženjem rješenja na problem optimalna zaustavljanja. Teorija realnih opcija počela se razvijati s radom McDonalda i Siegela (1984), a proširivana je u različitim smjerovima. Njezin je pregled dan u knjizi Dixita i Pindycka (1994), a nešto novija i matematički zahtjevnija rasprava pružena je u knjizi Stokeyja (2009).

U bazičnome modelu ireverzibilnih investicija u kontinuiranom vremenu tvrtka, odnosno menadžer, mora odlučiti o investiranju u jedan projekt (McDonald i Siegel, 1984). Osnovna je varijabla stanja u modelu dakle investicijska prilika koja se može poduzeti uz određene fiksne troškove. Troškovi investiranja I poznati su i fiksni, a vrijednost projekta, V, prati geometrijsko Brownovo gibanje:

$$dV = \alpha V dt + \sigma V dz \tag{31}$$

gdje je dz inkrement Wienerova procesa, s očekivanom vrijednosti 0, α konstantna stopa rasta, a σ volatilnost. Prema jednadžbi (31) trenutačna je vrijednost projekta poznata, ali su buduće vrijednosti projekta log-normalno distribuirane s varijancom koja raste linearno s vremenom (Dixita i Pindyck, 1994).

Kao i u prijašnjim poglavljima, V označuje diskontirane očekivane novčane tokove, a ne novčane tokove same po sebi. Jednostavno pravilo neto sadašnje vrijednosti podrazumijeva investiranje ako vrijedi $V > I$. U uvjetima nesigurnosti i ireverzibilnih investicija čekanje na nove informacije može imati veliku vrijednost, pa optimalno investicijsko pravilo treba usporediti investiranje danas i opcije investiranja u svim mogućim budućim stanjima. Drugim riječima, tvrtkina investicijska prilika ekvivalentna je *call* opciji, to jest pravu, ali ne i obvezi da se kupi dionica po određenoj (izvršnoj) cijeni. Vrijednost investicijske prilike (opcije da se investira) može se označiti s $F(V)$. Tvrtka tada maksimizira (Dixita i Pindyck, 1994):

$$F(V) = \max E[(V_T - I)e^{-\rho T}] \tag{32}$$

gdje je E očekivanje, T nepoznato vrijeme poduzimanja investicije, a ρ diskontna stopa. Pretpostavlja se da je $\rho > \alpha$, inače bi za tvrtku bilo optimalno da beskonačno odgađa investicijsku priliku. Tvrtka maksimira jednadžbu (32) s obzirom na jednadžbu (31). Ovako definirani problem označuje se kao problem optimalnog zaustavljanja u kontinuiranom

vremenu ili, u kontekstu investicijskog odlučivanja, kao optimalno vrijeme za instalaciju ireverzibilnih investicijskih projekata. Investiranje je optimalno kada su troškovi izgubljenih renti zbog odgađanja investicije veći od prinosa od čekanja.

Investicijska prilika, $F(V)$, ne donosi novčane tokove do vremena T, pa je jedini prinos od njezina držanja njezina kapitalna aprecijacija (Dixit i Pindyck, 1994). Stoga, u regiji u kojoj investiranje nije optimalno (regija kontinuiteta), Bellmanova je jednadžba dana s:

$$\rho F dt = E(dF) \tag{33}$$

Jednadžba (33) govori da je protekom vremena, dt, ukupni očekivani povrat na investicijsku priliku, $\rho F dt$, jednak ukupnom očekivanom prinosu kapitalne aprecijacije. Izraz dF može se proširiti primjenom Itove leme:

$$dF = F'(V)dV + \frac{1}{2}F''(V)(dV)^2 \tag{34}$$

$$dF = \alpha V F'(V)dt + \sigma V F'(V)dz + \frac{1}{2}\sigma^2 V^2 F''(V)dt \tag{35}$$

$$E(dF) = \alpha V F'(V)dt + \frac{1}{2}\sigma^2 V^2 F''(V)dt \tag{36}$$

gdje je jednadžba (35) dobivena uvrštavanjem vrijednosti za dV iz (31), a jednadžba (36) rezultat je primjene operatora očekivanja E ($E(dz) = 0$). Uvrštavanjem jednadžbe (36) u jednadžbu (33) i dijeljenjem s dtdobiva se Bellmanova jednadžba za kontinuiranu regiju:

$$\rho F(V) = \alpha V F'(V) + \frac{1}{2}\sigma^2 V^2 F''(V) \tag{37}$$

koja je zadovoljena za $V > V^*$. Budući da je granica V^* endogena, postoji problem slobodne granice (engl. *free-boundary problem*). Rješenje jednadžbe stoga zahtijeva ispunjenje sljedećih graničnih uvjeta:

$$F(0) = 0 \tag{38}$$

$$F(V^*) = V^* - I \tag{39}$$

$$F'(V^*) = 1 \tag{40}$$

Uvjet (38) pokazuje da je vrijednost investicijske prilike jednaka 0 kada je $V = 0$. Ovaj uvjet proizlazi iz jednadžbe (31). Uvjet (39) uvjet je podudaranja (engl. *value matching*). Kada tvrtka

investira, dobiva vrijednost projekta V, ali gubi mogućnost investiranja, $F(V)$. Kritična je vrijednost V^* ona pri kojoj su neto primici, $V - F(V)$, jednaki investicijskim troškovima I. Drugim riječima, projekt mora pokriti i izravne i oportunitetne troškove, $V^* = F(V^*) + I$. Uočljivo je kako kriterij neto sadašnje vrijednosti nije dostatan za donošenje odluke o investiranju. Razlog je u tome što imovina može ostvarivati prinose u svakom razdoblju (npr. dividende) pa veća nesigurnost povećava vrijednost $F(V^*)$. Uvjet (40) je uvjet finog uglađivanja (engl. *smooth pasting*).

Nakon definiranja problema, potrebno je pronaći rješenje diferencijalne jednadžbe (37) uz zadovoljenje uvjeta (38) – (40). Ovdje se prikazuje rješenje pomoću pristupa pogađanja. Pretpostavlja se da rješenje ima oblik (Dixita i Pindyck, 1994):

$$F(V) = AV^{\beta_1} \tag{41}$$

Uvjet (39) implicira:

$$AV^{*\beta_1} = V^* - I \tag{42}$$

Uvjet (40) implicira:

$$\beta_1 AV^{*\beta_1 - 1} = 1 \tag{43}$$

Kombinacija posljednjih dviju jednadžba daje:

$$V^* = \frac{\beta_1}{\beta_1 - 1} I \tag{44}$$

$$A = \frac{V^* - I}{V^{*\beta_1}} \tag{45}$$

Jednadžbe (44) i (45) daju rješenje za investicijsku priliku i optimalno investicijsko pravilo, V^*. Budući da je $\beta_1 > 0$, vrijedi da je $V^* > I$, što potvrđuje da u uvjetima ireverzibilnih investicija i nesigurnosti jednostavno pravilo neto sadašnje vrijednosti nije dostatno za objašnjenje investicijske dinamike. Nesigurnost i ireverzibilnost proizvode klin između kritične vrijednosti V^* i investicija I (Dixit i Pindyck, 1994).

Jednadžbu (44) je potrebno riješiti za β_1. Zamjenom pretpostavljenog rješenja (41) s diferencijalnom jednadžbom (37), s pretpostavkom $\delta = \rho - \alpha$, dobiva se:

$$\frac{1}{2}\sigma^2\beta(\beta-1)+(\rho-\delta)\beta-\rho=0 \tag{46}$$

Postoje dva korijena jednadžbe (46). Pozitivan korijen zadovoljava (Dixit i Pindyck, 1994):

$$\beta_1=\frac{1}{2}-\frac{(\rho-\delta)}{\sigma^2}+\sqrt{\left(\frac{(\rho-\delta)}{\sigma^2}-\frac{1}{2}\right)^2+2\frac{\rho}{\sigma^2}}>1 \tag{47}$$

Iz jednadžbe (47) mogu se izvesti zaključci o međuodnosu neizvjesnosti i investicija:

- β_1 je padajuća funkcija σ, pa se s rastom σ klin $\frac{\beta_1}{\beta_1-1}$ povećava. Riječima, što je veća razina nesigurnosti oko budućih vrijednosti V, veći je klin između V^* i I, pa tvrtke dulje čekaju na investicijski pothvat.
- β_1 je rastuća funkcija δ, pa veći δ znači manju vrijednost klina, $\frac{\beta_1}{\beta_1-1}$. Riječima, kako za rast prilagođena diskontna stopa profita raste, tvrtke se odlučuju za sve ranije investiranje.
- β_1 je padajuća funkcija ρ, pa se s rastom ρ klin $\frac{\beta_1}{\beta_1-1}$ povećava. Što se više diskontiraju troškovi, u odnosu na, za rast prilagođene koristi, dulje se čeka na investicije.

Korisno je proučiti granično ponašanje. Kada je $\sigma\to\infty$, vrijedi $\beta_1\to 1$ i $V^*\to\infty$. Ako je nesigurnost beskonačna, tvrtka nikada ne investira. Kada je $\sigma\to 0$, ponašanje investicija ovisi o vrijednosti α. Kada je $\alpha>0$, $\beta_1\to\frac{\rho}{\rho-\delta}$ i $V^*\to\left(\frac{\rho}{\delta}\right)I>I$. Kada je $\alpha\leq 0$, $\beta_1\to\infty$ i $V^*\to I$.

Sljedeće poglavlje opisuje učinak nesigurnosti na investicije unutar q-teorije investicija.

2.2.5 Q-teorija investicija u uvjetima nesigurnosti s proširenom funkcijom prilagođavanja

U q-teoriji investicija funkciju troškova prilagođavanja opisuje simetrična, glatka krivulja oko $I=0$. U realnosti, krivulja prilagođavanja može imati dodatna svojstva. Jedno od njih su fiksni troškovi prilagođavanja za bilo koju razinu investicija, koja stvara diskontinuiranu funkciju prilagođavanja. Drugo, važno je svojstvo investicija njihova ireverzibilnost. Investicijski su troškovi u većem dijelu nepovratni. Postrojenja i oprema se najčešće prodaju uz velik diskont,

a marketinški troškovi i slični troškovi podrške vezani uz projekt posve su nepovratni. Treće je svojstvo nesigurnosti oko novčanih tokova, što je detaljno razrađeno u prethodnom poglavlju.

Abel i Eberly (1994) su investicijski model s troškovima prilagođavanja proširili za gornje karakteristike. Nesigurnost se uvodi uključivanjem slučajne varijable ε_t u funkciju operativnog profita $\pi(K_t, \varepsilon_t)$, gdje ε_t prati difuzijski proces:

$$d\varepsilon(t) = \mu(\varepsilon(t))dt + \sigma(\varepsilon(t))dz \tag{48}$$

gdje je z Wienerov proces. Kapital se razvija prema formuli $dK(t) = (I(t) - \delta K(t))dt$. Povećanje bruto investicija zahtijeva plaćanje: 1) troškova kupnje po cijeni p_K^+ ili troškova prodaje po cijeni p_K^-, gdje vrijedi $p_K^+ \geq p_K^- \geq 0$, 2) troškova prilagođavanja 3) nenegativnih fiksnih troškova, $c(0, K)$, koji su neovisni o iznosu investicija, osim kada su investicije 0. Ukupni troškovi investiranja jednaki su umnošku kvalitativne varijable d i proširene funkcije prilagođavanja $c(I, K)$, koja je kontinuirana, strogo konveksna i dvaput diferencijabilna. Troškovi investiranja iznose 0 kada je $d = 0$, i $c(I, K)$, kada je $d = 1$.

Rizično neutralna tvrtka bira investicije kako bi maksimirala:

$$rV(K, \varepsilon) = \max_{I,d} \left\{ \pi(K, \varepsilon) - d\Phi(I, K) + \left(\frac{1}{dt}\right) E(dV) \right\} \tag{49}$$

s obzirom na difuzijski proces $d\varepsilon(t)$ i jednadžbu kapitala $dK(t)$ (za izvod Bellmanove jednadžbe pogledati dodatak u Abel i Eberly, 1994). Lijeva je strana zahtijevana profitabilnost tvrtke, a desna strana maksimirani očekivani povrat koji se sastoji od razlike očekivanih operativnih profita $\pi(K, \varepsilon)$ i proširenih troškova prilagođavanja $c(I, K)$ te očekivanih kapitalnih prinosa predstavljenih promjenom vrijednosti tvrtke. Autori pokazuju da se primjenom Itove leme, jednadžbi $d\varepsilon(t)$ i $dK(t)$ i izraza $(dK)^2 = 0$ dobiva:

$$rV = \max_{I,d} \left\{ \pi(K, \varepsilon) - d\Phi(I, K) + q(I - \delta K) + \mu V_\varepsilon + \frac{1}{2}\sigma^2 V_{\varepsilon,\varepsilon} \right\} \tag{50}$$

Kontrolne varijable su I i d, pa se maksimirajuća funkcija svodi na:

$$\max_{I,d} \{q(I) - d\Phi(I, K)\} \tag{51}$$

Gdje je $q \equiv V_K$. Optimalno ponašanje investicija karakterizirano je sljedećom jednadžbom:

$$\hat{I}(q,K) = \begin{cases} I^*(q,K) < 0, & ako\ q < q_1 \\ 0, & ako\ q_1 \leq q \leq q_2 \\ I^*(q,K) > 0, & ako\ q > q_2 \end{cases} \tag{52}$$

gdje su q_1 i q_2 dva različita rješenja jednadžbe (54). Riječima, ako se definiraju najmanji (q_1) i najveći korijen(q_1) za maksimand (52), mogu se razlikovati tri režima investicija: 1) bruto investicije su negativne ako je $q < q_{1,}$ 2) bruto investicije se ne mijenjaju ako je $q_1 \leq q \leq q_2$ i 3) bruto investicije su pozitivne ako je $q \leq q_2$. Uz uvjet da ne postoje fiksni troškovi investiranja te da je $\Phi(I,K)$ diferencijabilna u $I = 0$, postojat će samo jedan jedinični korijen, što dovodi do standardnog ponašanja investicija s troškovima prilagođavanja u uvjetima neizvjesnosti.

Na kraju, radi usporedbe s jednadžbom (23), prikazuje se jednadžba za q:

$$q_t = \int_0^\infty E_t\{\pi_k(K_{t+s}, \varepsilon_{t+s}) - d_{t+s}\Phi_K(I_{t+s}, K_{t+s})\}e^{-(r+\delta)s}\, ds > 0 \tag{53}$$

Jednadžba pokazuje da je q jednak očekivanom graničnom proizvodu kapitala, koji se sastoji od dviju komponenata: graničnog operativnog profita umanjenog za proširene granične troškove prema graničnom proizvodu kapitala. Ireverzibilnost investicija samo je poseban slučaj kada su troškovi prilagođavanja uvijek pozitivni (prodajna cijena nije dovoljna da pokrije fiksne troškove i troškove prilagođavanja). Međutim, neke analize (npr. Caballera i Engela 2008) pokazuju da je agregatno ponašanje investicija uz fiksne troškove isto kao i agregatno ponašanje investicija bez pretpostavke o fiksnim troškovima.

2.2.6 Modigliani-Millerova teorija irelevantnosti strukture kapitala

Svi do sada prikazani modeli investicija pretpostavljaju postojanje savršenih tržišta kapitala. Svi projekti s pozitivnom neto sadašnjom vrijednosti uspijevaju se realizirati internim ili izvanjskim financiranjem. Drugim riječima, struktura je kapitala irelevantna za donošenje odluke o realnim investicijama. Vrlo utjecajan rad, koji je bio temelj paradigme o irelevantnosti strukture financiranja (interno/eksterno, vlastito/tuđe financiranje) na vrijednost poduzeća i investiranje jest rad Modiglianija i Millera (1958). Autori su pokazali da, pod određenim uvjetima, struktura financiranja, to jest vrijednost svih potraživanja na tvrtkine buduće primitke, nema utjecaja na vrijednost poduzeća. Računovodstveno govoreći, vrijednost je određena

lijevom stranom bilance, realnim investicijama, a ne desnom stranom, strukturom financiranja. Poduzeća se ne trebaju brinuti o vrijednosti financijske poluge, politici isplate dividendi ili karakteristikama vrijednosnih papira koje emitiraju, jer izvori sredstava nisu bitni. Važan je karakter realnih investicija. U kontekstu prikazane q-teorije, investicije tvrtke ovise samo o profitabilnosti investicijskih prilika, koje se u neoklasičnoj teoriji investicija mjere Tobinovim q-om.

Modigiani-Millerova teorija irelevantnosti strukture kapitala može se opisati poznatom prvom propozicijom u Modigliani i Miller (1958). Radi ilustracije propozicije, pretpostavlja se da su poduzetnici rizično neutralni. Postoje dva izvora financiranja: dug D i kapital E. Tržišna vrijednost duga je dana s $V_D = \mathrm{E}(\min\{R, D\})$, a tržišna vrijednost kapitala s $V_E = \mathrm{E}(\max\{0, R - D\})$, gdje je R dohodak tvrtke. Prva propozicija dana je jednostavnom relacijom (Tirole, 2006):

$$V_D + V_E = \mathrm{E}(R) \tag{54}$$

gdje je $\mathrm{E}(R)$ očekivana vrijednost dohotka tvrtke s obzirom na neku distribuciju dohotka. Prema prvoj propoziciji, tržišna vrijednost tvrtke ne ovisi o kapitalnoj strukturi (Modigliani, Miller, 1958). Kada propozicija ne bi vrijedila, investitori bi mogli kupovati i prodavati jedinice duga i kapitala tako da zamjenjuju jedan novčani primitak za drugi. Kupovanjem podcijenjene vrijednosnice i prodavanjem precijenjene investitori bi izjednačili prinose vrijednosnica iz iste klase rizika. Drugim riječima, tvrtke s većim stupnjem financijske poluge ne mogu zahtijevati premiju u odnosu prema nezaduženim tvrtkama jer investitori mogu samostalno birati razinu poluge svog portfelja posuđujući novac preko privatnih računa.

Važno je istaknuti da Modigliani-Millerov teorem vrijedi samo uz jasne eksplicirane pretpostavke: 1) tržišta su potpuna, 2) nema transakcijskih troškova, 3) nema asimetričnosti informacija, 4) nema poreza, 5) nema troškova bankrota. Uz navedene pretpostavke, financijske varijable ne utječu na investicije, pa je teorija o financijskim frikcijama ponajprije usmjerena na otpuštanje navedenih pretpostavki. Unutar teorije financijskog ugovaranja najveći je napor učinjen u razvoju modela koje karakteriziraju asimetričnost informacija između menadžera i vlasnika ili poduzetnika i investitora (financijskih institucija). Ovakva su istraživanja objašnjena u sljedećem poglavlju.

2.3 Značajke financijskog ograničenja kao problema financijskog ugovaranja

Prikazani teorijski modeli investicija u poglavlju 2.2. pretpostavljaju savršena tržišta kapitala, odnosno pretpostavljaju da su eksterni i interni izvori financiranja savršeni supstituti. Sve relevantne informacije za donošenje odluke o investiranju sadržane su u tržišnoj vrijednosti tvrtke, q, a ostale varijable poput novčanih tokova ili intenziteta zaduženosti nemaju dodatne prediktivne sposobnosti za objašnjenje investicijske dinamike. Ako tvrtka raspolaže projektom s pozitivnom neto sadašnjom vrijednosti (sa opcijom čekanja) pri danoj kamatnoj stopi, uvijek će realizirati financiranje po danoj stopi radi pokretanja investicijske aktivnosti.

U praksi, investitori ili financijski intermedijari (banke, fondovi) ne raspolažu potpunim informacijama o investicijskom projektu ili dužniku. Investitori često nemaju znanja za procjenu kreditne sposobnosti dužnika ili nemaju dovoljan poticaj za aktiviranje različitih oblika nadzora dužnika. Asimetričnost informacija stvara agencijske troškove između investitora i poduzeća, pa i investitori snose djelomičan rizik investicijskog pothvata. U ovom se poglavlju prikazuju teorijski modeli racioniranja kredita kao problema financijskog ugovaranja zbog asimetričnosti informacija. Pokazat će se da u uvjetima racioniranja kredita i likvidnog ograničenja poslovne investicije ne ovise samo o q-u nego i o financijskim varijablama poput novčanog toka i intenziteta zaduženosti.

2.3.1 Heuristički opis pojma financijskog ograničenja

Investicijske pothvate i operativne izdatke poduzeće može financirati na dva načina. Prvo je interno financiranje, odnosno prikupljanje novčanih sredstava iz poslovanja društva. To se ponajprije odnosi na financiranje iz zarada poduzeća ili točnije, neto dobiti nakon poreza i umanjenja za davanja vlasnicima (dividende, otkup dionica, raspodjela dobiti). Interno financiranje uključuje i financiranje iz otpisa, rezerviranja i oslobađanja kapitala. Drugo je eksterno financiranje, koje može biti vlastito (s pristupom burzi ili bez njega) ili tuđe. Tuđe financiranje uključuje različite oblike dugoročna i kratkoročna kreditiranja te razne kreditne supstitute poput komercijalnih zapisa, dugoročnih obveznica i trgovačkih kredita.

Jedno od ključnih pitanja ovog rada jest: utječu li odluke o izvorima financiranja na investicijske odluke poduzeća? Ili, utječe li financijski položaj poduzeća, razina neto vrijednosti i/ili iznos neto radnoga kapitala na investicijsko ponašanje? Ako postoje poduzeća s

investicijskim prilikama i manjkom kapitala (novca), te s druge strane, postoje investitori s viškom novaca, ali bez investicijskih ideja, hoće li se i pod kojim uvjetima obaviti razmjena kapitala između dviju strana?

Prvo treba istaknuti da je prema klasičnoj mikroekonomskoj teoriji teško uopće opravdati postojanje tvrtke (Barnard, 2005). U uvjetima potpunih tržišta ne postoje budžetska ograničenja koja određuju maksimalan iznos zaduživanja u različitim ravnotežnim stanjima (Gale i Hellwig, 1985). Tvrtke se prikazuju kao proizvodni skup, a jedina interakcija na tržištu postiže se samo putem cijena (Barnard, 2005).

Prevladavajuća neoklasična q-teorija investicija (poglavlje 2.2.) pretpostavlja da je cjelokupna informacija o investicijama sadržana u varijabli q. Ako je vrijednost q-a iznad 1, poduzeće povećava vrijednosti kapitala jer su buduće očekivane koristi veće od troškova. Neoklasična q-teorija investicija pretpostavlja savršena tržišta kapitala što implicira financiranje svakog projekta s pozitivnom neto sadašnjom vrijednosti (korigirano za opciju čekanja). Model implicitno pretpostavlja neosjetljivost investicija na interne izvore financiranja (novčane tokove) jer se svaka profitabilna investicijska prilika može financirati iz eksternih izvora. U okviru investicijske regresijske jednadžbe pretpostavlja se da vrijednost koeficijenta uz novčane tokove iznosi 0. Irelevantnost financijskih faktora za investicijske odluke sadržana je i u Modigiliani-Millerovu teoremu irelevantnosti strukture kapitala (potpoglavlje 2.2.6). Pokazano je da uz određene pretpostavke izvori financiranja ne utječu na vrijednost poduzeća. Ukratko, svi modeli prikazani u poglavlju 2.2. impliciraju neovisnost investicija o strukturi izvora financiranja.

Modeli investicija, koji uključuju nesavršenosti na tržištu kapitala, uglavnom se svode na otpuštanje pojedinih pretpostavki na kojima se temelji rezultat Modigliani-Millera jer je u suprotnom nemoguće objasniti kako distribucija izvora financiranja utječe na investicije. U teoriji korporativnih financija i teoriji ugovora, od 70-ih godina, najviše je istraživanja provedeno o uvođenju pretpostavke asimetričnih informacija (Jensen i Meckling 1976; Myers 1977; Ross 1977.). Dok je prevladavajući neoklasični model investicija pretpostavljao da eksterni ponuditelji sredstava (banke) raspolažu jednakim informacijama (profitabilnost i rizik projekta) kao i menadžment kompanije, modeli asimetričnih informacija temelje se na pretpostavci da kreditori (principali, autsajderi, zajmodavci) ne mogu bez troškova pribaviti informaciju o mogućnostima i akcijama dužnika (agenta, poduzetnika). Kreditna su tržišta specifična upravo po tome što ih karakteriziraju problemi principala i agenata (odnosi između

tvrtke i-investitora te zajmoprimca izajmodavca). Problemi principala i agenata na financijskom se tržištu prevladavaju financijskim ugovorom.

Budžetsko ograničenje poduzeća dakle određeno problemom ugovaranja kreditnog ugovora između principala i agenta, a optimalno budžetsko ograničenje se održava u standardnom kreditnom ugovoru s mogućnošću bankrota (Gale i Hellwig, 1985). Standardni dugovni ugovor (engl. *standard debt contract*), SDU, sadržava tri ključne značajke (Gale i Hellwig, 1985): 1) kada je dužnik solventan, ugovor propisuje fiksne isplate prema kreditoru, 2) u uvjetima nemogućnosti izvršavanja fiksnih uplata (ogluhe na plaćanje), dužnik proglašava bankrot i 3) pri bankrotu se kreditor u što većem iznosu namiruje iz neto vrijednosti dužnika.

Općenito, na asimetričnosti informacija temelje se tri vrste modela (Bernard, 2005):

1. Modeli nepovoljnog izbora (engl. *adverse selection*) – informirana strana raspolaže nesavršenim informacijama o neinformiranoj strani, a neinformirana strana djeluje prva. S aspekta racioniranja kredita, dužnici koji imaju manji poticaj za vraćanje kredita imaju veći poticaj da traže kredit.
2. Moralni hazard – neinformirana strana djeluje prva. U kontekstu kreditnih tržišta opisuje situaciju u kojoj se dužnici mogu koristiti sredstvima na način koji je protivan interesima vjerovnika (uživanje privatnih koristi).
3. Modeli signalizacije – situacija je ista kao i pri nepovoljnu izboru, ali informirana strana djeluje prva.

Sva tri oblika nesavršenosti pridonose racioniranju kredita. Međutim, zašto banke ne financiraju projekte s pozitivnom neto sadašnjom vrijednosti ako imaju dovoljno raspoloživih sredstava (ako je potražnja veća od ponude pri danoj cijeni)? Stiglitz i Weiss (1981) među prvima su pružili odgovor na ovo pitanje pokazavši da u ekvilibriju tržište kredita može biti karakterizirano racioniranjem kredita. Problem se može objasniti kao rezultat moralnog hazarda ili nepovoljna izbora. S aspekta nepovoljna izbora, rast kamatne stope odvlači „dobre“ investitore, a zadržava one s manjom vjerojatnošću povrata posuđena iznosa. Stoga funkcija očekivane profitabilnosti banke s obzirom na kamatnu stopu ima oblik obrnuta slova U. Banka je spremna ponuditi kredite po ravnotežnoj kamatnoj stopi, pri kojoj potražnja nije jednaka ponudi. Banka ne želi ponuditi kredite po većoj kamatnoj stopi jer se povećanjem kamatne stope povećava i rizik ukupnog portfelja kredita i posljedično smanjuje očekivani prinos banke. S druge strane, poduzetnik ima sve manji udio u budućem profitu što smanjuje motiviranost za

konačno ostvarenje projekta. S aspekta moralnog hazarda, rastom kamatne stope raste privatna korist dužnika, to jest dužnik je demotiviran za ostvarenje projekta. Slično, povećanje kolateralnog ograničenja ne povećava prinos banke, jer veće kolateralno ograničenje odvlači investitore s dobrim bonitetom, a privlači one s lošim. Ukratko, racioniranje kredita ravnotežni je fenomen, a produkt je asimetričnosti informacija između dužnika i vjerovnika.

Opisani je model važan za razumijevanje međuodnosa investicija i stanja financijskih tržišta. Poduzećima može biti ograničeno izvanjsko financiranje zbog racioniranja kredita. Racioniranje kredita planirano je ograničavanje njihove ponude. Ako poduzetnik ima više istovjetnih zahtjeva za kredit, neki će biti prihvaćeni, a neki neće. Drugim riječima, racioniranje kredita ravnotežno je stanje potaknuto asimetričnošću informacija između dužnika i vjerovnika, pri čemu asimetričnost informacija može imati oblik moralnog hazarda ili nepovoljna izbora.

Prije prikaza ključnih teorijskih radova potrebno je objasniti i pojam financijskog ograničenja. Financijski ograničenima smatraju se poduzeća koja imaju investicijske prilike s pozitivnom neto sadašnjom vrijednosti, ali ih ne mogu financirati zbog tržišnih nesavršenosti koje su posljedica asimetričnosti informacija između principala i agenta. Nisu sve tvrtke, koje ne mogu ostvariti eksterno financiranje financijski ograničene. One koje imaju loše projekte ili je određenom tehnologijom nadzora ustanovljeno da ne mogu vratiti kredit ne smatraju se financijski ograničenima. U nastavku se daje pregled modela principal-agent koji objašnjavaju stanje racioniranja kredita, odnosno financijskog ograničenja poduzetnika kao problema financijskog ugovaranja.

2.3.2 Tiroleov model racioniranja kredita

2.3.2.1 Model fiksnih investicija

U nastavku se prikazuje model racioniranja kredita zbog moralnog hazarda prema Holmstrom i Tirole (2011) i Tirole (2006)[7]. Ovo je samo jedan od dostupnih modela, koji opisuju ulogu

[7] Moralni hazard može se objasniti na više načina. Neki primjeri uključuju nedovoljan trud poduzetnika, pokretanje projekata koji nisu u interesu vlasnika (engl. *pet projects*), ulaganje u postojeću industriju radi očuvanja pozicija, rast privatne koristi uživanjem u neposlovnim aktivnostima na trošak tvrtke i dr.

financijskih faktora na investicije poduzeća. Model je važan jer teorijski objašnjava utjecaj financijskog ograničenja na investicije, što je glavni predmet ovog rada.

U modelu postoje poduzeća (dužnici, insajderi, upućeni) i investitori (vjerovnici, kreditori). Oba agenta imaju neutralan odnos prema riziku (engl. *risk neutral*). Poduzeće nema dovoljno sredstava za financiranje projekta, koji zahtijeva investiranje fiksnog iznosa I. Realizacija projekta zahtijeva dodatno, eksterno financiranje u iznosu $I - A$, gdje je A neto vrijednost poduzeća. Sposobnost zaduživanja određena je neto vrijednošću poduzeća A. Neto vrijednost poduzeća (A) može imati različita određenja; novčana sredstva, kolateral, neto radnoga kapital i dr.. Radi pojednostavnjenja, neto vrijednost u nastavku označuje novac i likvidne vrijednosne papire ili jednostavno kapital koji poduzetnik može osigurati osobno ili putem tvrtke. Poduzetnik novac može investirati ili potrošiti. Važno je napomenuti da se pretpostavlja ograničena odgovornost poduzetnika, pa on ne može ostvariti negativnu vrijednost dohotka. Radi jednostavnosti, pretpostavlja se da investitori ostvaruju nulti profit, to jest postoji savršena konkurencija među njima[8].

U prvom se razdoblju potpisuju financijski ugovori i donose odluke o investicijama, I. U drugom se razdoblju ostvaruju prinosi na investiciju. Projekt može uspjeti i ostvarivati profit $R > 0$ s vjerojatnošću $p \in \{p_H, p_L\}$, gdje je $p_L < p_H$, ili propasti ($R = 0$). Uspije li, dio profita ostaje dužniku, R_b, a dio vjerovniku, R_l. Dakle, dužnik pri uspjehu zarađuje bruto novčani prinos R_b, a pri neuspjehu je prinos 0.

Problem moralnog hazarda uvodi se pretpostavljajući da poduzetnici mogu odlučiti hoće li raditi (djelovati, uložiti napor, ponašati se) ili uživati privatnu korist (nedolično se ponašati, izvlačiti se, zabušavati). Vjerojatnost uspjeha projekta ovisi o potonjem izboru. Vjerojatnost uspjeha projekta, ako poduzetnik ulaže napor, iznosi $p = p_H$ i ne donosi privatnu korist. Ako poduzetnik zabušava, vjerojatnost uspjeha projekta iznosi $p = p_L$ i on uživa privatnu korist

[8] Važan je element modela racioniranja kredita sposobnost verificiranja dohotka, odnosno mogućnosti vjerovnika da opazi prinos na projekt. S obzirom na sposobnost verifikacije dohotka projekta, razlikuju se četiri različita pristupa: 1) neverificirajući dohodak, poznat kao „cash register model“, kada vjerovnik ne može opaziti koliki je dio dohotka poduzetnik prisvojio, 2) djelomično verificirajući dohodak poznat kao model troškova verifikacije stanja (opisan u potpoglavlju 2.3.3.), 3) verificirani dohodak kojim je moguće manipulirati i 4) verificirajući dohodak. U ovom jednostavnome modelu dohoci su verificirajući (ne i privatna korist), a investitori pasivni. Ne postoji tehnologija nadzora kojom bi intermedijari smanjili privatnu korist poduzetnika i povećali vjerojatnost uspjeha projekta.

$B > 0$[9]. Privatna korist B i odnos vjerodostojnosti $\Delta p = p_H - p_L > 0$ agencijski su troškovi. Dakle, ako se poduzetnik odluči nedolično ponašati (iskoristiti privatnu korist B), vjerojatnost uspjeha projekta smanjuje se s p_H na p_L.[10]

Utjecaj moralnog hazarda može se objasniti i na sljedeći način. Neka je Z_1 vrijednost investicijske prilike ako poduzetnik uloži napor u projekt (formalno će Z_1 biti definiran kasnije). Neka je Z_0 vrijednost založena dohotka (također će biti definiran kasnije), odnosno vrijednost investicijske prilike s aspekta izvanjskih investitora (kreditora, vjerovnika). Razlika $Z_1 - Z_0$ poduzetnička je renta (engl. *entrepreneurial rent*), a rezultat je moralnog hazarda (mogućnosti poduzetnikova uživanja privatne koristi).

Prije prikaza jednadžbi još jednom se, radi preglednosti, definiraju varijable koje će se upotrebljavati u daljnjoj analizi:

1. $\boldsymbol{I}$: fiksni investicijski trošak projekta.
2. $\boldsymbol{A}$: neto vrijednost poduzeća (novčana sredstva, kolateral); kapital koji poduzetnik može osigurati osobno ili kroz tvrtku.
3. $\boldsymbol{R}$: prinos projekta, koji se sastoji od prinosa poduzeća R_b i prinosa vjerovnika R_l.
4. $\boldsymbol{p} \in \{\boldsymbol{p_H}, \boldsymbol{p_L}\}$**:** vjerojatnost uspjeha projekta ako poduzetnik ulaže napor (p_H) ili zabušava (p_L).
5. $\boldsymbol{B}$: privatna korist poduzetnika
6. $\boldsymbol{Z_1}$: vrijednost investicijske prilike ako se poduzetnik „ponaša".
7. $\boldsymbol{Z_0}$: vrijednost investicijeske prilike s aspekta izvanjskih investitora.

U nastavku se prikazuju poticajna ograničenja vjerovnika i poduzetnika te se izvodi jednadžba racioniranja kredita.

---

[9] Holmstrom i Tirole (2011) navode dva moguća razloga postojanja privatne koristi: egzogeno ograničenje isplate prinosa i endogeno ograničenje. Egzogeno ograničenje može uključivati uživanje socijalnog statusa pri uspjehu, uživanje u projektu te razlike u očekivanjima između poduzetnika i investitora. Endogeno ograničenje podrazumijeva prepuštanje dijela dohotka poduzetniku zbog poticajnih faktora (izbjegavanje prisvajanja outputa). Poduzetnik se neće truditi ako sav dohodak pripadne vjerovniku.

[10] Razlika između p_H i p_L može se shvatiti na sljedeći način. Poduzetnik pozajmljen novac može uložiti u efikasnu tehnologiju H, koja daje vjerojatnost uspjeha p_H. Međutim, poduzetnik može ulagati pozajmljena sredstva u neefikasnu tehnologiju L, koja daje manju vjerojatnost uspjeha p_L, ali omogućuje uživanje privatne koristi jer, primjerice, tehnologija L može biti jeftinija od tehnologije H.

Vrijednost investicijske prilike ako se poduzetnik „ponaša“ dana je sa $Z_1 = p_H R$. Pretpostavlja se da projekt ima pozitivnu neto sadašnju vrijednost ako poduzetnik uloži trud u projekt (to jest, ne uživa privatnu korist):

$$p_H R - I > 0 \tag{55}$$

ali negativnu neto sadašnju vrijednost ako poduzetnik zabušava (uživa privatnu korist B):

$$p_L R - I + B < 0 \tag{56}$$

iz čega je vidljivo da vjerovnik ostvaruje gubitak ako se neprimjereno ponaša (zabušava) pa ugovori koji potiču takvo ponašanje neće biti ni nuđeni. U modelu je zadovoljeno ograničenje nultog profita kreditora, koje je, pod pretpostavkom da je poduzetnik uložio napor u projekt, dano jednadžbom:

$$p_H R_l = I - A \tag{57}$$

Riječima, prinos projekta koji pripada vjerovniku mora biti jednak pozajmljenu iznosu.

Najzanimljivije je analizirati pod kojim će uvjetima poduzeće pokrenuti projekt (investirati). Poduzimanje investicijskog pothvata zahtijeva zadovoljavanje dvaju ograničenja. Prvo ograničenje odražava uvjete pod kojima će poduzetnik uložiti napor u projekt. Poduzetnik će uložiti napor ako je zadovoljeno poticajno kompatibilno ograničenje (engl. *incentive compatibility constraint*)[11]:

$$p_H R_b > p_L R_b + B \; ili \; \Delta p R_b \geq B \tag{58}$$

gdje je $\Delta p = p_H - p_L > 0$. Riječima, prinos na projekt uz ulaganje truda veći je od zbroja prinosa na projekt pri zabušavanju i privatnoj koristi. Maksimalni očekivani dohodak koji se može obećati kreditorima – očekivani založeni dohodak (engl. *expected pledgeable income*), pri uspjehu projekta, dan je sa:

$$Z_0 = p_H[R - B/\Delta p]$$

Izraz $Z_1 - Z_0 = p_H B/\Delta p$ naziva se agencijska (poduzetnička) renta – minimalni očekivani novčani izdatak koji zahtijeva dužnik kako bi imao poticaj za djelovanje. Sada se osnovna

[11] Općenitija bi formula bila: $p_H X_S + (1 - p_H)X_F \geq p_L X_S + (1 - p_L)X_f + B$, gdje je $X_S(X_f)$ poduzetnikova vrijednost bogatstva ako projekt uspije (podbaci). Jednadžba (57) pretpostavlja $X_f = 0$ (minimiziranje rente).

pretpostavka može zapisati na način $Z_0 < I < Z_1$: projekt ima pozitivnu neto sadašnju vrijednost ($I < Z_1$), ali se ne može samofinancirati ($Z_0 < I$). Iznos $I - Z_0$ mora osigurati poduzetnik.

Budući da kreditor mora dostići točku pokrića kako bi financirao projekt, drugi nužan uvjet financiranja jednakost je očekivana založenog dohotka i izdataka kreditora (participacijsko ograničenje, individualno racionalno ograničenje ili ograničenje točke pokrića)[12]:

$$Z_1 = p_H[R - B/\Delta p] \geq I - A \tag{59}$$

što donosi nužan uvjet financiranja projekta:

$$\bar{A} = p_H \frac{B}{\Delta p} - (p_H R - I) = I - Z_0 \tag{60}$$

Samo tvrtke koje zadovoljavaju $A > \bar{A}$ mogu financirati projekt. Jednostavno rečeno, dužnik (poduzetnik, tvrtka) mora imati dovoljno sredstava(A) kako bi mu se odobrio kredit. U suprotnom neće moći privući financiranje čak i kada projekt donosi pozitivan NSV, to jest, kredi će se racionirati. Ako poduzetnik raspolaže malim iznosima sredstava, potreban je veliki iznos eksternog financiranja kako bi pokrio svu investiciju. Međutim, što je veći iznos eksternog financiranja, udio je profita koji ostaje poduzetniku manji, što ga demotivira da uloži trud u projekt. Važno je ponovno podsjetiti da je ključan uvjet postojanja racioniranja kredita postojanje poduzetničke rente: $Z_1 - Z_0 > 0$. Ako je $Z_1 = Z_0$ ili je $A > I$, svi projekti s pozitivnim NSV-om bit će financirani jer poduzetnik ima dovoljno internih sredstava za financiranje projekta.

Korisnost poduzetnika također ovisi o vrijednosti A. Ako je $A < \bar{A}$, korisnost je jednaka $U = A$, a ako je $A > \bar{A}$, korisnost je jednaka $U = A + Z_1 - I$. Ako je $A < \bar{A}$, transferiranje sredstava od investitora prema poduzetnicima povećavat će društveni output, ali neće donijeti Pareto poboljšanje (pod pretpostavkom netransferirajuće korisnosti).

Ukratko, u modelu postoje dvije determinante kreditnog ograničenja (Tirole, 2006): 1) niska razina novčanih sredstava (nizak A), 2) visoki agencijski troškovi kao kombinacija privatne koristi B i omjera vjerodostojnosti $\Delta p/p_H$.

[12] Općentiji zapis ima sljedeću formu: $p_H(R - X_S) + (1 - p_H) - X_F \geq \mathrm{I} - \mathrm{A}$.

Mnogi empirijski radovi koji su testirali financijske frikcije u korporativnim investicijama odražavaju intuiciju iz ovog jednostavnog modela: 1) eksterni izvori financiranja skuplji su od internih izvora i 2) uz konstantne investicijske prilike, smanjenje neto vrijednosti smanjuje investicije.

Postojanje financijskog ograničenja u empirijskim radovima često se procjenjuje osjetljivošću investicija na novčane tokove za različite skupine poduzeća. Budući da se i u ovom radu financijsko ograničenje testira osjetljivošću investicija na novčane tokove, važno je razumjeti kakvi se rezultati mogu očekivati na temelju prikazana modela. Prema prikazanu modelu, stvaranje novčanog toka može pridonijeti rastu investicija za granične tvrtke, čiji je iznos novčanih sredstava, A, vrlo blizu, ali ispod granice $\bar{A} = I - Z_0$. Tvrtke koje raspolažu novčanim sredstvima iznad $\bar{A}$, ne povećavaju investicije zbog rasta novčanih tokova ili pada agencijskih troškova jer je ta skupina poduzeća i prije rasta bila financijski neograničena. Ukratko, utjecaj novčanog toka na investicije u agregatnom smislu najviše će ovisiti o distribuciji tvrtki s obzirom na A i Z_0.

2.3.2.2 Kontinuirani model investicija

U Tirole (2006) su pružene različite modifikacije modela iz potpoglavlja 2.3.2.1.. Ovdje će se posebno ispitati modifikacija u kojoj su investicije kontinuirana varijabla $I \in [0,\infty\rangle$. Pri uspjehu, tvrtka ostvaruje dohodak RI (konstantni prinosi na opseg), a pri neuspjehu 0. Pri zabušavanju, dužnik ostvaruje privatnu korist BI s vjerojatnošću uspjeha p_{L}. Kreditor pri neuspjehu prima 0, a pri uspjehu R_l, pri čemu je $R_l + R_b = RI$. Kao i prije, NSV projekta je pozitivan ako se poduzetnik „ponaša“ ($p_H R > 1$) te negativan ako zabušava ($1 > p_L R + B$). Kako bi se uklonila mogućnost beskonačnih investicija, pretpostavlja se

$$p_H R < 1 + \frac{p_H B}{\Delta p} \tag{61}$$

to jest, očekivani profiti po jedinici investicija manji su od agencijskih troškova po jedinici investicija.

Slijedeći analizu modela fiksnih investicija, poticajno kompatibilno ograničenje dano je s

$$(\Delta p) R_b \geq BI \tag{62}$$

a uvjet doprinosa pokriću (engl. *breakeven condition*)

$$p_H(RI - R_b) \geq I - A \tag{63}$$

Tržišta su kapitala kompetitivna, pa kreditori ostvaruju nulti profit. Socijalni je višak tada jednak neto korisnosti dužnika $(p_H R - 1)I$, a za dužnika je optimalno investirati što je više moguće. Međutim iznos investicija određen je kreditnom sposobnošću (sposobnošću izvanjskog financiranja), koja se dobije uvrštavanjem jednadžbe (63) u jednadžbu (62):

$$I \leq kA \tag{64}$$

gdje je

$$k = \frac{1}{1 - p_H(R - B/\Delta p)} > 1 \tag{65}$$

multiplikator koji odražava polugu poduzeća. Dakle, za poduzeće koje ima vrijednost novca A, optimalno je investirati kA. Drugim riječima, poduzeće će pozajmiti iznos $d = k - 1$. Maksimalni kredit dA označuje kreditnu sposobnost poduzeća. Zanimljivo je primijetiti da je financijska poluga d/k manja od 1.

Važan pojam za razumijevanje kreditnog ograničenja jest i cijena u sjeni za kapital (novčana sredstva) i bruto korisnost poduzetnika:

$$v = \frac{p_H B/\Delta p}{1 - p_H(R - B/\Delta p)} A \tag{66}$$

$$U_b^g \equiv vA \tag{67}$$

Cijena u sjeni za kapital rastuća je funkcija prinosa po jedinici investicija, R, i stupnja moralnog hazarda.

Ako se uvede oznaka $\rho_0 = p_H(R - B/\Delta p)$, u modelu varijabilnih investicija, osjetljivost novčanih investicija na novčane tokove dana je s:

$$\frac{\partial}{\partial \rho_0}\left(\frac{\partial I}{\partial A}\right) = \frac{1}{(1 - \rho_0)^2} > 0 \tag{68}$$

Tvrtke s manjim stupnjem financijskog ograničenja (manjim agencijskim troškovima), pokazuju veće osjetljivosti investicija na novčane tokove. U okviru jednadžbe (64) imaju veći

multiplikator i, stoga, veću osjetljivost investicija na novčane tokove. U potpoglavlju 3.2.1. pokazani su empirijski testovi osjetljivosti investicija na novčane tokove.

2.3.2.3 Utjecaj prezaduženosti na financiranje novih projekata

Prezaduženost (engl. *debt overhang*) je situacija u kojoj tvrtka zbog visoke zaduženosti ne može osigurati izvanjsko financiranje za nove investicijske prilike, čak i kada ima pozitivnu neto sadašnju vrijednost. Prezaduženost poduzeća stoga pridonosi racioniranju kredita. Međutim, ona je samo jedan od razloga pojave fenomena racioniranja kredita. Racioniranje kredita može iskusiti i poduzeće bez dugova. Tirole (2006) ističe dva izvora fenomena prezaduženosti: 1) smanjenje neto vrijednosti i 2) nemogućnost ponovnog pregovaranja.

Prvi razlog podrazumijeva (Tirole, 2006):

$$A > \bar{A} > A - D \geq 0 \tag{69}$$

Projekt bi bio financiran kada ne bi postojali dugovi D nastali u prethodnom razdoblju. Ovaj je rezultat posljedica modela opisanog u potpoglavlju 2.3.1.

U nastavku se opisuje utjecaj drugog razloga na prezaduženost i investicije. Pojava prezaduženosti zbog nemogućnosti pregovaranja o postojećim dugovima započela je s radom Myersa (1977), a u nastavku se prikazuje analiza Bhattacharya i Faure-Grimaud (2001) koja se nastavlja na Myersovu analizu (1977). Radi lakšeg praćenja analize, zadržava se notacija iz prethodne točke.

Postoje tri razdoblja. U vremenu t_0 tvrtka potpisuje ugovor o dugu nominalne vrijednosti D. Dug se otplaćuje u vremenu t_2, kada se realiziraju i prinosi na projekt. R_s označuje profit u stanju s gdje je $s = s_1, \dots, S$. *Ex ante* vjerojatnost da nastupi stanje s označeno je s p_s. U vremenu t_1 vlasnici kapitala (insajderi) mogu pokrenuti novu investiciju. Investicijski trošak za novu investiciju iznosi I, a primici stvoreni investicijom, u vremenu t_2 iznose Y_s. Dakle ukupni primici u vremenu t_2 iznose $\{R_s + Y_s\}_{s=1,..,S}$, ako vlasnici poduzmu investiciju u t_1, odnosno $\{R_s\}_{s=1,..,S}$, ako je ne poduzmu. Stanja su poredana $R_1 \leq \cdots \leq R_S$, što se zadržava i kada je poduzeta druga investicija, $\{R_1 + Y_1\} \leq \cdots \leq \{R_S + Y_S\}$. Nova se investicija može financirati samo emisijom novih izvanjskih potraživanja (engl. *outside claims*), to jest vrijednosnica.

Tri su osnovne pretpostavke modela:

1. Fenomen prezaduženosti postoji ako vrijedi:

$$\sum_{s=1}^{S} p_s \max\{R_s + Y_s - D, 0\} - I \leq \sum_{s=1}^{S} p_s \max\{R_s - D, 0\}, iako \sum_{s=1}^{S} p_s Y_s - I \geq 0 \tag{70}$$

2. Investicijska odluka vlasnika kapitala nije provjerljiva (engl. *non-contractibility*)
3. Konačni primici $Z_s \in [R_S, R_S + Y_S]$ su provjerljivi, ali ne i stanje s.

Potonja formalna rasprava može se dodatno objasniti pomoću primjera. Neka postoje samo dva stanja, $S = \{1,2\}$, s jednakom vjerojatnosti nastanka svakog stanja. U vremenu t_0 tvrtka emitira dug s nominalnom vrijednošću D kako bi finanicrala projekt s primicima $R_1 = 90$ i $R_2 = 130$. U vremenu t_1 pojavljuje se nova investicijska prilika s troškom $I = 10$. Projekt stvara dodatne primitke u oba stanja, $Y \geq 10$. Ako bi primici bili manji od deset, projekt bi imao negativnu neto sadašnju vrijednost, što je nezanimljiv slučaj. Tvrtke su zaštićene institutom ograničene odgovornosti.

Neka je $D = 110$. Ako poduzeće ostvaruje primitke Y manje od 20, bit će ispunjena prva pretpostavka. Iako projekt ima pozitivnu neto sadašnju vrijednost, neće biti financiran zbog toga jer je lijeva strana jednadžbe (70) manja od desne strane. Međutim, ako bi inicijalni investitori oprostili dio dugovanja, tako da dug iznosi $D = 100$, reprogramiranje duga i uklonilo bi problem zaduženosti i projekt bi mogao biti financiran. Dakle, smanjenje duga na 100 uz uvjet poduzimanja investicija stvara korist za sve tri strane. Međutim, ako se poduzimanje investicija ne može ugovoriti (engl. *non-notability*), uz to što će kreditori oprostiti dugove treba uzeti u obzir i mogućnost nepoduzimanja investicija. Tada bi najmanja nominalna vrijednost dugova koju bi prihvatili vjerovnici iznosila $D = 100$ jer je očekivani primitak vjerovnika jednak 15 bez obzira na to pokrene li se investicija ili ne. S druge strane, ako se dug smanji na 100, vlasnici kapitala spremni su investirati samo ako je $Y \geq 15$.

Autori predlažu drugu mogućnost. Umjesto smanjenja dugova, dužnik i vjerovnik mogu sklopiti ugovor o dužničko-kapitalnoj zamjeni (engl. *Debt-Equity Swap Contract*). Primjerice, dužnici mogu vjerovnicima ponuditi bezrizični dug u iznosu $D' = 90$ i udio u kapitalu, α. Očekivani primici kreditora tada iznose

$$\alpha\left[\frac{1}{2}(90+Y-90)+\frac{1}{2}(130+Y-90)\right]+90$$

Ovaj je izraz veći od 100 (iznosa reprogramiranog duga) samo ako je $\alpha > \frac{1}{2} + Y$. Za vlasnike kapitala očekivani primici iznose:

$$(1-\alpha)\left[\frac{1}{2}(40+Y)+\frac{1}{2}(Y)\right]-10 \geq (1-\alpha)\frac{1}{2}[40]$$

Ako se α zamijeni najmanjom vrijednosti koju prihvaća vjerovnik, investicija postaje profitabilna za dužnika ako $Y \geq \sqrt{200} = 14.14$. Može se zaključiti da korištenje dugovno-kapitalne zamjene, umjesto jednostavnog oprosta dugova, omogućuje bolji ugovor jer je zahtijevani primitak za točku pokrića vlasnika kapitala manji u drugom slučaju ($14.14 < 15$).

Potonja rasprava odražava važnost oprosta dugova za povećanje investicijske aktivnosti. Prema rezultatima modela, oprost dugova trebao bi pridonijeti rastu investicija ako poduzeće ima profitabilne investicijske prilike i velike dugove. U empirijskom dijelu rada testirat će se utjecaj Zakona o financijskom poslovanju i predstečajnoj nagodbi, koji omogućuje oprost i odgodu dugova, na investicije, pa je važno razumjeti očekivane rezultate modela s obzirom na teorijski prikaz u ovoj točki.

Utjecaj reprogramiranja na investicije može se razumjeti i u okviru Tiroleova modela racioniranja kredita. Ako se pretpostavi da: 1) je dug postojećih investitora stariji dug (engl. *senior debi*), 2) tvrtka mora tražiti financiranje od novih izvanjskih investitora 3) založeni dohodak novog projekta nije dostatan za pokrivanje starih dugova ($\bar{A} + p_H D > 0$), pa tvrtka ne može pokrenuti projekt s pozitivnom neto sadašnjom vrijednosti jer novi investitori zahtijevaju

$$p_H\left[R-\left(\frac{B}{\Delta p}\right)-D\right] \geq I \;\; ili \; \bar{A}+p_H D \geq 0 \tag{71}$$

što je u suprotnosti s trećom pretpostavkom. Ukratko, tvrtka neće moći pribaviti sredstva od novih investitora ako ponovno ne dogovori oprost dijela duga od inicijalnih investitora. Oprost dijela duga može aktivirati projekt, što može stvoriti korist za sve tri strane – tvrtku, inicijalne investitore i nove investitore.

Ako se potonja razmatranja primijene na četvrtu hipotezu o učincima Zakona o financijskom poslovanju i predstečajnoj nagodbi (oprosta i odgode dugova) na investicije poduzeća, može se očekivati pozitivan utjecaj zakona na investicije. Nakon kontrole za investicijske prilike, tvrtke nakon reprograma smanjuju D i/ili dogovaraju iznos α, što povećava iznos založena dohotka i, konačno, kreditnu sposobnost u financiranju novih projekata.

2.3.3 Trošak verifikacije stanja

Trošak verifikacije stanje (engl. *costly state verification*, *CSV*) ili TVS ima pojedine sličnosti s Tiroleovim modelom racioniranja kredita opisanim u prethodnoj točki. Riječ je o modelu moralnog hazarda u kojem poduzetnik može prisvojiti dio dohotka od projekta, a kreditor ne može djelovati na poticaje poduzetnika. Međutim, prisvajanje dohotka nema oblik privatne koristi (B), već skrivena dohotka. Primjerice, poduzetnik može prijaviti manji dohodak od stvarnog. Ključna je pretpostavka opet postojanje asimetričnosti informacija. Dužnik može opaziti stanje (dohodak) u vremenu 1, a kreditor ne može[13]. Kreditori mogu verificirati stvarnu vrijednost dohotka jedino uz dodatne troškove revizije, K. Ova se vrijednost najčešće interpretira kao trošak u stečajnim postupcima. Stanje imovine tvrtke opaža se pošto se ona ogluši na plaćanje. Ključni radovi, koji se koriste TVS modelom uključuju rad Townsenda (1979) te Galea i Hellwiga (1985), a u nastavku se prikazuje prema Tirole (2006) i Gale i Hellwig (1985).

Dohodak R je slučajna varijabla (zbog slučajne tehnologije ili slučajnih cijena) distribuirana na $[0,\infty\rangle$, s gustoćom $p(R)$[14]. Redoslijed je aktivnosti sljedeći. U prvom se razdoblju potpisuje ugovor o kreditiranju projekta s investicijskim troškovima I (koji se mogu shvatiti kao input u proizvodnom procesu) u iznosu $I - A$. U drugom se koraku ostvaruje dohodak R. Poduzetnik izvještava o realiziranu dohotku, $\hat{R}$. Kreditor odlučuje želi li obaviti reviziju te se na kraju obavlja otplata prema ugovoru. Ugovor je dakle definiran skupom (I, K, A, ξ), gdje je ξ slučajna varijabla jednaka 1 ako investitor opaža stanje u vremenu 1 i 0 u suprotnom slučaju.

[13] Moguće je dodati trošak koji penalizira dužnika ako bankrotira, ali ovdje se apstrarhira za ovo proširenje (za detalje pogledati Gale i Hellwig, 1985).
[14] Gale i Hellwig (1985) uvode distribuciju stanja u razdoblju 1, ali se ovdje slijedi pristup distribucija profita prema Tirole (2006).

Provjera stanja (dohotka) u razdoblju 1 izaziva investitoru trošak pa se ne može očekivati opažanje u svakom stanju. Provedba ugovora stoga zahtijeva otkrivanje poduzetnikova dohotka, $\hat{R}$. Na temelju informacije o prijavljenu dohotku investitor odlučuje želi li opaziti stvarno stanje R i platiti troškove revizije, K. Radi jednostavnosti, pretpostavlja se da odluka o otkrivanju stvarnog stanja, $\xi(R)$ može poprimiti vrijednost 0 ili 1 za svaki R. Uz izostanak revizije, prinos investitora iznosi $R_1(\hat{R})$ te $R_1(\hat{R}, R)$ pri reviziji. Za poduzetnika, uz izostanak revizije, $\xi(R) = 1$, nagrada iznosi $\omega_0(\hat{R}, R) = R - R_1(\hat{R})$, te $\omega_1(\hat{R}, R) = R - R_1(\hat{R}, R)$ u suprotnom. Potonje se kompaktnije može zapisati na sljedeći način (Tirole, 2006)[15]

$$\omega(R) \equiv \xi(\hat{R})\omega_0(R, R) + \left(1 - \xi(\hat{R})\right)\omega_1(R, R)$$

Ugovor je dakle definiran skupom (I, K, A, ξ): definiranje iznosa duga D, izostanak revizije ako je dug D isplaćen te revizija i izostanak nagrade ako dug nije otplaćen. Formalno, ako je $R \geq D$, tada je , $\xi(\hat{R}) = 1$, a ako je $R < D$, tada je , $\xi(\hat{R}) = 0$, i $\omega(R) = \max(R - D, 0)$.

Optimalni ugovor maksimira očekivani dohodak dužnika s obzirom na poticajno ograničenje dužnika i ograničenje točke pokrića kreditora:

$$\max_{\xi, \omega_0 \omega_1,} \left\{ \int_0^\infty \omega(R) p(R) \mathrm{dR} \right\} \tag{72}$$

$$\omega(R) = \max_{\hat{R}} \left\{ \xi(\hat{R})\omega_0(\hat{R}, R) + \left(1 - \xi(\hat{R})\right)\omega_1(\hat{R}, R) \right\} \tag{73}$$

$$\int_0^\infty [R - \omega(R) - [1 - \xi(R)]K] \; p(R) dR \geq I - A \tag{74}$$

Ako investitor ne opaža stanje, D iznosi $R_1(R)$. Pri reviziji ukupan prinos ne može biti veći od D. Ekonomski gledano, skup koji predstavlja udio dohotka u kojem nema revizije potreban je radi uštede troškova revizije.

Prikazani modeli pokazuju da je dug optimalan ugovor za financiranje investicija jer uklanja potrebu za provjerom vrijednosti kolaterala kada se ugovor potpisuje i pri otplati duga. Samo će kad je posrijedi ogluha na plaćanje postojati potreba za vrednovanjem kolaterala (Holmstrom, 2015).

[15] Analiza implicira da vrijedi princip otkrivanja. Jednostavno rečeno, dužnik ima poticaj prijavljivati stvarno stanje (Gale i Hellwig, 1985.)

2.3.4 Teorija hijerarhije financijskih izbora

Počevši od Fazzaria i dr. (1988), stupanj financijskog ograničenja testira se osjetljivošću investicija na novčane tokove za različite, apriorno utvrđene skupine poduzeća. Osnovna je pretpostavka modela da kreditno ograničene tvrtke mogu financirati investicijske projekte samo iz internih izvora, pa bi one trebale pokazivati veće osjetljivosti investicija na novčane tokove od neograničenih tvrtki (za detaljan pregled pogledati poglavlje 3.2.). Empirijski su radovi također pokazali da interni izvori financiranja imaju najveći udio u ukupnoj strukturi financiranja, a slijedi ih eksterno financiranje dugom (pogledati poglavlje 4.4.). Brojni radovi u posljednja dva desetljeća pokušavaju objasniti ova dva empirijska fenomena.[16] Jedna od utjecajnijih teorija iz korporativnih financija, koja pokušava objasniti ovaj fenomen, teorija je hijerarhije financijskih izbora (engl. *hierarchy of finance model* ili *pecking-order theory*). Jednostavno rečeno, teorija pretpostavlja da troškovi financiranja rastu s rastom asimetričnosti informacija, pa menadžment pri odluci o financiranju investicija preferira interna sredstva kao najjeftiniji izvor financiranja. Slijedi financiranje dugom, a na kraju financiranje kapitalom kao najskuplji oblik financiranja. Teoriju je popularizirao rad Myersa i Majfula (1984). U nastavku se prikazuje model spomenutih autora, ali, radi konzistentne , i model prema Tirole (2006).

Dosadašnji modeli (poglavlja 3.2., 3.3.) objašnjavaju fenomen financijskog ograničenja uz pretpostavku postojanja moralnog hazarda, a teorija hijerarhije financiranja proučava se unutar modela nepovoljna izbora. Za razliku od prvih modela, u kojima poduzetnik može uživati privatnu korist, modeli nepovoljna izbora pretpostavljaju da poduzetnik ima potpunu informaciju o investicijskom projektu ili karakteru poduzetnika, a investitori imaju samo djelomičnu informaciju. Asimetričnost informacija između investitora i poduzetnika glavno je odstupanje od modela Modigliania i Millera (1958).

Poduzetnik nema sredstava ($A = 0$) za financiranje investicijskog projekta s troškom I. Projekt donosi prinos $\mathrm{R^F}$ pri neuspjehu (likvidacijska vrijednost, engl. *salvage value*) i $\mathrm{R^F} + \mathrm{R} = \mathrm{R^S}$ pri uspjehu. Kamatna je stopa normalizirana i iznosi 0 (nema diskontiranja). Ako je dužnik „dobar“, vjerojatnost uspjeha projekta iznosi p, a ako je loš, iznosit će q. Pretpostavlja se $\mathrm{p} > \mathrm{q}$ i $\mathrm{pR} > \mathrm{I}$. Poduzetnik posjeduje privatnu informaciju o tipu menadžera (dobar/loš). Kapitalna

[16] U potpoglavlju 2.2.6. pokazano je da je prema MM teoriji struktura kapitala irelevanatna za vrijednost tvrtke. Tvrtka je indiferentna prema izvorima financiranja investicijskih projekata.

su tržišta kompetitivna i zahtijevaju prinos 0 te pridružuju vjerojatnosti α i $1-\alpha$ da će poduzetnik biti dobar/loš. Asimetričnost informacija (točnije nepovoljan izbor) očituje se u tome da investitori ne znaju tip poduzetnika (dobar/loš).

Očekivana vjerojatnost uspjeha dana je s $m = \alpha p + (1-\alpha)q$. Pretpostavlja se da je založeni dohodak veći od investicijskog troška: $mR^S + (1-m)R^F > I$. Neka $\{R_b^S, R_b^F\}$ označuje prinose poduzetnika pri uspjehu i neuspjehu. Točka pokrića investitora dana je s

$$m(R^S - R_b^S) + (1-m)(R^F - R_b^F) \geq I \tag{75}$$

Dobar dužnik maksimira

$$pR_b^S + (1-p)R_b^F \tag{76}$$

S obzirom na uvjet (75). U optimumu, ograničenje (75) je vezano pa se dobiva (Tirole, 2006, str. 247):

$$\begin{aligned} pR_b^S + (1-p)R_b^F \\ = [pR^S + (1-p)R^F - I] - (1-\alpha)(p-q)[(R^S - R_b^S) - (R^F \\ - R_b^F)] \end{aligned} \tag{77}$$

Prva uglata zagrada na desnoj strani jednadžbe (77) označava sadašnju vrijednost dobrog dužnika, a druga zagrada diskont nepovoljna izbora (engl. *adverse-selection discount*). Kako je diskont rastuća funkcija od R_b^F, dužnik bira $R_b^F = 0$, to jest kompletnu likvidacijsku vrijednost založit će za siguran dug. Ostatak sredstava prikuplja emitiranjem kapitala:

$$m(R^S - R_b^S) = I - R^F \tag{78}$$

Što su veći investicijski troškovi *I* ili što su veći problemi nepovoljna izbora, poduzetnik će morati emitirati više kapitala. Zaključak je da investitor prvo založi likvidacijsku vrijednost radi emitiranja duga, a tek potom emitira kapital.

Kako su istaknuli Fazzari i dr. (1988) te Bond i Meghir (1994), teorija hijerarhije financiranja podrazumijeva veliku osjetljivost investicija na novčane tokove, posebno u financijski ograničenim poduzećima. Provedeno je mnogo empirijskih testova ove hipoteze, a njihov pregled dan je u poglavlju 3. Teorija hijerarhije izbora objašnjava i pozitivnu korelaciju

profitabilnosti tvrtke i niskih vrijednosti pokazatelja financiranja. Jednostavno, visoko profitabilne tvrtke ne posuđuju kapital zato što im ne treba eksterno financiranje za rast. Drugim riječima, ne postoji ciljana struktura kapitala koju tvrtka smatra primjerenom.

Druge dvije važne teorije strukture kapitala jesu teorija kompromisa (engl. *trade-off theory*) i teorija slobodnih novčanih tokova (engl. *free cash flow theory*). Prema teoriji kompromisa, tvrtka posuđuje sredstva do iznosa gdje je granična vrijednost poreznog štita od dodatnog zaduženja jednaka povećanju sadašnje vrijednosti troškova financijskih poteškoća (Myers, 2001). Ova teorija predviđa visoke iznose financijske poluge za tvrtke visoke kreditne sposobnosti, što je često u suprotnosti s dostupnim podacima (visoka je korelacija između profitabilnosti i niske financijske poluge). Teorija slobodnih novčanih tokova predviđa rast vrijednosti tvrtke pri visokim omjerima zaduženosti usprkos troškovima financijskih poteškoća ako operativni novčani tokovi tvrtke nadmašuju profitabilne investicijske prilike (Myers, 2001). Kako je predmet ovog rada međuovisnost strukture kapitala i odluke o investicijama, a ne strukture kapitala tvrtki *per se*, u nastavku se neće dati detaljnija teorijska rasprava o pristupima kao ni empirijski testovi koji su testirali spomenute teorije.

2.4 Značajke likvidnog ograničenja poduzeća

U ovom se poglavlju opisuje međuodnos investicija i likvidnosti poduzeća. Prvo se u poglavlju 2.4.1. heuristički opisuje pojam likvidnog ograničenja te se razlikuju financijska i likvidna ograničenja. U poglavlju 4.2. opisuje se Tireolov model preventivne potražnje za likvidnošću i njezin utjecaj na investicijsku dinamiku.

2.4.1 Heuristički opis likvidnog ograničenja

Jedan je od ključnih doprinosa ovog rada razlikovanje financijskog i likvidnog ograničenja prilikom testiranja utjecaja financijskih frikcija na investicije poduzeća. Ekonomska teorija ova dva pojma, barem kada je riječ o ponašanju tvrtki, najčešće upotrebljava kao sinonime. U okviru analize parcijalne ravnoteže tvrtki riječ je o situaciji kada poduzeća ne mogu financirati projekte usprkos pozitivnoj neto sadašnjoj vrijednosti projekta. U prošlom je poglavlju pokazano kako

modeli racioniranja kredita donose financijsko *ili* likvidno ograničenje. U nastavku se opisuje razlika između ovih dvaju pojmova te se opisuju značajke likvidnog ograničenja.

Prvo, treba naznačiti da se sadržaju likvidnosti u literaturi i praksi pripisuju različita značenja. Jednom se pod likvidnosti podrazumijeva mogućnost monetizacije ili realizacije određena oblika imovine, odnosno vremenska udaljenost sredstva od oblika novca. Primjerice, kratkotrajna su potraživanja likvidnija od nekretnina jer se brže i uz manje troškove mogu transformirati u novac. Drugo shvaćanje likvidnost izjednačuje sa sposobnošću plaćanja dospjelih obveza. Ako poduzeće može plaćati dospjele obveze, likvidno je. U ovom se radu sposobnost plaćanja dospjelih obveza definira kao (tehnička) solventnost. Prema takvom shvaćanju, ne postoje različite razine ili stupnjevi solventnosti poduzeća; ono je jednostavno solventno ili insolventno. Insolventnost najčešće uzrokuje stečaj, pa se ovom shvaćanju pridružuje pravno obilježje. Treće je shvaćanje likvidnosti dinamično, a odnosi se na „moć raspolaganja i ta se moć očituje kao neka količina raspoloživog novca u nekom trenutku ili razdoblju“ (Tintor, 2009.). Naglasak nije na ocjeni sadašnjeg stanja, nego na mogućnosti prilagođavanja u nekom razdoblju. Poduzeće dakle raspolaže postojećim i potencijalnim novčanim sredstvima. Potencijalni novac podrazumijeva novac pristigao iz uobičajena poslovanja ili novac pristigao prijenosom imovine vjerovniku, prodajom (tržišna likvidnost). Dodatno likvidnost podrazumijeva i mogućnost da se osiguraju dovoljna sredstva za plaćanje dospjelih obveza otvaranjem kreditnih linija ili emitiranjem vrijednosnica (financijska likvidnost). U nastavku ovog rada likvidnosti se pridružuje treće značenje. Likvidnost je sposobnost uspostavljanja i održavanja dužničko-vjerovničkih odnosa uz razumne troškove (Tintor, 2009). Iz ovakve definicije likvidnosti proizlazi i određenje likvidnog ograničenja. Poduzeće je likvidno ograničeno kada ne može održavati dužničko-vjerovničke odnose, odnosno kada je likvidnost ispod normirane (teorijski rečeno optimalne) likvidnosti.

Ovako definirana likvidnost, odnosno likvidno ograničenje, razlikuje se od pojma financijskog ograničenja. Financijsko ograničenje odražava kreditnu sposobnost poduzeća koja je, kako je pokazano, određena neto vrijednošću poduzeća, a likvidno ograničenje odražava sposobnost upravljanja postojećim i potencijalnim novčanim sredstvima, a određena je razinom kratkotrajne imovine i obveza te rizikom transformacije imovine u novac. Kreditna sposobnost uvjetuje mogućnost financiranja u određenom trenutku, a likvidnost je dinamički koncept orijentiran na mogućnost održavanja odgovarajućih proporcija kratkotrajne imovine i obveza. Važno je također istaknuti da financijsko ograničenje ne mora ugrožavati opstanak poduzeća jer ono može rasti internim financiranjem, a nelikvidnost direktno ugrožava opstanak poduzeća

jer implicira nemogućnost ispunjenja obveza u kratkom roku, što donosi financijske poteškoće. Druga je važna razlika u drugom dijelu definicije likvidnosti– „uz razumne troškove“. Naime, s aspekta financijskog ograničenja, ne postoji pretjerana solventnost. Kreditna sposobnost zahtijeva sposobnost izvršavanja obveza po financijskim i trgovačkim kreditima, a uvjetovana je neto vrijednošću poduzeća. S druge strane, likvidnost zahtijeva da se odnosi održavaju uz razumne troškove (postoji određena optimalna razina kojoj se teži). To znači da je za poduzeće, osim nelikvidnosti, jednako opasna i prevelika likvidnost. Pretjerana likvidnost donosi oportunitetne troškove i smanjuje profitabilnost poduzeća.

Nakon definicije valja objasniti važnost likvidnosti za odluke o investicijama. U standardnoj mikroekonomskoj teoriji, u uvjetima savršenih tržišta ne može postojati problem financijskog ili likvidnog ograničenja jer poduzeća mogu zadovoljiti financijske potrebe uzimanjem kredita ili izdavanjem dužničkih ili vlasničkih vrijednosnih papira. Irelevantnost upravljanja likvidnošću i financijskog ograničenja za investicije potječe još od Keynesa (1936). Dokle god postoje savršena tržišta kapitala, odluke su o likvidnosti irelevantne. Ako projekti poduzeća imaju pozitivnu neto sadašnju vrijednost, ona će moći osigurati dostatnu likvidnost za financiranje projekata. Čak i ako poduzeće ima visoke dugove (prezaduženo je) te istodobno raspolaže profitabilnim projektom, može refinancirati postojeće obveze i financirati novi projekt (pogledati poglavlje 3.1.3.). Na savršenim tržištima ne postoji nesigurnost oko transformacije kratkotrajne imovine u novac, pa zbog oportunitetnih troškova nije oportuno gomilati likvidnost radi zaštite od budućih rizika. Također, u uvjetima potpunih tržišta (Arrow-Debreu svijet) tvrtka ima mogućnost kupovati imovinu za zaštitu od svih rizika, pa tako i rizika likvidnosti.

U stvarnosti poduzeća ne čekaju na idiosinkratične (likvidne) šokove nepripremljena. Na početku, kada poduzeće izabire iznos financiranja i investiranja, buduće potrebe za likvidnošću nisu poznate (budući likvidni šokovi imaju karakter slučajnosti). Buduće potrebe za likvidnošću poduzeća mogu osiguravati *ex ante* ili *ex post.* Povećanje likvidnosti *ex ante* podrazumijeva gomilanje likvidnosti, što stvara visoke oportunitetne troškove. *Ex post*, likvidnost može biti osigurana emitiranjem vrijednosnica ili korištenjem kreditnim linijama, ali takvo osiguranje likvidnosti, pošto je nastupio šok likvidnosti, može biti otežano jer se smanjuje ponuda kredita. Tvrtke se mogu koristiti i derivativima, ali su empirijska istraživanja pokazala da su novac i novčani ekvivalenti ipak ključan izvor likvidnosti (Almeida i dr., 2014). U budućem su razdoblju dakle moguća najmanje dva stanja: tvrtka, zbog likvidnog šoka, može biti likvidna ili

nelikvidna, to jest likvidno neograničena ili ograničena. Tvrtka je likvidno ograničena ako s postojećim i potencijalnim novčanim sredstvima ne može financirati postojeće i buduće obveze.

Jedan od ključnih ciljeva ovog rada jest utvrditi postoji li utjecaj stanja likvidnosti (upravljanja likvidnošću) na realne aktivnosti poduzeća, konkretno realne investicije. Empirijska će se procjena temeljiti na testiranju osjetljivosti investicija na novčane tokove kao funkcije stanja likvidnosti. Naime, određen je broj empirijskih radova pokazao da osjetljivost investicija na novčane tokove raste s povećanjem stupnja financijskog ograničenja, a određen je broj radova pokazao upravo suprotno (za detalje pogledati poglavlje 3.2.). Likvidno ograničenje dodaje novu dimenziju u raspravi o međuovisnosti novčanih tokova i investicija. Naime, uspostavljanje likvidnosti prvotni je cilj u hijerarhiji ciljeva poduzeća jer dugoročna nelikvidnost uzrokuje ogluhu na plaćanje i propast poduzeća. Stoga će likvidno ograničena poduzeća novi novčani tok upotrebljavati za uspostavljanje primjerene (normirane, optimalne) likvidnosti, odnosno za prelazak iz skupine nelikvidnih u skupinu likvidnih poduzeća. Dapače, nelikvidna poduzeća radi uspostavljanja likvidnosti mogu biti prisiljena prodavati postojeću imovinu, to jest bilježiti dezinvestiranje. Drugim riječima, likvidno ograničena poduzeća često mogu pokazivati negativnu osjetljivost investicija na novčane tokove. Rast stupnja likvidnosti pridonosi rastu koeficijenta uz novčane tokove. Nakon uspostavljanja primjerene likvidnosti, poduzeća se koriste novim novčanim tokom za investicije (ako postoje investicijske prilike). Međutim, nakon ulaska u fazu pretjerane likvidnosti, osjetljivost investicija na novčane tokove ponovno teži nuli jer novi novčani tok više ne utječe na likvidno ograničenje. Jedino ograničenje za investiranje može biti postojanje investicijskih prilika, agregatna potražnja, neizvjesnost i slično. Drugim riječima, odnos novčanih tokova i investicija po prirodi je nelinearan. Osjetljivost investicija na novčane tokove iznosi nula ili je negativna za likvidno ograničena poduzeća, pozitivna je za granično likvidna poduzeća te je vrlo niska za poduzeća s visokom likvidnošću. Ova teorija ne predviđa malo investicija za prelikvidna ili nelikvidna poduzeća, već objašnjava važnost osjetljivosti investicija na novčane tokove kao funkcije likvidnosti. Osjetljivost investicija na novčane tokove služi kao empirijski dizajn za procjenjivanje hipoteze o postojanju likvidnog ograničenja, kao financijske frikcije, odnosno nesavršenosti na financijskim tržištima.

Međuodnos investicija, novčanih tokova te financijskog i likvidnog ograničenja može se prikazati pomoću slike 2.7. Slika objašnjava odnos novčanog tokova i investicija za četiri različite skupine poduzeća. Skupine se razlikuju s obzirom na stupanj likvidnog i financijskog ograničenja. U prvoj su skupini poduzeća s niskim stupnjem financijskog i likvidnog

ograničenja. Riječ je najčešće o velikim poduzećima koja imaju nisku stopu zaduženosti i visoke stope profitabilnosti. Kao primjer može se navesti hrvatska tvrtka Adris d.d. Investicije ove skupine poduzeća trebale bi pokazivati nisku ili nultu osjetljivost investicija na novčane tokove jer poduzeća imaju dovoljno internih sredstava i dovoljnu kreditnu sposobnost za financiranje investicijskih projekata. Druga skupina označuje poduzeća s visokim financijskim ograničenjem i niskim likvidnim ograničenjem. Ovdje je najčešće riječ o malim, mladim poduzećima koja ostvaruju profitabilno poslovanje, ali nemaju dovoljno založenog dohotka ili kolaterala za eksterno financiranje. Ova se skupina može označiti kao tvrtke s internim rastom. Za njih se očekuje pozitivna osjetljivost investicija na novčane tokove pošto dostignu dovoljnu razinu likvidnih sredstava za zaštitu od očekivanih likvidnih šokova. U trećoj su skupini poduzeća s visokim stupnjem financijskog i likvidnog ograničenja, to jest tvrtke u financijskim poteškoćama. Za ovu skupinu poduzeća očekuje se nulta ili čak negativna osjetljivost investicija na novčane tokove jer poduzeća novi novčani tok upotrebljavaju za uspostavljanje primjerene likvidnosti (efekt likvidnog ograničenja). Četvrtu skupinu poduzeća obilježava niska razina financijskog ograničenja i visoka razina likvidnog ograničenja. U prvi se tren čini da ova skupina nije egzistentna jer niski stupanj financijskog ograničenja implicira mogućnost kreditiranja u bilo kojem trenutku i, , dostatnu likvidnost za održavanje poslovanja. Međutim, postoje poduzeća koja su dugoročno nelikvidna, ali uspijevaju preživjeti zbog netržišnih uvjeta financiranja (meko proračunsko ograničenje). Primjer su u Hrvatskoj brodogradilišta u državnom vlasništvu koja godinama financira država, domaće kompanije koje financiraju strani vlasnici u inozemstvu ili velike kompanije koje pronalaze alternativne izvore financiranja (primjer Agrokora). Ova je skupina poduzeća označena kao Ponzijeva shema jer je održivost poslovanja često uvjetovana spremnosti vjerovnika da financira poduzeće u stanju nelikvidnosti i tehničke insolventnosti. Moguće je i da ovoj skupini pripadaju poduzeća s privremenim šokovima malih iznosa, koji ne ugrožavaju opstanak poduzeća. Poduzeće može prelaziti i iz jedne skupine u drugu. Primjerice, poduzeće s internim rastom zbog pada potražnje može prijeći u skupinu poduzeća s financijskim poteškoćama i prodavati vlastitu imovinu radi ostvarivanja primjerene likvidnosti.

Likvidno ograničenje		Financijsko ograničenje: Nisko	Financijsko ograničenje: Visoko
	Nisko	Tvrtke gomilaju novac (engl. c*ash hoarding firms*)	Tvrtke s internim rastom (engl. *internal growth firms*)
	Visoko	Tvrtke unutar Ponzieve sheme (engl. *Ponzi scheme frims*)	Tvrtke u financijskim poteškoćama (engl. *financial distressed firms*)

Slika 2-7: Međuovisnost financijskog i likvidnog ograničenja

Prema spoznajama autora ovog rada, ne postoji teorijski model investicija koji razlikuje financijsko i likvidno ograničenje. Izuzetak je rad Clearya, Povela i Raitha (2007), u nastavku CPR, u kojem se prvi put uvodi razlika između eksternog i internog financijskog ograničenja. Eksterno financijsko ograničenje odražava nesavršenost na tržištima kapitala i njezin utjecaj na investicije. Interno financijsko ograničenje odražava odnos internih sredstava i investicija. Osnovna je razlika analize CPR-a i prikazanog opisa u predviđanju osjetljivosti investicija na novčane tokove. Autori predviđaju negativnu osjetljivost za sva poduzeća koja nemaju dostatnu razinu neto vrijednosti te pozitivne koeficijente uz novčane tokove za poduzeća s pozitivnom neto vrijednosti. Prema slici 2-7 efekt je kompleksniji i ovisi o međuovisnosti financijskog i likvidnog ograničenja.

Hipoteza o utjecaju likvidnog ograničenja na investicije u skladu je s rezultatima istraživanja o međuovisnosti novčanih tokova i novca (poglavlje 3.2.2.), koja konzistentno potvrđuju pozitivan utjecaj rasta novčanih tokova na razinu novca za financijsko ograničena poduzeća. Primjerice ACW su pokazali da je granična sklonost štednji pozitivna funkcija novčanih tokova za financijski ograničena poduzeća. Rezultati ovih istraživanja pokazuju da financijski neograničena poduzeća ne stvaraju novu likvidnost iz novčanih tokova, što je upravo u skladu s prikazanom teorijom.

U okviru formalnih modela, međuovisnost investicija i likvidnosti najčešće se analizirala u okviru modela potražnje za likvidnošću (novčanim sredstvima). Iako opisivanje modela potražnje za likvidnošću nadilazi predmet i ciljeve ovog rada, važno je razumjeti osnovne

teorijske pristupe izučavanja ovog fenomena. Literaturu koja istražuje ovaj fenomen može se podijeliti u četiri skupine s obzirom na motiv držanja novca (Bates, Kahle i Stulz, 2009.):

1. Transakcijski motiv – optimalna razina novca ovisi o odnosu transakcijskih troškova konvertiranja novca i upotrebi novca za buduća plaćanja. Zbog nižih transakcijskih troškova, veće tvrtke drže manje novca.
2. Motiv preventivne štednje (engl. *precautionary savings*) – tvrtke koje imaju otežan pristup izvanjskom financiranju i koje su izloženije većim rizicima (veća volatilnost novčanih tokova) drže veće svote novca. Ova skupina radova predviđa i veće omjere novca za tvrtke s većim investicijskim prilikama.
3. Porezni motiv – multinacionalne tvrtke drže veće svote novca zbog poreznih troškova povezanih s repatrijacijom zarada ostvarenih u inozemstvu.
4. Motiv agencijskih troškova – što su veći agencijski troškovi između menadžmenta i vlasnika, to su veći iznosi zadržanih zarada i novca.

Sva četiri motiva međusobno utječu na dinamiku držanja novca. U nastavku se opisuju formalni modeli potražnje za likvidnošću i utjecaj likvidnih šokova na investicije unutar modela moralnog hazarda opisanog u poglavlju 2.3.2.. Fokus je na međuovisnosti stanja likvidnosti i korporativne politike upravljanja likvidnošću na investicije. Znatno širi pregled radova o politici upravljanja likvidnošću dan je u radovima Almeida i dr. (2014) i Strebulaev i Whited (2012).

2.4.2 Holmstrom-Tiroleov model potražnje za likvidnošću

2.4.2.1 Model potražnje za likvidnošću u modelu fiksnih investicija

Potražnja za likvidnošću zahtijeva i formalno objašnjenje. U nastavku se prikazuje model prema Holmstrom i Tirole (1998), Tirole (2006) i Holmstroma i Tirole (2011). Model je nadogradnja modela racioniranja kredita opisanog u poglavlju 3.1.1. Kao i u modelu fiksnih investicija, u poglavlju 3.1.1., poduzetnici mogu uživati privatne koristi (kozmetičke investicije, poduzetničke rente i dr.), što stvara jaz između ukupnog i založenog prinosa. Dužnik i kreditor imaju neutralnu sklonost prema riziku, poduzetnik je zaštićen graničnom odgovornošću, a investitori potražuju stopu povrata jednaku nula.

Iako se nadovezuje na model iz poglavlja 3.1.1., model potražnje za likvidnošću sadržava dodatna svojstva. Uvodi se dodatno, srednje razdoblje (razdoblje 1), između razdoblja financiranja (razdoblje 0) i razdoblja realizacije dohotka (razdoblje 2). U međurazdoblju dužnik je pogođen šokom likvidnosti, koji mora prevladati kako bi se nastavio i ostvario uspjeh. Šok likvidnosti može se shvatiti kao potreba za reinvestiranjem, nova investicijska prilika ili pad zarada koji treba amortizirati. Dužnik šok likvidnosti može prevladati na dva načina: gomilanjem likvidnosti ili kreditnom linijom. Gomilanje likvidnosti podrazumijeva čuvanje likvidnih instrumenata prije pojave šoka te monetizaciju tako čuvane imovine ako nastupi šok. Kreditna linija podrazumijeva pribavljanje likvidnih sredstava pri nastanku šoka.

U vremenu 0 dužnik raspolaže imovinom A i posuđuje iznos $I - A$, gdje je I fiksni trošak investiranja. U razdoblju 1projekt stvara deterministički verificirajući dohodak $r \geq 0$. Opstanak projekta zahtijeva reinvestiranje u razdoblju 1, u iznosu ρ, gdje je ρ nepoznat *ex ante* te ima kumulativnu distribuciju $F(\rho)$ s funkcijom gustoće $f(\rho)$ na $[0,\infty\rangle$. Realizacija ρ-a vidljiva je u vremenu 1. Ako tvrtka ne reinvestira u vremenu 1, pokreće likvidaciju. Likvidacijska vrijednost tvrtke iznosi 0. Ako tvrtka reinvestira ρ, u drugom razdoblju stvara dohodak R s vjerojatnošću p ili 0 s vjerojatnošću $1 - p$. Ako se poduzetnik ponaša (ne koristi privatnu korist), vrijedi $p = p_H$, a ako se ne ponaša (uživa privatnu korist) vrijedi $p = p_L = p_H - \Delta p$.

Optimalno je nastaviti s projektom ako je vrijednost nužnog reinvestiranja manja od određene razine:

$$\rho \leq \rho^* \tag{79}$$

Neto korist poduzetnika dana je jednadžbom:

$$U_b(\rho^*) = [r + F(\rho^*)p_H R] - \left[I + \int_0^{\rho^*} \rho f(\rho^*) d\rho\right] \tag{80}$$

gdje je $F(\rho^*) = \Pr(\rho \leq \rho^*)$ vjerojatnost nastavka projekta (tvrtke). Prva zagrada odražava očekivane prihode, a druga ukupne troškove (inicijalna investicija plus očekivana vrijednost reinvestiranja). Dobro ponašanje poduzetnika podrazumijeva osiguranje R_b, tako da vrijedi $(\Delta p)R_b \geq B$.

Založeni dohodak, deflacioniran za investicijske troškove $I - A$ je jednak:

$$\mathcal{P}(\rho^*) - (I - A) = \left[r + F(\rho^*)\left[p_H\left(R - \frac{B}{\Delta p}\right)\right]\right] - \left[I - \int_0^{\rho^*} \rho f(\rho^*) d\rho + A\right] \quad (81)$$

Derivacija jednadžbe (80) i (81) daju dva rezultata: 1) NPV projekta (U_b) raste u ρ^* dok vrijedi $\rho^* < p_H R$, te pada nakon toga, 2) založeni dohodak projekta ($\mathcal{P}$) raste u ρ^*dok vrijedi $\rho^* < p_H\left(R - \frac{B}{\Delta p}\right)$, te pada nakon toga.

S obzirom na kvalitetu bilance plaćanja dužnika, mogu se razlikovati tri slučaja:

1. Efikasan iznos likvidacije: $\mathcal{P}(p_H R) \geq I - A$. Uspostavlja se najbolje rješenje za dužnika ($\rho^* = P_H R$), jer se stvara dovoljan prinos da se pokriju troškovi investitora
2. Efikasan iznos likvidacije: $\mathcal{P}(p_H R) < I - A \leq \mathcal{P}\left(p_H\left(R - \frac{B}{\Delta p}\right)\right)$. U ovom slučaju poduzetnik u međurazdoblju ne dobiva ništa ($r_b = 0$), a pri nastavku dobiva najmanji potreban iznos, $R_b = B/\Delta p$, koji ga potiče na ponašanje.
3. Odsutnost financiranja: $\mathcal{P}\left(p_H\left(R - \frac{B}{\Delta p}\right)\right) < I - A$. U ovom slučaju financiranje nije moguće jer založeni dohodak nije dostatan za kompenziranje troškova investitora.

Iz potonje je analize jasno zašto je nesigurnost oko šoka likvidnosti ključna determinanta potražnje za likvidnošću. Kada bi ρ bila deterministička varijabla, tada investitori u slučaju $\rho < p_H\left(R - \frac{B}{\Delta p}\right)$ ne bi financirali projekt u razdoblju 0 jer bi znali da bi tada morali pokriti i troškove šoka likvidnosti pa bi ukupni troškovi bili veći od vrijednosti založenog dohotka u razdoblju 2.

O problemu likvidnosti poželjno je razmišljati u terminima osiguranja. Veliki je šok likvidnosti kao nastanak nepovoljna događaja (npr. nesreća u osiguranju), a izostanak šoka kao odsutnost osiguranog događaja. Kada bi poduzetnik unaprijed znao vrijednost šoka, ne bi postojala potreba za držanjem novca.

2.4.2.2 Potražnja za likvidnošću unutar modela kontinuiranih investicija

Model u nastavku slijedi potonji model, ali se pretpostavlja da investicije mogu poprimiti kontinuum vrijednosti. Notaciju i pregled prate Holmstroma i Tirole (2011) i Tirole (2006). Pretpostavlja se da šok likvidnosti, ρ, može poprimiti dvije vrijednosti: ρI s vjerojatnošću λ i 0

s vjerojatnošću $1-\lambda$. U prvom slučaju tvrtka je „intaktna“, a u drugom „u teškoćama“. Tvrtka će investiciju započetu u razdoblju 0 završiti samo ako osigura dostatnu likvidnost za prevladavanje likvidnog šoka. Ponovno je ključna pretpostavka modela da tvrtke ne mogu založiti (engl. *pledge*) sav prinos od investicije[17] U svim ostalim elementima model je isti kao i model u potpoglavlju 3.1.1.2. Privatna korist od zabušavanja iznosi BI. Projekt ima prinos RI pri ponašanju i 0 pri zabušavanju. Vjerojatnost uspjeha projekta pri ponašanju iznosi p_H, a pri zabušavanju p_L.

Prvo navodimo osnovne pretpostavke modela. Pretpostavimo da vrijedi:

$$\rho_0 \equiv p_H\left(R-\frac{B}{\Delta p}\right) < c \equiv \min\left\{1+\lambda\rho, \frac{1}{1-\lambda}\right\} < \rho_1 \equiv p_H R \tag{82}$$

gdje je ρ_0 založeni dohodak, a ρ_1 ukupni primitak po jedinici investicija. Pretpostavka (82) podrazumijeva pozitivni NPV projekta, ali i potrebu poduzetnika za izvanjskim financiranjem. U slučaju izostanka šoka ($\lambda = 0$), model je isti kao i u potpoglavlju 3.1.1.2. ($\rho_0 < 1 < \rho_1$). U slučaju nastavka projekta, poduzetnik može zaraditi 0 u slučaju neuspjeha i R_b u slučaju uspjeha, gdje je R_b dovoljno visok da zadovolji poticajno ograničenje $\Delta p R_b \geq BI$. Ako jednadžba ima znak jednakosti, kompletan založeni dohodak $p_0 I$ odlazi investitoru.

Postavlja se pitanje: kakvo će biti ponašanje poduzetnika i investitora „u teškoćama“ (pojava potrebe za reinvestiranjem ρ po spašenoj jedinici uz vjerojatnost λ)? Moguća su dva slučaja. Jedan je obustava projekta jave li se „teškoće“. Tada investitor ostvaruje priljev samo kad je tvrtka „intaktna“. Točka pokrića dana je s

$$(1-\lambda)p_0 I = I - A \tag{83}$$

Iz toga se može izvesti investicijski kapacitet

$$I = \frac{A}{1-(1-\lambda)p_0} \tag{84}$$

što je poopćenje jednadžbe (70) iz potpoglavlja 2.3.2.1. Korisnost je poduzetnika jednaka

$$U_b^0 = \left[\left(p_1 - \frac{1}{1-\lambda}\right) / \left(\frac{1}{1-\lambda} - p_0\right)\right] A \tag{85}$$

[17] Autori termine založeni dohodak (engl. *pledgeable income*) i kolateral u okviru prezentiranog modela smatraju sinonimima.

Prosječni trošak više ne iznosi 1, kao u modelu bez šoka likvidnosti, nego $1/(1-\lambda)$ jer investicija donosi prinos samo bez likvidnog šoka.

Ako se projekt nastavi i nakon „teškoća“, budžetsko ograničenje poduzetnika dano jednadžbom:

$$I \leq A + (1-\lambda)\rho_0 I + \lambda(\rho_0 - \rho)I \tag{86}$$

iz čega se ponovno izvodi investicijski kapacitet:

$$I = \frac{A}{(1+\lambda\rho) - p_0} \tag{87}$$

a NPV (dužnikova korisnost) dan je s

$$U_b^1 = \frac{p_1 - (1+\lambda\rho)}{(1+\lambda\rho) - p_0} A \tag{88}$$

Politika ovladavanja likvidnim šokom optimalna je ako je $U_b^1 \geq U_b^0$, to jest $1 + \lambda\rho \leq 1/(1-\lambda)$, što se može zapisati i kao

$$(1-\lambda)\rho \leq 1 \tag{89}$$

Jednadžba (89) je nužan i dovoljan uvjet nastavka projekta pri stanju λ. Riječima, nastavak projekta poželjan je ako je intenzitet šoka (ρ) nizak ili vrlo vjerojatan (visoki λ).

Valja ponovno istaknuti da je ključna pretpostavka modela pretpostavka $\rho_0 < \rho$. Razliku između ρ_0 i ρtvrtka mora osigurati korištenjem likvidnim sredstvima iz razdoblja 0. Ako se iznos likvidnoti koju tvrtka potražuje označi s L, optimalna je razina livkidnosti dana s (Almeida i dr., 2014):

$$L = (\rho - \rho_0)I = \frac{(\rho - \rho_{0_1})A}{1 - \rho_0 + \lambda\rho} \tag{90}$$

Novčana sredstva imaju dvostruku vrijednost za poduzeće. Prvo, likvidna sredstva omogućuju poduzimanje investicijskih projekata. Drugo, važnost novca funkcija je mogućnosti nastanka šoka likvidnosti. Razlika $\rho - \rho_0$ može se shvatiti kao mjera financijskog ograničenja. Što je potonja razlika veća, i potražnja je za likvidnošću veća. Ako je $\rho_0 > \rho$, ne postoji potražnja tvrtke za novom likvidnošću. Ovi teorijski rezultati u skladu su s empirijskim istraživanjima u poglavlju 3.2.1.

2.5 Makroekonomski modeli s financijskim frikcijama

Ovo se poglavlje bavi makroekonomskim implikacijama modela prikazanih u poglavljima 2.3 i 2.4.. Drugim riječima, modeli razvijeni u prethodnim dvama poglavljima služe kao mikroosnova prevladavajućih makroekonomskih modela. Prvo se daje kratak pregled povijesnih radova. Potom se prikazuju formalni modeli kanala zaduživanja poduzeća (potpoglavlje 2.5.2.) i bankovnoga kanala financijskih frikcija (potpoglavlje 2.5.3.). Na kraju se prikazuju modeli koji ističu važnost politike likvidnosti poduzeća i ponude sigurne imovine za agregatne investicije poduzeća (potpoglavlje 2.5.4.).

2.5.1 Kratak pregled povijesnih radova

Pregled makroekonomskih modela s financijskim frikcijama sadržava prikaz temeljnih teorijskih modela, koji se koriste financijskim frikcijama u ponašanju investicija unutar standardnih DSGE modela (dinamičkih modela opće ravnoteže). Pregledni radovi i knjige, koji su povezani s ovim pregledom uključuju Brunemeier i Sannikov (2012), Quadrini (2011 i Gertler i Kiyotaki (2010). Prikazuju se glavni doprinosi u razumijevanju investicijskoga kanala poslovnih ciklusa, a izostavljaju se radovi koji ističu važnost potrošačkog kanala dinamike poslovnih ciklusa.

Prvi teorijski doprinos za razumijevanje odnosa financijskih varijabli i ekonomskih ciklusa dao je Fisher (1933) u prvom izdanju časopisa „Econometrica“, u kojem je iznio svoju teoriju o dugovnoj deflaciji. Kreditni ciklus pokreću labavi uvjeti kreditiranja i (pre)optimistična očekivanja o budućim profitima. Investitori očekuju velike prinose na uloženi kapital, pa investicije snažno rastu. Međutim, nelinearnu dinamiku pokreću dva faktora: „Poremećaji u ova dva faktora – dugu i kupovnoj moći monetarne jedinice, dovest će do poremećaja u svim, ili gotovo svim ostalim ekonomskim varijablama. S druge strane, odsutnost dugova i deflacije čini poremećaje u ostalim varijablama preslabim da bi doveli do kriza poput onih 1837, 1873. ili 1923–1933.“ Naime u financijskim krizama zbog pada potražnje često se smanjuje cijena jer poduzeća žele time privući više potrošača. Pad cijena proizvoda prati i pad cijena nadnica kako bi se zadržale iste marže. Pad cijena zbog krize stvara teret dužnicima jer dugovi ostaju stalni dok se plaće smanjuju. Ukratko, nastaje transformacija bogatstva od dužnika prema

kreditorima. Vrijedi i obrnuto. Inflacija smanjuje dugovno opterećenje i povećava kupovnu moć dužnika. Na strani poduzeća, smanjenje novčanih tokova tvrtke i pad vrijednosti kolaterala smanjuju investicije – kanal bilance stanja. Kriza je dakle rezultat pozitivne povratne petlje koju stvaraju deflacijska spirala, realan rast dugova i prodaja imovine iz nužde.

King (1994) je formalno analizirao transmisijski mehanizam dugovne deflacije. Kako on ističe, osnovni je faktor velikog pada agregatne potražnje promjena u distribuciji neto vrijednosti (bogatstva) od dužnika prema kreditorima. U modelu postoje dva agenta, dva dobra (potrošno i kapitalno) i stohastički dohodak od čijih se promjena ne može osigurati – stohastički model s heterogenim agentima konačnog horizonta koji proizvodi efekt štednje iz opreznosti (engl.. *preacutionary savings*). Jedan je agent obdaren fiksnom količinom a kapitala, koji ne deprecira u vrijednosti i isplaćuje se na kraju razdoblja za q_t jedinica potrošnje. Vrijednost q_t je stohastička i neosigurljiva, pa agent mora posuditi sredstva kako bi financirao potrošnju prije razdoblja T. Drugi agent prima stohastičke dohotke u svakom razdoblju. Dio dohotka štedi posuđujući sredstva na tržištu kapitala. Očekivana vrijednost budućeg bogatstva jednaka je za oba agenta i iznosi 1, ali se distribucija vjerojatnosti očekivanog bogatsva razlikuje. Model proizvodi drukčiju putanju potrošnje da dva agenta. Zbog razlika u graničnoj sklonosti potrošnji, dužnik (agent 1) će trošiti manje prije konačnog razdoblja. Šokovi će imati znatno snažniji utjecaj u agenata koji ima veću potrošnju iz raspoloživa bogatstva na dužnike. Budući da imaju veću graničnu sklonost prema potrošnji, šok na njihov dohodak uzrokuje financijsku krizu.

Keynes (1936) je s druge strane bio usmjeren na transmisijski mehanizam bankovnoga kanala. Velikoj je depresiji, slično kao i Velikoj recesiji, prethodio snažan rast cijena imovine prije krize i snažan pad poslije nje. Keynes je istraživao upravo utjecaj pada cijena imovine na proces financijske intermedijacije. Iako Keynesova teorija ne uključuje eksplicitno financijski sektor, špekulacija i „“animal spirits“ na financijskom tržištu mogu uzrokovati nelinearnost i amplifikaciju šokova.

Minsky (1986) je razvio koherentni verbalni model koji se temelji na „hipotezi o financijskoj nestabilnosti“. Fazu gospodarskog rasta karakterizira akumulacija kredita i preinvestiranje, a praćena je i precijenjenim vrijednostima financijske i realne imovine, niske volatilnosti i, često, niske cijene rizika. Za razumijevanje endogenosti poslovnih ciklusa važno je razumjeti fenomen „stabilizirajuće nestabilnosti“. Rast ekonomske aktivnosti i cijena imovine smanjuje percepciju rizika, pa ekonomija prelazi iz faze stabilnog internog financiranja prema Ponzijevu sustavu

financiranja. U određenom trenutku, zbog neodrživosti financiranja, nastaje snažna kontrakcija („Minskyev moment“). Minskyeva je teorija usredotočena na investicije poduzeća, a ponašanju kućanstava obraća se manje pozornosti. Investicijski kanal, koji je predmet istraživanja u ovom radu, rezultat je percepcije rizika i poduzimanja rizičnih investicija zbog povoljnih poslovnih okolnosti.

Keen je u brojnim radovima (1995, 2012), primjenom ortodoksne metodologije – teorije kompleksnosti i sistemske dinamike, pokušao testirati relevantnost Mynskyovih pretpostavki o funkcioniranju ekonomskog sustava. Glavni uzrok nestabilnosti Keen vidi u financijskom sektoru kao izvoru moralnog hazarda. Financijske institucije potiču kreditnu ekspanziju rastom ponude kredita, koja je ponajprije okrenuta prema špekulativnim aktivnostima (rast cijena imovine) umjesto profitabilnim investicijama. Stabilno razdoblje razvoja kapitalizma nema karakteristike velike umjerenosti, nego, suprotno, „zatišje je pred buru“. Nestabilnosti se stvaraju u vremenima niske volatilnosti (usporediti s rezultatima Brunemeira i Sannikova (2011) koji se opisuju niže).

Ključan je dio Keenove teorije drukčije shvaćanje agregatne potražnje. Potražnja je striktno monetaran fenomen: kupnja dobara i usluga zahtijeva raspolaganje novčanim sredstvima. Ekonomski agenti mogu trošiti novac koji već posjeduju ili mogu posuditi novac u banci. Kada posuđuju novac od banke, agenti povećavaju svoju potrošačku sposobnost bez njezina smanjivanja u drugih agenata. Tako rastom duga raste ukupan dohodak u gospodarstvu.

Dakle, Keen ističe da je privatni dug ključna determinanta agregatne potražnje, pa glavni uzrok Velike recesije vidi upravo u padu privatnog duga. Definicija agregatne potražnje razlikuje se od uobičajene kenezijanske definicije[18]. Formalno, agregatna je potražnja jednaka:

$$Y + \frac{d}{dt}D = GDP + NAT \tag{91}$$

gdje je Y agregatna potražnja, $\frac{d}{dt}D$ promjena duga, a NAT neto obrtaj imovine. Neto obrtna imovina jednaka je umnošku cijene indeksa imovine (P), količini imovine (Q) i obrtaja imovine (T). Ako se agregatna potražnja definira na potonji način, kretanja u privatnom dugu postaju ključna komponenta poslovnih ciklusa. Keen naime odbacuje standardnu pretpostavku o djelovanju novčanog multiplikatora te pretpostavlja kreditnu ekonomiju u kojoj kreditna

[18] O ovoj se temi vodila zanimljiva rasprava u ekonomskoj blogosferi između Paula Krugmana i Stevea Keena.

aktivnost banaka određuje monetarne agregate i iznos privatnog duga, a ne obrnuto. Ekonomski rast prije krize bio je dakle potaknut rastom agregatne potražnje kao rezultata rasta privatnog duga, pri čemu je privatni dug usmjeravan u špekulativne aktivnosti umjesto u realne investicije. Dakle, rast je duga i glavni pokretač rasta cijena imovine koje s rastom privatnog duga zatvara pozitivnu petlju. Cijene imovine s vremenom moraju ostvariti nagli pad jer rast duga ne može ostati pozitivan zauvijek. U određenom trenutku balon cijena imovine ispuhuje se dok dugovi ostaju isti.

Za potonju teoriju ključno je napuštanje pretpostavke o raspoloživim sredstvima (engl. *Loanable funds*), prema kojoj su poslovne banke intermedijari, koji primaju sredstva od štediša i plasiraju ih dužnicima. Suprotno od toga, banke mogu odobravati kredite ni iz čega i sekundarnom emisijom novca stvarati agregatnu potražnju koja presudno utječe na poslovne cikluse.

2.5.2 Kanal zaduživanja poduzeća

2.5.2.1 Trošak verifikacije stanja

Modeli u nastavku pružaju formalnu razradu teorija koje su opisane u prošlom poglavlju. Iako se prijašnji modeli u određenim dijelovima mogu smatrati intuitivno prihvatljivima, vrlo je složeno pitanje njihove matematičke analize. Potrebno je napustiti uobičajene pretpostavke, poput, recimo, pretpostavke o reprezentativnom agentu i potpunim tržištima (Quadrini, 2011), što zahtijeva i drukčije numeričke metode traženja rješenja.

Zajedničko je svojstvo svih do sada opisanih radova postojanje određenog oblika nesavršenosti na tržištu kapitala. U fazi ekspanzije stvaraju se tržišne neravnoteže ili baloni, koji pucaju nakon određenog događaja koji se često označava kao „Minskyov moment“. Potom nastupa amplifikacija i/ili perzistentnost početnog šoka. Radovi prikazani u nastavku formalno razrađuju amplifikacijski mehanizam s jedne strane i perzistentnosti šokova s druge strane. Amplifikacijski šokovi mogu biti direktni ili indirektni (Brunnemeier i Oehmke, 2013). Primjer direktnog amplifikacijskog mehanizma čine financijske zaraze ili naglo povlačenje bankovnih depozita, što čine stanovnici ili banke. Indirektna amplifikacija podrazumijeva eksternalije, najčešće putem cjenovnog mehanizma. Primjerice, likvidacija materijalne imovine radi

uspostavljanja primjerene likvidnosti, može, zbog pada cijena, utjecati na bilancu stanja ostalih agenata.

Valja podsjetiti da financijske frikcije i amplifikacijski mehanizam mogu djelovati na strani dužnika (kanal bilance stanja dužnika) i na strani kreditora (kanal bilance stanja kreditora). Ovaj rad ponajprije se usredotočuje na testiranje prvoga kanala iako je u praksi vrlo teško razgraničiti ova dva kanala. U nastavku je stoga naglasak na istraživanjima koja amplifikacijski mehanizam nastoje objasniti djelovanjem investicijskog kanala financijskih frikcija.

Bernanke i Gertler (1989) izradili su model s financijskim frikcijama u kojem se amplifikacija događa zbog smanjenja neto vrijednosti zaduženih poduzetnika. Autori su se dakle usredotočili na tvrtkin kanal zaduživanja u kojem je neto vrijednost poduzetnika ključna varijabla. Glavni propagator kreditnih nesavršenosti asimetričnost je informacija između dužnika i kreditora (troškovi agenta).[19] Numeričko rješenje modela dano je u Calstrom i Fuerst (1997).

U nastavku je pružen sažet prikaz modela. Agenti nisu homogeni. Dio su poduzetnici (η), a dio su kućanstva $(1-\eta)$[20]. Poduzetnici mogu transformirati potrošna dobra (i_t) u kapitalna dobra (ωi_t), gdje je ω idiosinkratični šok s distribucijom G i očekivanom vrijednošću 1 (agregatno, potrošna se dobra pretvaraju u kapitalna u odnosu jedan prema jedan). Kasnije će se vidjeti da neki autori pretpostavljaju $E[\omega] = 0$, što implicira konstantan agregatni stok kapitala u svim razdobljima, za razliku od predmetnog slučaja, koji implicira kapitalnu akumulaciju. U modelu ne postoje troškovi prilagođavanja (ignorira se tehnološka likvidnost), za razliku od modela koji će se razmatrati kasnije.

Poduzetnici se mogu financirati iz vlastitih izvora (neto vrijednost poduzeća, n_t) i tuđih izvora, posuđujući od kućanstava potrošna dobra ($i_t - n_t$), a vraćaju $\{\omega, \overline{\omega}\} \times i_t$. Eksterni su troškovi viši od internih troškova zaduženja. Visina eksternih troškova inverzno ovisi o neto vrijednosti poduzeća. Neto vrijednost poduzeća prociklična je varijabla pa je eksterna premija posljedično protociklična. Dale, financijske frikcije djeluju putem promjena u neto vrijednosti.

Temeljna je frikcija u modelu pretpostavka o troškovima verifikacije stanja (TSV). Kako je opisano u poglavlju 3.1.2., ova pretpostavka podrazumijeva da je eksterno financiranje skuplje od internih izvora financiranja. Frikcija pretpostavlja da je informacija o ω (šok) dostupna poduzećima bez troška. S druge strane, kućanstva mogu verificirati stanje samo uz troškove

[19] Troškovi agenta podrazumijevaju sukobljene interese dužnika i kreditora.
[20] Korištena notacija i neki komentari iz Brunemeier i ostali (2012) i Quadrini (2011).

nadzora (μi_t jedinica kapitala)[21]. Poduzetnici prikazuju samo pravo stanje ω-a (nema moralnog hazarda). Kućanstva provjeravaju poduzeća samo ako ne plate dug, plaćaju troškove verifikacije i prisvajaju rezidualnu imovinu poduzetnika. Poduzeća ne mogu ispuniti svoju obvezu iz ugovora ako je ω nizak, to jest ako je ω manji od $\overline{\omega} = (1 + r)(i - n)/i$, gdje je r kamatna stopa i tada kreditori zarađuju $\omega i - \mu i_t$. Iz izraza je vidljivo da je granica neispunjenja obveza (engl. *default treshold*) rastuća funkcija financijske poluge $\frac{i-n}{i}$ i kamatne stope r. U suprotnom, ako je $\omega > \overline{\omega}$, kreditori zarađuju $\overline{\omega}$.

Poduzeća biraju iznos investicija $i$kako bi maksimirala neto vrijednost:

$$\underset{i_t}{\text{maks}} \int_{\overline{\omega_t}}^{\infty} (\omega - \overline{\omega_t})\, dG(\omega) i_t q_t \tag{92}$$

gdje je q_t cijena kapitala. Integral započinje s $\overline{\omega}$ jer tvrtke za $\omega < \overline{\omega}$ ne mogu ispuniti obveze pa je neto vrijednost 0. Ograničenje je dano s:

$$\left[\int_0^{\overline{\omega_t}} (\omega - \mu) dG(\omega) + (1 - G(\overline{\omega_t})\overline{\omega_t})\right] i_t q_t = i_t - n_t \tag{93}$$

Jednadžba (93) je uvjet nultog profita na kompetitivnom tržištu (engl. *zero-profit condition*). Na desnoj je strani iznos koji pozajmljuju kućanstva (posuđuju poduzetnici). Na lijevoj je strani iznos koji vraćaju poduzetnici ako je $\omega < \overline{\omega}$ i $\omega > \overline{\omega}$. Uvjet implicitno definira kamatnu stopu koju određuje kreditor, a koja je funkcija n_t, i_t, q_t.

Uvjet je prvog reda

$$i_t = \psi(q_t) n_t \tag{94}$$

gdje je ψ poluga, koja je rastuća funkcija cijene kapitala. Dakle, investicije su rastuća funkcija cijene kapitala i neto vrijednosti poduzeća jer povećanje obiju varijabla smanjuje $\overline{\omega_t}$. Time je određena ponuda kapitala koja ima pozitivan nagib (prva derivacija s obzirom na q_t je > 0). Linearnost investicija i tehnologije nadzora omogućuje agregaciju u modelu.

U radu se upotrebljava standardni (negativni) šok produktivnosti, a dinamika pokazuje perzistentno ponašanje neto vrijednosti poduzeća: negativan šok smanjuje neto vrijednost poduzeća što, zbog rasta vjerojatnosti bankrota, povećava financijsku frikciju (pomiče krivulju

[21] Uz $\mu = 0$, model se reducira na standardni RBC model. U kalibraciji se vrijednost aproksimira troškovima bankrota (npr. troškovi revizije, pravnih usluga i sl., koji se javljaju pri bankrotu) i iznosi oko $\mu = 0.20$.

troškova verifikacije) i posljedično smanjuje investicije. Pad u ponudi kapitala smanjuje kapital i output u $t+1$, što ponovno smanjuje neto vrijednost. Također raste cijena kapitala, što pridonosi rastu povrata na interna sredstva. Potrebno je dulje razdoblje kako bi poduzetnici prikupili dovoljno zadržanih zarada za financiranje novih projekata. Smanjenje cijene kapitala prigušuje šok, što znatno odudara od modela koji će se kasnije proučavati gdje se šok amplificira. Glavna razlika prema standardnome modelu RBC-u grbava je putanja investicija. Krivulja investicija pomiče se ulijevo, output opada, pa se smanjuje i neto vrijednost u sljedećem razdoblju.

Dakle, temeljna financijska frikcija u modelu endogena je promjena u eksternoj financijskoj premiji. Eksterna financijska premija razlika je između troška korištenja internim sredstvima i troškova izvanjskog zaduženja emisijom duga ili kapitala. Eksterno je financiranje skuplje od internog financiranja i financijska premija postoji sve dok eksterno financiranje nije posve kolateralizirano. Osnovni rezultati modela jesu: 1) dugovna deflacija može imati važan i stalan utjecaj na realnu aktivnost, 2) model s agencijskim troškovima uzrokuje *hump-shaped* efekt investicija na šok produktivnosti.

Bernanke, Gertler i Gilstrich (1999) opisani su model proširili dodajući mu novac i pretpostavku o ljepljivosti cijena (model NK). Primjena modela NK omogućuje analiziranje utjecaja monetarne politike. Međutim, u smislu dinamike modela mnogo su važnije dvije promjene: 1) uvodi se tehnološka nelikvidnost u obliku nelinearnih troškova prilagođavanja kapitala,[22] 2) šok pogađa kupce kapitala, a ne proizvođače kapitala (poduzetnike) kao u prošlome modelu. Koncept je poznat pod nazivom „koncept financijskog akceleratora“. Osnovna je karakteristika ciklusa, u usporedbi s prošlim modelom, pojačanje (amplifikacija) šoka u njemu.

Slično kao i u prošlome modelu, ključna je kauzalna veza u modelu ona između eksterne financijske premije[23] i neto vrijednosti dužnika.[24] Može se reći da je kao i u prošlom modelu ključna varijabla neto vrijednost poduzetnika. Veće vrijednosti neto bogatstva omogućuju porast samofinanciranja i kolateralnog zaduživanja, čime se izbjegavaju troškovi agenta i

[22] Funkcija troškova prilagođavanja odražava tehnološku nelikvidnost: $K_{t+1} = \Phi\left(\frac{I_t}{K_t}\right)K_t + (1-\delta)K_t$. Izraz u zagradi stopa je investicija. Troškovi prilagođavanja podrazumijevaju konkavnost funkcije Φ (za detalje pogledati odjeljak Bernanke, Gertler i Gilstrich (1999))

[23] Eksterna financijska premija razlika je između troškova izvanjskog zaduženja i oportunitetnih troškova korištenja internim sredstvima. Kao aproksimacija, može se uzeti razlika kamatnih stopa na bankovne kredite (korporativne obveznice) i prinosa vrijednosnica države. Npr., u SDA-u je to razlika između BBB stopa i kamatne stope federalnih rezervi.

[24] Neto vrijednost dužnika = likvidna sredstva + vrijednost kolaterala – obveze.

smanjuje eksterna financijska premija. To je pretpostavka koja slijedi prethodni model. Nesavršeno kapitalno tržište u modelu financijskog akceleratora ima ova obilježja:

- eksterno je financiranje skuplje od internog financiranja
- premija na eksterno financiranje inverzno je povezana s neto vrijednošću poduzeća, koja je jednako zbroju internih (likvidnih) sredstava i kolateralne vrijednosti nelikvidne imovine pad neto vrijednosti stvara amplifikacijske učinke šokova (smanjenje potrošnje, investicija i proizvodnje).

U modelu postoje tri agenta: kućanstva, poduzetnici i trgovci. Trgovci kupuju robu od poduzetnika i prodaju je kućanstvima. Djeluju na tržištu monopolističke konkurencije, što omogućuje uvođenje pretpostavke ljepljivosti cijena. Poduzetnici su najvažniji u modelu. Postoji konstanta vjerojatnost γ da će poduzetnici preživjeti do sljedećeg razdoblja U svakom razdoblju poduzetnici kupuju fizički kapital (K_{t+1}^{j}) po cijeni kapitala Q_t, a financiraju se iz neto vrijednosti N_{t+1}^{j} (profita od kapitala i dohotka od rada) i tuđih izvoraB_{t+1}^{j}. Dakle, iznos koji poduzetnici posuđuju iznosi $Q_t K_{t+1}^{j} - N_{t+1}^{j}$. Poduzetnici ostvaruju povrat na kapital u iznosu ωR_{t+1}^{k}, gdje je R_{t+1}^{k} povrat na kapital u agregatnoj ravnoteži. Kao i u CF i BG, postoji CSV obrazac (troškovi verifikacije iznose $\mu\omega^{j} R_{t+1}^{k} Q_t K_{t+1}^{j}$). Također, kao i prije, verifikacija se događa prema sljedećoj jednadžbi (usporediti s jednadžbom (93)):

$$\left[(1-\mu)\int_{\dot{0}}^{\varpi} \omega dG(\omega) + (1 - G(\overline{\omega_t})\overline{\omega_t})\right] R_{t+1}^{k} Q_t K_{t+1}^{j} = R_{t+1}(Q_t K_{t+1}^{j} - N_{t+1}^{j}) \tag{95}$$

gdje je R_{t+1} nerizična kamatna stopa, a $1 - G(\overline{\omega_t})$ vjerojatnost defaulta. Jednadžba (95) pokazuje da vrijednost $\overline{\omega_t}$ ovisi o premiji projekta koju ostvaruju poduzetnici. Ako je ona niža od očekivane, raste vjerojatnost bankrota, a time i $\overline{\omega_t}$. Dakle, vjerojatnost bankrota i premija na bankrot rastu ako je agregatna premija manja od očekivane. S druge strane idiosinkratični šokovi ω_t nisu bitni jer se rizik može posve diversificirati.

Investicijski sektor maksimira razliku između prihoda i investicija. Prvi uvjeti optimiranja za investicijski sektor daju:

$$q_t = \Phi'(\frac{I_t}{K_t})^{-1} \tag{96}$$

Rast cijena kapitala pridonosi rastu investicija. Kada bi funkcija bila linearna, rast cijena kapitala pridonio bi beskonačnu rastu investicija. Što je funkcija konkavnija, to je rast investicija umjereniji.

Poduzetnici maksimiraju vrijednost neto bogatstvo u sljedećem razdoblju:

$$\max_{k_{t+1}} E\left[\int_{\overline{\omega_t}}^{\infty} (\omega - \overline{\omega_t})\, dG(\omega) R_{t+1}^{k} Q_t K_{t+1}^{j}\right] \tag{97}$$

Maksimiranje (97) uz ograničenje (95) daje uvjete prvog reda (usporediti s jednadžbom (94)):

$$Q_t K_{t+1}^{j} = \psi\left(\frac{E[R_{t+1}^{k}]}{R_{t+1}}\right) N_{t+1}^{j} \tag{98}$$

Vrijednost u zagradi diskontirani je povrat na kapital. Jednadžba prikazuje vezu između kapitalnih izdataka tvrtke i financijskih uvjeta, koji se mjere kao odnos očekivana prinosa na kapital i nerizična prinosa te neto vrijednosti. Primjerice, rast očekivana diskontnog povrata na kapital smanjuje očekivanu vjerojatnost bankrota. Poduzetnik se može zadužiti za dodatan iznos. Poduzeće je ograničeno u rastu duga zbog povećanja očekivanih troškova bankrota rastom duga. Agregiranjem za sve poduzetnike dobiva se ponuda kapitala.

Negativni šok (primjerice povećanje federalne kamatne stope) smanjuje neto vrijednost, što povećava financijske frikcije i smanjuje investicije. Međutim, za razliku od prošlog modela koji stvara prigušene efekte, smanjenje potražnje za kapitalom (ne ponude!) smanjuje cijenu kapitala. Pad cijena imovine smanjuje neto vrijednost tvrtke, što povećava financijske premije, a to dodatno potiče pad investicija. Multiplikativni efekt ogleda su u pozitivnoj petlji koju zatvaraju investicije, cijene imovine i neto vrijednost. Multiplikativni efekt stvara perzistentnije ponašanje varijabli. Za razliku od prethodnog modela, postoji amplifikacijski efekt zbog uvođenja konveksnih troškova prilagođavanja investicija i utjecaja na potražnju, a ne na ponudu za kapitalom.

2.5.2.2 Modeli s kolateralnim ograničenjem

Kiyotaki i Moore (1997) analizirali su sustav u kojem je rizik nevraćanja kredita osiguran kolateralom, pa je i iznos zaduženja uvjetovan vrijednošću kolaterala, što je bitna razlika prema prethodnim modelima koji su se koristili CSV-om kao inputom. Trajna dobra stoga imaju

dvojnu ulogu: služe kao faktor proizvodnje i kao kolateral pri zaduživanju, a ponuda im je konstantna (u drugom dijelu rada prikazana je mogućnost promjenjiva kapitala). U formalnom obliku financijska je frikcija dana s:

$$Rb_t \leq q_{t+1}k_t \tag{99}$$

Iznos kredita ne može biti veći od sadašnje vrijednosti realne imovine (zemlje). U prethodnome modelu financijska premija je ovisila o odnosu neto vrijednosti i vrijednosti kapitala. U (99) kamatna stopa na izvanjsko zaduženje je konstantna, a pošto ograničenje postane vezano (engl. *binding*), postaje beskonačna. Poduzeća ne mogu emitirati novi kapital, pa kreditni limit ovisi o cijeni kolaterala (kapitala). Na mikrorazini, interna sredstva poduzeća postaju funkcija cijene imovine ako tvrtka posjeduje velike količine dugotrajne imovine (kapitala, zemlje).

Budući da je riječ o modelu racionalnih očekivanja, agenti savršeno predviđaju buduće cijene imovine. S druge strane, cijena kolaterala ovisi o veličini kreditnog limita. Dinamička međuovisnost kreditnog limita i cijena imovine (kolaterala) stvara perzistentan i pojačavajući utjecaj na šokove.

Druga promjena u odnosu prema prethodnim modelima uvođenje je preferencijske heterogenosti. Postoje dva proizvodna sektora koji se razlikuju u nestrpljivosti (β) i tehnologiji (y). Ova pretpostavka nije važna za modele s konačnim horizontom (BGG), ali jest kada je horizont agenta beskonačan. Produktivni agenti imaj linearnu proizvodnu funkciju, a neproduktivni konkavnu. Produktivni su agenti nestrpljiviji (imaju manju β), što znači da neće akumulirati beskonačne iznose kapitala (u BGG poduzetnici „umiru“).

U ravnoteži produktivni agenti posuđuju do maksimuma (jednadžba (99) je vezana) i ne troše ništa od proizvedenog outputa. To implicira da je potražnja za imovinom (zemljom) dana s:

$$k_t \leq \frac{1}{q_t - \frac{q_{t+1}}{R}}[(a + q_t)k_{t-1} - Rb_{t-1}] \tag{100}$$

Izraz u uglatoj zagradi označava poduzetnikovu neto vrijednost na početku razdoblja t, to jest vrijednost razmjenjivog outputa i vrijednosti imovine iz prethodnog razdoblja umanjenu za isplate dugova. Jednadžba (100) govori da se agent koristi neto vrijednošću za financiranje razlike između cijene q_t imovine i iznosa koji može posuditi po svakoj jedinici imovine $\frac{q_{t+1}}{R}$.

Neproduktivni agenti (skupljači) izabiru imovinu $\underline{k_t}$ (uvjet prvog reda):

$$\frac{1}{R}F'\left(\underline{k_t}\right) = q_t - \frac{q_{t+1}}{R} \tag{101}$$

Dakle, neproduktivni agenti potražuju imovinu do razine pri kojoj nije zadovoljen uvjet da je diskontirani granični proizvod jednak oportunitetnim troškovima (troškovima korištenja).

Negativni šok smanjuje neto vrijednost poduzeća. Dodatno, smanjuje se cijena kapitala, što smanjuje kapitalne dobitke agenata. Kreditno ograničena poduzeća nemaju kreditnu sposobnost za zaduživanje, pa se smanjuje potražnja za kapitalom (investicije). U modelu postoje dva multiplikativna efekta. Prvi (statički) multiplikativni efekt nastavlja se smanjenjem troškova korištenja (*user costs*),[25] što uzrokuje prodaju kapitala iz nužde (engl. *fire sales*) od produktivnijeg sektora prema manje produktivnim sektoru, što uzrokuje pad cijena imovine. Pad cijene kapitala znači dodatan pad neto vrijednosti što započinje petlju ispočetka. Drugi (dinamički) multiplikativni efekt nastavlja se smanjenjem potražnje što znači manje prihode u sljedećem razdoblju, pa neto vrijednost kreditno ograničenih poduzeća dodatno opada. Učinak dinamičkog multiplikativnog efekta nadilazi statički efekt.

Može se reći da su do sada prezentirani radovi (BG, BGG, KM) klasične referencije za veliku većinu radova iz makroekonomije s financijskim frikcijama u posljednjih 25 godina. Neki radovi postižu slične rezultate iako se frikcije formalno razlikuju. Na primjer, Cooley, Marimon i Quadrini (2004) koriste se frikcijom ograničene prisilne naplate. Agenti koji ne ispune obvezu iz financijskog ugovora bivaju isključeni iz intertemporalnih transakcija (financijskih tržišta), a imovina može služiti kao instrument naplate neplaćenih dugova.

Brunnemeier i Sannikov (2011) slijede prethodna tri modela, ali rade model u kontinuiranu vremenu s kompletnom ravnotežnom dinamikom, a ne samo blizu ravnotežnog stanja. Drugim riječima, primjenjuje se rekurzivni pristup rješavanja nelinearnog problema optimiranja umjesto loglinearizacije oko stabilnog stanja, kao u prethodnim modelima. Kada je sustav blizu stohastičkog stabilnog stanja, produktivni se agenti lako prilagođavaju na umjerene šokove, ali zbog velikih šokova i velikog odmaka od stabilnog stanja agenti smanjuju svoju poziciju utječući na cijene imovine i tako stvarajući pojačavajuću spiralu. Model pokušava objasniti stiliziranu činjenicu o relativno stabilnom ekonomskom rastu s niskom volatilnošću s jedne strane i ponašanje sustava u vrijeme kriza s druge strane. Razina zaduživanja nije dana egzogeno, kao u Kiyotaki i Moore (1997), već je poduzetnici određuju endogeno, pri čemu se

[25] Troškovi korištenja razlika su između cijene imovine u trenutačnom razdoblju i diskontirane vrijednosti zemlje u sljedećim razdobljima.

suočavaju s *trade-offom* velikih prinosa i visokog rizika. Razlog slabih amplifikacijskih učinaka blizu stabilnog stanja upravo je u mogućnosti endogena prilagođavanja kapitala. U normalnim vremenima, agenti izabiru omjere kapitala koji im osiguravaju ublažavanje mogućih gubitaka. Višak profita isplaćuje se u obliku dividendi, a gubici se apsorbiraju smanjenim isplatama. Pri velikim šokovima agenti moraju smanjivati svoje pozicije čime utječu na cijene imovine. Što je veće smanjenje cijena, to je jača depresija. Dakle, amplifikacijski je učinak znatno izraženiji u negativnim nego u pozitivnim šokovima.

Model proizvodi još jedan vrlo važan rezultat poznat kao paradoks volatilnosti. Smanjenje egzogene agregatne volatilnosti u novčanom toku poduzeća vodi prema manje stabilnoj ekonomiji. Razlog je u tome što smanjenje volatilnosti novčanih tokova potiče produktivne agente na povećanje financijske poluge što smanjuje apsorpcijsku sposobnost neto vrijednosti u prilagođavanju šokovima. Također, derivativi koji omogućuju agentima izbjegavanje rizika potiču agente na držanje manjih razina neto vrijednosti i povećanje poluge, što povećava sistemski rizik. Alati koji su proizvedeni za efikasnije upravljanje dugom i rizikom povećavaju ukupni sistemski rizik čineći ekonomiju podložnijom nestabilnostima. Standardni su modeli rizika neprihvatljivi jer uspostavljaju kauzalni odnos niske volatilnosti i niskog rizika ne uzimajući u obzir ono što se događa u pozadini.

2.5.3 Odnos financijske intermedijacije i investicijske aktivnosti poduzeća

Do sada prikazani radovi impliciraju kompetitivnost kreditnog sektora, a ističu neto vrijednost dužnika. Međutim, financijske frikcije i amplifikacijski mehanizam mogu se pojaviti na strani kreditora, posebno poslovnih banaka. Ovaj kanal utjecaja poznat je kao bankovni kanal bilance stanja. Kada banke imaju ograničen kapital, pogoršanje financijske situacije može ograničiti ponudu kredita i tako amplificirati šokove. S tog aspekta, promjene u investicijama nastaju zbog promjene u ponudi kredita, a u manjem stupnju zbog promjene u potražnji.

Razlikovanje izvora djelovanja frikcija važno je i za nositelje ekonomske politike jer svaki kanal podrazumijeva njezine različite intervencije. Problemi s dužnikovim kanalom mogli bi se prebroditi oprostom dugova, a oni u kanalu kreditora saniranjem banaka ili povećanjem likvidnosti. Za izučavanje kanala primjereno je promatrati modele koji sadržavaju frikcije na strani dužnika i kreditora (takozvani *doubledecker* modeli). U nastavku se prikazuju teorijski modeli bankovnog kanala financijskih frikcija.

Model Holmströma i Tirolea (1997) nastavlja se na model racioniranja kredita prikazan u poglavlju 2.3.2, pa analiza slijedi notaciju iz tog poglavlja. Tvrtke mogu financirati projekte izravno od štediša (investitora) i neizravno posredovanjem bankarskih institucija. Moralni se hazard pojavljuje na dvjema razinama. Prva implicira uživanje privatne koriti poduzetnika pri zabušavanju. Drugo, banke, za razliku od investitora, mogu smanjivati moralni hazard tehnikama nadzora

Kronologija je modela sljedeća. U nultom se razdoblju potpisuju financijski ugovori i donose odluke o investicijama, I, pri čemu se pretpostavlja da vrijednost investicija premašuje neto vrijednost projekta, $I > A$. U prvom razdoblju banka može nadzirati poduzetnika. Banka će nadzirati samo ako postoji poticaj, to jest ako je izloženost banke prema investitoru dovoljno velika. U drugom se razdoblju realiziraju prinosi na investiciju.

Dakle, osnovna je razlika prema modelu iz potpoglavlja 3.1.1. uvođenje intermedijara i tehnologije nadzora. Intermedijari mogu nadzirati poduzetnike uz trošak $c > 0$ smanjujući privatnu korist na $b > B$. Financijski intermedijari nadzorom uklanjaju projekt s B, ali još ostaje mogućnost b. Problem moralnog hazarda prisiljava intermedijare da ulažu dio svoga kapitala u tvrtke koje nadziru stvarajući iznos a kapitala K_m. Svi su projekti savršeno korelirani. Bez ove pretpostavke mogla bi nastati situacija u kojoj intermedijari ne moraju polagati nikakav kapital. Investitori očekuju stopu povrata γ, a intermedijari β pri čemu je β > γ zbog troškova nadzora.

Na početku će se ukratko ponoviti model iz potpoglavlja 3.1.1. Poduzetnici mogu financirati projekte izravno ili preko intermedijara. Ako se pretpostavi da su zahtijevane investicije fiksne, nužan uvjet izravna financiranja dan je poticajnim kompatibilnim ograničenjem dužnika:

$$R_f > B/\Delta p \tag{102}$$

Maksimalni očekivani dohodak koji se može obećati investitorima – mogući očekivani dohodak (engl. *expected pledgeable income*), dan je s

$$p_H[R - B/\Delta p] \tag{103}$$

Izraz $p_H B/\Delta p$ naziva se agencijska renta – minimalni očekivani novčani izdatak koji zahtijeva dužnik kako bi imao poticaj za djelovanje. Budući da kućanstva (investitori) moraju ostvariti prinos γ na investiciju $I - A$, to zahtijeva da očekivani dohodak ne može biti manji od tržišne vrijednosti sredstava, $\gamma[I - A]$. Nužan i dovoljan uvjet pristupa izravnu financiranju dan je s:

$$\gamma[I - A] \leq p_H[R - B/\Delta p] \tag{104}$$

što donosi

$$\bar{A}(\gamma) = I - p_H/\gamma[R - (B/\Delta p)] \tag{105}$$

Samo tvrtke koje zadovoljavaju $A > \bar{A}(\gamma)$ mogu se koristiti direktnim financiranjem. Drukčije izraženo, investicije su linearne u neto vrijednosti (Brunemeier i Sanikov, 2012): $I = \psi_d(\gamma)A$ gdje je $\psi_d = [1 - p_H/\gamma(R - \left(\frac{B}{\Delta p}\right))]^{-1}$. Jednostavno rečeno, dužnik (poduzetnik, tvrtka) mora imati dovoljno sredstava kako bi mu se odobrio kredit.

Sada se promatra utjecaj djelovanja intermedijara. Intermedijacija uklanja projekt s velikom privatnom koristi (B). Poticajno ograničenje poduzetnika sada je dano s $R_f > b/\Delta p$. Može se pretpostaviti $R_f < B/\Delta p$, inače bi se poduzetnik ponašao i mimo nadzora. Slično, poticajno je ograničenje intermedijara dano s $R_m > c/\Delta p$. Neka je I_m iznos kapitala koji intermedijari investiraju u tvrtku koju žele nadzirati. Tada je stopa povrata intermedijara dana s $\beta = p_H R_m/I_m$, pri čemu je $\beta > \gamma$.[26] Kombiniranjem svih potonjih jednadžbi, maksimalan iznos investiranja, koji se može financirati indirektnim izvorima financiranja, dan je s:

$$\underline{A}(\gamma, \beta) = I - I_m(\beta) - p_H/\gamma[R - \frac{b + c}{\Delta p}))] \tag{106}$$

Samo tvrtke koje zadovoljavaju $A > \underline{A}(\gamma)$ mogu se služiti neizravnim financiranjem. Investicije su ponovno linearna funkcija neto vrijednosti, $I = \psi_d(\gamma, \beta)A$. U radu je pretpostavljeno da je $\psi_d(\gamma, \beta) > \psi_d(\gamma)$, pa tvrtke mogu prikupiti više kapitala neizravnim financiranjem.

Ako vrijedi $\underline{A}(\gamma) < A < \bar{A}(\gamma)$, tvrtke moraju dio projekta financirati u intermedijara, a ostatak od neinformiranih investitora. Budući da banke moraju držati dio kapitala u tvrtkama koje financiraju, broj tvrtki koje će primiti bankovno financiranje ovisi o ukupnoj razini kapitala u bankovnom sustavu, K_m. Važan je rezultat modela to što iznos kreditne aktivnosti (zaduženja) ovisi o kapitalu banke. Tvrtke s niskom neto vrijednosti mogu odbiti financiranje samo od intermedijara, a one s visokom neto vrijednošću mogu dobiti financiranje izravno od investitora.

[26] Ako kapital nadzornika ne bi bio ograničen, tada bi vrijedilo $\beta = \gamma$, a nadzornik bi od dužnika primao iznos c.

U ravnoteži se izjednačuje ponuda i potražnja za informiranim kapitalom:

$$K_m = D_m(\gamma, \beta) = \left[G\left(\bar{A}(\gamma)\right) - G\left(\bar{A}(\gamma, \beta)\right)\right] I_m(\beta) \tag{107}$$

S obzirom na jednadžbu (109), mogu se razlikovati tri vrste recesija (Tirole 2006):

1. industrijska recesija (kanal bilance stanja) koja pomiče distribuciju $G(A)$ prema nižim vrijednostima A
2. kreditni slom (kanal zaduživanja) koji smanjuje K_m
3. nedostatak štednje što onemogućuje investicije.

Rezultati modela pokazuju da se tvrtke s većom neto vrijednosti mogu osloniti na jeftine izvore financiranja, a druge se oslanjanju na informacijski intenzivnije oblike financiranja (nadzor). Povećanje neto vrijednosti povećava ukupni output u gospodarstvu, što je upravo logika dužnikova kanala financijskih frikcija. S druge strane, ako se smanji nadzor kapitala, prvo će biti potisnute tvrtke s niskim iznosima kapitala. Pogoršanje u bilancama intermedijara može uzrokovati pad ponude kapitala i, u konačnici, pad investicija, što je osnovni rezultat kreditnoga kanala financijskih frikcija.

Postoji skupina radova koji unutar modela DSGE objašnjavaju bankovni kanal financijskih frikcija. U Diamon i Rajan (2009) prisutnost tržišnog rizika i rizika financiranja može natjerati banke da smanje kreditiranje. Ako šok pogodi ranjivije banke, i zdrave će banke smanjiti kreditiranje jer će očekivati prodaju imovine po prodajnim cijenama iz nužde (engl. *firesale price*). Gertler i Kiyotaki (2010) proširuju modele iz potpoglavlja 2.5.2 dodajući financijski sektor koji u krizi može imati ograničen pristup izvorima depozitima i ostalim izvorima financiranja. Model Beunneemeiera i Sannikova (2014) inkomponira sve do sada spominjane karakteristike: perzistentnost šokova, amplifikaciju, nelinearnu likvidnu spiralu, endogeni rizik, financijski sektor i „paradoks volatilnosti“. Amplifikaciju i visoku volatilnost uzrokuju ograničenja intermedijara.

Može se zaključiti da osim tvrtkinu kanalu bilance stanja prikazana u poglavlju 2.5.2, investicije tvrtki mogu biti pod negativnim utjecajem kontrakcije ponude kredita zbog problema u bilanci financijskih intermedijara (kanal zaduživanja). U modelima ograničenje najčešće proizlazi iz propisanih kapitalnih ograničenja, ali općenito može biti riječ o bilo kojem negativnom šoku na financijske institucije, zbog kojeg banke smanjuju ponudu kredita i posljedično se smanjuju investicije.

3 EMPIRIJSKI PRISTUPI PROCJENJIVANJA FINANCIJSKOG I LIKVIDNOG OGRANIČENJA KAO ZNAČAJKI INVESTICIJSKOGA KANALA FINANCIJSKIH FRIKCIJA

3.1 Sistematizacija empirijskih istraživanja o investicijskom kanalu financijskih frikcija

U ovom se poglavlju daje pregled empirijskih istraživanja o financijskim frikcijama i njihovu utjecaju na ponašanje poslovnih investicija i opću razinu makroekonomske aktivnosti. Cilj je testirati već predočene teorijske modele racioniranja kredita (moralni hazard, nepovoljan izbor, ograničeno ispunjenje) kao mikroosnovu makroekonomskih modela s financijskim frikcijama.

Različiti su kriteriji raščlambe empirijskih pristupa za procjenjivanje financijskog ograničenja. U ovom radu, u pregledu empirijskih radova, koristit će se kriterijem empirijskog dizajna. Drugim riječima, radovi se klasificiraju u tri skupine, ovisno o izabranu empirijskom dizajnu za procjenjivanje financijskog ograničenja i njegovu utjecaju na investicije i makroekonomske ishode. Empirijski je dizajn ključan jer je osnovni problem procjene financijskog ograničenja razgraničavanje utjecaja potražnje i ponude kredita, odnosno odgovoriti na pitanje: je li promjena u kreditnoj aktivnosti posljedica promjene u potražnji za kreditima ili ponudi kredita?

Prva skupina radova financijsko ograničenje procjenjuje mjerenjem osjetljivosti investicija na novčane tokove. Druga skupina radova financijsko ograničenje procjenjuje primjenom efekta tretmana. Tako se pokušava prebroditi problem endogenosti koji je prisutan u prvoj skupini istraživanja. Treća skupina, označena kao ostali metodološki pristupi, uključuje primjenu ostalih empirijskih dizajna u mjerenju financijskog ograničenja: strukturne ekonometrijske modele, kolateralni kanal, primjenu anketnih podataka i kanal bilance stanja. Na kraju poglavlja prikazuju se empirijski pristupi za procjenu likvidnog ograničenja te se ukratko opisuju pristupi procjenjivanja bankovnog kanala financijskih frikcija. Literatura o likvidnom ograničenju znatno je oskudnija od one o procjeni financijskog ograničenja jer se u teoriji ova dva pojma najčešće uzimaju kao sinonimi. Upravo je temeljni doprinos ovog rada konceptualno razdvajanje ovih dvaju pojmova te njihova empirijska procjena.

Osim prikazane klasifikacije, postoje i drukčiji pristupi klasifikacije empirijske literature o financijskim frikcijama. U empirijskoj makroekonomskoj literaturi o kreditnom kanalu postoje tri moguća kanala utjecaja financijskih frikcija na realnu aktivnost (Bank for International Settlements, 2011):

1. **Dužnikov kanal bilance stanja** koji uključuje odnos bilance stanja poduzeća i investicija ili proizvodnje (fluktuacije neto vrijednosti i investicija poduzeća).
2. **Tvrtkin kanal zaduženja** (**bankovni kanal bilance stanja**) – koji uključuje odnos bilance stanja financijskih intermedijara (banke, osiguravajuća društva, poslovni anđeli) na financijsku aktivnost tvrtke (nedostatna razina kapitala financijskih intermedijara). Ovaj se kanal može podijeliti na bankovni kanal zaduženja i bankovni kapitalni kanal.
3. **Kanal likvidnosti** (bankovni kanal financiranja) koji označuje napad na banke (engl. *bank run*) i općenito nesposobnost kreditiranja zbog rizika likvidnosti.

Prvi se kanal u modelima zbiva kroz dva mehanizma. Prvi je mehanizam eksterne financijske premije, koja je u inverznu odnosu s bonitetom poduzeća, koji se aproksimira razinom neto vrijednosti tvrtke (kapitalom, novčanim sredstvima, kolateralom). Drugi mehanizam djeluje promjenom vrijednosti kolaterala koji služi kao sredstvo kreditnog osiguranja. U oba slučaja narušavanje financijskog položaja tvrtke smanjuje sposobnost zaduživanja zbog rasta rizika, što u konačnici smanjuje ponudu kredita.

Drugi kanal podrazumijeva kontrakciju kreditne aktivnosti banaka zbog negativna (monetarnog) šoka likvidnosti. Dva su uvjeta nužna kako bi kanal imao utjecaja. Prvi je nesposobnost banke da pronađe druge izvore financiranja, a drugi je ovisnost tvrtke o bankovnom kreditiranju. Ovaj kanal može se označiti i kao kreditni lom zbog kapitalnoga bankovnog ograničenja.

Treći kanal uključuje odluke banaka o izvorima financiranja (zaduživanje preko nacionalnih granica, depoziti). Brunnermeier (2012) razlikuje tri vrste likvidnosti: 1) tehnološka likvidnost, 2) tržišna likvidnost i 3) likvidnost financiranja. Prva dva oblika likvidnosti određena su aktivom, a treći je oblik određen pasivom u bilanci poduzeća ili banke. Likvidnost financiranja sposobnost je banke ili poduzeća da pribavi nove oblike financiranja prodajom imovine ili uzimanjem novih kredita. Narušavanje bilo kojeg oblika likvidnosti može uzrokovati nekongruentnost kratkoročne aktive i pasive i, posljedično, kontrakciju ponude kredita.

U okviru potonje podjele, empirijski modeli u ovom radu uglavnom su orijentirani na kanal bilance stanja, to jest međuovisnosti neto vrijednosti poduzeća i investicija. Pri tome se ne literatura ne raščlanjuje na područje korporativnih financija i makroekonomsku empirijsku literaturu iz financijskih frikcija. U preglednim radovima često se analizira jedno od dvaju spomenutih područja, ali, u konačnici obje skupine radova objašnjavaju isti fenomen, pa njihovo konceptualno razgraničavanje ne pridonosi razumijevanju teorijskih različitosti. Iako

se nesavršenost na kapitalnim tržištima može teorijski prikazati na različite načine, svi modeli u konačnici dijele zajedničku karakteristiku: financijske varijable poput financijske poluge, pokrivenosti kamata ili stanja likvidnosti imaju važnu ulogu u donošenju odluka o ulaganjima u novu dugotrajnu imovinu i, posljedično, opće makroekonomske ishode.

Iako je u središtu pozornosti ovog rada utjecaj financijskih frikcija na investicije, u literaturi se često analiziraju i brojne druge determinante ponašanja investicija. Primjerice, 4. poglavlje Istraživanja MMF-a o poslovnim investicijama (MMF, 2015), pokazuje da ponašanje agregatnih investicija u razvijenim zemljama najbolje objašnjava agregatna potražnja, a nesigurnost i financijsko ograničenje posebni su, ali manje značajni faktori. Popis determinanti može se dodatno proširiti. Marco Buti navodi sljedeće faktore ponašanja investicija (Buti, 2014): 1) uska grla u regulaciji, 2) spori ekonomski rast (akceleracijski efekt), 3) pad javnih investicija, 4) financijska fragmentacija i 5) visoka razina ekonomske nesigurnosti. Iako se potonji strukturni faktori (i mnogi drugi) mogu smatrati važnima za objašnjenje investicija, pregled literature u nastavku neće obuhvatiti njihovu važnost. Logično je prihvatiti njihovu važnost, međutim u procjeni investicijske jednadžbe apstrahira se za dugoročne, strukturne faktore te se pozornost usmjerava na ciklične varijable poput dodane vrijednosti, prosječnog Q-a, novčanog toka i ostalih. U nastavku se detaljno prezentira svako od spomenutih skupina istraživanja za procjenu financijskog ograničenja na investicije.

3.2 Analiza financijskog ograničenja procjenom osjetljivosti investicija na novčane tokove za poduzeća različita financijskog položaja

U teorijskom prikazu q-teorije investicija (poglavlje 2.2.), iz problema optimiranja tvrtke izvedena je neoklasična investicijska jednadžba prema kojoj je kompletna informacija o investiranju sadržana u varijabli q, a ostale varijable, osima q-a, nemaju utjecaj na ponašanje investicija (jednadžba 21). To se odnosi i na neto vrijednost jer se pretpostavljaju savršena tržišta kapitala. Posljedica takva shvaćanja bilo je zanemarivanje financijskih faktora, i u teorijskim i u empirijskim modelima investicija. Pretpostavljalo se postojanje reprezentativne tvrtke, što je impliciralo primjenu istoga empirijskog modela za sve tvrtke (Hubbart, 1988). Međutim, empirijski radovi, koji su testirali q-teoriju investicija, pokazali su da q nema prediktivnu sposobnost objašnjavanja investicijske dinamike. Primjerice, Summers (1981) je

pokazao da povećanje cijene u sjeni za kapital od jedan posto povećava investicije samo 0,02 posto.

U teorijskom modelima koji se temelje na asimetričnim informacijama, s druge strane, nesavršenosti na tržištu kapitala (financijske frikcije) utječu na investicije ograničenom ponudom kapitala za projekte s pozitivnom NSV-om (pogledati poglavlje 2.3.). Za danu razinu investicijskih prilika, informacijskih troškova i tržišnih kamatnih stopa tvrtke s većom neto vrijednošću (manjom zaduženosti, većim kolateralom) trebale bi imati veće investicijske stope. Brojni su radovi testirali hipotezu o financijskom ograničenju tvrtki i pokušali odgovoriti na pitanje: jesu li i koliko poduzeća financijski ograničena? Financijska ograničenja nisu vidljiva u financijskim izvještajima tvrtki i općenito se može reći da se ona ne razmatraju u dostupnim podacima, pa su istraživači bili usredotočeni na razvoj metodologije koja će omogućiti dosljednu procjenu financijskog ograničenja i njegova utjecaja na investicije.

Jedan od prvih pokušaja testiranja financijskog ograničenja rad je Fazzarija, Hubbarda i Petersena (1988), nadalje FHP. Autori su pokušali riješiti problem identifikacije ponude i potražnje za kreditima uspoređujući osjetljivost investicija na novčane tokove u skupini tvrtki različitih financijskih karakteristika (apriorno ograničenih i neograničenih). Jedan od osnovnih rezultata djelovanja financijskih frikcija različita je hijerarhija financijskih izvora: interna su sredstva jeftinija od eksternih izvora financiranja (duga i kapitala) jer se ne zahtijeva plaćanje rizične premije (pogledati poglavlje 2.3.4.). Zato bi dostupnost likvidnih sredstava (novca) trebala utjecati na investicije iznad q-a (tvrtke s većim q-om više investiraju, ali ne dovoljno više zbog financijskog ograničenja). Drukčije rečeno, dostupnost izvanjskog financiranja zbog veće neto vrijednosti ili novčanog toka pozitivno utječe na investicijsku aktivnost. To je suprotno standardnoj neoklasičnoj teoriji investicija koja pretpostavlja savršena tržišta kapitala, a prema kojoj fluktuacije u novčanim tokovima (neto vrijednosti) ne bi trebale utjecati na investicije.

Međutim, postavlja se problem provedbe: koji „proxy“ upotrijebiti kao mjeru vjerojatnosti apriornog kreditnog ograničenja tvrtki? Spomenuti autori koristili su se politikom dividenda tvrtki. Veća je vjerojatnost da tvrtke s manjom isplatom dividendi (manjom vrijednosti omjera dividendi i dobiti) imaju veća kreditna ograničenja pri izvanjskom financiranju. U kasnijim su se radovima kao *proxy* upotrebljavali veličina tvrtke, kreditne ocjene, starost tvrtke, pokazatelji zaduženosti i različiti indeksi financijskog položaja (vidjeti recimo Almeida, Campello i Weisbach, 2004. ili Farre-Mensa i Ljungqvist, 2013). Ponovno valja upozoriti na problem

identifikacije potražnje i ponude za kreditima. Naime smanjenje kreditiranja može biti posljedica smanjenih investicijskih prilika ili narušavanja neto vrijednosti banaka ili poduzeća. Spomenuti autori nastojali su apstrahirati potražnu stranu kreditnog procesa, odnosno analizirati ograničenja ponude kapitala financijskih intermedijara.

Drugo važno pitanje jest: koji *proxy* upotrijebiti za investicijske prilike? U teorijskom prikazu pokazano je da rast investicijskih prilika podrazumijeva pomicanje profitne funkcije u desno. Rast profita povećava neto vrijednost pa rast neto vrijednosti nije rezultat financijskog ograničenja nego boljih investicijskih prilika. Kasnije će se pokazati da je ovo ključni metodološki problem ove skupine istraživanja. Pozitivna osjetljivost investicija na novčane tokove može odražavati bolje investicijske prilike, a ne financijsko ograničenje.

Treće, važno je odrediti *proxy* za promjenu u neto vrijednosti (Hubbard, 1988). Prvo je pitanje kako mjeriti neto vrijednost, a drugo, kako izolirati promjenu neto vrijednosti od promjene potražnje za investicijama zbog većih investicijskih prilika. Moguće je da su novčani tokovi povezani s budućom profitabilnošću. Pritom pozitivna korelacija između novčanih tokova i investicija zapravo označava korelaciju između očekivane profitabilnosti i investicija (rezultat standardne neoklasične investicijske jednadžbe). U radovima spomenutih autora, ali i u brojnim drugima, upotrijebljen je Tobinov q kao *proxy* za investicijske prilike. Druga je mogućnost korištenje određenom mjerom kolaterala ili novca u užem ili širem smislu.

Regresijska investicijska jednadžba reducirane forme koja služi u procjeni financijskog ograničenja ima sljedeći oblik (FHP.):

$$\left(\frac{I}{K}\right)_{it} = f\left(\frac{X}{K}\right)_{it} - g\left(\frac{CF}{K}\right)_{it} + u_{it} \tag{108}$$

gdje su I_{it} investicije tvrtke i u razdoblju t, Krazina kapitala (ili vrijednost imovine), X vektor varijabli koje determiniraju investicije, a u_{it} pogreške relacije. Funkcija g ovisi o internim novčanim tokovima tvrtke (CF) i „reprezentira potencijalnu osjetljivost investicija na fluktuacije u dostupnom internom financiranju – pošto smo kontrolirali za investicijske prilike sadržane u X“ (najčešće q) (FHP). Drugim riječima, CF je *proxy* za interna sredstva tvrtke.

Primjena jednadžbe (114) unutar q-teorije daje jednadžbu (FHP):

$$\left(\frac{I}{K}\right)_{it} = \alpha_i + \alpha_t + \beta Q_{it} - \mu\left(\frac{CF}{K}\right)_{it} + u_{it} \tag{109}$$

gdje su varijable definirane kao i u jednadžbi (108), a Q_{it} označava prosječni q za tvrtku i u razdoblju t, a služi kao *proxy* za Tobinov granični Q_{it}[27], to jest investicijkse prilike. Q_{it} se najčešće procjenjuje pomoću jednadžbe (Erickson i Whited, 2000):

$$q = \frac{D_{it} + S_{it} - N_{it}}{K_{it}} \tag{110}$$

gdje je D_{it} tržišna vrijednost duga, S_{it} tržišna vrijednost kapitala (dionica), N_{it} zamjenska vrijednost zaliha, a K_{it} zamjenska vrijednost stoka kapitala. Jednadžba (109) je dakle standardna investicijska jednadžba potražnje za investicijama (neoklasični ili Tobinov q-model) proširen za financijske varijable koje trebaju biti *proxy* za financijska ograničenja.

Umjesto q-a, kao proxy za investicijske prilike može se upotrijebiti stopa rasta prihoda (npr. Tarassow 2014) ili druge potražne varijable. Obje bi varijable trebale kontrolirati za potražne faktore. U suprotnom bi pozitivni novčani tokovi mogli biti interpretirani kao pomaci u potražnji, a ne promjene u ponudi kredita, koje su rezultat nesavršenih kapitalnih tržišta. Interna sredstva također se mogu prezentirati na različite načine. Najčešći pristup je korištenje novčanih tokova kao u Fazzari i ostali (1988), ali moguće je za neto vrijednost upotrijebiti operativni dohodak poduzeća (bruto dodana vrijednost umanjena za troškove proizvodnje) ili zadržane zarade (zadržane zarade nakon isplate dividendi korporativna su štednja).

Radovi prije Fazzaria i ostalih (1988) uvodili su pretpostavku o reprezentativnom agentu i primijenili jednadžbu (109) na veliki uzorak tvrtki u SAD-u. Koeficijent μ tipično je bio signifikantno veći od 0, što je impliciralo odbacivanje neoklasične teorije investicija. Međutim, takve procjene imale su dva velika problema. Jedan je problem endogenosti – pozitivna korelacija novčanih tokova i u_{it}. Konkretnije, novčani tokovi mogu biti pozitivno korelirani s očekivanom budućom profitabilnošću.[28] Tvrtke s visokim novčanim tokom vjerojatno imaju kvalitetnije proizvode, pa time i poticaj za investiranje. Drugi je problem pogreška u mjerenju (engl. *measurement error*) q-varijable, koji je pristran prema gore na μ. Treći je problem izbor endogene varijable kao kriterija razgraničavanja ograničenih i neograničenih poduzeća. Moguće je da poduzeća mijenjaju politiku dividendi prema željenim investicijama, a ne obrnuto (Hansen, 1999).

[27] U teorijskom pregledu (potpoglavlje 2.2.3.2.) pokazano je koje pretpostavke moraju vrijediti da granični q bude jednak prosječnom q.
[28] Utjecaj rasta očekivane profitabilnosti na investicije prikazan je u teorijskom pregledu (potpoglavlje 2.3.2.).

Autori su pokušali riješiti potonji problem odvojenom procjenom μ-a za tri skupine poduzeća, pri čemu su skupine uspostavljene prema politici isplate dividendi (prva su skupina poduzeća s manje od10 % omjera isplate dividendi, a treća s više od 20 %). Regresijska je jednadžba uključivala i fiksne efekte tvrtke i vremena. Uzorak je sadržavao 421 veliku tvrtku iz SAD-a od 1970. do 1984. Rezultati testiranja pokazali su da tvrtke iz prve skupine imaju veći μ (0,461 sa standarnom pogreškom 0,027) od poduzeća iz treće skupine (regresijski koeficijent iznosi 0,23 uza standardnu pogrešku 0,010). $\bar{R}^2$ iz prve grupe varira $0{,}46 - 0{,}55$, ovisno o razdoblju. Dodavanje novčanog toka u regresijsku jednadžbu povećava $\bar{R}^2$ za 0,23 u prvoj, 0,11 u drugoj i 0,08 u trećoj skupini poduzeća. Analiza robusnosti (dodavanje pomaknutih varijabli Q-a i CF-a i dr.) ne mijenja znatno prvotni rezultat, pa se jednostavno može zaključiti da fenomen financijskog ograničenja ima signifikantan utjecaj na investicije. Tvrtke koje su iscrpile sve interne izvore financiranja postaju osjetljivije na fluktuacije u novčanim tokovima, za razliku od zrelih, dividendnih tvrtki.

Hubbard (1998) i Stein (2003) daju pregled brojnih radova koji su nakon radova FHP empirijski testirali utjecaj novčanih tokova na investicije za različite, apriorno utvrđene skupine poduzeća. Hubbard je usredotočen na osjetljivost investicija na novčane tokove. Stein (2003) osim asimetričnosti informacija pruža pregled radova koji su se bavili utjecajem troškova kontrole menadžmenta na investicije. Naime, ponašanje investicija može biti rezultat optimističnih ili pesimističnih očekivanja menadžmenta.

Potonja analiza osjetljivosti investicija na novčane tokove provodila se na uzorku poduzeća iz različitih zemalja. Najviše je istraživanja provedeno na uzorku poduzeća iz SAD-a na temelju baze podataka Compustat. Oliner i Rudebusch (1992) koristili su se panelom američkih tvrtki i potvrdili da su asimetričnost informacija i financijsko ograničenje osnovna determinanta koja objašnjava pozitivnu osjetljivost investicija na novčane tokove. Hsiao i Tahmiscioglu (1997) na uzorku od 561 tvrtke iz proizvodnog sektora od 1971. do 1992. procjenjivali su pet različitih funkcija investicija od kojih tri sadržavaju mjeru likvidnosti (novčani tok umanjen za dividende), a preostale dvije čine Tobinov q model i model prodajnih kapaciteta. Za razgraničavanje ograničenih i neograničenih poduzeća korišten je pokazatelj intenzivnosti kapitala (granična vrijednost iznosi 0,55). Rezultati pokazuju visoku signifikantnost procijenjenih parametara uz novčane tokove. Kapitalno intenzivnija poduzeća imaju od 60 % do 80 % veću osjetljivost investicija na novčane tokova.

Abaob i Marouene (2013) su na uzorku 88 tunižanskih tvrtki dobili potvrdu rezultata FHP (1988) i Clearya te ostalih (2007). Guariglia, Tsoukalas i Tsoukas (2012) su na uzorku poduzeća iz razvijenih zemalja pokazali da tvrtke s problemom prilagođavanja kapitala pokazuju veći stupanj financijskog ograničenja. Hoshi, Kashyap i Scharfstein (1991) su na uzorku japanskih proizvodnih poduzeća pokazali da poduzeća sa slabijim vezama s poslovnim bankama imaju veću osjetljivost investicija na novčane tokove. Shin i Park (1999) na uzorku korejskih tvrtki od 1994. do 1995. nisu pronašli pozitivnu korelaciju između investicija i internih sredstava za *chaebol* kompanije (veliki poslovni konglomerati u većinskom vlasništvu jedne obitelji), a u ostalim su tvrtkama pronašli pozitivnu korelaciju, što potvrđuje veće financijsko ograničenje za drugu skupinu tvrtki.

Neki su radovi kao zavisnu varijablu umjesto investicija upotrijebili ulaganje u istraživanje i razvoj. Primjerice, Himmelberg i Petersen (1994) su na uzorku od 179 malih tvrtki iz visokotehnološke industrije od 1983. do 1987. testirali odnos investiranja u istraživanje i razvoj te internih sredstava. Primjenjujući metodu fiksnih efekata, autori su zaključili da male tvrtke iz visokotehnološkog sektora pokazuju ekonomski i statistički signifikantnu osjetljivost investicija na novčane tokove. Drugim riječima, male visokotehnološke tvrtke pretežito se iz internih sredstava.

Gertler i Gilchrist (1994) proveli su sličan test, ali su se usredotočili na efekte monetarne politike. Kao kriterijem razlikovanja financijski ograničenih i neograničenih poduzeća koristili su se veličinom tvrtke. Kratkoročni se dug poduzeća sastoji od bankovnih kredita, a kratkoročni je dug velikih kompanija ravnomjerno raspodijeljen na bankovni dug i komercijalne papire. Autori potom promatraju različito ponašanje zaliha, prihoda i kratkoročna duga tvrtki zbog promjene monetarne politike. Rezultati potvrđuju hipotezu nesavršenih financijskih tržišta. Prihodi malih tvrtki pokazuju veću amplifikaciju od onih velikih tvrtki. Zaoštrena monetarna politika ne utječe na zaduživanje velikih tvrtki, ali uzrokuje snažan pad zaduženja i zaliha malih tvrtki. Gilchrist i Himmelberg (1995) potvrdili su općenitu važnost novčanih tokova za investicije te posebno potvrdili veću osjetljivost za poduzeća koja imaju ograničen pristup financijskim tržištima.

Bernarke Gertler i Gilchrist (1996) pružili su teorijski i empirijski prikaz fenomena financijskog akceleratora. U teorijskom je pregledu (potpoglavlje 2.5.2.1.) pokazano da je temelj financijskog akceleratora CSV pretpostavka koja implicira ograničavanje kredita poduzećima s većim agencijskim troškovima. Recesija i posljedično pad neto vrijednosti negativno utječu

na granične tvrtke. Autori pretpostavljaju da su to većinom male tvrtke. U empirijskom dijelu autori slijede rad Gertlera i Gilchrista (1994). Raščlanjuju tvrtke na velika i mala poduzeća prilagođavajući uzorak za specifičnost industrije. Rezultati su slični kao i u potonjem radu. Poduzeća koja su apriorno identificirana kao ograničena pokazuju manju osjetljivost realnih varijabli na promjene u kamatnoj stopi (monetarne šokove). Osnovni je problem isti kao i u proučavanja investicija. Rast novčanih tokova može reprezentirati veće investicijske prilike.

Većina do sada prikazanih radova služi se bazom podataka izlistanih tvrtki zbog mogućnosti uporabe Tobinova $q -$ a kao *proxyja* za investicijske prilike. Međutim, u sve se više radova u uzorak uvrštavaju i tvrtke koje nisu na organiziranim tržištima kapitala. Carrascal i Ferrando (2008) su na temelju baze neizlistanih tvrtki iz Njemačke, Belgije, Nizozemske, Francuske, Italije i Španjolske pokazali da dugovni teret (engl. *debt burden*) utječe na investicije. Tarassow (2014) se koristio panel- podacima za Njemačku i pokazao da određene financijske varijable (posebice pokazatelj pokrivenosti kamata) razdvajaju financijski ograničena i neograničena poduzeća.

Zaključno, može se reći da su brojna istraživanja koja su na uzorku različitih zemalja, koristeći se različitim ekonometrijskim metodama, potvrdila pozitivnu osjetljivost investicija na novčane tokove za većinu tvrtki, pri čemu postoji heterogenost u osjetljivosti za različite skupine poduzeća.

3.2.1 Utjecaj financijskih frikcija na razinu novčanih sredstava

Financijsko ograničenje može se testirati i unutar politike upravljanja novčanim sredstvima (engl. *cash management*). Ako tvrtka nije financijski ograničena, ne treba čuvati novac za buduće investicije, pa iznos držana novca ne bi trebao ovisiti o novčanim tokovima ili volatilnosti novčanih tokova. Obrnuto, ako su tvrtke financijski ograničene, odlučit će držati novac kako bi se osigurale od mogućeg naglog pada novca u budućnosti čime bi izgubile mogućnost financiranja dodatnih investicija.

Almeida, Campello i Weisbach (2004, nadalje ACW) su kao zavisnu varijablu umjesto investicija upotrijebili graničnu sklonost štednji iz novčanih priljeva. Autori su prezentirali teorijski i empirijski model. Rezultat teorijskog modela pokazuje različito ponašanje financijski ograničenih i neograničenih tvrtki s obzirom na osjetljivost novčanih tokova na novčana

sredstva: ($\frac{\partial C}{\partial c_0}$): 1) $\frac{\partial C}{\partial c_0}$ je pozitivan za financijski ograničene tvrtke 2)$\frac{\partial C}{\partial c_0}$ je neodređen za financijski neograničene tvrtke. Drugim riječima, financijski bi ograničene tvrtke trebale povećavati iznose novca zbog pozitivnih šokova novčanih tokova (pozitivna korelacija između novčanih sredstava i novčanog toka). Autori su testirali potonje hipoteze na uzorku od 29.954 poduzeća od 1971. do 2000. Osnovna regresijska jednadžba ima oblik (usporediti s jednadžbom (109)):

$$\Delta cashholdings_{it} = \alpha_0 + \alpha_1 Cashflow_{it} + \alpha_2 Q_{it} + \alpha_3 Size_{it} + u_{it} \qquad (111)$$

gdje je $cashholdings$ omjer stanja novca i tržišne vrijednosti ukupne imovine, $Cashflow$ odnos zarada uvećanih za amortizaciju i ukupne imovine, a $Size$ prirodni logaritam imovine. Alternativna specifikacija dodaje sljedeće nezavisne varijable: kapitalne izdatke, akvizicije (tvrtke mogu skupljati novac radi budućih investicija i akvizicija), promjene u radnom kapitalu i promjene u kratkoročnom dugu (zamjena za novac). Važna je procjena α_1. Valja primijetiti da je kao zavisna varijabla upotrijebljena financijska, a ne realna varijabla (investicije). Više je pokazatelja upotrijebljeno kao mjera financijskog ograničenja: veličina poduzeća, veličina imovine, postojanje rejtinga obveznica, rejting komercijalnih vrijednosnih papira, KZ indeks. Rezultati pokazuju da financijski ograničene tvrtke drže veće iznose novčanih sredstava od neograničenih tvrtki (15 % prema 8 % imovine). Rezultati regresijske jednadžbe pokazuju da financijski ograničene tvrtke za svaki dolar uvećanja novčanog toka štede između 5 i 6 centi, a neograničene tvrtke ne štede ništa. Može se zaključiti da financijski ograničene tvrtke drukčije reagiraju na promjene novčanih sredstava zbog financijskog ograničenja. Istraživanje autora ima implikacije i za politiku likvidnosti. Ako tvrtke nisu financijski ograničene, uvijek se mogu financirati iz eksternih izvora, pa nema potrebe za stvaranjem likvidnosti.

Han i Qiua (2007) u teorijski model ACW-a uvode odnos preventivne štednje i volatilnosti novčanih tokova. Uz pretpostavku nemogućnosti zaštite od rizika, veća osjetljivost novčanih tokova povećava preventivnu potražnju za likvidnošću. Empirijski je test proveden na uzorku tromjesečnih financijskih izvještaja nefinancijskih poduzeća (Compustat) za razdoblje od 1997. do 2002. Tvrtke su podijeljene u financijski ograničene i neograničene koristeći se indeksima financijskog ograničenja (veličina, omjer isplate dividendi, rejting). Rezultati procjene dinamičkog panela pokazuju da volatilnost novčanih tokova utječe na iznos držane razine novca za financijski ograničena poduzeća, ali ne i za financijski neograničena poduzeća. Sufi (2009) je također pokazao da financijska ograničenost, mjerena kao nedostupnost kreditnih linija, pridonosi pozitivnoj vezi između novčanih tokova i investicija.

Baum i dr. (2009) su, koristeći se metodologijom ACW, na uzorku od 6970 tvrtki iz 36 različitih zemlja od 1989. do 2006. pokazali kako je osjetljivost novčanih sredstava na novčane tokove znatno veća u ekonomijama utemeljenim na tržištu (engl. *market-based economies*) nego u bankocentričnim ekonomijama.

Podaci za tvrtke u EU (ECB, 2013) pokazuju da velike tvrtke drže relativno manje novca od malih tvrtki. Novčani tokovi i volatilnost novčanih tokova pozitivno koreliraju s novčanim sredstvima, a poluga negativno korelira. Efekt poluge pojačao se poslije krize što može implicirati pritisak na razduživanje poduzeća. Osjetljivost opipljive imovine i novčanih sredstava također je pozitivna jer se opipljiva imovina može upotrijebiti kao kolateral pri zaduživanju pa njezin veći udio povećava kreditnu sposobnost (zamjena novčanih sredstava i kolaterala).

3.2.2 Problem endogenosti i ostale kritike u procjenjivanju osjetljivosti investicija na novčane tokove

Može se zaključiti da testiranje hipoteze o financijskim frikcijama unutar q-teorije investicija najčešće uključuje regresiranje investicija na neku od mjera financijskog ograničenja i na novčane tokove. Regresija se može provoditi na razini tvrtki ili na agregatnoj razini. Provedeno je mnogo takvih testova i može se zaključiti da regresiranje investicija na Tobinov q i novčane tokove tipično rezultira malim pozitivnim koeficijentom na q i signifikantnim pozitivnim koeficijentom na novčane tokove. Mali koeficijent uz q obično se objašnjava velikim konveksnim troškovima prilagođavanja, a veliki koeficijent uz novčane tokove za zadužene tvrtke uzima se kao dokaz postojanja financijskog ograničenja tvrtki. Međutim, brojni radovi nakon radova FHP upozoravali su na određene probleme pri testiranju standardnoga linearnog investicijskog regresijskog modela s novčanim tokovima. Dva glavna prigovora odnose se na problem endogenosti (nedostajuća varijabla, odnosno pogreška u mjerenju q-a) i apriorno razgraničavanje poduzeća. Prvi je prigovor posebno problematičan. Novčani tokovi vrlo vjerojatno snažno koreliraju s budućom profitabilnošću. U nastavku se prikazuju radovi povezani s potonjom kritikom.

Najpoznatija je kritika Kaplana i Zingalesa (1997), koji su pokazali da financijski neograničene tvrtke imaju signifikantno veću osjetljivost investicija na novčane tokove od ograničenih tvrtki. Dakle, visoki koeficijenti uz novčane tokove ne mogu biti dokaz financijskog ograničenja.

Autori su pružili empirijski i teorijski dokaz svojih tvrdnji. U nastavku ukratko se prikazuje model prema Kaplan i Zingales (1997) i Romer (2011).

Tvrtka bira investicije kako bi maksimirala profit. Prinos na ulaganje dan je proizvodnom funkcijom $F(I)$, za koju vrijedi $F' > 0, F'' < 0$. Investicije mogu biti financirane internim (W) i eksternim sredstvima (E). Trošak internih sredstava jednak je trošku kapitala (R) i jednak je 1. Troškovi eksternog financiranja dani su funkcijom $C(E, k)$, gdje je E iznos sredstava, a k mjera agencijskih troškova. Tvrtka bira I kako bi maksimirala:

$$\max_{I} F(I) - C(E, k) - I \tag{112}$$

gdje je $I = W + E$, a C je konveksna u E. Uvjeti prvog reda dani su jednadžbom:

$$F_I(I) = 1 + C_1(I - W, k) \tag{113}$$

Implicitnim deriviranjem po W dobiva se (analiza po k daje slične rezultate):

$$\frac{dI}{dW} = \frac{C_{11}}{C_{11} - F_{11}} \tag{114}$$

gdje je C_{11} nagib krivulje ponude eksternog financiranja, a F_{11} nagib krivulje potražnje za investicijama (Fazzari i ostali, 2000). Izraz je pozitivan uz prijašnju pretpostavku o konveksnosti funkcije C. Investicije su osjetljive na interna sredstva (savršena tržišta kapitala podrazumijevaju $C(.) = 0$). Ovaj je rezultat u skladu s hipotezom FHP – rast internih sredstava povećava investicije tvrtki koje su financijski ograničene. Da bi se testirao uvjet monotono padajućeg odnosa investicija i novčanog toka, autori su diferencirali jednadžbu (120), čime se dobiva:

$$\frac{d^2I}{dW^2} = \left[\frac{F_{111}}{F_{11}} - \frac{C_{111}}{C_{11}}\right]\frac{F_{11}^2 C_{11}^2}{(C_{11} - F_{11})^3} = \frac{F_{111}{C^2}_{11} - C_{111}{F^2}_{11}}{(C_{11} - F_{11})^3} \tag{115}$$

Predznak izraza $\frac{d^2I}{dW^2}$ ovisi o predznaku izraza u uglatoj zagradi. Ako je $F_{111} > 0$ ili $C_{111} < 0$, izraz u zagradi bit će pozitivan. Međutim, iste varijable mogu biti i drukčijeg predznaka. Autori tvrde da radovi koji su testirali odnos investicija i novčanih tokova nisu procjenjivali predznake uz $F'''(.)$ i $C'''(.)$, pa testovi ne daju točnu procjenu o odnosu novčanih tokova i investicija. Odnos ovisi o obliku funkcije proizvodnje i funkcije troškova. Na kraju valja primijetiti da autori ne negiraju postojanje financijskog ograničenja, nego osporavaju opravdanost pristupa radova FHP i radova ostalih autora koji financijsko ograničenje testiraju uključivanjem

novčanih tokova u investicijsku jednadžbu. Naime, moguće je da odnos nije monoton zato što je nepoznat predznak druge derivacije.

Fazzari i ostali (2000) u odgovoru na kritiku Kaplan i Zingales (1997) tvrde da teorija zapravo jasno upućuje na predznak treće derivacije. Uvjet da $\frac{dI}{dW}$ bude veći za ograničena je poduzeća e

$$\frac{C_{11}^{ograničena}}{C_{11}^{neograničena}} > \frac{F_{11}^{ograničena}}{F_{11}^{neograničena}} \tag{116}$$

Autori tvrde da ne postoji razlog zašto bi desna strana bila pozitivna. S druge strane, brojni radovi upućuju na zaključak da $C_{11}^{neograničena}$ teži nuli s rastom razlike između investicija i internih sredstava. Postoji empirijski i teorijski temelj koji pokazuje da $C_1(I - W, k)$ raste polako, ali nakon određenog stupnja postiže veliki rast (zbog financijskog ograničenja), što implicira $C_{111} > 0$ i negativan $\frac{d^2I}{dW^2}$. Drugim riječima, investicije su manje osjetljive na novčane tokove kada tvrtka ima veće iznose internih sredstava.

Ukratko, u svojem istraživanju Kaplan i Zingales (1997) kritiziraju mogućnost monotone povezanosti investicija i novčanih tokova. U empirijskoj analizi, autori su se koristili istim uzorkom kao FHP, 49 tvrtki s niskim omjerom isplate dividendi od 1970. do 1984. Koristeći se podacima iz godišnjih financijskih izvještaja (likvidna imovina, iznos obveza) i bilješkama iz godišnjih financijskih izvještaja (pisma menadžera i članova uprave o stanju tvrtke), tvrtke su podijeljene u pet kategorija s obzirom na vjerojatnost financijskog ograničenja. Tako je 85 % poduzeća bilo klasificirano u prve dvije skupine (skupina poduzeća koja su mogla povećati investicije), a samo 2,6 % tvrtki svrstano je u skupinu financijski ograničenih poduzeća. Dodatno, autori su testirali jednadžbe za neograničena i ograničena poduzeća. Rezultati su pokazali da ograničena poduzeća imaju veće koeficijente uz novčane tokove od neograničenih poduzeća, u cijelom uzorku, uza sve kriterije raščlanjivanja ograničenih i neograničenih tvrtki. Do istog je došao i Cleary (1999) na uzorku od 1317 tvrtki iz SAD-a: tvrtke s boljim bonitetom imaju veću osjetljivost investicija na novčane tokove. Zaključak je da nedostatak isplate dividendi i signifikantnost novčanih tokova ne mogu biti korisni indikatori financijskog ograničenja (razlog može biti preventivna štednja poduzeća).

Fazzari i ostali (2000) ponudili su nekoliko argumenta kao odgovor na potonju empirijsku analizu Kaplana i Zingalesa. Prvo, kvalitativni podaci prikupljeni iz izvještaja menadžera nisu vjerodostojni jer menadžeri nisu obvezni navoditi financijsko ograničenje kao faktor

nepoduzimanja projekta s pozitivnim NPV-om, čak i kada oni postoje. Drugo, kako bi identificirali neograničene tvrtke, autori su računali pokrivenost fiksnih materijalnih investicija novčanim tokovima umjesto ukupnih investicija (materijalne + zalihe + potraživanja). Potonji je argument važan i za rezultate regresije. Moguće je da financijski ograničene tvrtke imaju male koeficijente uz novčane tokove jer se moraju koristiti novčanim tokovima za uspostavljenje likvidnosti (izbjegavanje bankrota), pa bi bilo primjerenije za varijablu investicija upotrijebiti širu definiciju investicija. Također, što je poduzeće financijski ograničenije, to će biti motiviranije držati više novčanih sredstava kao osiguranje od nepredviđenih događaja. Treće, autori tvrde da je identificiranje potencijalno financijski ograničenih tvrtki na temelju podataka iz financijskih izvještaja pogrešno. Primjerice, maleni dugovi mogu biti posljedica male potražnje za dugom (konzervativne politike) i nemogućnosti povećanja financijske poluge. Slično vrijedi i za pokrivenost kamata. Niski iznos pokrivenosti kamata može implicirati kreditnu sposobnost, ali i postojanje financijskog ograničenja. Može se zaključiti da se rasprava vodila o monotonosti funkcije osjetljivosti investicija na novčane tokove i da ne postoji konsenzus o monotono rastućoj osjetljivosti.

Erickson i Whited (2000) pokazali su da veliki koeficijent uz novčane tokove može biti rezultat pogreške u mjerenju q-a (engl. *measurement error in* q). Koristeći se podacima o 737 proizvodnih poduzeća od 1992. do1995. autori su, primijenivši model mjerne pogreške (engl. *measurement error models*)[29] i GMM procjenitelj identificirali pogreške u mjerenju u standardnoj regresijskoj jednadžbi investicija. Rezultati su pokazali da je procjenitelj uz q-varijablu viši nego OLS procjenitelj, a koeficijent je uz varijablu novčanog toka viši za tvrtke koje nisu financijski ograničene. Rezultati pokazuju da visoki koeficijenti uz novčane tokove ne moraju biti dokaz financijskih ograničenja, ali ne i da tvrtke ne mogu biti financijski ograničene.

Alti (2003) je pokazao da koeficijent uz novčane tokove može biti pozitivan i u modelima bez financijskih ograničenja. U modelu ne postoji ograničenje na zaduživanje. Tvrtke su nesigurne u vezi s kvalitetom projekta, pa su šokovi na novčane tokove vrlo informativni za očekivanu buduću profitabilnost. Mlade tvrtke stoga snažno reagiraju na šokove novčanih tokova. Rezultati su modela: 1) investicije su osjetljive na novčane tokove za sve tvrtke, čak i uz uvjetovanost na Tobinov q, 2) osjetljivost je veća za mlade, male tvrtke s visokim stopama

[29] Riječ je o regresijskim modelima koji vode računa o mogućoj pogrešci u mjerenju nezavisne varijable. Ako postoji pogreška u mjerenju, standardne pretpostavke linearne regresije stvaraju nekonzistentne procjenitelje, što znači da procijenjeni parametri ne teže pravim vrijednostima, čak i za velike uzorke.

rasta, 3) Tobinov q neprimjerena je mjera investicijskih prilika za manje, mlade tvrtke. Autori posebno objašnjavaju zašto je q loša mjera investicijskih prilika za mlade, male tvrtke. Novčani tokovi u jednoj godini pružaju informaciju o kvaliteti projekta i pridonose signifikantnu povećanju investicija, a Tobinov q ne sadržava tu informaciju. Također, Tobinov q sadržava informaciju o dugoročnim mogućnostima rasta, ali ne govori mnogo o kratkoročnim investicijama, dok novčani tokovi služe kao dobar *proxy* za tekuću profitabilnost i kratkoročnu dinamiku investicija.

Moyen (2002) je pokazao da ograničene tvrtke mogu pokazivati manju osjetljivost na novčane tokove od neograničenih. Autor potvrđuje rezultate Gomesa (2001) – korelacija između investicija i novčanih tokova može biti pozitivna i u financijski neograničenim tvrtkama, čak i veća nego u ograničenim tvrtkama. Cummis, Hassett i Oliner (1999) procjenjivali su neoklasičnu investicijsku jednadžbu, ali su, osim prosječnog q-a, kao mjeru tvrtkinih fundamenata upotrijebili i „realni“ q (razdoblje od 1982. do 1999.). Realni q dobiven je iz podataka o očekivanim zaradama poduzeća. Procjenjivanje investicijske regresijske jednadžbe OLS-om daje rezultate suprotne onima u FHP. Dodavanjem realnog q-a osjetljivost investicija i novčanih tokova postaje nesignifikantna za ograničena i za financijski neograničena poduzeća[30]. Bond i ostali (2004) također su pokazali da pogreške u mjerenju očekivane profitabilnosti tvrtke objašnjavaju većinu opažene pozitivne korelacije između fiksnih investicija i novčanog toka. Autori su u klasičnu $q-$jednadžbu investicija za testiranje financijskog ograničenja dodali očekivanu profitabilnost analitičara na organiziranim tržištima kapitala. Poslije kontroliranja za buduću profitabilnost posve nestaje osjetljivost između novčanih tokova i investicij**a.**

Bushman, Smith i Zhang (2012) uobičajenu su mjeru neto vrijednosti, zarade prije amortizacije, raščlanili na dvije novčane kategorije: nenovčanu obračunsku komponentu radnog kapitala (engl. *non-cash working capital accrual component- WCACC*) i novčanu komponentu. Investicije i WCACC pokazuju pozitivnu korelaciju zbog zakonitosti rasta (očekuje se održavanje konstantnog koeficijenta konstitucije), a osjetljivost investicija i novčane komponente pokazuju negativne vrijednosti i opadaju kao funkcija financijskog ograničenja, što je u suprotnosti s hipotezom da financijski ograničenija poduzeća ostvaruju veće osjetljivosti

[30] Kritiku ovog istraživanja dali su Carpenter i Guariglia (2006). Autori su pokazali da je u dinamičkom ekonometrijskom modelu, procijenjenom GMM-om, osjeljtivost investicija na novčane tokove niska bez obzira na to upotrebljava li se prosječni q ili „realni“ q. Autori su također pokazali da rezultati nisu robusni na male promjene specifikacije modela i izbora uzorka.

novčanih tokova i investicija. Drugim riječima, pozitivna osjetljivost investicija na novčane tokove logična je posljedica rasta poduzeća, jer veće investicije zahtijevaju i veći radni kapital. George, Kabir & Qian (2011) na uzorku tvrtki iz Indije pronašli su pozitivnu korelaciju između investicija i novčanih tokova za sva, apriorno ograničena i neograničena poduzeća. Grullon, Hund i Weston (2017) analizirali su utjecaj q i novčanh tokova na investicije najvećih kompanija u SAD-u. Rezultati su pokazali znatno veći koeficijent uz novčani tok u svim specifikacijama, što je suprotno hipotezi o financijskom ograničenju.

U pojedinim je radovima u središtu pozornosti rast tvrtke, zaposlenosti ili ukupne imovine (npr. Oliviera i Fortunato, 2006; Fagiolo i Luzzi, 2006). Međutim, oni imaju iste nedostatke kao i empirijski radovi koji su testirali osjetljivost investicija na novčane tokove, pa se neće detaljnije analizirati.

Sve potonje kritike standardne regresijske jednadžbe (Erickson i Whited, 2000; Gomes, 2001; Alti, 2003 i dr.) mogu se sažeti u tvrdnji da se, čak i bez financijskog ograničenja, može očekivati pozitivna korelacija između novčanog toka i investicija ako novčani tokovi sadržavaju informaciju o odnosu realne potražnje za investicijama i investicijskih prilika.

Na kraju se sažimaju svi problemi standardne regresijske jednadžbe investicija s novčanim tokovima kao nezavisnom varijablom:

1. Problem endogenosti (nedostajuća varijabla) – novčani su tokovi u korelaciji s investicijskim prilikama. Oni su *proxy* za buduću profitabilnost te ne pružaju dokaze o postojanju ograničenja. Uključivanje Tobinova q-a ne rješava nužno problem zbog moguće pogreške u njegovu mjerenju.
2. Različita apriorna klasifikacija poduzeća daje različite rezultate testova.
3. Pogreška u mjerenju q-a – prosječni q loš je *proxy* za marginalni q.
4. Novčani se tokovi, umjesto za investicije, mogu upotrijebiti u druge svrhe: za zalihe, radni kapital ili štednju iz opreznosti (u intertemporalnome modelu tvrtke štede kako bi se osigurale od budućih rizika).
5. Nemonotona relacija između novčanih tokova i investicija – nekoliko problematičnih tvrtki koristi se novčanim tokovima za isplatu dugova. Posrnule tvrtke koriste se njima za otplatu postojećih zajmova. U uzorku su samo tvrtke s pozitivnim internim sredstvima (novčanim tokovima), čime se isključuje velik dio tvrtki, koje pokazuju negativan odnos između novčanih tokova i investicija (Cleary i ostali, 2007).

6. Neovisne promjene u internim sredstvima (Hubbard, 1988) – novčani tokovi mogu biti korelirani s pogreškama relacije. Primjerice, u_{it} može sadržavati agregatni tehnološki šok, pa rast novčanih tokova odražava rast potražnje za investicijama. Problem se može ublažiti uvođenjem pomaknutih varijabli. Kao instrumentalna varijabla za novčane tokove mogu se upotrijebiti izdaci za poreze (Hubbard, Kashyap i Whited, 1995).
7. Pretpostavlja se da su tvrtke tijekom promatrana razdoblja uvijek u istom režimu zaduženosti. Moguće je da tijekom vremena poduzeće prelazi iz skupine nezaduženih u skupinu (pre)zaduženih poduzeća ili obrnuto.
8. Problem autokorelacije pogrešaka relacije u većini specifikacija investicijske jednadžbe (Cummis, Hassett i Oliner, 1999).

Potonjim nedostacima treba dodati i praktičan problem. Prvo, iz financijskih su izvještaja dostupni samo godišnji podaci, što stvara preveliki vremenski pomak između opservacija. Drugo, uzorci u istraživanjima pretežito su javne kompanije koje posluju na organiziranim tržištima kapitala, pa se uzorak ne može smatrati reprezentativnim za ostale oblike organiziranja (društva s ograničenom odgovornošću, obrte). To je posebno izraženo u zemljama s nerazvijenijim tržištima kapitala. Treće, osjetljivost investicija na novčane tokove može biti pod snažnim utjecajem nekoliko tvrtki (postojanje ekstremnih vrijednosti). Treba biti oprezan i pri mjerenju novčanih tokova. Slobodne novčane tokove treba umanjiti za zahtijevane izdatke (npr. izdatke za mirovinske planove). Mnogi radovi koriste se balansiranim panelima, što može uzrokovati pristranost preživljavanja (engl. *survivorship bias*) (Baum, 2006). Na kraju, poduzeća mogu prelaziti tijekom vremena iz jednog stanja u drugo (iz financijski neograničenih u ograničena i obrnuto).

U području korporativnih financija niz je radova koji osjetljivost investicija i novčanih tokova pokušavaju objasniti troškovima agenta. Primjerice, oslanjanje na interne izvore financiranja može biti rezultat ponašanja menadžera i preferencija vlasnika, koji imaju averziju prema izvanjskom nadzoru ili pokazuju visoku averziju prema riziku i uz visoke novčane tokove. Također, moguće je da menadžeri maksimiraju neku drugu funkciju osim budućih dividendi. Iako je ova skupina istraživanja izvan objekta promatranja ovog rada, važno je primijetiti da osjetljivost investicija na novčane tokove može biti pod utjecajem troškova agenta i bihevioralnih karakteristika menadžera.

Poseban je problem klasifikacija tvrtki na ograničene i neograničene *ex ante* (vidjeti Farre-Mensa i Ljungqvist (2013) niže). Na primjer, Kaplan i Zingales (2000) navode da bi prema

kriterijima FHP Microsoft bio ograničena kompanija iako nije imala dugova i raspolagala s devet bilijuna dolara na računu. Dodatno, mjere financijskog ograničenja mogu same biti pod utjecajem financijskog ograničenja (Bond i ostali, 2004). Posebno je problematično ako se za granične varijable upotrebljavaju kontrolne (endogene) varijable poput isplate dividendi. Naime, poduzeća mogu mijenjati isplatu dividendi kako bi prilagođavala razinu investicija. Postavlja se i problem dinamike. Mala tvrtka može biti okarakterizirana kao ograničena. Ista ta tvrtka može rasti i, nakon prelaska proizvoljne granice, može s vremenom postati neograničena, što je posebno problematično ako se koristi dugim vremenskim serijama (dinamička pogreška klasifikacije – engl. *misclassification*).

3.2.3 Problem apriorne klasifikacije tvrtki

Već je nekoliko puta spomenuto da je apriorna klasifikacija tvrtki na financijski ograničene i neograničene važan korak u svim radovima koji se koriste osjetljivošću investicija na novčane tokove kao testom financijskog ograničenja. U sljedećoj tablici pružen je pregled različitih kriterija i popis radova u kojima se upotrebljavaju različiti kriteriji razgraničavanja.

Tablica 3-1: Kriteriji razgraničavanja poduzeća

Kriterij razgraničavanja	Primjeri istraživanja
Politika isplate dividendi – što je veći stupanj isplate dividendi, manji je stupanj financijskog ograničenja	Fazzari i ostali (1988), Cleary (1999), Hovakimian i Titman (2006), Bushman, Smith i Zhang (2012).
Veličina – što je tvrtka veća, manji je stupanj financijskog ograničenja	Oliner i Rudebusch (1992), Himmelberg i Petersen (1994), Gertler i Gilchrest (1994), Gilchrist i Himmelberg (1995), Bernarke Gertler i Gilchrist (1996), Almeida, Campello i Weisbach (2004), Hovakimian i Titman (2006), Guariglia (2007)
Izlistavanje — tvrtke koje su na organiziranim tržištima kapitala manje su financijski ograničene	Almeida, Campello i Weisbach (2004) Guariglia (2007)

Starost – što je tvrtka starija, to je manje financijsko ograničenje	Guariglia (2007), Beck et al. (2004), Schaler (1993), Oliner i Rudebusch (1992), Devreux i Schiantarelli (1990) Gertler (1988), Hovakimian i Titman (2006)
Članstvo u skupini kompanije – tvrtke koje su članovi grupacija manje su financijski ograničene	Hoshi, Kashyap & Scharfstein (1991), Shin & Park (1999), George, Kabir & Qian (2011)
Postojanje rejtinga obveznica – tvrtke koje imaju kreditni rejting manje su financijski ograničene	Cummis, Hassett i Oliner (1999), Almeida, Campello i Weisbach (2004), Hovakimian i Titman (2006)

Ovom popisu treba dodati i rad Lamonta, Polk i Saa-Requejoa (2001), koji su koristeći se logit-modelom, varijable iz Zingales (1997) i uzorkom iz FHP konstruirali indeks KZ. On se vrlo često upotrebljava u empirijskim radovima o financijskom ograničenju pri čemu se najčešće tvrtke u gornjem tercilu smatraju ograničenima, a u donjem tercilu neograničenima.

Farre-Mensa i Ljungqvist (2013) testirali su koliko dobro apriorni kriteriji o raščlanjivanju financijski ograničenih poduzeća mjere financijsko ograničenje. Autori su testirali pet kriterija raščlanjivanja: isplata dividendi, postojanje kreditnog rejtinga, indeks KZ, Hadloch-Pierceov indeks i Whited-Wuov indeks. Svi indeksi, osim KZ-a, vrlo slično identificiraju ograničena i neograničena poduzeća. Ograničene su tvrtke manje, mlađe, imaju manju polugu, manje opipljive imovine i veći omjer tržišne i knjigovodstvene vrijednosti. U provođenju testova osnovna je hipoteza da ograničene tvrtke imaju neelastičnu ponudu eksternoga kapitala. Ako je ponuda kapitala dana s $p(k)$, tada je tvrtka ograničenija što je veća neelastičnost ponude (što je krivulja strmija). Autori su proveli tri testa:

1. *Korištenje šokom uvećanja poreza kao šokom na potražnju za dugom.* Poduzeća povećavaju udio duga u strukturi kapitala zbog rasta poreza, zbog učinaka poreznog štita. Tvrtke koje su ograničene ne bi trebale povećati investicije zbog povećanja poreza u državi u kojoj posluju. Rezultati pokazuju da financijski ograničene tvrtke (prema pet pokazatelja zaduženosti) povećavaju svoju polugu zbog rasta poreza.
2. *Korištenje promjenom bankovnog poreza kao šokom ponude kredita.* Financijski neograničene tvrtke ne bi trebale biti pod utjecajem promjene ponude duga zbog negativna poreznog šoka na banke jer imaju mogućnost alternativna financiranja.

Upotrijebljen je procjenitelj *difference-in-differences,* kao i u prošlom pristupu. Jednopostotno povećanje bankovnog poreza smanjuje ponudu kredita za 1,5 –1,8 %. Rezultati regresije OLS pokazuju da se dugovi ograničene tvrtke jednako ponašaju nakon šoka ponude.

3. *Recikliranje kapitala, koje se odnosi na isplatu dividendi i otkup dionica po kapitalu unutar godine dana.* Tvrtka koja reciklira kapital može se smatrati neograničenom. Rezultati potvrđuju hipotezu da ograničene tvrtke recikliraju kapital.

Autori zaključuju da kriteriji razlikovanja kojima se koristi u literaturi o financijskim ograničenjima upućuju na neke bitne razlike u ponašanju poduzeća, ali da one nisu posljedica financijskog ograničenja.

3.2.4 Analiza financijskog ograničenja poduzeća primjenom *threshold* regresije

U ovom se poglavlju prikazuju radovi koji za procjenu stupnja ograničenosti u istraživanju primjenjuju metodu *threshold* regresije. Hansen (1999) je prvi upotrijebio tu metodu za procjenjivanje financijskog ograničenja tvrtki. Autor je prepoznao dva problema u pristupu Fazzarija i dr. (1988). Prvo, omjer je isplate dividendi endogena (kontrolna) varijabla, a upotreba endogene threshold varijable dovodi do pristranih procjenitelja. Drugo, autori se koriste *ad hoc* metodom za podjelu uzorka (vrijednosti granica iznose 0,1 i 0,2). Hansen, koristeći se metodom *threshold* regresije, pokušava prevladati navedene nedostatke. Uzorak se sastoji od 565 tvrtki, za razdoblje od 1973. do 1987. (balansirani panel). Kao *threshold* varijabla (egzogeni indikator) izabran je intenzitet dugoročnog financiranja. Rezultati pokazuju postojanje dviju granica, čije vrijednosti iznose 0,016 i 0,536 (prva je signifikantna uz razinu značajnosti 1 %, a druga uz razinu značajnosti 5 %). Vrijednosti koeficijenata uz novčane tokove po režimima iznose: 0,063, 0,098, 0,039. Iznenađujuća je posljednja vrijednost jer bi najzaduženija poduzeća trebala pokazivati i najveću osjetljivost investicija na novčane tokove. Najveći broj opservacija pripada drugom režimu (u prosjeku 81 % ukupnog broja opservacija). Prvi režim sadržava 12 %, a treći 7 % opservacija. Dinamika pokazuje rast udjela visokozaduženih poduzeća, sa 6 % na 16 %. Ukratko, ne može se prihvatiti hipoteza o monotono rastućoj osjetljivosti novčanih tokova i investicija kao funkcija rasta intenziteta dugoročna financiranja.

Tarassow (2015) se koristio uzorkom njemačkih poduzeća svih veličina (od mikro- do velikih) kako bi testirao postojanje financijskog ograničenja i adekvatnost korištenja različitim financijskim varijablama kao apriornim kriterijima ograničenosti. Rezultati pokazuju da se ne može odbaciti nulta hipoteza o linearnome modelu, kada se kao *threshold* varijabla upotrebljava financijska poluga, intenzitet dugoročna financiranja (ukupne obveze – kratkoročne obveze/ukupni kapital) i vrijednost kolaterala (zbroj zaliha dodirljive imovine i novca kroz dodirljivu imovinu). Dakle, nije primjereno razdvajanje ograničenih i neograničenih poduzeća prema potonjim trima kriterijima jer stvaraju nepristrane procjenitelje. S druge strane, u pokazatelju pokrića kamata, pokazatelju solventnosti i profitabilnosti može se odbaciti hipoteza o nepostojanju granice. Vjerojatnost da tvrtka pripada određenom režimu ne ovisi o njezinoj veličini, čime se implicira da veličina tvrtke nije dobar apriorni pokazatelj za razlikovanje ograničenih i neograničenih tvrtki.[31] Očito je da upotreba različitih kriterija razgraničavanja poduzeća može dati različite (katkad i proturječne) empirijske rezultate. Vrijednosti koeficijenta uz novčane tokove veće su za tvrtke koje pripadaju režimu većega kreditnog ograničenja. Primjerice, za tvrtke koje imaju pokrivenost kamata iznad 0,25 one su 0,213, a za poduzeća ispod granice vrijednost koeficijenta je 0,.104. Takvi su rezultati u skladu s teorijskim predviđanjima prema kojima investicije financijski ograničenih tvrtki više ovise o novčanim tokovima. Zaključno, tvrtke koje pripadaju režimu poduzeća s visokim rizikom bankrota pokazuju veću osjetljivost novčanih tokova i investicija.

Shen i Wang (2007) primijenili su istu metodu za razdoblje od 1991. do 1997., na uzorku od 115 korporacija koje kotiraju na tajlandskoj burzi. Kao *threshold* varijabla poslužio je prilagođeni pokazatelj financijske poluge. Rezultati pokazuju postojanje četiriju režima, pri čemu postoji monotona rastuća osjetljivost investicija na novčane tokove, od nezaduženih prema zaduženim poduzećima. Ammer (2011) je primijenio *panel smooth threshold* regresijski model (engl. *panel smooth threshold model*) i pokazao da je financijska liberalizacija u azijskim zemljama očekivano smanjila stupanj financijske ograničenosti poduzeća.

[31] Do istog su zaključka došli i Gala i Julio (2012.), koji su pokazali da je veličina tvrtke povezana s tehnološki opadajućim prinosima, a ne financijskim ograničenjem (Gala i Gomes, 2013.).

3.3 Analiza financijskog ograničenja primjenom metode efekta tretmana

Potonje kritike empirijske literature o osjetljivosti investicija na novčane tokove potvrđuju poteškoće u razlikovanje stvarne i lažne kauzalnosti. Moguće je da financijski ograničene tvrtke imaju visoke koeficijente uz novčane tokove zbog perzistentnijih investicijskih prilika. Osnovni je problem endogenosti, koji je tipičan za sva empirijska istraživanja.[32] Drugim riječima, problem nedostatne varijable (engl. *omitted variable*) stvara prividnu korelaciju između novčanih tokova i investicija (pristranost prema gore ili prema dolje).

Rješenje problema endogenosti implicira pronalaženje šoka na neto vrijednost (novčane tokove) koji su egzogeni na investicijske prilike (u_{it}) i Tobinov q. Prednost korištenja dobro identificiranim šokom ponude u tome je što uklanja mogućnost pada kreditne aktivnosti zbog pada potražnje za kreditima. U kontekstu regresijske jednadžbe investicija velik dio literature bavi se pronalaženjem savršenog egzogenog instrumenta za novčane tokove. U nastavku se prikazuju radovi iz kategorije (kvazi)prirodnih eksperimenata koji nastoje izolirati šok na tvrtkinu financijsku poziciju, koji je nekoreliran s investicijskim prilikama.

Calomiris i Hubbard (1995) su kao šok (tretman) upotrijebili promjenu porezne politike vlade SAD-a 1935. godine. Promjena je uključivala prirez na nedistribuirane zarade poduzeća, što je stvaralo jaz između internih i eksternih izvora financiranja. Uzorak je imao 228 proizvodnih tvrtki u razdoblju od 1934. do 1938. Tvrtke su podijeljene u tri skupine ovisno o veličini razreda prireza kojem pripadaju (tri skupine s obzirom na apriorni stupanj financijskog ograničenja). Tvrtke koje su pripadale skupini financijski ograničenih poduzeća pokazivale su najveću osjetljivost investicija na novčane tokove. Analiza robusnosti pokazala je još jedan zanimljiv rezultat: ako se kao zavisna varijabla upotrijebi radni kapital, osjetljivost je radnoga kapitala i novčanih tokova još veća, što implicira da se radni kapital upotrebljava kao varijabla za smanjivanje utjecaja šokova.

Blanchard, Lopez-de-Silanes i Schleifer (1994) su kao instrument novčanih tokova upotrijebili novac zarađen neočekivanim pobjedama u sudskim sporovima. Tvrtke u uzorku uglavnom imaju mali q i niske investicije u temeljnoj djelatnosti. Tvrtke su novac uglavnom upotrebljavale za korporativne akvizicije te za isplate menadžerima, a omogućeno im je i

[32] Jednostavno rečeno, problem endogenosti podrazumijeva korelaciju između eksplanatorne varijable i pogrešaka u regresijskoj jednadžbi. Endogenost dovodi do nepristranih i nekonzistentnih procijenjenih parametara, pa je pouzdano zaključivanje o populaciji nemoguće.

dodatno zaduženje. To je u suprotnosti s pretpostavkom o savršenim tržištima kapitala, prema kojima će dodatni novčani tok iznad investicijskih prilika biti isplaćenim vlasnicima u obliku dividendi ili otkupom dionica.

Lamont (1997) je analizirao kretanje investicija naftnih i nenaftnih dijelova istog poduzeća nakon naftnog šoka 1986. godine (pad cijena nafte 50 Osnovna je pretpostavka da naftni šok ne utječe (ortogonalan je) na investicijske prilike nefinancijskih poduzeća. Iako su novčani tokovi nenaftnog sektora rasli poslije naftnog šoka, investicije su u odnosu prema prihodima pale, što implicira postojanje financijskog ograničenja. Nedostatak su obaju rada mali uzorci (Blanchard i ostali (1949) koriste se uzorkom od 13 tvrtki, a Lamont (1997) ima ukupno 40 opservacija).

Rauh (2006) je proučavao tvrtke koje imaju obvezu uplate sredstava u mirovinski fond radi ispunjenja obveza prema mirovinskim planovima zaposlenika, kada je imovina mirovinskog fonda veća od obveza. Tvrtke u kojih je sadašnja vrijednost imovine mirovina manja od sadašnje vrijednosti obveza mogu se označiti kao potkapitalizirane (engl. *underfunded*) i na kraju razdoblja moraju uplatama pokriti manjak. Neuravnoteženost imovine i obveza primarno je određena promjenom vrijednosti imovine mirovinskog fonda (dionice, obveznice itd.). Osnovna je identifikacijska pretpostavka ortogonalnost (neovisnost) varijacija u cijenama imovine i (neopaženih) investicijskih prilika koje su korelirane s novčanim tokovima. Empirijska se strategija dakle svodi na uspoređivanje ponašanje investicija poduzeća koja su obvezna uplaćivati obvezne doprinose i onih koja nemaju tu obvezu. Uzorak su 1522 tvrtke od1990. do 1998. Rezultati regresije pokazuju da za svaki dolar rasta obveznih doprinosa kapitalne investicije padaju 0,60 – 0,70 $, snažna je negativna povezanost, a koeficijent je uz novčane tokove 0,10 – 0,15 $. Zaključuje se da promjena internih sredstava snažno utječe na ponašanje investicija.

Hovakimian i Titman (2006) analizirali su osjetljivost investicija na novčana sredstva dobivena prodajom imovine (uzorak je 9751 tvrtka iz SAD-a). Osnovna je pretpostavka da novčana sredstva od prodaje imovine ne koreliraju s investicijskim prilikama. Rezultati pokazuju da, nakon kontrole za novčane tokove i investicijske prilike, novčana sredstva od prodaje imovine pozitivno koreliraju s investicijama, pri čemu postoji monotono rastuća osjetljivost kako tvrtke postaju financijski ograničenije (mlađe i manje tvrtke; tvrtke koje ne isplaćuju dividende; nemaju izlistane obveznice; imaju veće omjere tržišne i knjigovodstvene vrijednosti).

Lemmon i Roberts (2007) procjenjivali su utjecaj promjena u ponudi kapitala na financijsku i investicijsku politiku poduzeća koristeći se procjeniteljem *„difference-in-differences“* i metodom uparivanja (engl. *matching method*). Autori su se koristili trima odvojenim egzogenim šokovima na ponudu kredita u 1989. godini, a to su: 1) propast Drexel Burnham Lambert, Inc, 2) prihvaćanje Zakona o reformi financijskih institucija, restrukturiranju i prisilnoj naplati (Financial Institution Reform, Restructuring and Enforcement Act – FIRREA) i 3) promjena u smjernicama o kreditnom rejtingu Nacionalne udruge osiguravajućih društava (National Association of Insurance Companies – NAIC). Kombinacija šokova uzrokovala je snažne restrikcije u ponudi kapitala kompanijama bez investicijskog rejtinga. Rezultati pokazuju da tvrtke niskoga kreditnog rejtinga (tretmanska skupina) smanjuju stopu investicija 5 % više nego one bez kreditnog rejtinga (kontrolna skupina).

Velika recesija potaknula je brojna istraživanja o investicijama tijekom velikih šokova. Almeida i ostali (2012) proučavali su utjecaj šoka ponude eksternog financiranja u kolovozu 2007. godine na investicije poduzeća. Analizirali su utjecaj uvjeta financijskog ugovaranja na investicijske mogućnosti uspoređujući reagiranje investicija tvrtki koje su morale refinancirati svoje kredite u vrijeme šoka i tvrtki koje nisu morale refinancirati dugoročne dugove (frikcija refinanciranja). Autori su primijenili procjenitelj uparivanja *difference-in-differences* kako bi kontrolirali za neopažene idiosinkratične efekte tvrtke. Eksperimentalna je bila skupina poduzeća s potencijalnim negativnim efektima zbog ograničenja refinanciranja, a kontrolna su skupina bile tvrtke koje nisu trebale refinancirati dug u vrijeme krize.[33] Tvrtke u eksperimentalnoj skupini iskusile su pad prosječnih kvartalnih investicija od 5,7 % do 7,8 %, a one iz kontrolne skupine nisu iskusile pad investicija. Investicije tvrtki iz eksperimentalne skupine u prva tri tromjesečja 2008. iznosile su samo trećinu investicija prije krize. Ista analiza za druga razdoblja pokazuje da pad stope rasta investicija vrijedi samo za razdoblje oko 2007. godine. Autori su također procijenili standardnu regresijsku jednadžbu (nezavisne varijable uključuju q, novčane tokove, veličinu tvrtke, industriju, kreditni rejting, novčana sredstva i pokazatelj financiranja), dodajući varijablu dospijeća duga. Dodavanje kontrolnih varijabli ne umanjuje znatno vrijednost koeficijenta uz dospijeće duga. Nakon 2008. godine obje su skupine tvrtki imale vrlo slične obrasce ponašanja investicija.

Giroud i Mueller (2015) analizirali su utjecaj promjena potražnje kućanstava (aproksimirana promjenom cijena nekretnina) na zaposlenost i investicije visoko i nisko zaduženih tvrtki.

[33] Konkretnije, u eksperimentalnoj su skupini poduzeća čiji je omjer duga koji dospijeva unutar godine dana i ukupnog duga veći od 20 %. Ostale tvrtke pripadaju kontrolnoj skupini.

Rezultati pokazuju veću osjetljivost za visoko zadužene tvrtke. U modelu prostornih podataka, koeficijent uz promjenu potražnje kućanstava za lokalne jedinice visoko zaduženih tvrtki iznosi 0,084 (signifikantno uz razinu značajnosti od 1 %), a za nisko zadužene tvrtke 0,023 (nesignifikantno). Pad zaposlenosti nakon Velike recesije gotovo je posve objašnjen padom zaposlenosti visoko zaduženih tvrtki. Panel-analiza na razini tvrtke pokazuje veću osjetljivost investicija na promjenu potražnje (0,024 nasuprot 0,001), te veću razinu dodatnog zaduživanja za nisko zadužene tvrtke. Rezultati stoga potvrđuju postojanje kanala bilance stanja. Bahle i Stulz (2013) ispitivali su hipotezu bankovnog kanala, prema kojoj bi tvrtke ovisne o bankarskom financiranju trebale biti pogođenije financijskom krizom. Koristeći se bazom podataka Compustat, autori su pokazali da tvrtke ovisne o bankama ne investiraju manje od drugih tvrtki. Smanjenje investicija objašnjava veći stupanj zaduženosti tvrtki prije financijske krize.

3.4 Ostali metodološki pristupi identificiranja financijskog ograničenja

U ovom se poglavlju ukratko opisuju ostali metodološki pristupi procjenjivanja financijskog ograničenja. U poglavlju 3.4.1. prikazuju se istraživanja koja se koriste strukturnim ekonometrijskim modelima. U 3.4.2. pokazuju se anketna istraživanja o postojanju financijskog ograničenja. Na kraju se posebna pozornost obraća radovima koji su analizirali međuodnos duga korporativnog sektora i investicija poduzeća u vrijeme Velike recesije (recesija bilance stanja) te kolateralnom kanalu financijskih frikcija.

3.4.1 Analiza financijskih frikcija pomoću strukturnih ekonometrijskih modela

Za razliku od empirijskih metoda prirodnog eksperimenta i osjetljivosti investicija na novčane tokove, neki radovi pokušavaju riješiti problem identifikacije (endogenosti) rješavanjem i procjenjivanjem problema dinamičkog programiranja tvrtke uz pretpostavku nesavršenih tržišta kapitala i procjenjivanjem pouzdanosti modela primjenom strukturnih procjenitelja. Ova je skupina radova fokusirana na odstupanje od pretpostavki linearne homogenosti q-modela investicija, koja implicira jednakost graničnog i prosječnog q-a. Tako se pokušava riješiti problem pogreške u mjerenju Q-a i konstruirati točnija specifikacija modela. Radovi se mogu podijeliti s obzirom na element u kojem model odstupa od standardnog neoklasičnog modela

investicija. Primjerice, Abel i Eberly (1994, 1997), Cooper i Haltiwanger (2006) uključuju nehomogene troškove investicija, a Hennessy i Whited (2007) eksterno financiranje. U nastavku se pruža lapidaran prikaz pojedinih modela.

Gomes (2001), Cooper i Ejarque (2003) te Abel i Eberly (2010) u modele uključuju opadajuće prinose na opseg ili tržišnu moć, a novčani tokovi sadržavaju pogrešku u mjerenju q-a. Gomes (2001) je kritizirao uporabu regresijskih jednadžbi reducirane forme koje su izvedene iz strukturnih modela tvrtki te je međuovisnost financijskih ograničenja i investicija proučavao unutar modela parcijalne ravnoteže s heterogenim firmama. Problem standardne regresijske funkcije investicija očituje se u tome što su šokovi na output i novčane tokove pozitivno autokorelirani, pa je moguće dobiti snažnu, ali prividnu autokorelaciju između ovih varijabli. Postoji endogenost s lijeve i s desne strane regresijske jednadžbe. Postojanje financijskog ograničenja nije dovoljno za pozitivan μ jer je ono već uključeno u tržišnu vrijednost tvrtke (varijabla q). Jednostavno rečeno, osjetljivost investicija na novčane tokove nije nužan ni dovoljan uvjet za postojanje financijskog ograničenja jer postoje druge dimenzije modela, koje su bitne za investicijsku jednadžbu (ulaz novih tvrtki, izlaz postojećih, skuplje izvanjsko financiranje). Cooper i Ejarque (2003) su numerički riješili model s kvadratnim troškovima prilagođavanja i konkavnim prihodima, koji su konzistentni s teorijom iz industrijske organizacije o tržišnoj moći. Autori su pronašli slične koeficijente u investicijskoj jednadžbi, čak i bez postojanja financijskih ograničenja. Autori zaključuju da visoki koeficijenti uz novčane tokove odražavaju tržišnu moć tvrtki, a ne financijska ograničenja. Dapače, koeficijent uz novčane tokove je opadajuća, a ne rastuća funkcija troškova eksternog financiranja. Abel i Eberly (2010) nadovezuju se na prethodna dva istraživanja, ali pružaju analitičko rješenje zatvorene forme za q (za razliku od prijašnih radova, koji su jednadžbe rješavali numerički). Autori su razvili neoklasični model investicija bez troškova prilagođavanja i financijskih ograničenja. Prva promjena implicira da je granični q jednak 1, a prosječni q varira stohastički. Varijabla q u modelu odražava očekivanja oko stope rasta budućih prihoda, a novčani tokovi odražavaju troškove korištenja kapitalom, posebno stopu deprecijacije. Budući da obje varijable (rast prihoda i amortizacija) određuju investicije, I će korelirati s q i novčanim tokovima. Iako su temeljne pretpostavke izmijenjene, rezultati analitičkog modela da li su jednake empirijske rezultate – mali koeficijent uz q i veliki koeficijent uz novčane tokove, posebno za male, brzorastuće kompanije.

Glavni nedostatak potonjih strukturnih procjenitelja fokusiranje je na jedan šok koji je savršeno koreliran s investicijskim prilikama. Gilchrist i Sim (2014) su u strukturni model uvrstili i

makroekonomske efekte. Autori su također testirali investicijsku jednadžbu reducirane forme. Upotrijebili su dvije metode procjene: fiksne efekte s instrumentalnim varijablama i diferencirani GMM-om. Zavisna je varijabla ponovno odnos investicija i kapitala, a nezavisne varijable čine pomaknuti odnos investicija i kapitala, odnos domaćih i stranih prihoda u odnosu prema kapitalu (aproksimira fundamente investiranja), i varijabla koja reprezentira promjenu inozemnih obveza. Rezultati pokazuju da koeficijent uz varijablu koja održava promjenu tereta vanjskog duga ima negativan predznak. Ako se tvrtke podjele s obzirom na razinu vanjskog duga i izvoza, ada rezultati pokazuju da one s niskim izvozom i visokim vanjskim dugom pokazuju najveću osjetljivost investicija na bilančne varijable. Dakle, koristeći se regresijskom jednadžbom reducirane forme, autori su zaključili da devaluacija tečaja efektom bilance stanja ima negativan utjecaj na investicije.

Braun i Larrain (2005) su, koristeći se podacima o godišnjoj proizvodnji 28 proizvodnih poduzeća iz 111 zemalja od 1963. do 1999. pokazali su da su industrije ovisnije o izvanjskom financiranju jače pogođene recesijom. U proizvodnim sektorima koji su ovisni o izvanjskom financiranju, proizvodnja u prosjeku pada 5,4 %, a u ostalim zemljama 4,5 %. Diferencijski je efekt dakle 0,9 %.

Caggese (2007) je test financijskog ograničenja izveo iz strukturnog modela rizično neutralne tvrtke koja proizvodi output koristeći se dvama komplementarnim faktorima proizvodnje, fiksnim i varijabilnim kapitalom. Fiksni je kapital ireverzibilan, a varijabilni se može prilagođavati bez ograničenja. Kreditiranje zahtijeva djelomičnu pokrivenost kredita kolateralom.

Rad rješava važan nedostatak do sada spomenutih empirijskih radova o financijskim frikcijama. Naime, većina istraživanja o financijskom ograničenju u uzorak uključuje tvrtke na organiziranim tržištima kapitala. Na taj su način istraživanja isključivala manje tvrtke za koje postoji veća vjerojatnost ograničenja. Uzorak autora sadržava manje talijanske tvrtke s podacima iz financijskih izvještaja i kvalitativnim podacima s anketnim odgovorima menadžmenta. Rezultati modela pokazuju da je korelacija varijabilnoga kapitala i novčanog toka signifikantno pozitivna za male tvrtke i mala i nesignifikantna za velike tvrtke.

Još je mnogo radova koji su odnos investicija i strukture kapitala analizirali pomoću dinamičkih modela investicija i primjenom strukturnih procjenitelja. Budući da se ovaj doktorski rad ponajprije orijentira na metodologiju prikazanu u poglavljima 3.2. i 3.3., pružen je pregled radova koji ističu objašnjenje investicijske dinamike i posebno odjeljivosti investicija na

novčane tokove. Čitateljima koje više zanima ova skupina istraživanja preporučuje se pregledni rad Strebulaeva i Whited (2012).

3.4.2 Analiza financijskog ograničenja primjenom anketnih podataka

Alternativni način testiranja financijskog ograničenja metoda je anketiranja. Umjesto na podatke iz financijskih izvještaja, metoda anketiranja oslanja se na izravan način testiranja financijskog ograničenja. Menadžerima se postavlja jedno ili nekoliko pitanja, poput: Je li Vaša tvrtka financijski ograničena? Je li Vam odbijen zahtjev za kredit? Koliko iznosi trošak zaduživanja? itd. Postoje određene prednosti izravne metode procjenjivanja kreditnog ograničenja. Prvo, moguće je testirati sve vrste poduzeća. Drugo, odgovori implicitno kontroliraju za investicijske prilike.

Primjer je ovog empirijskog pristupa rad Campelloa i dr. (2010). Autori su anketirali 1050 financijskih menadžera u 39 zemalja Sjeverne Amerike, Europe i Azije u prosincu 2008. godine kako bi procijenili jesu li tvrtke bile financijski ograničene u vrijeme globalne krize. Rezultati su pokazali da prosječno ograničena tvrtka planira u prosjeku smanjiti zaposlenost 11 % (neograničena 9 %), tehnološku potrošnju 9 % (neograničena 0,6 %), kapitalne investicije 9 % (neograničene 4,5 %), marketinške izdatke 33 % (4,5 %) i isplate dividendi 11 % (2,9 %). Tijekom financijske krize 86 % ograničenih poduzeća tvrdilo je da nisu investiralo zbog financijskih ograničenja, a u neograničenih je poduzeća to bilo 44 %. Od ograničenih, 56 % ne investira, a ostatak se koristi internim izvorima financiranja. Istraživanje je također pokazalo da financijski ograničena poduzeća prodaju znatno više imovine od neograničenih te time utječu na pad cijena imovine.

U radu Velimira Šonje (2014) identifikacija dodatnog[34] financijskog ograničenja provedena je na temelju podataka iz tromjesečnih anketa poduzeća, uz kombiniranje anketnih podataka s podacima iz godišnjih financijskih izvještaja. Primijenjena je logit i probit- panel regresijska analiza na uzorku 280 hrvatskih poduzeća iz prerađivačke industrije, graditeljstva i usluga. Analizirano je razdoblje krize, od trećeg tromjesečja 2008. do drugog tromjesečja 2014. Dodatna financijska ograničenja nisu ozbiljnije ograničavala rast velikih poduzeća pošto je prvi

[34] Autor je financijska ograničenja podijelio na normalna i dodatna. Normalna ograničenja proizlaze iz pada potražnje, rasta rizika i kamatnih stopa. Dodatna se ograničenja diferenciraju na kreditni lom, institucionalna ograničenja i bilančne krize.

udar krize 2009. jenjao. Međutim, mala su se poduzeća sve do kraja 2012. susretala s dodatnim financijskim ograničenjima. Sklonost izvozu smanjuje vjerojatnost pojave financijskog ograničenja u velikim, no ne i u malim poduzećima.

Od ostalih radova u kojima je primijenjena metoda anketiranja u identificiranju financijskog ograničenja valja izdvojiti radove Savignac (2009) te Beck i ostalih (2008). Glavni nedostatak ove metode može biti subjektivnost menadžmenta pri odgovaranju na pitanja. Postoje također radovi, koji su se usmjerili na anketiranje financijskih institucija o broju kreditnih zahtjeva, broju odbijenih zahtjeva i razlozima njihova odbijanja. Međutim, takva su istraživanja rijetka zbog poteškoća u pribavljanju podataka.

Svjetska banka redovito provodi anketiranje među poduzećima kako bi identificirala broj onih koja su financijski ograničena. Izvještaj o globalnom financijskom razvoju (2014) sažima brojna istraživanja i prikazuje podatke o financijskoj uključenosti pojedinaca i poduzeća za brojne zemlje. Zemlje su podijeljene na zemlje niskog, srednjeg i visokog dohotka. Anketiranjem se prvo identificira udio tvrtki koji se prijavio za kredit u određenu razdoblju (ovdje za 2013. godinu). Od tvrtki koje se nisu prijavile za kredit, 44 % poduzeća u zemljama s niskim dohotkom nedobrovoljno je isključeno iz prijave za kredit, 28 % u zemljama sa srednjim dohotkom i 20 % u zemljama s višim dohotkom. Za velike je tvrtke taj postotak manji (25 % za zemlje s niskim i 14 % za zemlje sa srednjim i visokim dohotkom). Taj je broj donja granica ograničenja jer nekim poduzećima koja su se prijavila za njega, kredit nije odobren. Važno je istaknuti i razloge nedobrovoljna isključivanja iz kreditnog odnosa: najčešći su razlog visoke kamatne stope, zatim kompleksnost prijave i kolateralni zahtjevi. Zaključno, u zemljama u razvoju brojna su poduzeća financijski ograničena.

U poglavlju 2.1.3. opisana je anketa o dostupnosti eksternog financiranja mikro, malih, srednjih i velikih poduzeća, koju provodi ECB. Ankete impliciraju postojanje financijskog ograničenja tijekom kriznih godina i postupan oporavak s odmakom od krize. Posljednji podaci pokazuju da je udio financijski ograničenih poduzeća u prosjeku bio nizak na kraju 2015. godine. Istraživanje dakle potvrđuje fluktuacije u ponudi kredita financijskih institucija: jači stupanj racioniranja kredita u vrijeme krize i otpuštanje kolateralnih i ostalih kreditnih ograničenja poslije krize.

3.4.3 Kolateralni kanal i tvrtkin kanal bilance stanja

U pregledu teorijskih modela objašnjeno je kako asimetričnost informacija racionira kredite. Samo poduzeća koja raspolažu dostatnom neto vrijednosti mogu financirati investicije iz eksternih izvora. Investicijska prilika (projekt), uz danu neto vrijednost, treba osiguravati razinu zajamčena dohotka iznad troška financiranja. U praksi, neto vrijednost mogu biti novčana sredstava na računima banaka, kratkoročni vrijednosni papiri, police osiguranja, jamci i dr. oblici osiguranja. Vrlo čest oblik osiguranja na financijskom tržištu opipljiva je imovina poduzeća: građevinski objekti (nekretnine) ili pogoni i oprema. Upravo je kolateral, uz kamatnu stopu, najvažnija odrednica kreditnog ugovora.

Iako se kamatnim stopama u ekonomskoj teoriji pridaje središnja važnost, istraživanja su o utjecaju vrijednosti kolaterala za investicijsku aktivnost u rjeđa. Prema neoklasičnoj teoriji investicija, promjena vrijednosti kolaterala ne bi trebala utjecati na korporativne investicije, iznad q-a. Stoga nije čudno što je prije pojave Velike recesije zanemaren utjecaj kolaterala i kolateralne poluge na investicijsku aktivnost i ekonomsku aktivnost općenito. Izuzetak su radovi Geanakoplosa (1997), koji je razvio teoriju ciklusa kolateralne poluge (engl. *leverage cycle*).

Izazov u testiranju hipoteze o utjecaju promjene vrijednosti kolaterala na investicije isti je kao i u prijašnjim radovima: treba pronaći one varijacije u vrijednosti kolaterala koje su ortogonalne na investicijske prilike. Benmelech, Garmaise i Moskowitz (2005) koriste se uredbom o prostornom uređenju (engl. *zoning*) za određivanje kolateralne vrijednosti komercijalne imovine, koja se prodaje ako se ne ispune obveze iz kreditnog ugovora. Pretpostavka je da je imovinu u reguliranim područjima teže iskoristiti u novim aktivnostima (engl. *redeployable asset*)[35]. Autori su kontrolirali mnoge karakteristike nekretnina (cijena, fiksni efekti, tip nekretnine itd.). Istraživanje je pokazalo da veći stupanj fleksibilnosti imovine stvara dužničke ugovore koji su: 1) veći u iznosu, 2) duljeg dospijeća i 3) nižih kamatnih stopa.

Chaney, Sraer i Thesmar (2010) također su testirali kolateralni kanal – utjecaj varijacije u cijenama nekretnina kao šoka na vrijednost kolaterala na investicije poduzeća. Autori su uspoređivali ponašanje investicija među tvrtkama koje posluju na istoj lokaciji, ali imaju različiti portfelj. Važan je dio analize rješavanje problema endogenosti: 1) cijene nekretnina

[35] Višenamjenska imovina (engl. *redeployable asset*) jest imovina koja nije specijalizirana i koja se može upotrebljavati na različite načine (u produktivne svrhe) te time ostvaruje veću likvidacijsku vrijednost. Takva je imovina pogodnija kao sredstvo osiguranja pri dužničkom financiranju.

mogu biti *proxy* lokalnih šokova potražnje, 2) problem reverzne kauzalnosti – investicije velikih tvrtki utječu na cijena nekretnina. Prvi su problem autori razriješili uspoređivanjem rentijera i vlasnika nekretnina u istom gradu. Drugi su problem riješili uvođenjem instrumenta cijena nekretnina koristeći se interakcijom dugoročne kamatne stope i lokalne elastičnosti ponude zemljišta. Regresijska jednadžba ima sljedeći oblik:

$$I_{it}^{s} = \alpha_i + \alpha_t + \beta REValue_i \times \frac{P_t^s}{P_{93}^s} + \gamma \frac{P_t^s}{P_{93}^s} + \kappa \sum_k X_k^i \times P_t^s + controls_{it} + u_{it}$$

gdje su I_{it}^{s} omjer investicija i pomaknutog ulaganja u postrojenja i opremu (PPE), $REValue_i$ je omjer tržišne vrijednosti nekretnina 1993. pomaknutog PPE-a, $\frac{P_t^s}{P_{93}^s}$ mjeri rast cijena nekretnina u državi s od 1993. do vremena t. Kontrolne su varijable standardne, omjer novčanih tokova i PPE-a, pokazatelj financijske poluge i q. α_i i α_t su fiksni efekti tvrtke i vremena. Varijabla $\frac{P_t^s}{P_{93}^s}$ kontrolira za ukupni utjecaj rasta cijena nekretnina na investicije bez obzira na to imaju li tvrtke nekretninu. X_k^i su varijable koje kontroliraju za odluke o vlasništvu nad nekrentinom. Glavna varijabla $REValue_i \times \frac{P_t^s}{P_{93}^s}$ odražava fluktuacije u tržišnim vrijednostima specifične imovine u vlasništvu tvrtke. Dakle, β mjeri rast investicija koji proizlazi iz rasta cijene nekretnina koje tvrtka posjeduje, a ne agregatni šok cijena. Rezultati pokazuju da je od 1993. do2007. povećanje vrijednosti kolaterala za 1 dolar pridonijelo rastu investicija od 6 centi. Važno je istaknuti da je koeficijent dvostruko veći u financijski ograničenih tvrtki. Također, ako se kao zavisna varijabla upotrijebi izdani dug, dolar povećanja vrijednosti kolaterala povećava emisiju duga 13 centi.

Mnogi su autori kao ključan razlog slaba ekonomskog rasta poslije Velike recesije navodili prezaduženost korporativnog sektora i, posljedično, dugogodišnje razduživanje kompanija. Ovaj kanal financijskih frikcija poznat je pod nazivom recesija bilance stanja (engl. *balance sheet recesion*). Jednostavno rečeno, visoki privatni dugovi uzrokuju promjenu ponašanja tvrtki ili potrošača tako da se, zbog negativnog šoka, povećava štednja i otplata dugova, a smanjuju potrošnja i investicije. Pojam „recesija bilance stanja“ prvi je upotrijebio Koo u knjizi „Sveti gral makroekonomije“ (2008). U standardnom neoklasičnome modelu poduzeća maksimiraju profit, a Koo ističe da postoje razdoblja u kojima ona minimiziraju dugove kao odgovor na „lošu“ bilancu. Poduzeća se razdužuju sve dok ne postanu solventna. Usprkos izrazito niskim (nultim) kamatnim stopama i snažnoj monetarnoj ekspanziji, tvrtke ne

povećavaju investicije zbog problema prezaduženosti. Zarade služe za vraćanje dugova, a ne za nove investicije.

Osim Kooova niz je radova koji su istraživali utjecaj prezaduženosti i korporativnog razduživanja na investicijsku aktivnost poduzeća. Goretti i Souto (2015) primjenom panel-fiksnih efekata na razini sektora (21 sektor) za osam razvijenih europskih zemalja (Austrija, Belgija, Francuska, Njemačka, Italija, Nizozemska, Portugal i Španjolska) pronašli su negativnu vezu između korporativnih investicija i zaduženja. Osjetljivost novčanih tokova i financijske poluge iznosi- 0.23, što implicira odbijanje hipoteze o savršenim tržištima kapitala. Šagovac i Šikić (2016) su na uzorku od 18.235 poduzeća iz Hrvatske analizirali utjecaj stupnja zaduženosti i likvidnosti na poslovne investicije i zaposlenost u vrijeme Velike recesije. Autori su potvrdili važnost kanala bilance stanja: tvrtke sa slabijom bilancom (većom zaduženošću) pokazuju veći pad investicija nakon financijske krize. Pad investicija još je veći promatra li se odnos prosječno likvidnih i nelikvidnih tvrtki.

3.5 Međuovisnost potražnje za likvidnošću i investicijske aktivnosti poduzeća

U poglavlju 2.4. dana je teorijska analiza međuovisnosti investicija, strukture financiranja i potražnje za likvidnošću. Provedeno je ključno razlikovanje između financijskog i likvidnog ograničenja kao značajki financijskih frikcija. Financijsko ograničenje odražava kreditnu sposobnost poduzeća, odnosno stupanj povjerenja u izvršenje kreditnih obveza. Tvrtke s niskom neto vrijednosti ne uživaju povjerenje investitora, pa ne mogu osigurati eksterno financiranje čak i ako raspolažu projektom s pozitivnom neto sadašnjom vrijednosti. Likvidno ograničenje podrazumijeva nemogućnost uspostavljanja i održavanja dužničko-vjerovničkih odnosa. Poduzeće je likvidno ograničeno ako nema dovoljno likvidnih sredstava za pokrivanje tekućih obveza. U takvim uvjetima ono čak i uz rast agregatne potražnje ili rast novčanih tokova ne povećava investicijsku aktivnost sve dok ne dostigne razinu normirane likvidnosti.

Razgraničavanje likvidnog i financijskog ograničenja implicitno je analizirano u Fazzari i Petersen (1993). Kako bi procijenili ukupno financijsko ograničenje tvrtki, autori su reduciranu investicijsku jednadžbu proširili za promjene radnoga kapitala. Radni kapital služi kao varijabla za ublažavanje šokova na novčane tokove pa mogućnost uglađivanja investicija ovisi o razini radnoga kapitala tvrtki. Uloga radnoga kapitala može se objasniti heuristički. Pretpostavimo negativan šok na novčane tokove za financijski ograničenu tvrtku. S obzirom na to da raste

vrijednost u sjeni (engl. *shadow value*), tvrtke će odgovoriti smanjivanjem stope akumulacije imovine. Tvrtka međutim ne mora jednako smanjiti radni i fiksni kapital. Kako je cilj poduzeća glatka funkcija investicija, ono će izabrati smanjenje radnoga kapitala kao reakciju na temporalno smanjenje novčanog toka. Budući da je radni kapital reverzibilan, može biti izvor sredstava, pa tvrtka može izabrati i negativan radni kapital. Postojanje radnoga kapitala stoga olakšava tvrtkino kratkoročno financijsko ograničenje (Fazzari i Petersen, 1993). Dakle, ako je razina radnog kapitala niska u odnosu prema fiksnim investicijama, očekuje se da će sposobnost uglađivanja investicija biti manja i šok na novčane tokove snažnije će utjecati na investicije. Radni je kapital važna varijabla i za štednju iz opreznosti. Zbog svega rečenog, on bi trebao karakterizirati višak osjetljivosti u odnosu prema fiksnim investicijama.

Autori su testirali dvije pretpostavke: 1) kada se uvrsti u investicijsku jednadžbu, koeficijent uz radni kapital ima negativan predznak, 2) uobičajeni procjenitelj osjetljivosti novčanih tokova podcjenjuje utjecaj novčanih tokova na investicije. Ako se kao zavisna varijabla umjesto investicija u fiksni kapital upotrijebe investicije u radni kapital ($\Delta W/K$), koeficijent uz novčane tokove pokazat će znatno veću osjetljivost (0,839 prema 0,380). Ako se kao zavisna varijabla upotrijebe investicije u obje vrste kapitala, koeficijent će jednostavno biti jednak zbroju pojedinih koeficijenata (1,221).

Ključna regresijska jednadžba ista je kao i jednadžba (115), ali skup nezavisnih varijabli čini i promjena radnoga kapitala ($\Delta W/K$). Važno je primijetiti da radni kapital može poslužiti kao izvor sredstava i kao korisnik sredstava. Procjenitelj 2SLS uz novčane tokove iznosi 0,743 (što je dvaput više u odnosu prema standardnoj jednadžbi, 0,382), a koeficijent uz promjenu radnoga kapitala iznosi - 0,430. Budući da je promjena neto radnoga kapitala pozitivno korelirana s profitima i prihodima, vjerojatno je da ona također kontrolira za potražne faktore i da bi predznak trebao obiti pozitivan. Rezultati također upućuju na zaključak da bi financijsko ograničenje tijekom padova ekonomske aktivnosti trebalo biti veće nego u vremenima rasta jer je manji potencijal radnoga kapitala da se upotrebljava kao varijabla prilagođavanja. Uključivanje duga (ponovno kao instrumentalna varijabla) umjesto radnog kapitala u regresiju donosi pozitivan i signifikantan utjecaj duga na investicije. Uključivanje prihoda smanjuje sve procjenitelje zbog pozitivne korelacije prihoda, radnog kapitala i novčanog toka, ali smjer povezanosti nepromijenjen je i signifikantan.

Dinga i ostali (2009) identificirali su upravljanje radnim kapitalom kao ključnu varijablu koja objašnjava brz rast investicija u Kini (usprkos ograničenjima u eksternom financiranju). Kako

je objašnjeno u potonjem ulomku, radni kapital nema, za razliku od fiksnog kapitala, problem ireverzibilnosti, pa se može lakše smanjivati i upotrebljavati kao prilagođavajuća varijabla. Istraživanje je provedeno u 116.724 tvrtke od 2000. do 2007. Na desnoj strani investicijske jednadžbe autori su upotrijebili interakciju vremenske i industrijske komponente kao aproksimaciju poslovnih ciklusa kako bi kontrolirali za investicijske prilike (umjesto Tobinova q-a). Tvrtke su podijeljene u dvije skupine: one s visokim i niskim razinama radnoga kapitala, kako bi se promatralo različito ponašanje investicija s obzirom na razinu radnoga kapitala. Rezultati su pokazali da su tvrtke s visokim radnim kapitalom imale veću osjetljivost radnog kapitala na promjene novčanih tokova, a time i veću mogućnost prilagođavanja (u prosjeku ovoj skupini pripadaju mlada, mala, brzorastuća poduzeća). Također, tvrtke s većim iznosom radnog kapitala pokazale su manju osjetljivost stopa investicija na novčane tokove. Drugim riječima, tvrtke mogu smanjivanjem radnoga kapitala izglađivati investicije pri negativnu šoku novčanog toka te akumulirati radni kapital radi preventivnih razloga, kada su šokovi novčanog toka pozitivni.

Prema spoznajama autora ovog rada, Cleary, Povel i Raith (2007), u nastavku CPR, prvi su uveli razliku između eksternog i internog financijskog ograničenja, koje u nekim obilježjima odgovara razlici između financijskog i likvidnog ograničenja opisana u poglavlju 2.5.1. Interno je ograničenje uvjetovano razinom raspoloživih internih sredstava, a eksterno je određeno stupnjem nesavršenosti na tržištima kapitala, kojima je poduzeće izloženo. Autori su teorijski i empirijski pokazali da odnos investicija i novčanih tokova ima oblik slova U. Investicije su opadajuća funkcija novčanih tokova (internih sredstava) kada su interna sredstva negativna ili vrlo niska, *vice versa.* Nakon određene razine, povećanje internih sredstava povećava i osjetljivost novčanih tokova i investicija.

U teorijskom dijelu autori su naveli tri ključne pretpostavke modela: 1) eksterna sredstva skuplja su od internih,[36] 2) eksterni troškovi endogeno su određeni investitorovim zahtjevom za određenim iznosom zarade i 3) investicije su prilagodljive (moguće su veće i manje investicije). Posljednja je pretpostavka vrlo važna jer upravo izbor između projekata različitih veličina omogućuje nemonotonost investicija. Važan element modela likvidacijska je vrijednost, koju poduzetnik plaća ako ne ispuni obveze (bankrot), a to je sastavni dio kreditnog ugovora. Ako se pretpostavi da neto vrijednost može poprimiti samo strogo pozitivne vrijednosti (kao u primjerice već prikazanim teorijskim modelima BGG (1999), Calstrom i

[36] U modelu je veći trošak eksternih sredstava rezultt asimetričnosti informacija: kreditori ne mogu opaziti prihode tvrtke, pa dužnik i vjerovnik sklapaju ugovor (pogledati poglavlju 2.3.2.).

Fuerst (1997) ili u empirijskim radovima u Fazzari i ostali (1988)), odnos između investicija i internih sredstava bit će monoton.

Odnos između efekta prihoda i efekta troška stvara ključnu dinamiku u modelu. Efekt troška podrazumijeva veće troškove otplate i veći rizik ogluhe na plaćanje kao funkciju rasta investicija. Efekt prihoda podrazumijeva rast prihoda od investicije, što smanjuje rizik bankrota i otplate. Prvi efekt podrazumijeva pozitivan, a drugi negativan odnos novčanih tokova i investicija. Model pokazuje da će pri niskim trenutačnim novčanim tokovima efekt prihoda prevladati, pa će osjetljivost investicija na novčane tokove biti negativna. U empirijskom dijelu autori su koristeći se standardnom regresijom i regresijom „spline“ za razdoblje od 1980. do 1990. potvrdili negativan odnos novčanih tokova i investicija za negativne razine obrtnih sredstava te pozitivan odnos za poduzeća koja imaju pozitivne razine obrtnog kapitala.

Guariglia (2007) je, slijedeći CPR, testirao stupanj internog i eksternog financijskog ograničenja na uzorku izlistanih i neizlistanih tvrtki iz Ujedinjenoga Kraljevstva, za razdoblje od 1993. do 2003. Iznos raspoloživih novčanih tokova služi kao *proxy* varijabla pri procjeni internoga financijskog ograničenja. Veličina i starost tvrtke služe kao *proxy* varijabla za procjenu eksternoga financijskog ograničenja. Kao i u CPR, tvrtke koje imaju negativne iznose novčanog toka imaju i negativnu osjetljivost investicija na novčane tokove. Rastom novčanog toka, kao mjere interna ograničenja, raste i osjetljivost investicija na novčane tokove. Financijsko ograničenje testirano je stupnjem osjetljivosti investicija na novčane tokove za poduzeća različitih veličina. Najveću osjetljivost pokazuju poduzeća koja su ujedno mala (visok stupanj eksternog ograničenja) i imaju visoke iznose novčanih tokova (mali stupanj internog ograničenja).

Bates, Kahle, Stulz (2009) analizirali su fenomen gomilanja likvidnosti (engl. *cash hoarding*) u SAD-u. Od 1980. do 2006. novčani omjer (odnos novca i ukupne imovine) rastao je po prosječnoj stopi od 0,46% godišnje. U terminima razina, novčani je omjer rastao s 10,5 % u 1980. godini na 23,2 % u 2006 godini. Novčani omjer raste za sve percentile distribucije. Autori identificiraju nekoliko faktora rasta novčanog omjera: 1) tvrtke s većim idiosinkratičnim šokovima (rizikom) pokazuju veći rast novčanog omjera, 2) manje tvrtke drže veće iznose novca od velikih tvrtki, 3) tvrtke koje ne isplaćuju dividendu imaju znatno veći rast novčanog omjera (113 %) od dividendnih poduzeća (0%), 4) rastom neto radnoga kapitala tvrtke drže manje neto novca jer se radni kapital može smatrati zamjenom za novac, 5) tvrtke s većim investicijskim prilikama gomilaju novac, 6) tvrtke s R&D investicijama drže veće iznose novca

jer tvrtke koje ulažu u građevinske objekte ili pogone i opremu mogu kupljenu imovinu upotrijebiti kao kolateral pri zaduživanju. Pinkowitz, Stulz i Williamson (2013) istraživali su kretanje novčanog omjera nakon krize. Autori su pokazali da se kompletan rast novca, iznad očekivanih vrijednosti, odnosi na najveće multinacionalne kompanije s velikim ulaganjima u istraživanje i razvoj.

Hipoteza o utjecaju likvidnog ograničenja na investicije u skladu je s rezultatima istraživanja iz poglavlja 3.2.2.. Primjerice, ACW su pokazali da je granična sklonost štednji (stvaranje novca) pozitivna funkcija novčanih tokova za financijski ograničena poduzeća. Kao *proxy* financijski ograničenih poduzeća autori su upotrijebili različite kriterije (veličina poduzeća, veličina imovine, rejting obveznica, indeks KZ), ali sve su specifikacije potvrdile heterogenost osjetljivosti novca na novčane tokove, za različite skupine poduzeća. Ova skupina istraživanja pokazuje važnost novca ili u širem smislu likvidnosti za likvidno i financijski ograničena poduzeća. Rezultati pokazuju da financijski neograničena poduzeća ne stvaraju novu likvidnost iz novčanih tokova, što je upravo u skladu s prikazanom teorijom. Bruinshoofd i Kool (2006) pokazali su da je prilagodba u likvidnosti znatno brža kada je poduzeće ispod granice primjerene likvidnosti nego kada je iznad.

Korisno je podsjetiti se rasprave s početka poglavlja 3.4.2., o empirijskom dizajnu FHP. U odgovoru na kritiku Kaplana i Zingalesa (1997), Fazzari i ostali (2000) tvrdili su kako je moguće da financijski ograničene tvrtke imaju male koeficijente uz novčane tokove jer se moraju koristiti novčanim tokovima za uspostavljenje likvidnosti (izbjegavanje bankrota), pa bi bilo primjerenije za varijablu investicija upotrijebiti širu definiciju investicija. Također, što je poduzeće financijski ograničenije, to će biti motiviranije držati više novčanih sredstava kao osiguranje od nepredviđenih događaja. Potonja teza autora upravo je rezultat djelovanja likvidnog ograničenja na odnos između investicija i novčanih tokova poduzeća i u skladu je s rezultatima istraživanja koja nisu pronašla vezu novčanih tokova i investicija za financijski ograničene tvrtke.

3.6 Financijske frikcije i ponuda kapitala (bankovni kanal zaduživanja)

U drugom poglavlju opisano je kontraciklično kretanje kreditnih plasmana banaka. Primjerice, izvještaj ECB-a (2013) pokazuje nagli pad u kreditiranju nefinancijskih poduzeća tijekom i

nakon financijske krize (kreditor je bankarski sektor). Stopa rasta kreditnih plasmana pala je s 15 % u 2008. godini na – 2,.1% u prvom tromjesečju 2010. godine. Osnovno pitanje skupa istraživanja koja su se bavila međuodnosom investicijske aktivnosti i financijskih tržišta te investicijskim kanalom financijskih frikcija glasi: Je li smanjenje kreditnih plasmana u vremenima financijske krize rezultat smanjenje potražnje za kreditima ili to što su financijske institucije ograničile tu ponudu. U svim, do sada prikazanim istraživanjima, naglasak je bio na odnosu likvidne pozicije i financijske strukture nefinancijskih poduzeća na investicijsku aktivnost. Poduzeća koja ne raspolažu zahtijevanom razinom neto vrijednosti, zbog djelovanja moralnog hazarda ili nepovoljna izbora, ne mogu financirati projekte s pozitivnim NSV-om. U ovom se poglavlju pruža pregled empirijskih radova, čiji je glavni predmet istraživanja bankovni kanal financijskih frikcija. Bankovni kanal podrazumijeva kontrakciju ponude kredita zbog šoka na bankarsko poslovanje.

Nužan uvjet postojanja frikcija u ponudi kapitala jest nefleksibilnost izvora financiranja. Kada bi dužnici imali mogućnost brzog i jeftinog prijelaza od jednog prema drugom kreditoru, bankovni bi kanal malo utjecao na ukupnu kreditnu aktivnost. Teorijski, postoje tri razloga zašto tvrtke ne mogu lako promijeniti banku (Chodorow-Reich, 2014.):

1. Nepovoljan izbor za dužnike koji mijenjaju kreditora.
2. Signalizirajući ekvilibrij (engl. *signaling equlibrium*), koji podrazumijeva smanjenje moralnog hazarda.
3. Smanjenje troškova nadzora *ex ante* (due diligence) ili *ex post* (trošak verifikacije stanja) u ponavljajućih kredita

Chodorow-Reich (2014) je, koristeći se podacima banaka i poduzeća, proučavao utjecaj bankovne krize na zaposlenost. Analiza se temeljila na uzorku od 2000 nefinancijskih tvrtki u vremenu financijske krize (2008–2009). Propast Lehman Brothersa označio je egzogeni šok ponude kredita. Tvrtke koje su imale bliže odnose s bolesnim bankama, imale su i manju mogućnost dobivanja kredita, veće kamatne stope na kredite (ako su im odobreni) i veći pad zaposlenosti. Postoji razlika u utjecaju šoka ponude kapitala ovisno o tipu tvrtke. Male tvrtke imale su znatno veći pad zaposlenosti zbog šoka ponude nego velike tvrtke koje su se mogle zadužiti na tržištu obveznica.

Adrian, Colla i Shin (2012) analizirali su utjecaj kreditnog loma uza vrijeme financijske krize u SAD-u (2007–2009). Na agregatnoj razini, autori su analizirali međuodnos knjigovodstvene vrijednosti aktive i poluge banaka. Naime, imovina i dugovi su u odnosu 1:1 dok je kapital

konstantan (ljepljiv) tijekom promatrana razdoblja. Drugim riječima, kreditna je aktivnost prociklična, a rezultat je povećanja i smanjenja poluge (uz konstantni kapital).[37] Mikroanaliza se provodila nad uzorkom nefinancijskih poduzeća te količine i cijene odobrenih kredita od 1998. do 2010. godine. Rezultati empirijske analize pokazuju sljedeće: 1) snažna kontrakcija ponude kredita financijskih intermedijara (pad novih plasmana od 50 %), 2) udvostručen rast direktnog financiranja emisijom korporativnih obveznica i 3) snažan rast troškova financiranja, kako direktnih, tako i indirektnih. Iz potonjeg se može zaključiti da je u vrijeme krize potražnja za kreditima neelastična, a ponuda kredita elastična, što se odražava u padu kreditnih plasmana prema bankama i rastu plasmana na tržištu korporativnih obveznica uz istodoban rast cijena na oba tržišta. Za razumijevanje poslovnih ciklusa ključnu ulogu ima poluga financijskog sektora, a ne neto vrijednost poduzeća.

Ciccarelli i dr. (2010) koristili su se anketnim odgovorima iz anketa o bankovnom kreditiranju (BLS) za 12 europskih zemalja i odgovorima iz ankete viših kreditnih službenika (SLO) za SAD, a koje banke trebaju dostavljati na zahtjev središnje banke. Iz ankete se izravno mogu identificirat potražnja za kreditima i kreditni standardi. Autori su primijenili model VAR i zaključili da je bankovni kanal ponude kredita važniji od kanala bilance stanja poduzeća. Racioniranje kredita i pooštravanje kreditnih uvjeta utječu na kontrakciju investicija. Jimenez i dr. (2010) koristili su se kreditnim prijavama kao podlogom za razgraničavanje kreditnih kanala bilance stanja i zaduživanja kombinirajući ih s mikropodacima o financijskom položaju poduzeća i banaka. Autori su pokazali da 1) smanjenje BDP-a ili rast kamatne stope smanjuju vjerojatnost prihvaćanja kreditnih zahtjeva, 2) smanjenje kapitala tvrtke smanjuje vjerojatnost odobravanja kredita, a smanjenje kapitala banke povećava stopu odobravanja kredita i 3) negativni efekt manjeg BDP-a ili viših kamatnih stopa, na odobravanje kredita, jači je za tvrtke s manjim kapitalom ili likvidnošću.

Mian, Sufi i Verner (2017) služili su se različitim iskustvima američkih saveznih država vezano za primjenu bankovne deregulacije, za razdoblje od 1983. do1989. Države koje su prije provele deregulaciju iskusile su signifikantno veći rast kreditne emisije kućanstvima i poduzećima. One su iskusile i mnogo snažniji rast zaposlenosti u industrijama koje prodaju nezamjenjiva dobra, ali ne i u onima koje prodaju zamjenjiva dobra. Glavni je rezultat istraživanja spoznaja da rast kredita djeluje na rast gospodarske aktivnosti poticanjem agregatne potražnje, a ne rastom

[37] Ovo empirijsko opažanje vrlo je važno pri modeliranju bankovnoga kanala. Autori u teorijskom dijelu pretpostavljaju da je kapitalno ograničenje vezano u svim stanjima, a većina drugih modela pretpostavlja vezano ograničenje samo u vremenima recesije.

produktivnosti tvrtke. Također, države koje su prije provele deregulaciju, iskusile su veći pad BDP-a i zaposlenosti nakon kreditnog loma 1989. godine. Osnovni razlog autori vide u ljepljivosti nadnica koje su relativno više rasle u državama s ranijom deregulacijom.

Čeh, Dumičić i Krznar (2011) upotrebom *switching* modela procjenjivali su ponudu i potražnju za kreditima kućanstava i poduzeća, u RH, od 2000. do 2010. Rezultati su pokazali postojanje triju različitih podrazdoblja kreditne aktivnosti u RH: 1) 2000–2002. obilježila je ravnoteža ponude i potražnje, 2) 2002–2008. obilježio je višak ponude kredita i 3) 2008. godine dogodio se kreditni lom, odnosno nagli pad ponude kredita. Autori su potvrdili postojanje efekta racioniranja kredita poduzeća u vrijeme financijske krize, ali i postupna oporavka u 2010. godini.

4 ANALIZA ZNAČAJKI INVESTIRANJA I FINANCIRANJA PODUZEĆA U REPUBLICI HRVATSKOJ

4.1 Definicija varijabli i pokazatelja poslovanja poslovnih subjekata

Nakon pregleda teorijskih i empirijskih radova o investicijskom kanalu financijskih frikcija (poglavlja 2 i 3), slijedi pregled mikropodataka kojima se koristi u doktorskom radu. To znači definiranje uzorka i varijabli koje se upotrebljavaju u analizi. Potom se primjenjuju metode deskriptivne analize nad definiranim uzorkom kako bi se opisalo ponašanje investicija te međuovisnost investicija i financijskih varijabli. Poglavlje 4.2. opisuje ključne agregatne i rezidualne indikatore poslovanja poduzeća, strukturu investicija u Republici Hrvatskoj. Poglavlje 4.3. proučava financijsku strukturu poslovnih subjekata, izvore financiranja investicija i međuovisnost financijske situacije i investicijske aktivnosti. Poglavlje 4.4. analizira likvidnu poziciju poduzeća i odnos obrtnih sredstava i investicija.

U nastavku se opisuju varijable koje će se upotrebljavati u analizi investicija i financijske aktivnosti poslovnih subjekata (tablica 4-1). Sistematizacija varijabli odražava logiku specifikacije modela u empirijskoj analizi[38].

Podaci se odnose na sve pozicije iz računovodstveno-financijskih izvještaja (bilanca, račun dobiti i gubitka, procijenjeni izvještaj o novčanom toku) i dodatnih izvještaja (dodatni podaci financijskog izvještaja poduzetnika – obrazac POD-DOP), na godišnjoj razini. Podaci uključuju sva trgovačka društva (društva s ograničenom odgovornošću i dionička društva), obrte koji su po zakonu dužni izrađivati i predavati financijska izvješća mjerodavnim institucijama i zadružna poduzeća. Svi su financijski izvještaji nekonsolidirani. Nebalansirani panel podataka, od 2000. do 2014. sadržava ukupno 187.237 subjekata (1.234.433 opservacija). Broj subjekata raste s vremenom (primjerice, u 2000. bilo je ukupno 58.717 subjekata, 2008. 89.656, a u 2014. 104.280 subjekta), s izuzetkom 2001. i 2011. godine, kada se broj subjekata smanjio prema prošloj godini.

[38] U ekonometrijskoj analizi u poglavljima 5. i 6., apsolutne vrijednosti varijabli prikazane u tablici, dijelit će se s vremenski pomaknutim (engl. *lag*) vrijednostima imovine ili kapitala. Dva su razloga za to: 1) investicijska jednadžba izvedena iz teorijskog modela (optimizacijskog problema) sadržava varijable normalizirane za pomaknutu vrijendost kapitala, 2) istim pristupom koriste se gotovo sva empirijska istraživnaja koja procjenjuju investicijsku jednadžbu (pogledati poglavlje 3.2.),

Tablica 4-1: Tablica varijabli

Naziv varijable	Definicija varijable	Način mjerenja varijable
1. Kapital	U računovodstvenom smislu, kapital ili glavnica je „vrijednost koju vlasnici ulože u poduzeće uvećana za sve vrijednosti koje su tvorene tijekom poslovanja“. (Žager i dr., 2008., str. 61). U radu se odnosi na vrijednost trajnih dobara uloženih u proizvodnju radi stvaranja nove vrijednosti. Kao mjera kapitala služi zamjenska vrijednost kapitala koja korigira knjigovodstvene vrijednosti za promjene cijena kapitalne imovine.	1) Sadašnja vrijednost materijalne imovine iz repozitorija računovodstveno-financijskih izvještaja koje vodi Financijska agencija. 2) Zamjenska vrijednost kapitala prema Salinger i Summers (1981.): $K_t = (1 - a_t)K_{t-1}CPI_t + (MI_t + AM_t) - MI_{t-1}$, gdje je a_t godišnja stopa amortizacije, CPI_t indeks potrošačkih cijena, AM_t ukupna godišnja amortizacija u razdoblju t, a MI_t sadašnja vrijednost materijalne imovine.
2. Veličina poduzeća (imovina)	Imovina je ekonomski resurs u vlasništvu poduzeća kojim se koristi radi ostvarivanja buduće ekonomske koristi	Podaci o knjigovodstvenoj vrijednosti imovine preuzeti su iz repozitorija računovodstveno-financijskih izvještaja koje vodi Financijska agencija.
3. Investicije	Investicije su ulaganje nekog iznosa novca u različite oblike sredstava radi ostvarivanja budućih ekonomskih koristi. U radu će se upotrijebiti četiri mjere investicija: „investicije“, „investicijski novčani tok“, „bruto kapitalna formacija“ i „neto investicije“	1) **Investicije**: razlika neto materijalne imovine u sadašnjem razdoblju uvećana za amortizaciju i neto vrijednosti materijalne imovine u prošlom razdoblju, $\mathrm{i_t} = (\mathrm{MI_t} + \mathrm{A_t}) - \mathrm{MI_{t-1}}$ (izvor podataka: Financijska agencija). 2**) Investicijski tok**: uključuje materijalnu i financijsku imovinu, a računa se na temelju bilance razlika (izvor podatka: FINA). 3) **Bruto kapitalna formacija**: iskazuje se ukupan iznos „vrijednosti nove dugotrajne imovine (osim zemljišta i šuma) nabavljene od proizvođača ili trgovaca, ukupan iznos vrijednosti izgrađene nove dugotrajne imovine i ukupan iznos vrijednosti nabave nove dugotrajne imovine financijskim leasingom u izvještajnoj godini“ (DZS, POD-DOP obrazac). 4) **Neto investicije**: izračunane su kao razlika sadašnje vrijednosti materijalne imovine, , $\mathrm{MI_t} - \mathrm{MI_{t-1}}$ (izvor podatka: FINA).
4. Neto vrijednost	U teorijskim modelima pod neto vrijednošću podrazumijevaju različite veličine: novac, kolaterala, neto radni kapital (Tirole, 2006), a u ovom radu neto vrijednost podrazumijeva novčani tok ili stopu gotovine.	1) Novčani je tok jednak zbroju amortizacije i neto dobiti. 2) Stopa gotovine udio je novca i kratkotrajnih vrijednosnih papira u ukupnoj aktivi (izvor podatka: FINA).

5. Koeficijent zaduženosti	Koeficijent zaduženosti pokazatelj je financiranja koji odražava značajku strukture kapitala kao važnog činitelja zaštite vlastitog kapitala.	Varijabla je jednaka omjeru ukupnog duga i ukupne imovine. Podaci su preuzeti iz repozitorija Financijske agencije.
6. Pokriće troškova kamata	Pokriće troškova kamata indikator je kreditne sposobnosti koji odražava sposobnost poduzeća da novčanim tokovima pokrije obveze plaćanja kamata.	Varijabla se računa kao odnos zarada prije kamata i poreza (EBIT) i troškova kamata. Podaci za izračun preuzeti su iz repozitorija financijskih izvještaja Financijske agencije
7. Tekuća likvidnost	Tekuća likvidnost pokazatelj je likvidnosti koji odražava sposobnost održavanja dužničko-vjerovničkih odnosa uz razumne troškove (Tintor, 2009)	Varijabla se računa kao odnos kratkotrajne imovine i kratkotrajnih obveza. Podaci za izračun preuzeti su iz repozitorija financijskih izvještaja Financijske agencije.
8. Neto radni kapital	Neto radni kapital vrijednost je tekuće imovine koja ostaje na raspolaganju poduzeću nakon oduzimanja vrijednosti kratkotrajnih obveza.	Varijabla se računa kao razlika kratkotrajne imovine i kratkotrajnih obveza. Podaci za izračun preuzeti su iz repozitorija financijskih izvještaja Financijske agencije.
9. Stopa likvidnosti	Alternativna mjera likvidnosti koja neto radni kapital uvećava za novčane tokove u tekućem razdoblju	Varijabla se računa kao razlika kratkotrajne imovine i kratkotrajnih obveza, uvećane za tekuće novčane tokove (izvor podatka: FINA).
10. Rentabilnost ukupnoga kapitala	Rentabilnost ukupnoga kapitala pokazatelj je profitabilnosti koji upućuje na snagu uvećanja bogatstva.	Varijabla se računa kao odnos bruto dobiti (EBIT) i ukupnog kapitala deflacionirana za promjenu cijena (izvor podatka: FINA).
11. Nova dodana vrijednost	Nova dodana vrijednost rezidualna je veličina proizvodnog procesa, a aproksimira vrijednost agregatne potražnje na razini poduzeća (razlika vrijednosti ostvarene proizvodnje i prethodnih učinaka) (Tintor, 2009).	Varijabla je jednaka je zbroju dobiti prije poreza, neto kamatnih rashoda (financijski rashodi umanjeni za financijske prihode) i troškova osoblja. Podaci za izračun preuzeti su iz repozitorija financijskih izvještaja Financijske agencije.
12. Dodana vrijednost	Nova dodana vrijednost aproksimacija je za ukupnu proizvodnju u poduzeću. Jednaka je dodanoj novoj vrijednosti, uvećanoj za amortizaciju.	Varijabla je jednaka zbroju dobiti prije poreza, neto kamatnih rashoda (financijski rashodi umanjeni za financijske prihode), troškova osoblja i amortizacije. Podaci za izračun preuzeti su iz repozitorija financijskih izvještaja Financijske agencije.
13. Broj zaposlenih	Broj zaposlenih u tvrtki na kraju poslovne godine.	Podaci su preuzeti iz baze podataka Financijske agencije.
14. Kriza	Kvalitativna varijabla jednaka jedan za opservacije nakon 2007. godine. Ova varijabla kontrolira za egzogene šokove na investicije nakon pojave financijske krize.	Varijabla ima vrijednost jedan za razdoblja nakon 2007. godine i 0 za razdoblja prije 2007. godine.
15. Amortizacija	Amortizacija odražava dio novčanog toka s jedne strane (rashod koji nije nužno izdatak) i „obračun trošenja dugotrajne imovine s druge strane“ .	Varijabla je preuzeta iz repozitorija financijskih izvještaja Financijske agencije.
17. Bruto domaći proizvod	BDP je vrijednost finalnih dobara i usluga proizvedenih u zemlji tijekom dane godine, izraženo u novčanim jedinicama.	Podaci o BDP-u preuzeti su iz Eurostatove baze podataka.

4.2 Analiza općeg stanja i položaja poslovnih subjekata

U poglavlju 2.3 pružen je pregled ponašanja investicija u Hrvatskoj i Europskoj uniji koristeći se agregatnim podacima službenih statističkih institucija. U ovom se poglavlju detaljnije analizira kretanje investicija (poglavlje 4.1.), međuovisnost financijskog položaja poduzeća i investicija (poglavlja 4.2. i 4.3) te odnos investicija i likvidnosti (poglavlje 4.4.) koristeći se mikropodacima iz računovodstveno-financijskih izvještaja. Naglasak je na deskriptivnoj analizi strukture i dinamike ključnih varijabli. Cilj je proučiti ključne važne odnose kako bi se stekli uvidi o važnosti financijskih varijabli za investicije nefinancijskog sektora.

Za početak ćemo prikazati dinamiku i strukturu dodane vrijednosti. Prije deskriptivne analize važno je razumjeti kako se iz financijskih izvještaja pojedinih tvrtki izvodi agregatna mjera BDP-a (vidi Vollrath, 2016). Autor objašnjava kako se iz računa dobiti i gubitka dolazi do mjere BDP-a. Kreće se od računa dobiti i gubitka:

$$prihodi - direktni\ troškovi + izdaci\ Tvrtkama = troškovi\ rada + kamate + dividende + rente + amortizacija + profit$$

Jednadžba vjerno pokazuje dvostruku narav dodane vrijednosti. S proizvodnog aspekta (lijeva strana jednadžbe), dodana vrijednost jednaka je razlici prihoda (ukupnog outputa na razini zemlje) i direktnih troškova, povezanih s proizvodnjom dobara (intermedijarna dobra na agregatnoj razini). Desna strana jednadžbe definira dodanu vrijednost s dohodovnog aspekta, odnosno kao zbroj svih dohodaka koja (nefinancijski) poslovni subjekti isplaćuju. Dakle, dodana vrijednost na razini poslovnog subjekta je jednaka:

$$dodana\ vrijednost = troškovi\ rada + kamate + dividende + rente + amortizacija + profit$$

Ova jednadžba vrijedi za sve tvrtke u nekoj ekonomije. Ona vrijedi i za ostale (institucionalne) jedinice koje stvaraju dodanu vrijednost poput središnje države, lokalne vlasti, izvanproračunskih korisnika, OPG-ova i financijskih institucija. Zbrajanjem obiju strana jednadžbe za sve tvrtke (i ostale jedinice) u ekonomiji dobiva se:

$$BDP = \sum troškovi\ rada + \sum kamate + \sum dividende + \sum rente + \sum amortizacija + \sum profit$$

Lijeva strana jednadžbe je BDP jer je BDP po definiciji jednak zbroju dodane vrijednosti svih nefinancijskih poduzeća (i ostalih sektora). Desna strana jednadžbe naziva se i bruto domaći dohodak i u teoriji bi trebao biti jednak BDP-u. Valja napomenuti da BDP, odnosno dodana vrijednost ne govori mnogo o uspješnosti neke kompanije. Ona je jednostavno mjera ukupne proizvodnje.

Pokazano je kako se iz zbroja dodane vrijednosti svih tvrtki računa bruto domaći proizvod jedne države. Analiza BDP-a na ovaj način može pružiti dodane uvide u opisu i objašnjenju ekonomskog rasta u RH. Za početak, korisno je analizirati kretanje ukupne dodane vrijednosti nefinancijskih poslovnih subjekata u RH. Na slici 4-1 prikazana je struktura dodane vrijednosti za nefinancijska poduzeća od 2000. do 2014. Dodana je vrijednost računana po dohodovnoj metodi, kao zbroj neto dobiti, poreza na dobit, neto financijskih rashoda (razlika između financijskih rashoda i financijskih prihoda), troškova osoblja i amortizacije. Dodana bi vrijednost trebala približno aproksimirati kretanje bruto domaćeg proizvoda za sva nefinancijska poduzeća. Očekivano, slika 4-1 pokazuje rast dodane vrijednosti u pretkriznom razdoblju i pad nakon krize. Zanimljivo je da je 2011. i 2014. godine zabilježen rast dodane vrijednosti iako je službena statistika bilježila pad bruto domaćeg proizvoda na agregatnoj razini.

Najveći udio u strukturi dodane vrijednosti ima trošak osoblja. Udio troškova osoblja u pretkriznom razdoblju relativno je stabilan, ali raste nakon financijske krize (s 57 % u 2007. na 61 % 2009. godini), što implicira ljepljivost plaća i poteškoće u provođenju interne devalvacije. Prosječni je udio troškova osoblja oko 59 % dodane vrijednosti. Po visini udjela slijedi amortizacija, koja čini u prosjeku 24 % udjela u dodanoj vrijednosti. Porez na dobit je relativno stabilan u promatranu razdoblju i u prosjeku iznosi oko 4 %. Neto dobit znatno je porasla u pretkriznom razdoblju, ali isto je tako snažno pala poslije krize. Primjerice, od 2005. do 2007. godine neto dobit činila je oko 16 novododane vrijednosti, dok je 2010. godine ostvaren neto gubitak na agregatnoj razini. Nakon krize profiti u prosjeku čine tek 4 % dodane vrijednosti (11 % u pretkriznom razdoblju). Neto financijski rashodi također pokazuju oscilacije tijekom promatranog razdoblja. Prije krize financijski su prihodi pokrivali financijske rashode, a poslije krize neto financijski rashodi poprimili su otprilike 10 % dodane vrijednosti i postali veći od

neto dobiti i poreza zajedno. Nakon krize, značajan udio dodane vrijednosti čine troškovi kamata. Može se zaključiti da su najvolatilnije komponente dodane vrijednosti neto dobit i neto financijski rashodi. U relativnom smislu, rast neto dobiti najviše je pridonio rastu dodane vrijednosti u pretkriznom razdoblju, ali je neto dobit snažno pala nakon krize, a snažno su rasli neto financijski rashodi.

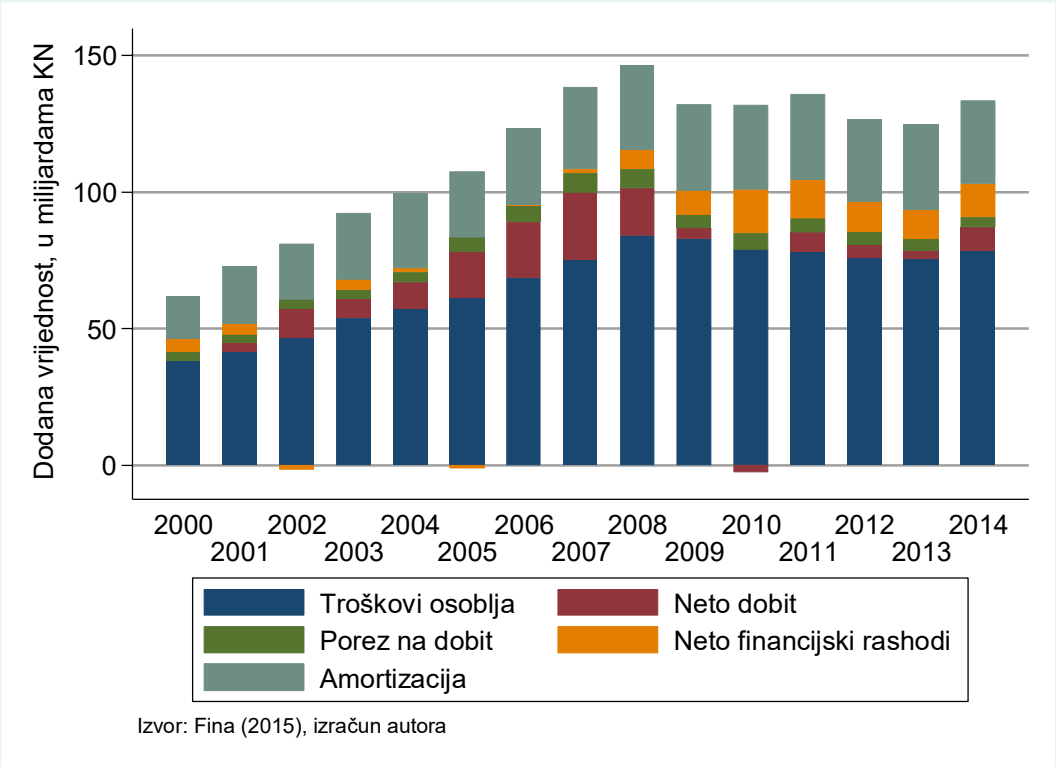

Slika 4-1: Struktura i dinamika novododane vrijednosti nefinancijskih poduzeća, u milijardama kuna, od 2000. do 2014.

Prije analize investicija poželjno je analizirati i kretanje ključnih agregatnih varijabli kako bi se analiza investicija na mikrorazini povezala s općim trendovima poslovanja svih poduzeća. Slika 4.2 sadržava četiri odvojena grafikona, koji odražavaju kretanje ključnih varijabli poslovanja. Prvi grafikon pokazuje kretanje broja zaposlenih. Postoji jasan trend rasta u pretkriznom razdoblju, sa složenom prosječnom godišnjom stopom rasta (CAGR) zaposlenosti od 3 % godišnje. Nakon Velike recesije, od 2008. do 2011., broj zaposlenih manji je otprilike 100.000, što iznosi 10, 52 % ukupno zaposlenih u 2008. godini. Nakon 2011. broj zaposlenih na istoj je razini (oko 850.000 zaposlenih). Drugi grafikon pokazuje kretanje ukupnih prihoda, aktive i vlastitog kapitala. Rast aktive je veći od rasta vlastitog kapitala, što indicira rast financijske poluge. Ukupni prihodi pokazuju slične oscilacije kao i broj zaposlenih: prihodi u razdoblju

2000–.-2008 rastu po složenoj prosječnoj stopi rasta od 10 %, a nakon 2008. godine razina prihoda pada na razine iz 2006. godine. Treći grafikon pokazuje odnos uvoza i izvoza (izvoz označuje prihod od prodaje u inozemstvu). Graf korespondira s dinamikom bilance plaćanja za cjelokupno gospodarstvo. U razdoblju 2002–2008. vrijednost uvoza u prosjeku je 50 % veća od vrijednosti izvoza. Nakon krize, uvoz znatno pada i dostiže razine iz 2003. godine. Zanimljivo je primijetiti da je izvoz nakon pada u 2009. godini nastavio trend rasta iz pretkriznog razdoblja, a uvoz je ostao isti sve do 2014. godine. Tako je izvoz postao veći od uvoza (2011. godina). Može se pretpostaviti veća financijska ili likvidna ograničenost uvozno orijentiranih poduzeća koja su ovisna o kretanjima domaće agregatne potražnje. Zanimljivo je primijetiti da ponašanje uvoza prati agregatnu poslovnu aktivnost s jednim pomakom unatrag. Četvrti grafikon pokazuje dinamiku osnovnih rezidualnih učinaka poduzeća: profita, profita prije poreza, profita prije kamata i poreza (EBIT) i profita prije kamata, poreza i amortizacije (EBITDA). Profiti rastu s 0 na 22 milijarde kuna u razdoblju 2000–2007., a u . prešli su u gubitke. Nakon 2011. zabilježen je rast profita. Zanimljivo je primijetiti širenje raspona između EBIT-a i profita prije poreza, što indicira snažan rast neto financijskih rashoda nakon krize. EBITDA ne bilježi tako velike kolebljivosti kao prihodi ili profiti (vrijednost 2014. tek je neznatno niža od one iz 2008.).

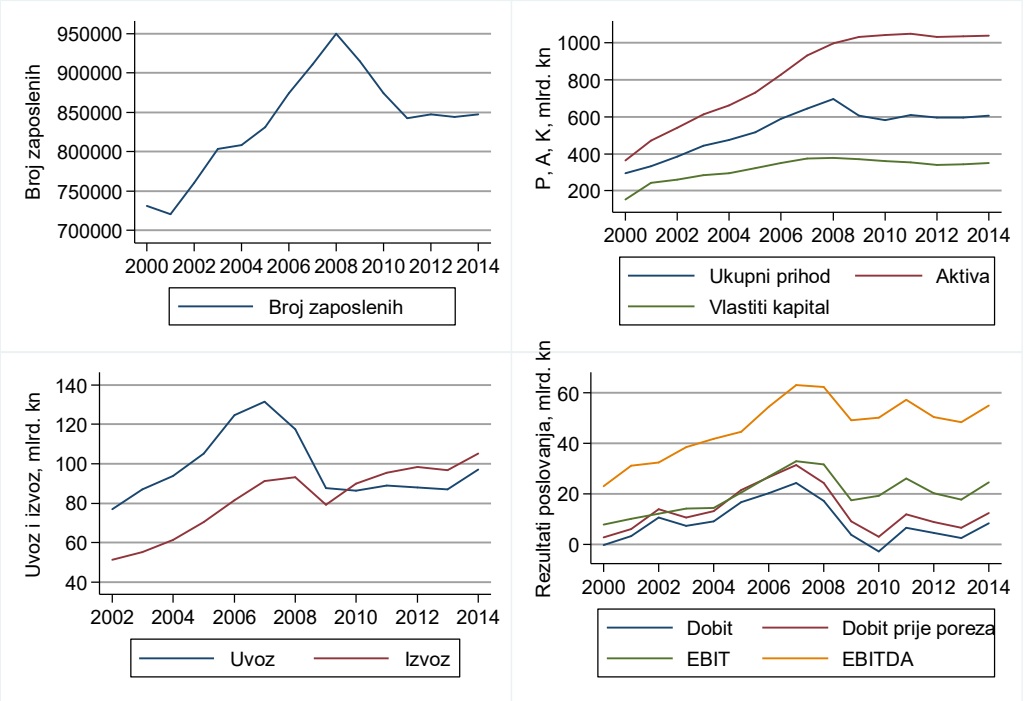

Izvor: Fina (2015), izračun autora

Slika 4-2: Vremenski odsječci ključnih varijabli poslovanja

U literaturi iz ekonomike rasta, kao ključnu determinantu autori su prepoznali rast produktivnosti stalnim inovacijama (npr. Solow 1956). Rast produktivnosti (tehnologije) najčešće se mjeri pomoću Solowljeva reziduala. U teorijskom smislu, tako definirana tehnologija može uključivati beskonačno mnogo načina povećanja produktivnosti. Ipak najčešće se misli na tehnološke inovacije (npr. željeznica, telegraf, internet) ili financijske inovacije (npr. sekuritizacija, promjena regulacije). Osim ekonomskog rasta, produktivnost je važan faktor u objašnjavanju investicijske i financijske aktivnosti poduzeća. Primjerice, rast kreditne aktivnosti može biti posljedica veće potražnje za kreditima rastom produktivnosti, a može biti i rezultat rasta kreditne ponude. Upravo se rast cijena nekretnina u SAD-u i nekim europskim zemljama pokušavao racionalizirati argumentom o rastu produktivnosti. Stoga je važno utvrditi odnos kreditnog rasta i rasta produktivnosti kako bi se ispitala održivost uzlazne faze ekonomskog ciklusa potaknute kreditnom ekspanzijom.

Mjere produktivnosti mogu se svrstati u dvije skupine. Prve su parcijalne ili jednofaktorske mjere produktivnosti, koje su odnos određene mjere za output i jedne mjere za input. Druga skupina uključuje višefaktorske mjere produktivnosti koje stavljaju u odnos mjeru outputa i skup inputa.

Slika 4-3 prikazuje očekivanu vrijednost produktivnosti rada i višefaktorske produktivnosti. Opservacije u prvom razdoblju (2001. godina) vjerojatno su rezultat određenih ekstremnih vrijednosti (engl. *outlier*). Produktivnost rada izračunana je kao omjer dodane vrijednosti i broja zaposlenih. Ona pokazuje rast produktivnosti u pretkriznom razdoblju (2002–2008) od 43 %, a slijedi snažan pad stopa rasta. Od 2009. do 2014. stopa rasta produktivnosti rada iznosila je 5 %. Nakon krize zabilježene su velike oscilacije produktivnosti, a snažan rast bio je u posljednjoj godini (7,8 %).

Produktivnost rada kao mjera produktivnosti ima brojne nedostatke.[39] U literaturi se stoga kao mjera produktivnosti često upotrebljava mjera višefaktorske produktivnosti koja u izračunu uvažava kombinacije inputa. Inputi su rad (troškovi osoblja), kapital (sadašnja vrijednost materijalne imovine) i materijalni troškovi (sirovine, materijali i ostali troškovi). Prema ovoj mjeri produktivnost pokazuje manje stope rasta. Naime, u pretkriznom razdoblju (2000–2008) ukupni rast produktivnosti iznosio je 5,5 %. U dvije godine krize (2009–2010) zabilježen je pad od 5,5 %, a u postkriznom razdoblju ponovno je, uz velike oscilacije, zabilježen rast od 1,9 %. U cijelom promatranom razdoblju produktivnost je rasla otprilike 2 %.

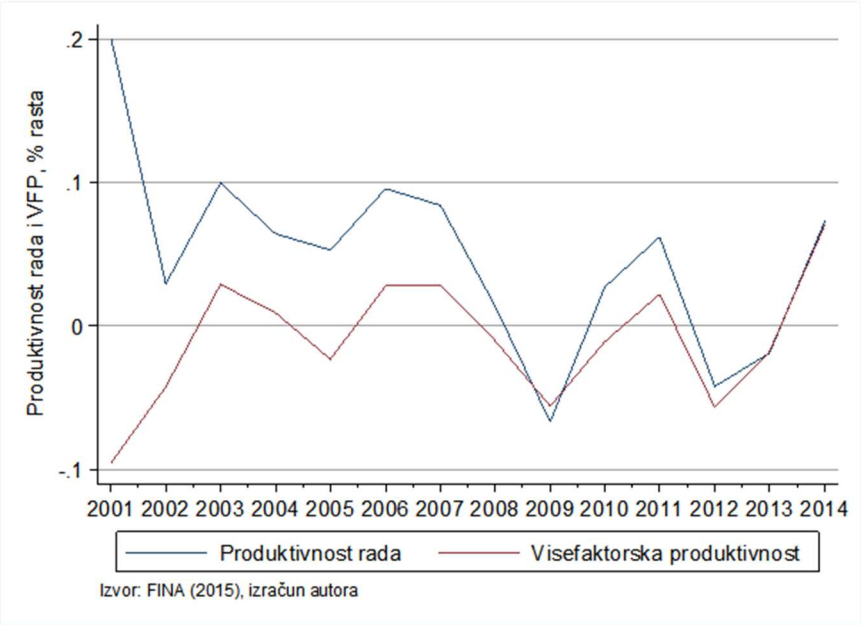

Slika 4-3: Dinamika parcijalne i višefaktorske produktivnosti nefinancijskih poduzeća od 2001. do 2014.

[39] Produktivnost rada ne upućuje na promjene u produktivnosti kapitala i ostalih inputa. Ako produktivnost ostalih inputa opada, pruduktivnost rada precjenjivat će agregatnu razinu produktivnosti.

Kako je predmet ovog rada objašnjenje utjecaja financijskih faktora na investicije i ekonomsku aktivnost, važno je utvrditi odnos produktivnosti i kreditne aktivnosti. Uspoređujući produktivnost s dinamikom kredita nefinancijskim poduzećima (slika 2-3), jasno se uočava jaz između stope rasta kredita i rasta produktivnosti nefinancijskim poduzećima. U pretkriznom razdoblju (2000–2007), stopa rasta kredita bila je 200 %, a stopa rasta višefaktorske produktivnosti iznosila je samo 5,5 %. Ako se umjesto podataka HNB-a o kreditima nefinancijskim poduzećima rast kreditne aktivnosti mjeri rastom kratkoročnih i dugoročnih obveza prema bankama i drugim financijskim institucijama, jaz je još veći, jer rast obveza od 2000. do 2007. iznosio je čak 368 %. Ipak treba upozoriti na to da su potonje mjere produktivnosti samo približne. Detaljnija analiza međuovisnosti produktivnosti i kreditne i investicijske aktivnosti nadilazi predmet istraživanja u ovom radu.

4.3 Struktura i dinamika investicija poslovnih subjekta

U nastavku se detaljnije opisuju značajke investicija za sva nefinancijska poduzeća, od 2001. do 2014. Valja se podsjetiti na to da su u poglavlju 4.1. već opisani različiti načini mjerenja investicija. Opisani su pojmovi „investicija“, „bruto kapitalne formacije“, „investicijskog toka“ i „neto investicija“ te točan način mjerenja. Slika 4-4 prikazuje dinamiku svih četiriju mjera investicija. Iz slike je vidljivo da sva četiri vremenska odsječka imaju sličnu dinamiku kretanja tijekom promatrana razdoblja, ali se mjere investicija razlikuju po iznosima.

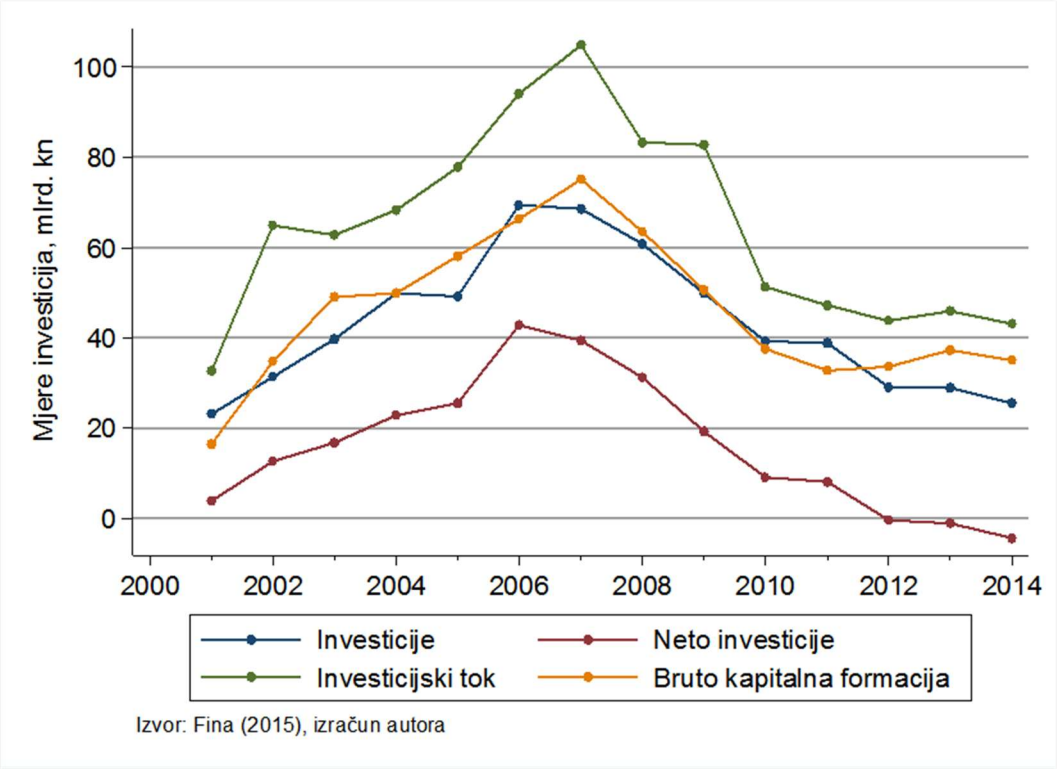

Slika 4-4: Investicije, bruto kapitalna formacija, investicijski tok i neto investicije nefinancijskih poduzeća od 2001. do 2014. u milijardama kuna

Na slici se vidi da je kretanje četiriju vremenskih odsječaka ciklično. Primjećuje se rast investicija u pretkriznom razdoblju i stalan pad investicijske aktivnosti nakon Velike recesije. Jedina je razlika u tome što investicije i neto investicije pokazuju pad vrijednosti već nakon 2006. godine, a ostale dvije mjere investicija pokazuju preokret tek godinu dana kasnije. U brojkama, investicije su rasle s 23 milijarde kuna 2001. godine na 69 milijardi kuna 2007. godine što je prosječan složeni godišnji rast od 20 %. Nakon izbijanja financijske krize, vrijednost investicija stalno opada te je 2014. godine iznosila 25 milijardi kuna, što je 62,88 % manje nego 2007. Bruto kapitalna formacija i investicijski tok pokazuju nešto manji pad investicija nakon krize (53 % i 57 % od 2008. do 2014.), ali jasno se očituje pad u vrijeme krize i stagnacija posljednjih godina. Zanimljivo je primijetiti da su poduzeća, gledano prema kriteriju neto investicija, dezinvestirala u prethodna tri razdoblja. Drugim riječima, tvrtke su u većem stupnju monetizirale materijalnu imovinu nego što su investirale u novu materijalnu imovinu. Rezultat je manje neto investicija na početku 2012. godine nego u svim prethodnim godinama. Promatrajući cijelo razdoblje, poslovni su subjekti najmanje investirali u 2014. godini.

U tablici 4-2 dan je pregled osnovnih statističkih veličina za sve četiri skupine investicija. Očekivane vrijednosti odgovaraju agregatnim razinama. Pri tome investicijski tok ima najveću vrijednost jer uključuje i financijske investicije. Važno je napomenuti da postoji velik broj opservacija s vrijednosti 0. To posebno vrijedi za varijablu bruto kapitalne formacije. Od svih opservacija bruto kapitalne formacije u razdoblju 2000–2014, 72,65 % ima vrijednost 0. Investicije, s druge strane, imaju vrijednost 0 u 30,55 % svih opservacija. Velik broj nultih vrijednosti nije rezultat nedostajućih podataka (engl. *missing values*). Mogu se izdvojiti dva razloga velikog udjela nultih vrijednosti. Prvo, najveći dio uzorka čine mikro i mala poduzeća koja imaju vrlo malo kapitala i imovine. Najčešće je riječ o poslovnim subjektima s ni jednim ili jednim zaposlenim. Ove tvrtke nemaju dostatnu razinu založena dohotka za pokretanje investicija, a često i vrlo niske prihoda. Drugo, investicije pokazuju mnogo nultih vrijednosti zbog visokih troškova prilagođavanja te visokih fiksnih troškova investicijskih pothvata (vidjeti poglavlje 2.2.4. i 2.2.5. gdje su opisani utjecaji ovih faktora na investicije). Bez ovih svojstava, investicije bi trebale bilježiti frekventnije promjene manjih inkremenata.

Tablica 4-2: Statističke veličine za različite mjere investicija, u tisućama kuna, od 2000.do 2014.

Varijable	(1) mean	(2) sd	(3) min	(4) p25	(5) p50	(6) p75	(7) max
Investicije	592.7	22,105	-4.632e+06	0	3.149	60.90	7.686e+06
Neto investicije	220.9	19,163	-5.152e+06	-24.81	-0.107	5.544	7.560e+06
Bruto kap. formacija	529.9	19,169	-2,930	0	0	4.183	5.876e+06
Investicijski tok	751.3	28,591	-3.726e+06	0	3.002	64.27	1.089e+07

Izvor: FINA (2015.), izračun autora

Osim ako nije drukčije navedeno, u radu se pod investicijama podrazumijeva plava linija na slici 4-4. Budući da je varijabla investicija u središtu pozornosti u cjelokupnoj analizi, primjereno je posebno proučiti njezinu strukturu i način mjerenja. Naime, kao što je opisano u poglavlju 4.1., investicije su jednake razlici zbroja materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju ($i_t = (MI_t + A_t) - MI_{t-1}$). Postavlja se pitanje kako se odnositi prema investicijama novoosnovanih poduzeća. Naime, za njih ne postoji opservacija za MI_{t-1}, pa je pitanje je li primjerenije investicije tada tretirati kao nedostajuću vrijednost (što je zadana procedura u svim statističkim paketima) ili kao investicije za to razdoblje uzeti $MI_t + A_t$. Moguće je obaviti još jednu prilagodbu. Ako poslovni subjekt nije predao financijski izvještaj jednu godinu, ali ga je predao sljedeću godinu, pitanje je kako

tretirati investicije u sljedećoj godini: treba li usporediti tekuću vrijednost s vrijednošću pomaknutom za dva razdoblja ili je tretirati kao nedostajuću vrijednost.

Grafički je analiziran utjecaj ovih dviju odluka na dinamiku investicija. U drugoj je prilagodbi identificirana vrlo mala razlika u razinama investicija, pa se u nastavku pozornost obraća prvoj prilagodbi.

Grafikoni na slici 4-5 odražavaju utjecaj različita mjerenja investicija na dinamiku investicija na agregatnoj razini. Plava krivulja prikazuje investicije za sva poduzeća pod pretpostavkom da se investicije novoosnovanih poduzeća označe kao nedostajuća vrijednost. Crvena krivulja uključuje i investicije novoosnovanih poduzeća. Drugim riječima, razlika između dviju krivulja odražava investicije novoosnovanih poduzeća (ako ne postoji MI_{t-1}, investicije su jednake iznosu $MI_t + A_t$).

Iz grafičkog prikaza 4-5 uočava se postojanje neuobičajenih vrijednosti investicija u 2001. i 2002. godini. Detaljnijom je analizom e ustanovljeno da dvije opservacije utječu na snažan pad investicija u 2002 godini, kako za plavu, tako i za crvenu krivulju (s novoosnovanim poduzećima i bez njih). HEP d. d. je imao pad investicija odu 21,7 milijardi kuna, a Hrvatske šume 17,4 milijarde kuna. Utvrđeno je da je HEP proknjižio građevinske objekte u ostalu dugotrajnu financijsku imovinu. Dakle nije riječ o dezinvestiranju nego o računovodstvenom preknjižavanju. U Hrvatskih šuma istodobno je smanjena materijalna imovina (zemljišta) i aktive. Može se pretpostaviti da je riječ o prijenosu vlasništva nad imovinom u javno vlasništvo ili tvrtke kćeri. Ako se iz uzorka izbace ova dva poduzeća, dobije se desni grafikon na slici 4-5. Nakon prilagodbe za veliki pad investicija u 2002. godini, i dalje postoji velika neusklađenost u 2002. i posebno u 2001. godini. Analizom je ustanovljeno da je razlog ove neusklađenosti rast investicija Hrvatskih cesta d. o. o. od 68,4 milijarde kuna u 2001. godini. Poduzeće je osnovano 13. travnja2001. godine, a u kapital je preuzelo velik udio imovine nastao ulaganjem u cestovnu infrastrukturu. Velikom jazu između krivulja u 2001. godini pridonijelo je i osnivanje Hrvatskih autocesta d. o. o. To je poduzeće nakon osnivanja imalo vrijednost materijalne imovine (investicija) od 19,8 milijardi kuna. Jaz u 2002. godini uglavnom je posljedica ulaganja trgovačkog društva HEP operator distribucijskog sustava d. o. o. od 8,6 milijardi kuna. Ako bi se investicije s uključenim novoosnovanim poduzećima (crvena krivulja) prilagodile tako da se iz uzorka izbrišu tri navedena poduzeća (HEP operator distribucijskog sustava d. o. o., Hrvatske ceste d. o. o., Hrvatske autoceste d. o. o.), plava i crvena linija poprimale bi slične vrijednosti, odnosno nestao bi jaz koji postoji u 2001. i 2002. godini.

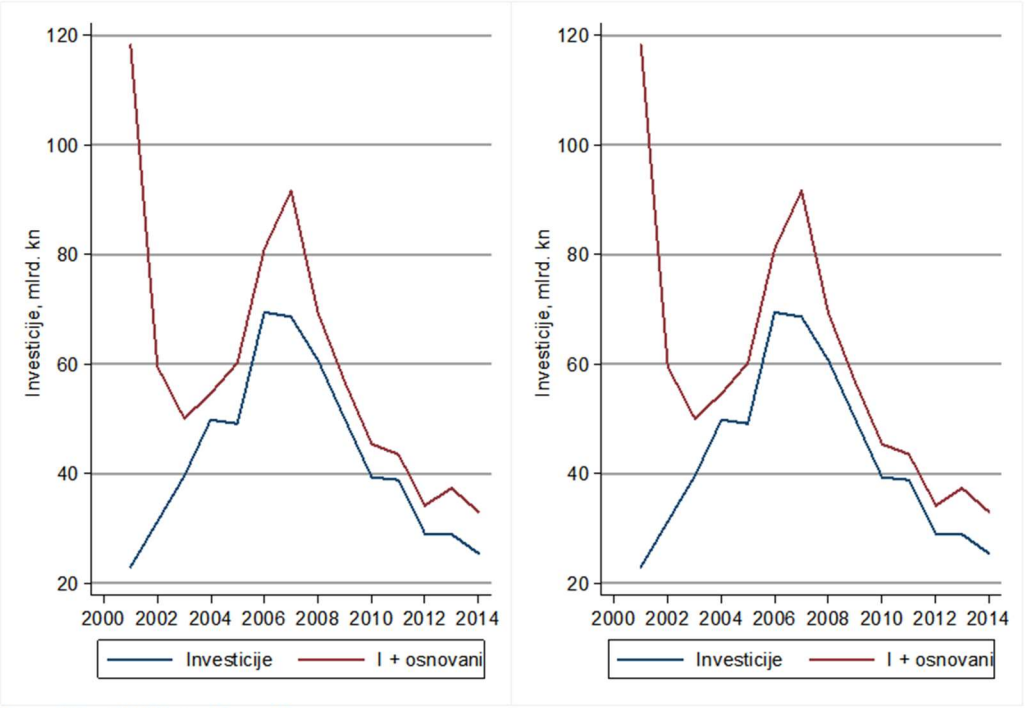

Izvor: Fina (2015), izračun autora

Slika 4-5: Dinamika investicija i investicija s novoosnovanim subjektima od 2001. do 2014.

Zaključno, uključivanje novoosnovanih poduzeća povećava vrijednost investicija u svim razdobljima, ali je jaz relativno stabilan (prosječna razlika iznosi 9 milijardi kuna), izuzev 2007. godine, kada su investicije, uključujući novoosnovane subjekte, bile 23 milijarde kuna veće od onih bez uključivanja ulaganja novoosnovanih poduzeća. U skladu s očekivanjima, jaz je veći u vrijeme ekspanzije nego u vrijeme kontrakcije. U nastavku rada, pod investicijama se podrazumijevaju investicije bez novoosnovanih poduzeća (plava krivulja na desnom grafikonu odnosno plava krivulja na slici 4-8). Uzorak ne uključuje dva poduzeća koja stvaraju ekstremno niske vrijednosti investicija u 2002. godini (Hrvatske šume d. o. o., HEP d. d.), osim ako nije drugačije napomenuto.

Analizirajući sliku 4-5, utvrđeno je da razine agregatne investicijske aktivnosti mogu biti pod snažnim utjecajem nekoliko velikih poduzeća. Radi dobivanja uvida o koncentriranosti investicijske aktivnosti, u tablici 4-3 dan je prikaz poslovnih subjekata s najvećim iznosom investicija, po izvještajnim razdobljima. Za svako razdoblje izabrano je pet poduzeća s najvećim udjelom investicija. U lijevom dijelu tablice za mjeru investicija upotrijebljena je varijabla investicija, a na desnoj strani bruto kapitalna formacija (BKF). Kolona „% ukupnih“ označava udio investicija pojedinog poduzeća u ukupnom zbroju investicija za dano izvještajno razdoblje. Iznosi investicija obračunani su u milijardama kuna. Jedina prilagodba koja je

napravljena odnosi se na ukupne razine investicija u 2002 godini, u kojoj su izbačene opservacije s neuobičajenim vrijednostima (HEP d. d. i Hrvatske šume d. o. o.). Vrijednosti investicija u 2001. godini nedostaju zbog nepostojanja pomaknutih vrijednosti materijalne imovine. Ako bi se investicijama pridružila opažanja o investicijama novoosnovanih poduzeća, udio poduzeća s najvećim investicijama u 2001. i 2002. godini bio bi znatno drukčiji zbog osnivanja Hrvatskih cesta d. o. o. i Hrvatskih autocesta d. o. o.

Prosječni udio investicija pet poslovnih subjekata s najvećim iznosom investicija u izvještajnom razdoblju iznosi oko 21 % (21,77 % za BKF i 20,95 % za investicije). Dakle, bilo da se investicije mjere na temelju podataka Državnog zavoda za statistiku ili iz objavljenih financijskih izvještaja, petina ih se odnosi na investicije pet poduzeća. Koristeći se podacima DZS-a, pet najvećih investitora ostvarilo je najveći udio u investicijama 2000. godine (31,31 % ukupnih investicija), a najmanji 2014. godine (15,96 % ukupnih investicija). Koristeći se podacima iz financijskih izvještaja, najveći je udio zabilježen 2001. godine (33,91 %), a najmanji 2011. godine (15,40 %). Koncentriranost investicija smanjila se nakon financijske krize, ali je i dalje ostala vrlo visoka (od 2000.do 2008. iznosila je 23,12 % za BKF i 22,45 % za investicije, a nakon krize pala je na 19,73 % i 18,94 %). Udio investicija subjekata s najvećom investicijskom aktivnosti iznosio je u prosjeku 7,46 % za BKF i 8,79 % za investicije. Također se može primijetiti da se udjeli pet najvećih investitora u ukupnim investicijama razlikuju po godinama. Za mjeru bruto kapitalne formacije najveći je udio zabilježen 2003. godine (11,90 %, a za mjeru „investicija“ 2001. godine (28,10 %).

Tablica 4-3: Investicije i bruto kapitalna formacija (BKF) u milijardama kuna od 2000. do 2014.

Naziv	Godina	BKF	% ukupnih	Naziv	Godina	Investicije	% ukupnih
HRVATSKA ELEKTROPRIVREDA-d.d.	2000	1,78	10,90%	-	-		-
VIPnet d.o.o.	2000	1,27	7,79%	-	-		-
INA-INDUSTRIJA NAFTE d.d.	2000	0,75	4,61%	-	-		-
Hrvatski Telekom d.d.	2000	0,70	4,27%	-	-		-
PLIVA FARMACEUTIKA d.d.	2000	0,61	3,73%	-	-		-
Hrvatske autoceste d.o.o.	2001	1,53	8,56%	Hrvatski Telekom d.d.	2001	4,92	19,62%
HRVATSKA ELEKTROPRIVREDA-d.d.	2001	1,50	8,42%	HRVATSKA ELEKTROPRIVREDA-d.d.	2001	1,64	6,53%
Hrvatski Telekom d.d.	2001	1,05	5,89%	TLM TVORNICA LAKIH METALA d.d.	2001	0,74	2,96%
HŽ d.o.o.	2001	0,50	2,78%	VIPnet d.o.o.	2001	0,64	2,55%
INA-INDUSTRIJA NAFTE d.d.	2001	0,44	2,45%	INA-INDUSTRIJA NAFTE d.d.	2001	0,56	2,24%
Hrvatske autoceste d.o.o.	2002	3,40	9,59%	Hrvatske autoceste d.o.o.	2002	4,32	13,82%
VIPnet d.o.o.	2002	1,43	4,03%	AUTOCESTA RIJEKA-ZAGREB, društvo d.d.	2002	0,92	2,94%
Hrvatski Telekom d.d.	2002	1,39	3,93%	HŽ d.o.o.	2002	0,69	2,21%
INA-INDUSTRIJA NAFTE d.d.	2002	0,90	2,55%	JADROPLOV d.d.	2002	0,68	2,18%
Hrvatske ceste d.o.o.	2002	0,73	2,06%	VIPnet d.o.o.	2002	0,55	1,75%
Hrvatske autoceste d.o.o.	2003	5,88	11,90%	Hrvatske autoceste d.o.o.	2003	5,50	13,99%
INA-INDUSTRIJA NAFTE d.d.	2003	1,86	3,77%	HŽ d.o.o.	2003	1,60	4,07%
HEP-Operator distribucijskog sustava d.o.o.	2003	1,31	2,65%	HEP-Operator distribucijskog sustava d.o.o.	2003	1,39	3,52%
HŽ d.o.o.	2003	1,28	2,60%	HEP-Proizvodnja d.o.o.	2003	1,32	3,36%
AUTOCESTA RIJEKA-ZAGREB, društvo d.d.	2003	1,12	2,27%	INA-INDUSTRIJA NAFTE d.d.	2003	1,03	2,62%
Hrvatske autoceste d.o.o.	2004	4,75	9,48%	Hrvatske autoceste d.o.o.	2004	4,20	8,39%
INA-INDUSTRIJA NAFTE d.d.	2004	2,19	4,36%	INA-INDUSTRIJA NAFTE d.d.	2004	1,57	3,13%
HŽ d.o.o.	2004	1,84	3,66%	HŽ d.o.o.	2004	1,47	2,93%
AUTOCESTA RIJEKA-ZAGREB, društvo d.d.	2004	1,12	2,23%	HEP-Operator distribucijskog sustava d.o.o.	2004	1,10	2,20%
Hrvatske ceste d.o.o.	2004	0,91	1,82%	Hrvatske ceste d.o.o.	2004	0,94	1,88%
Hrvatske autoceste d.o.o.	2005	3,93	6,75%	INA-INDUSTRIJA NAFTE d.d.	2005	3,71	7,44%
MAJEX d.o.o.	2005	3,86	6,63%	Hrvatske autoceste d.o.o.	2005	3,37	6,77%
INA-INDUSTRIJA NAFTE d.d.	2005	3,21	5,51%	HEP-Operator distribucijskog sustava d.o.o.	2005	1,44	2,90%
HEP-Operator distribucijskog sustava d.o.o.	2005	1,23	2,12%	HŽ d.o.o.	2005	0,97	1,96%
Hrvatski Telekom d.d.	2005	1,06	1,81%	Hrvatski Telekom d.d.	2005	0,78	1,57%
INA-INDUSTRIJA NAFTE d.d.	2006	4,22	6,32%	ZAGREBAČKI HOLDING d.o.o.	2006	7,69	10,87%
Hrvatske autoceste d.o.o.	2006	3,10	4,64%	Hrvatske autoceste d.o.o.	2006	2,28	3,23%
ENI CROATIA B.V.	2006	1,72	2,58%	INA-INDUSTRIJA NAFTE d.d.	2006	1,91	2,70%
Hrvatske ceste d.o.o.	2006	1,34	2,01%	HEP-Operator distribucijskog sustava d.o.o.	2006	1,36	1,93%
HEP-Operator distribucijskog sustava d.o.o.	2006	1,34	2,01%	HŽ d.o.o.	2006	1,36	1,92%
INA-INDUSTRIJA NAFTE d.d.	2007	4,20	5,56%	ZAGREBAČKI HOLDING d.o.o.	2007	4,57	6,52%

Hrvatske autoceste d.o.o.	2007	3,82	5,06%	Hrvatske autoceste d.o.o.	2007	3,21	4,59%
AUTOCESTA RIJEKA-ZAGREB, društvo d.d.	2007	2,83	3,75%	INA-INDUSTRIJA NAFTE d.d.	2007	2,25	3,21%
ZAGREBAČKI HOLDING d.o.o.	2007	1,82	2,42%	HEP-Operator distribucijskog sustava d.o.o.	2007	1,54	2,20%
Hrvatske ceste d.o.o.	2007	1,68	2,22%	UniCredit Leasing Croatia d.o.o.	2007	1,36	1,94%
AUTOCESTA RIJEKA-ZAGREB, društvo d.d.	2008	4,07	6,38%	INA-INDUSTRIJA NAFTE d.d.	2008	3,49	5,35%
Hrvatske autoceste d.o.o.	2008	4,00	6,28%	Hrvatske autoceste d.o.o.	2008	3,46	5,30%
INA-INDUSTRIJA NAFTE d.d.	2008	3,83	6,01%	LIDL HRVATSKA d.o.o.	2008	1,64	2,52%
HEP-Operator distribucijskog sustava d.o.o.	2008	1,23	1,92%	HEP-Operator distribucijskog sustava d.o.o.	2008	1,32	2,02%
Hrvatske ceste d.o.o.	2008	1,15	1,81%	Hrvatski Telekom d.d.	2008	1,11	1,70%
INA-INDUSTRIJA NAFTE d.d.	2009	4,38	8,65%	INA-INDUSTRIJA NAFTE d.d.	2009	4,53	8,67%
Hrvatske autoceste d.o.o.	2009	3,60	7,11%	ZAGREBAČKI HOLDING d.o.o.	2009	2,60	4,97%
Hrvatske ceste d.o.o.	2009	1,80	3,55%	Hrvatske autoceste d.o.o.	2009	2,51	4,80%
ZAGREBAČKI HOLDING d.o.o.	2009	1,75	3,46%	Hrvatski Telekom d.d.	2009	1,03	1,97%
AUTOCESTA RIJEKA-ZAGREB, društvo d.d.	2009	1,20	2,37%	TRGOVAČKI CENTAR ZAGREB d.o.o.	2009	0,94	1,80%
INA-INDUSTRIJA NAFTE d.d.	2010	2,82	7,46%	INA-INDUSTRIJA NAFTE d.d.	2010	2,73	6,85%
PLINACRO d.o.o.	2010	1,43	3,79%	Hrvatski Telekom d.d.	2010	2,21	5,56%
Hrvatske autoceste d.o.o.	2010	1,41	3,72%	PLINACRO d.o.o.	2010	1,45	3,63%
Hrvatski Telekom d.d.	2010	1,11	2,93%	ZAGREBAČKI HOLDING d.o.o.	2010	1,01	2,53%
Hrvatske ceste d.o.o.	2010	1,02	2,70%	KONZUM, trgovina na veliko i malo d.d.	2010	0,98	2,47%
INA-INDUSTRIJA NAFTE d.d.	2011	1,39	4,22%	ZAGREBAČKI HOLDING d.o.o.	2011	1,98	5,02%
Hrvatske autoceste d.o.o.	2011	1,39	4,22%	INA-INDUSTRIJA NAFTE d.d.	2011	1,40	3,56%
Hrvatske ceste d.o.o.	2011	1,00	3,03%	HEP-Proizvodnja d.o.o.	2011	0,94	2,38%
Hrvatski Telekom d.d.	2011	0,88	2,67%	Hrvatski Telekom d.d.	2011	0,91	2,31%
HEP-Proizvodnja d.o.o.	2011	0,85	2,58%	HEP-Operator distribucijskog sustava d.o.o.	2011	0,84	2,13%
Hrvatske autoceste d.o.o.	2012	1,71	5,06%	HEP-Operator distribucijskog sustava d.o.o.	2012	1,06	3,62%
Hrvatske ceste d.o.o.	2012	1,32	3,92%	Hrvatski Telekom d.d.	2012	0,98	3,35%
INA-INDUSTRIJA NAFTE d.d.	2012	1,14	3,38%	Hrvatske autoceste d.o.o.	2012	0,97	3,29%
Hrvatski Telekom d.d.	2012	1,13	3,33%	Hrvatski operator prijenosnog sustava d.o.o.	2012	0,86	2,94%
HEP-Operator distribucijskog sustava d.o.o.	2012	0,96	2,84%	HŽ PUTNIČKI PRIJEVOZ d.o.o.	2012	0,71	2,41%
Hrvatske autoceste d.o.o.	2013	2,43	6,49%	Hrvatski Telekom d.d.	2013	1,09	3,68%
INA-INDUSTRIJA NAFTE d.d.	2013	1,89	5,06%	HŽ INFRASTRUKTURA d.o.o.	2013	1,08	3,67%
HŽ INFRASTRUKTURA d.o.o.	2013	1,39	3,71%	Hrvatske autoceste d.o.o.	2013	1,08	3,65%
Hrvatski Telekom d.d.	2013	1,36	3,63%	HEP-Operator distribucijskog sustava d.o.o.	2013	0,87	2,93%
OŠTRA STINA d.o.o.	2013	0,96	2,57%	VIPnet d.o.o.	2013	0,75	2,53%
INA-INDUSTRIJA NAFTE d.d.	2014	1,61	4,59%	HRVATSKA ELEKTROPRIVREDA-d.d.	2014	2,57	9,21%
Hrvatske ceste d.o.o.	2014	1,08	3,06%	JADROPLOV d.d.	2014	1,04	3,72%
HŽ INFRASTRUKTURA d.o.o.	2014	0,98	2,79%	HEP-Operator distribucijskog sustava d.o.o.	2014	0,99	3,55%
PETROL d.o.o.	2014	0,97	2,76%	Hrvatski Telekom d.d.	2014	0,94	3,38%
HEP-Operator distribucijskog sustava d.o.o.	2014	0,97	2,76%	HŽ INFRASTRUKTURA d.o.o.	2014	0,87	3,11%

Promatrajući cijelo razdoblje, najviše su investirale Hrvatske autoceste d. o. o. Ukupan je iznos bruto kapitalne formacije 40,93 milijardi kuna, što je 6,19 % ukupnih investicija u cijelom razdoblju od 2000. do 2014. Valja podsjetiti da je poduzeće osnovano 2001. godine, što znači da bi utjecaj bio i veći kada bi se gledalo razdoblje od 2001. godine. U 2014. godini agregatna bruto kapitalna formacija za cijelu RH iznosila je 35 milijardi kuna, što znači da je bruto kapitalna formacija Hrvatskih autocesta d. o. o. od 2001. do 2014. bila veća od svih investicija u 2014. godini. Ukupni iznos investicija od 2001. do 2014. iznosio je 30,90 milijardi kuna, što je 5 % ukupnih investicija. Ako bi se investicijama pridružilo i povećanje materijalne imovine iz 2001. godine, kada je poduzeće osnovano, iznos bi svakako bio veći. Nakon Hrvatskih autocesta d. o. o., najveći iznos bruto kapitalne formacije ostvarila je INA-industrija nafte d. d., 34.83 milijarde kuna ili 5,27 % ukupnih investicija od 2000. do 2014. Ako se upotrebljava mjera investicija, ukupne investicije iznose 23,18 milijardi ili 3,74 % ukupnih investicija. Treći subjekt je Autocesta Rijeka – Zagreb d. d., s ukupnim ulaganjem (BKF) od 10,.33 milijarde kuna ili 1,56 % ukupnih investicija. Po mjerama investicija, treći, najveći investitor je Zagrebački holding d. o. o. s ulaganjem od 17,83 milijarde kuna ili 2,88 % ukupnih investicija. Međutim, ovo ulaganje djelomično je rezultat ujedinjavanja više javnih poduzeća u gradu Zagrebu jer su tijekom promatranog razdoblja pojedina poduzeća pridruživana Zagrebačkom holdingu, pa se u materijalnu imovinu dodavala imovina pripojenih poduzeća. Zbrajajući investicije triju subjekata s najvećim iznosom investicija u promatranu razdoblju, može se zaključiti da čine 13, 03 % (mjereno bruto kapitalnom formacijom), odnosno 11,61 % ukupnih investicija (mjereno mjerom „investicija“). Proizlazi da investicije velikih poduzeća uvelike određuju agregatne investicije u Republici Hrvatskoj. Zanimljivo je primijetiti da se najveći udio ukupnih investicija odnosi na ulaganje u prometnu infrastrukturu (poduzeća Hrvatske autoceste d. o. o. i Autocesta Zagreb – Rijeka d. o. o.), otprilike 10 % ukupnih investicija za razdoblje od 2000. do 2014. Valja također istaknuti da su sve tri tvrtke u državnom vlasništvu. Ako se investicije mjere BKF-om, 10 od 18 najvećih investitora u većinskom je državnom vlasništvu, a ako se kao mjera upotrijebe investicije, 13 od 21 subjekta u većinskom su državnom vlasništvu. Pri tome su poduzeća koja su u promatranu razdoblju privatizirana (poput HT-a d. d.) evidentirana kao privatna.

Deskriptivna analiza investicija nastavlja se slikom 4-6, na kojoj su prikazane investicije po industrijama, u milijunima kuna od 2001. do 2014. Najveće industrije u Hrvatskoj prema kriteriju investicija su trgovina, prerađivačka industrija i građevinarstvo. Sve tri djelatnosti pokazuju slična ciklična kretanja. U djelatnosti građevinarstva, u pretdkriznom razdoblju

(2001–2007), investicije su se povećale otprilike 6 puta, a 2012. vratile su se na razine iz 2001. Cikličnost građevinskog sektora bila bi još izraženija ako bi joj se pridodao sektor nekretnina. S druge strane, djelatnosti trgovine i prerađivačka djelatnost imale su manju cikličnost. Investicije su rasle okvirno 150 % u pretkriznom razdoblju te su se vratile na pretkrizne razine 2012. godine. Zanimljivo je primijetiti da poljoprivreda bilježi relativno niske iznose investicija tijekom cijelog razdoblja. Djelatnosti prijevoza, električne energije, stručne djelatnosti, usluge smještaja i informacija bilježe relativno manje i stabilne razine investicija.

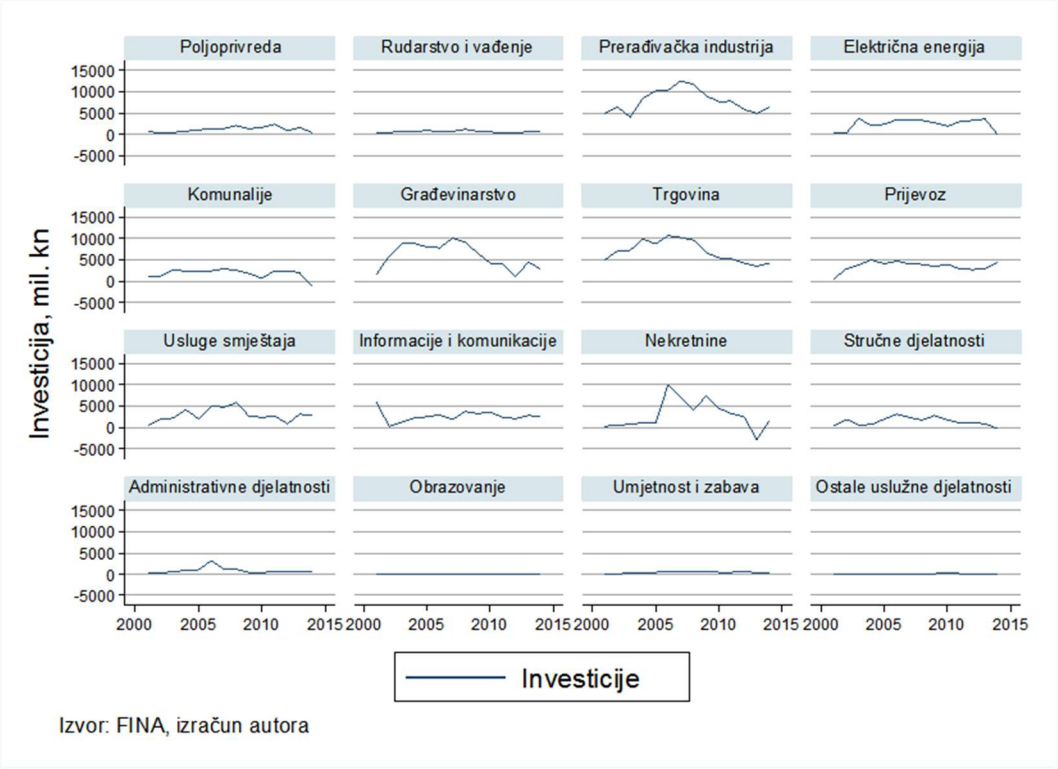

Slika 4-6: Investicije po djelatnostima, u milijunima kuna, od 2001.do 2014.

Sljedeći kriterij opisivanja investicija čini veličina poduzeća (slika 4-7). Kriteriji razlikovanja poduzeća prema veličini dani su u tablici 4-4. Poduzeće prelazi u višu skupinu ako su zadovoljena barem dva kriterija. Primjerice, kada poduzeće prijeđe 2,6 milijuna kn imovine i 5,2 milijuna kn prihoda (ili 10 zaposlenih), prelazi iz skupine mikro u skupinu malih poduzeća. U tablici 4-5 prikazan je broj poduzeća u skupini mikro, malih, srednjih i velikih poduzeća za izabrane godine. U prosjeku 86 % poduzeća pripada skupini mikro poduzeća, 11 % skupini malih poduzeća, 1 % skupini poduzeća srednje velikim, te 0,3 % velikim poduzećima. Struktura veličine poduzeća relativno je stabilna u cijelom razdoblju.

Tablica 4-4: Kriteriji razlikovanja veličine poduzeća

Veličina	Imovina	Prihodi	Zaposlenost
Mikro	2,600,000.00 kn	5,200,000.00 kn	10
Malo	30,000,000.00 kn	60,000,000.00 kn	50
Srednje	150,000,000.00 kn	300,000,000.00 kn	250
Veliko			

Izvor: FINA (2015.), autorov izračun

Tablica 4-5: broj poduzeća u grupi mikro, malih, srednjih i velikih poduzeća za izabrane godine

Veličina	2001	2005	2008	2012	2014
Mikro	49.171	62.245	75.848	85.607	92.780
Malo	6.605	9.184	11.768	9.724	10.029
Srednje	978	1.333	1.655	1.422	1.349
Veliko	230	304	382	313	309
UKUPNO	56.984	73.066	89.653	97.066	104.467

Izvor: FINA (2015.), autorov izračun

Slika 4-7 pokazuje strukturu ukupnih investicija prema veličini poduzeća. Otprilike 50 % investicija odnosi se na poslovne subjekte iz skupine velikih poslovnih subjekata, koji čine između 0,3 % i 0,5 % ukupnog broja poslovnih subjekata. Time se potvrđuju prijašnji zaključci o visokoj koncentriranosti investicijske aktivnosti. Male promjene u strukturi mogu se primijetiti nakon 2011. godine kada raste udio investicija mikro i malih poduzeća, a pada udio velikih poduzeća.

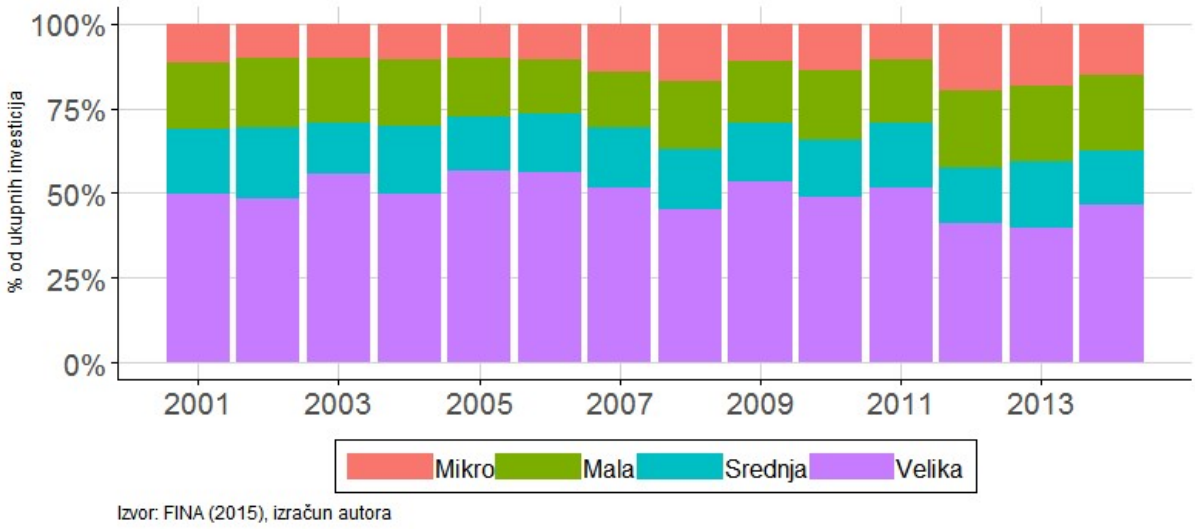

Slika 4-7: Struktura investicija prema veličini poduzeća od 2001. do 2014.

Često se kao kriterij razlikovanja financijskih ograničenih i neograničenih poduzeća upotrebljava upravo veličina poduzeća, pri čemu je ona aproksimirana knjigovodstvenom vrijednošću imovine. Očekuje se da velika poduzeća (s velikim iznosom imovine) imaju veću fleksibilnost u financiranju projekata, veće iznose kolaterala i manje troškove monitoringa (Gertler, Gilchrist, 1994). Na slici 4.8 prikazana je stopa investicija (odnos investicija i vremenski pomaknute vrijednosti ukupne imovine) za različite percentile veličine poduzeća. Medijan stope investicija za „mala“ poduzeća (manja od 10. percentila), pokazuje nulte vrijednosti tijekom cijelog promatranog razdoblja. To ne znači da mala poduzeća ne investiraju (slika 4-7 pokazuje da mala poduzeća investiraju), ali pokazuje da medijan 10 % najmanjih poduzeća iznosi nula, odnosno da vrlo mali broj malih poduzeća investira. „Veliki“ subjekti (iznad 90. percentila) investiraju više od „srednje“ velikih, ali im je dinamika vrlo slična tijekom promatrana razdoblja. Ovakvo kretanje ne mora nužno biti posljedica manjeg financijskog ograničenja velikih poduzeća, nego i većih investicijskih prilika ili manjih idiosinkratičnih šokova.

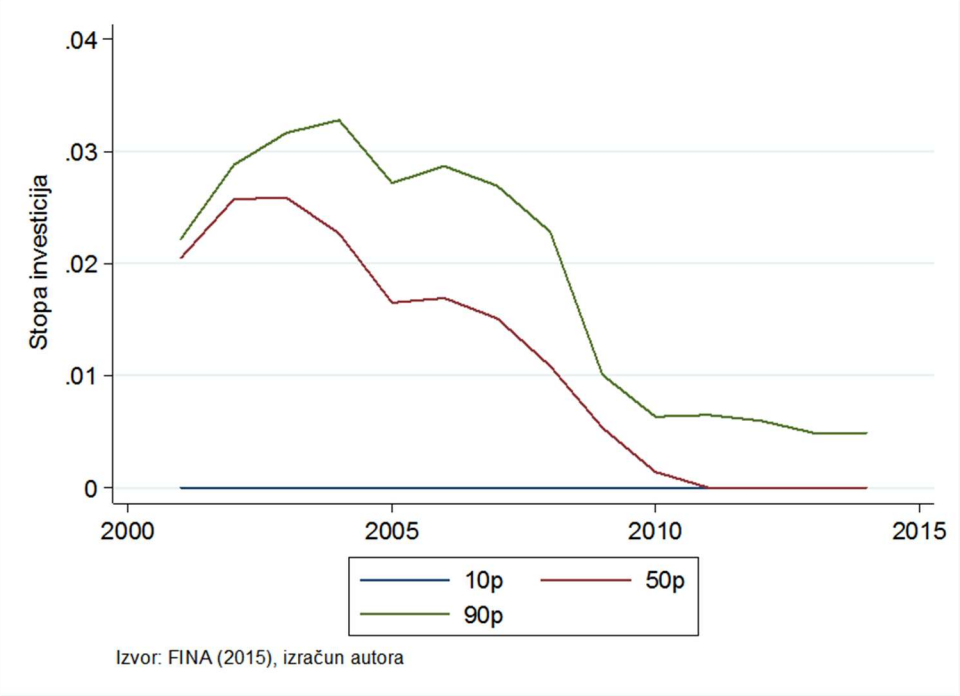

BILJEŠKA: Graf pokazuje medijane stope investicija za različite interkvantilne razmake veličine poduzeća (veličine ukupne imovine); 10p označuje medijan investicija za poduzeća koja su po veličini ispod 10. percentila, 50p između 40. i 60. percentila te 90p iznad 90. percentila. Veličina je aproksimirana knjigovodstvenom vrijednošću imovine.

Slika 4-8: Dinamika stope neto investicija za male, srednje i velike subjekte

Ako se investicije shvate u širem smislu kao „kombiniranje sredstava i njihovih transformacijskih sposobnosti za oblikovanje poslovne poluge radi racionalne snage zarađivanja“ (Tintor, 2009., str. 452), njihovo će razumijevanje zahtijevati analizu udjela pojedinog oblika imovine u ukupnoj aktivi. Tablica 4-2 pokazuje udio pojedinog oblika imovine u ukupnoj knjigovodstvenoj vrijednosti imovine. U prosjeku, kratkotrajna imovina jedna je trećina ukupne imovine, a ostatak se odnosi na dugotrajnu imovinu. Struktura materijalne imovine pokazuje sljedeće udjele: nematerijalna ulaganja i dugotrajna potraživanja u prosjeku su oko 2 % ukupne imovine, financijska ulaganja 11 %, a materijalna imovina 51 % ukupne imovine. Pri tome valja naznačiti da je udio materijalnih ulaganja pao s 53 % 2001. godine na 49 % 2014. godine. Izdaci za razvoj čine 0 % ukupne imovine. Ova je stavka toliko rijetka u financijskim izvještajima da bi se mogla posebno analizirati na razini poslovnog subjekta. U kratkotrajnom imovini najveći udio imaju potraživanja (16 % ukupne imovine) i zalihe (9 % ukupne imovine), a manji kratkotrajna financijska imovina (6 % ukupne imovine) i novac (3 % ukupne imovine), pri čemu novac i novčani supstituti pokazuju rast udjela sa 7 % na 11 % tijekom promatranog razdoblja (2000–2014). Također, rastu izvanbilančne stavke s 0 % u 2007. godini na 14 % u 2014. godini (nemoguće je utvrditi od čega se sastoji pozicija izvanbilančnih stavki).

Tablica 4-6: Struktura pasive, u postotku od ukupne imovine, od 2000. do 2014.

Oznaka pozicije	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014
A) POTRAŽIVANJA ZA UPISANI, A NEUPLAĆENI KAPITAL	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**
B) DUGOTRAJNA IMOVINA	**60%**	**67%**	**67%**	**66%**	**66%**	**66%**	**65%**	**64%**	**62%**	**64%**	**65%**	**64%**	**65%**	**65%**	**65%**
I. NEMATERIJALNA IMOVINA	**1%**	**2%**	**2%**	**2%**	**2%**	**2%**	**2%**	**2%**	**3%**	**3%**	**2%**	**2%**	**2%**	**2%**	**2%**
1. Izdaci za razvoj	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
2. Koncesije, patenti, licencije, robne i uslužne marke, softver i ostala prava	1%	1%	1%	1%	1%	1%	1%	1%	2%	2%	2%	2%	2%	2%	1%
3. *Goodwill*	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
5. Nematerijalna imovina u pripremi	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
II. MATERIJALNA IMOVINA	**48%**	**57%**	**56%**	**54%**	**54%**	**53%**	**52%**	**50%**	**49%**	**50%**	**50%**	**51%**	**51%**	**51%**	**51%**
1. Zemljište	6%	6%	5%	5%	5%	6%	6%	7%	7%	7%	7%	8%	8%	8%	8%
2. Građevinski objekti	25%	36%	35%	33%	33%	31%	29%	27%	26%	26%	26%	27%	27%	27%	27%
3. Postrojenja i oprema	8%	7%	7%	7%	7%	7%	6%	6%	6%	6%	6%	6%	6%	6%	6%
4. Alati, pogonski inventar i transportna imovina	4%	3%	3%	4%	4%	4%	4%	4%	3%	3%	3%	2%	2%	2%	2%
5. Biološka imovina	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
6. Predujmovi za materijalnu imovinu	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
7. Materijalna imovina u pripremi	4%	4%	4%	4%	4%	4%	5%	5%	6%	6%	6%	5%	5%	5%	5%
8. Ostala materijalna imovina	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
9. Ulaganje u nekretnine	0%	0%	0%	0%	0%	0%	0%	0%	1%	2%	2%	2%	3%	3%	3%
III. DUGOTRAJNA FINANCIJSKA IMOVINA	**10%**	**8%**	**7%**	**8%**	**8%**	**9%**	**8%**	**9%**	**9%**	**11%**	**11%**	**10%**	**11%**	**11%**	**11%**
1. Udjeli (dionice) kod povezanih poduzetnika	5%	4%	0%	0%	0%	0%	0%	0%	6%	8%	8%	7%	7%	7%	8%
2. Dani zajmovi povezanim poduzetnicima	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	0%	1%	1%	1%	1%
3. Sudjelujući interesi (udjeli)	0%	0%	3%	3%	4%	5%	4%	4%	1%	0%	0%	0%	0%	0%	0%
5. Ulaganja u vrijednosne papire	2%	1%	4%	3%	3%	3%	3%	3%	1%	1%	0%	0%	0%	0%	0%
6. Dani zajmovi, depoziti i slično	1%	1%	0%	0%	0%	0%	0%	0%	1%	1%	1%	1%	1%	1%	1%
7. Ostala dugotrajna financijska imovina	1%	1%	1%	1%	1%	1%	1%	1%	0%	0%	1%	1%	1%	1%	1%
IV. POTRAŽIVANJA	**1%**	**1%**	**2%**	**2%**	**2%**	**2%**	**3%**	**3%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**
1. Potraživanja od povezanih poduzetnika	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%

2. Potraživanja po osnovi prodaje na kredit	1%	0%	2%	2%	2%	2%	3%	3%	0%	0%	0%	0%	0%	0%	0%
V. ODGOĐENA POREZNA IMOVINA	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**1%**
C) KRATKOTRAJNA IMOVINA	**39%**	**32%**	**32%**	**33%**	**33%**	**33%**	**34%**	**35%**	**37%**	**35%**	**34%**	**35%**	**34%**	**34%**	**34%**
I. ZALIHE	**11%**	**9%**	**9%**	**9%**	**9%**	**9%**	**9%**	**10%**	**11%**	**10%**	**10%**	**10%**	**10%**	**9%**	**9%**
1. Sirovine i materijal	3%	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%	1%	1%
2. Proizvodnja u tijeku	2%	1%	1%	1%	2%	2%	2%	3%	3%	3%	3%	3%	3%	2%	2%
3. Gotovi proizvodi	2%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%
4. Trgovačka roba	4%	4%	4%	4%	4%	4%	4%	4%	4%	3%	4%	4%	3%	3%	3%
5. Predujmovi za zalihe	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
6. Dugotrajna imovina namijenjena prodaji	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	1%	1%
7. Biološka imovina	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
II. POTRAŽIVANJA	**20%**	**16%**	**14%**	**14%**	**14%**	**14%**	**15%**	**14%**	**17%**	**16%**	**15%**	**16%**	**15%**	**14%**	**14%**
1. Potraživanja od povezanih poduzetnika	2%	2%	0%	0%	0%	0%	0%	0%	2%	2%	2%	2%	2%	3%	2%
2. Potraživanja od kupaca	15%	12%	13%	13%	13%	13%	13%	13%	12%	11%	11%	11%	10%	10%	10%
3. Potraživanja od sudjelujućih poduzetnika	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
4. Potraživanja od zaposlenika i članova poduzetnika	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
5. Potraživanja od države i drugih institucija	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	2%	1%	1%	1%
6. Ostala potraživanja	2%	1%	0%	0%	0%	0%	0%	0%	1%	1%	1%	1%	1%	1%	1%
III. KRATKOTRAJNA FINANCIJSKA IMOVINA	**4%**	**5%**	**6%**	**7%**	**7%**	**7%**	**8%**	**8%**	**6%**	**6%**	**6%**	**6%**	**6%**	**6%**	**7%**
1. Udjeli (dionice) kod povezanih poduzetnika	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
2. Dani zajmovi povezanim poduzetnicima	1%	1%	0%	0%	0%	0%	0%	0%	1%	2%	2%	2%	2%	2%	2%
3. Sudjelujući interesi (udjeli)	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
5. Ulaganja u vrijednosne papire	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	0%	0%	1%	1%	1%
6. Dani zajmovi, depoziti i slično	3%	3%	4%	4%	4%	4%	5%	5%	4%	3%	3%	3%	3%	3%	3%
7. Ostala financijska imovina	0%	0%	2%	2%	2%	2%	2%	2%	1%	0%	0%	0%	0%	1%	1%
IV. NOVAC U BANCI I BLAGAJNI	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**4%**
D) PLAĆENI TROŠKOVI BUDUĆEG RAZDOBLJA I OBRAČUNATI PRIHODI	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**
E) UKUPNO AKTIVA	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**
F) IZVANBILANČNI ZAPISI	**6%**	**5%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**6%**	**6%**	**7%**	**7%**	**8%**	**13%**	**14%**

Slika 4-9 pokazuje strukturu investicija prema vrsti materijalne neto imovine od 2000. do 2014., u milijardama kuna. Na slici su prikazani agregatni udjeli pojedine komponente materijalne imovine u ukupnoj strukturi tijekom vremena. Pojedine su stavke izostavljene zbog zanemarivo male vrijednosti prema ukupnoj vrijednosti materijalne imovine.

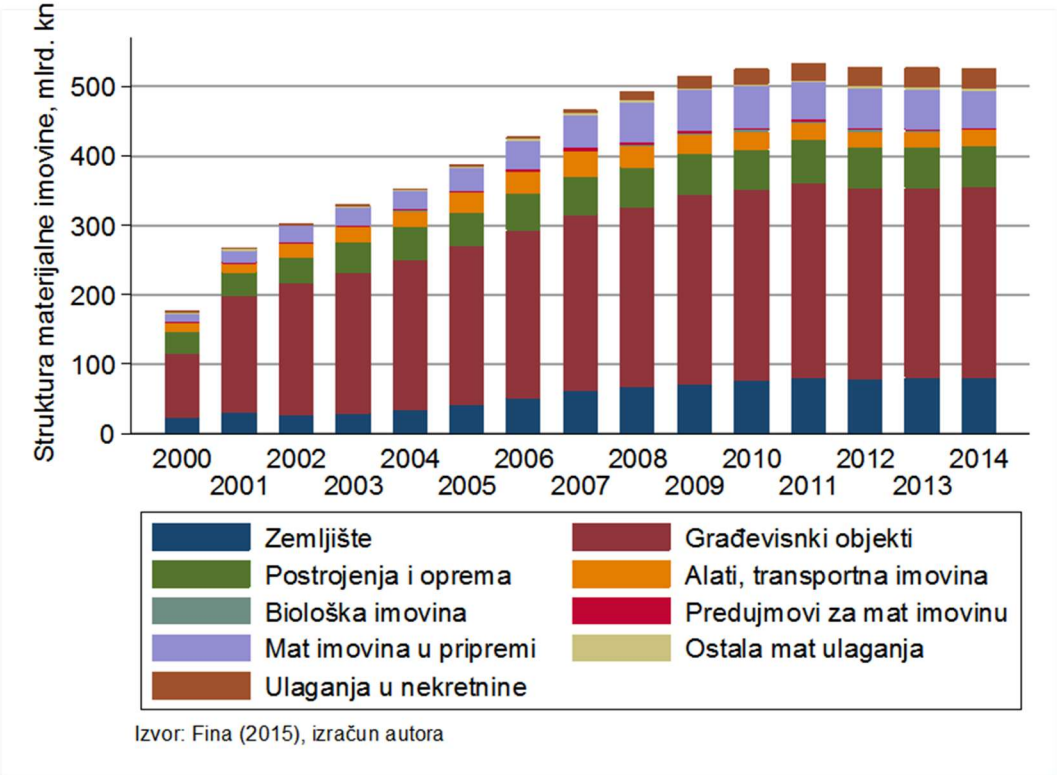

Slika 4-9: Struktura investicija u Republici Hrvatskoj prema vrsti materijalne imovine od 2000. do 2014. u milijardama kuna.

Slika 4-9 pokazuje da su poduzeća u cijelom promatranom razdoblju najvećim dijelom ulagala u građevinske objekte. Ako se tomu dodaju ulaganja u nekretnine koje počinju rasti 2007. godine i zemljišta, koja stabilno rastu poslije 2003. godine, može se zaključiti da je kompletan rast investicijske aktivnosti u Hrvatskoj bio usmjeren u izgradnju građevinskih objekata i nekretnina. Od 2000. do 2008. vrijednost građevinskih objekata kao elementa materijalne imovine rasla je sa 100 na 260 milijardi kuna. Upravo zbog ovako velikog rasta investicija u građevinske objekte izostavljanje ove komponente iz definicije investicija te fokusiranje samo na ulaganje u pogone i opremu (što je praksa u brojnim istraživanjima) može se smatrati neprimjerenim jer zanemaruje glavninu investicijske aktivnosti u predkriznom razdoblju. Slika 4-9 pokazuje da isključivanjem ulaganja u građevinske objekte nestaje većina investicija, kako u pretkriznom, tako i u kriznom razdoblju. Ulaganje u pogone i opremu, s druge strane, ima sve manji udio u ukupnoj materijalnoj imovini u promatranom razdoblju. Točnije, udio ulaganja u

postrojenja i opremu pada sa 17 % vrijednosti materijalnih ulaganja u 2000. godini na 11 % vrijednosti materijalnih ulaganja u 2014. godini.

Ulaganje u građevinske objekte čine ulaganja u stambene i poslovne objekte od različita materijala, ulaganja u ceste, željeznice te ostale građevinske objekte. Osnovano je pretpostaviti da su ulaganja u nekretnine pridonijela rastu njihovih cijena u pretkriznom razdoblju. Drugim riječima, nije se ulagalo u stvaranje novih potencijala uspjeha radi povećanja efikasnosti poduzeća, već u sudjelovanje u fazi rasta cijena nekretnina ili njihove prodaje tijekom rasta potražnje. Razlozi se mogu tražiti i u moralnom hazardu menadžera, koji su poduzimali kozmetičke investicije. Također, važno je primijetiti da investiranje u nekretnine olakšava financiranje (u odnosu prema npr. R&D investicijama) jer je riječ o opipljivoj imovini koja može poslužiti kao kolateral pri novom zaduživanju. U okviru već prikazane teorije, može se reći da je pri ulaganju u nekretnine vrijednost založenog (eng. *pledged*) dohotka veća nego u ostalim oblicima ulaganja.

Investicije poslovnih subjekata moguće je dodatno razlikovati s obzirom na oblik vlasništva (javno/privatno) i podrijetlo kapitala (domaće/strano). Slika 4-10 pokazuje udio investicija prema tipu vlasništva i podrijetlu kapitala poduzeća. Tijekom cijelog razdoblja privatne su investicije veće od javnih investicija. Udio privatnih investicija povećava se tijekom razdoblja, posebice nakon financijske krize. Međutim, valja podsjetiti da u ukupnom uzorku prevladavaju privatna poduzeća. Javna poduzeća čine samo 1,37 % ukupnog uzorka, ali udio ukupnih investicija u prosjeku je veći od 10%. Javne investicije relativno su važan dio svih investicija, pa se može implicirati znatan utjecaj javnih poduzeća i fiskalne politike koja djeluje kroz kanal javnih poduzeća na ukupne investicije. Važno je podsjetiti da su iz uzorka izbačena dva poduzeća u javnom vlasništvu (HEP d.d. i Hrvatske šume d.o.o), što dodatno podcjenjuje udio javnih u ukupnim investicijama. Primjerice, ako se u uzorak uvrste dva navedena poduzeća, udio javnih investicija u ukupnim investicijama u 2015. godini iznosit će 16,43 % (ispis izostavljen), nasuprot 7,8 % na grafu 4-10.

Donji dio slike 4-10 pokazuje dinamiku investicija s obzirom na podrijetlo kapitala. Poslovni subjekti podijeljeni su na dvije skupine. U prvoj su skupini poduzeća s natpolovičnim stranim podrijetlom kapitala, a u drugoj poduzeća s natpolovičnim domaćim podrijetlom kapitala. Statistika o podrijetlu kapitala bilježi se tek od 2008. godine pa je i na slici prikazano razdoblje od 2008. do 2014. Iako većinu investicija čine poduzeća s domaćim podrijetlom kapitala, postoji trend rasta udjela investicija poduzeća sa stranim podrijetlom kapitala. Točnije, udio

investicija poduzeća sa stranim podrijetlom kapitala raste s 22 % 2008. godine na 32,28 % 2014. godine.

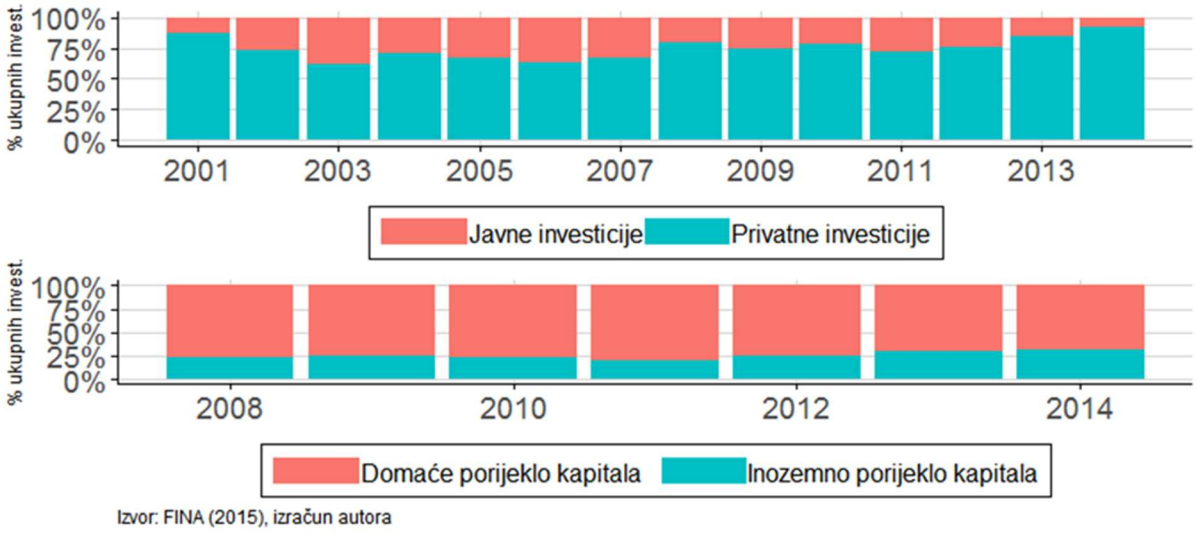

Slika 4-10: Udio investicija poduzeća s inozemnim i domaćim podrijetlom kapitala te javnih i privatnih investicija u ukupnim investicijama od 2000. do2014. u postocima od ukupnih investicija.

Potonju detaljnu raspravu o ponašanju investicija u Republici Hrvatskoj valja staviti u kontekst istraživanja ECB-a (2013) o međuovisnosti investicija i ključnih pokazatelja poslovanja u Europskoj uniji. Za istraživanje, ECB (2013) upotrijebili su bazu podataka privatnih i javnih tvrtki iz 17 europskih zemalja od 1993. do 2010. (baza podataka Bureau Van Dijk Amadeus). Osnovni su nalazi analize sljedeći:

- Tvrtke s većim odnosom novčanog toka i imovine više investiraju. Time se implicira postojanje korelacije novčanih tokova i investicijskih prilika. Korelacija je prisutna u svim zemljama i veća je što je tvrtka manja.
- Tvrtke koje imaju veći udio novca i novčanih ekvivalenata u ukupnoj imovini na početku godine imaju veće investicije u toj godini. Zanimljivo je da je odnos vrlo sličan bez obzira na veličinu tvrtke
- Tvrtke koje imaju najveće pokazatelje pokrivenosti kamata i financijske poluge imaju najmanju stopu investiranja. Pri tome je odnos nelinearan. Mali i srednji iznosi pokazatelja (prvi i peti decil) pokazuju vrlo slične stope investiranja, a visoko zadužene tvrtke imaju znatno niži iznos investiranja.

- Tvrtke s većim iznosom zaduženja imaju veći pad investicija poslije financijske krize. Mikropoduzeća koje pripadaju decilu najzaduženijih imala su pad od čak 88 % tijekom 2009. godine.
- Zanimljivo je da je stopa investicija bila niža u tvrtkama koje su imale veći udio trgovačkih kredita u strukturi financiranja, što implicira da takvi krediti, kao dio kratkotrajnih obveza, služe kao varijabla prilagođavanja šokovima.

Potonji nalazi ECB-a upućuju na veliku povezanost investicija i financijske situacije, što se analizira u sljedećem poglavlju.

4.4 Međuovisnost strukture financiranja i investicija poslovnih subjekata

U prošlom poglavlju naglasak je bio na deskriptivnoj analizi investicija poduzeća. U ovom se poglavlju pozornost obraća izvorima financiranja te posebno odnosu pokazatelja financiranja i investicija poduzeća.

U teorijskom i empirijskom pregledu literature o financijskim frikcijama i financijskom ograničenju poduzeća često se kao uzrok rasta i pada (ciklusa) investicija navodi ciklus u kretanju poluge. U vrijeme ekspanzije rastu kreditiranje banaka i, posljedično, financijske poluge poduzeća, što stvara prezaduženost (engl. *debt overhang*) mnogih poduzeća. Nakon negativnog šoka, poduzeća se razdužuju kako bi popravila financijsku poziciju (neto vrijednost).

Kretanje strukture kapitala, to jest udjela računovodstvenih agregatnih vrijednosti obveza i kapitala nefinancijskih poduzeća, za razdoblje od 2000. do 2014. prikazano je na slici 4-11. Slika pokazuje da je razdoblje ekonomske ekspanzije bilo popraćeno snažnim rastom agregatne poluge, odnosno rastom agregatnog duga kao komponente strukture financiranja. Udio kratkoročnih obveza pokazuje stabilnu razinu tijekom razdoblja, a udio kapitala i dugoročnih obveza pokazuju inverzan odnos: rast udjela dugoročnog financiranja pratio je istodoban pad udjela vlastitog kapitala u strukturi kapitala. Ranije su spomenuti radovi koji pronalaze značajnu korelaciju između rasta duga i vjerojatnosti ekonomskih kriza (npr. Koo, 2009). Iz slike je vidljivo da isti obrazac vrijedi i za poduzeća u RH. Nakon rasta 2001. godine kapital bilježi uravnotežen pad sve do 2012. godine. Potom se prepoznaje lagan pad kratkoročnih obveza i rast kapitala. Dio rasta kapitala vjerojatno može se pripisati učincima Zakona o

financijskom poslovanju i predstečajnoj nagodbi, koji vrijedi od 1. listopada 2012. godine, a koji se u praksi svodi na pretvaranje kratkoročnih dugova u vlastiti kapital, otpis dospjelih obveza i odgodu dugova. Učinci Zakona analiziraju se u 6. poglavlju ovog rada.

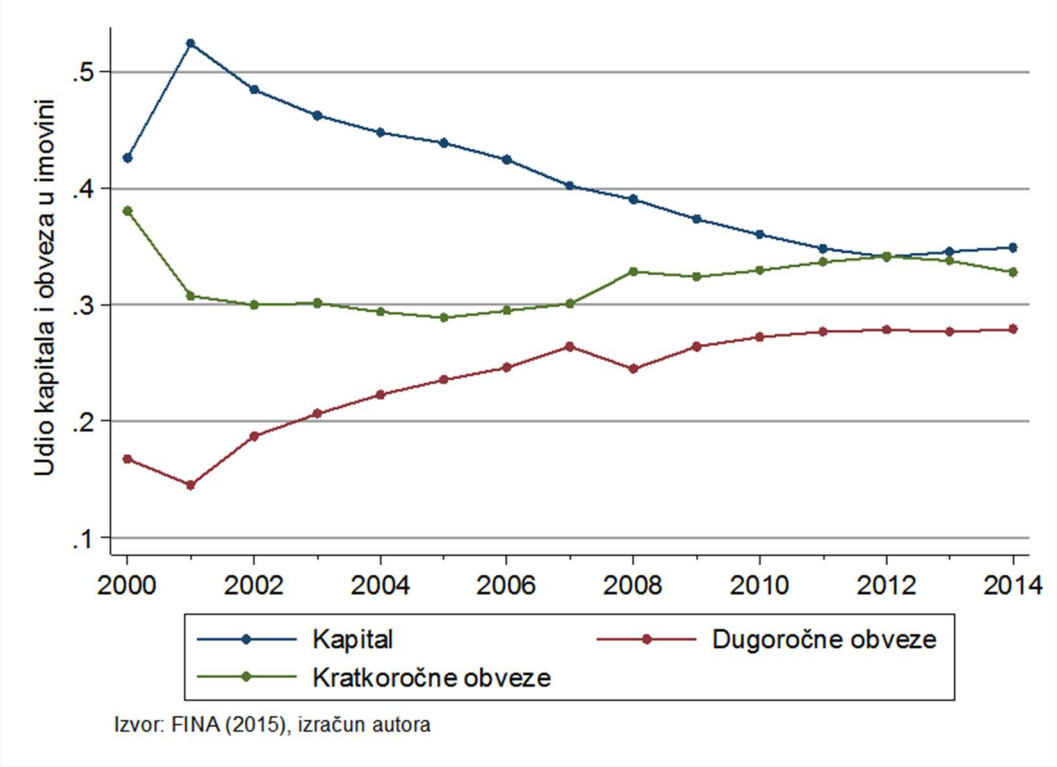

Slika 4-11: Struktura kapitala nefinancijskih poduzeća, udio knjigovodstvene vrijednosti pojedine komponente pasive u ukupnoj pasivi od 2000. do 2014.

Treba upozoriti na dvije empirijske poteškoće pri računanju zaduženosti i izvora financiranja nefinancijskog sektora. Prvo, riječ je računovodstvenim, a ne tržišnim vrijednostima. Poduzeća u RH rijetko provode revalorizaciju kapitalne imovine, pa se može očekivati da pokazatelji podcjenjuju vrijednosti kapitala. Ako bi se dinamika cijene kapitala kroz vrijeme aproksimirala stopama inflacije, onda bi pad vrijednosti kapitala kroz vrijeme bio manje izražen. Ako se tome pridoda rast cijena nekretnina u fazi ekspanzije, može se zaključiti da vrijednosti kapitala mogu biti znatno podcijenjene. Također, poduzeća uživaju određen stupanj slobode u određivanju amortizacijskih stopa kapitalne imovine koje utječu na vrijednost neto kapitala.

Važno je istaknuti da su navedeni izvori financiranja prikupljani od domaćih i od stranih investitora i banaka. Slika 4-11 pokazuje kako se hrvatska poduzeća financiraju na hrvatskom i europskom tržištu, ali se ne prepoznaje utjecaj domaćega financijskog sektora u financiranju investicijskih aktivnosti (koji je udio rezidenata, a koliko nerezidenata u strukturi financiranja).

Kako bismo analizirali strukturu zaduživanja s obzirom na podrijetlo izvora financiranja (zaduživanje na domaćem/inozemnom financijskom tržištu), na slici 4-12 prikazuje se struktura zajmova s obzirom na podrijetlo zajmova za razdoblje od 2008. do 2014. Zajmovi primljeni od domaćih sektora dodatno su klasificirani s obzirom na ročnost (kratkoročni / dugoročni zajmovi) i nositelje financiranja (pravne / fizičke osobe). Razdoblje promatranja kraće je jer nema dostupnih podataka za pretkrizno razdoblje. Iz grafikona je vidljivo da poduzeća više uzimaju zajmove od nerezidenata. U prosjeku za cijelo promatrano razdoblje, udio zajmova od nerezidenata iznosi 61 % svih zajmova. Dugoročni zajmovi rezidenata u prosjeku su pali s 22 % na 16 % svih zajmova, a kratkoročni su zajmovi pali sa 17 % na 14 %. Zanimljivo je primijetiti kako od 2010. godine postoji trend rasta zajmova od obrtnika i fizičkih osoba. Ovakvo kretanje odgovara dinamici obveza prema povezanim poduzetnicima, koje također rastu poslije krize. Rast udjela ovih zajmova može upućivati na veća financijska ograničenja jer poduzeća, zbog racioniranja kredita i povećanja nelikvidnosti počinju se koristiti interni prikupljenim sredstvima kao ublaživačima likvidnih šokova. Može se zaključiti da krediti nerezidenata čine relativno najveći i relativno konstantan udio u ukupnim zajmovima te da se od 2010. godine kratkoročni i dugoročni krediti rezidenata djelomično zamjenjuju zajmovima od obrta i fizičkih osoba.

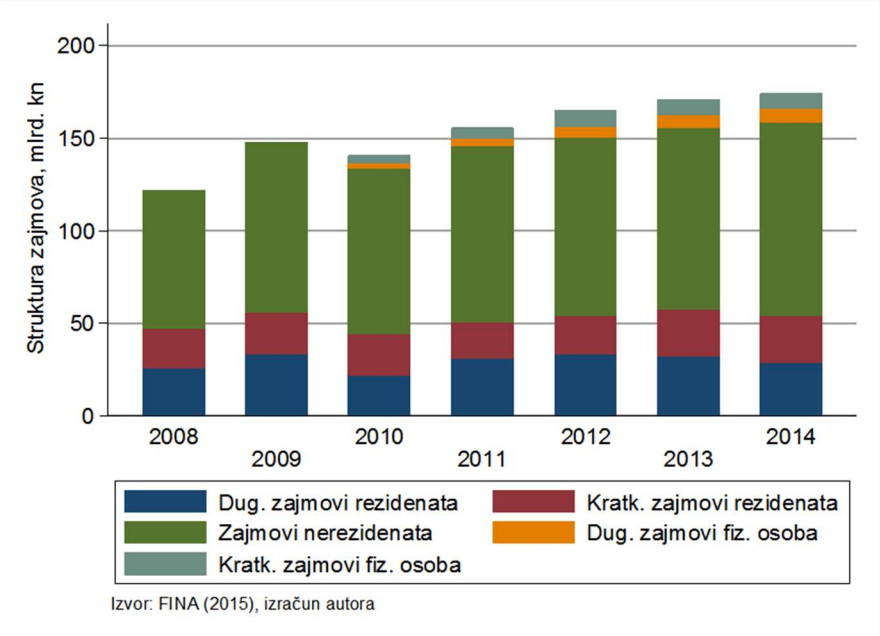

Slika 4-12: Struktura zajmova s obzirom na podrijetlo i ročnost u milijardama kuna od 2008. do 2014.

Nakon strukture kapitala pozornost je obraćena izvorima financiranja prema vrstama obveza i kapitala. Oni se mogu prikazati na dva načina: 1) kao vrijednost razina pojedinih oblika obveza i kapitala i 2) kao vrijednost toka pojedinih oblika novčanih tokova. U drugom slučaju izvori financiranja mogu se dodatno raščlaniti na bruto i neto izvore financiranja (Edwards i Fischer, 1994). U literaturi je drugi pristup prihvaćen kao primjereniji za analizu financiranja poduzeća, ali se u nastavku prikazuju oba pristupa jer su oba pogleda važna za razumijevanje odnosa financiranja i investicija.

Tablica 4-7 pokazuje izvore financiranja kao razine pojedine vrste obveza i kapitala za razdoblje od 2000. do 2014. Vrijednosti u tablici dobivene su agregiranjem pojedinačnih vrijednosti iz financijskih izvještaja poslovnih subjekata i dijeljenjem s ukupnom knjigovodstvenom vrijednosti imovine. Iz tablice je vidljiv snažan rast udjela bankovnih kredita u promatranu razdoblju. Ukupne obveze po bankovnim kreditima (kratkoročne i dugoročne) rasle su s 13 % 2000. godine na 26 % 2007. godine, a nakon krize pale su na 21 % ukupne pasive. Ako se obvezama prema bankama pridodaju i obveze po zajmovima i depozitima, ukupne obveze po kreditima u 2014. iznosile su 29 % ukupne aktive. Druga se važna promjena dogodila u obvezama prema povezanim poduzetnicima, koje su nakon krize rasle s 0 % ukupne aktive na čak 12 %. Međutim, važno je upozoriti da je ovakva dinamika vjerojatno rezultat promjena računovodstvenih politika koje nisu prikazivale ovu vrstu obveza u pretkriznom razdoblju (odatle i udio od 0 %). Ipak, uvidom u pojedine izvještaje iz javno dostupnih podataka za tvrtke s najvećim udjelom obveza prema povezanim poduzetnicima može se zaključiti da su vlasnici davanjem pozajmica vlastitim poduzećima pokušavali prebroditi financijske pritiske i pad agregatne potražnje. Ovakva promjena strukture financiranja može upućivati na kontrakciju u ponudi kredita. Ako se uvaži to da većina poduzeća u uzorku ne može izdavati obveznice jer je većinom riječ o malim i mikropoduzećima te slabija razvijenost financijskog tržišta u RH, može se pretpostaviti da su brojna poduzeća u RH smanjenje ponude kredita nadomještale pozajmicama od povezanih kompanija i vlasnika poduzeća, nasuprot velikim kompanijama u razvijenim zemljama, koje su nakon krize povećavale emisiju korporativnih obveznica (ECB, 2013). Tablica 4-7 pokazuje i stalan pad udjela trgovačkih kredita tijekom promatrana razdoblja (sa 16 % na 9 %). Zanimljivo je primijetiti stalno stvaranje negativnih zadržanih zarada na agregatnoj razini, kako prije krize, tako i nakon nje. Ostale komponente obveza pokazuju manje i relativno stabilne udjele u ukupnoj pasivi.

Potonja analiza daje korisne uvide u strukturu pasive, ali kao i u prošlom primjeru, postoji problem neusklađenosti knjigovodstvenih i tržišnih vrijednosti. Dodatno, tablica 4-7 ne

pokazuje kako se financiraju investicije poduzeća, već cjelokupno poslovanje. Stoga se u nastavku, umjesto strukture obveza, pozornost obraća izvorima financiranja investicija. Mayer (1990) je predložio korištenje izvještaja o novčanom toku, koji omogućuje promatranje izvora sredstava u pojedinoj godini, kao varijablu toka. Primjena ovog pristupa zahtijeva raspolaganje izvještajima o novčanom toku. Međutim, najveći dio poduzeća u uzorku nije obvezan predavati izvještaje o novčanom toku, pa se on može samo aproksimirati na temelju podataka iz bilance stanja i računa dobiti i gubitka. Stoga se za potrebe analize izvora financiranja investicija konstruira bilanca razlike kao promjena pojedinih oblika imovine i kapitala tijekom promatrana razdoblja.

Tablica 4-7: Struktura pasive, u postotku od ukupne imovine, od 2000. do 2014.

Pozicija	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014
A) KAPITAL I REZERVE	**46%**	**54%**	**50%**	**47%**	**46%**	**45%**	**43%**	**41%**	**39%**	**37%**	**36%**	**35%**	**34%**	**34%**	**35%**
I. TEMELJNI (UPISANI) KAPITAL	**44%**	**52%**	**48%**	**45%**	**42%**	**39%**	**35%**	**31%**	**30%**	**29%**	**29%**	**29%**	**29%**	**30%**	**30%**
II. KAPITALNE REZERVE	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**2%**	**2%**	**2%**	**3%**	**3%**	**3%**	**4%**
III. REZERVE IZ DOBITI	**4%**	**3%**	**4%**	**4%**	**3%**	**4%**	**3%**	**4%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**
IV. REVALORIZACIJSKE REZERVE	**5%**	**5%**	**2%**	**2%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**	**3%**
V. ZADRŽANA DOBIT ILI PRENESENI GUBITAK	**-8%**	**-7%**	**-7%**	**-5%**	**-5%**	**-4%**	**-2%**	**-1%**	**0%**	**0%**	**-1%**	**-3%**	**-4%**	**-4%**	**-5%**
VI. DOBIT ILI GUBITAK POSLOVNE GODINE	**1%**	**1%**	**2%**	**2%**	**2%**	**3%**	**3%**	**3%**	**2%**	**1%**	**0%**	**1%**	**0%**	**0%**	**1%**
VII. MANJINSKI INTERES	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**
B) REZERVIRANJA	**1%**	**1%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**	**1%**
C) DUGOROČNE OBVEZE	**16%**	**14%**	**18%**	**20%**	**22%**	**23%**	**24%**	**26%**	**24%**	**26%**	**27%**	**27%**	**28%**	**27%**	**27%**
1. Obveze prema povezanim poduzetnicima	1%	1%	0%	0%	0%	0%	0%	0%	4%	5%	5%	5%	6%	6%	6%
2. Obveze za zajmove, depozite i slično	4%	3%	2%	2%	3%	3%	3%	4%	4%	5%	5%	5%	5%	4%	4%
3. Obveze prema bankama i drugim financijskim institucijama	9%	8%	14%	14%	16%	16%	17%	18%	14%	14%	15%	14%	13%	15%	15%
6. Obveze po vrijednosnim papirima	0%	0%	0%	1%	1%	1%	1%	1%	1%	1%	0%	1%	2%	2%	1%
8. Ostale dugoročne obveze	0%	1%	1%	3%	3%	3%	3%	3%	0%	0%	1%	1%	1%	1%	1%
9. Odgođena porezna obveza	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
D) KRATKOROČNE OBVEZE	**34%**	**28%**	**29%**	**29%**	**29%**	**28%**	**29%**	**29%**	**32%**	**32%**	**32%**	**33%**	**33%**	**33%**	**32%**
1. Obveze prema povezanim poduzetnicima	3%	2%	0%	0%	0%	0%	0%	0%	4%	5%	5%	6%	6%	6%	6%
2. Obveze za zajmove, depozite i slično	3%	3%	0%	0%	0%	0%	0%	0%	3%	4%	4%	4%	4%	4%	4%
3. Obveze prema bankama i drugim financijskim institucijama	4%	4%	7%	7%	7%	7%	8%	9%	6%	6%	6%	6%	6%	6%	6%
4. Obveze za predujmove	1%	1%	1%	1%	1%	2%	1%	2%	1%	1%	1%	1%	1%	1%	1%
5. Obveze prema dobavljačima	16%	13%	15%	15%	14%	14%	14%	14%	13%	11%	11%	11%	11%	10%	9%
6. Obveze po vrijednosnim papirima	0%	0%	0%	0%	0%	0%	0%	0%	1%	1%	1%	1%	1%	1%	1%
8. Obveze prema zaposlenicima	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%
9. Obveze za poreze, doprinose i slična davanja	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%	2%
12. Ostale kratkoročne obveze	2%	2%	3%	3%	3%	3%	3%	3%	2%	2%	2%	2%	2%	2%	2%
E) ODGOĐENO PLAĆANJE TROŠKOVA I PRIHOD BUDUĆEGA RAZDOBLJA	**3%**	**2%**	**3%**	**3%**	**3%**	**4%**	**3%**	**3%**	**4%**	**4%**	**4%**	**4%**	**4%**	**4%**	**4%**
F) UKUPNO PASIVA	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**	**100%**
G) IZVANBILANČNI ZAPISI	**6%**	**5%**	**0%**	**0%**	**0%**	**0%**	**0%**	**0%**	**9%**	**9%**	**9%**	**10%**	**11%**	**17%**	**17%**

Ukupni novčani tok poduzeća može se raščlaniti na investicijski tok, financijski tok, operativni novčani tok i neto novčani tok. Investicijski tok uključuje ulaganja u realnu (materijalnu i nematerijalnu) i financijsku imovinu. Dakle, dio raspoloživih sredstava poduzeća odlazi u realnu, a dio u financijsku imovinu. Kako bi se identificirao iznos sredstava koja služe za realne investicije, potrebno je od financijskog toka oduzeti kupnju financijske imovine. Financiranje realne imovine po potonjem principu naziva se „neto financiranje“ (Edwards i Fischer, 1994). Ako se financijski tok ne umanji za financijske obveze već se pod investicijama podrazumijevaju financijske i realne investicije, financiranje investicija naziva se „bruto financiranje“.

U tablici 4-8 prikazani su prosječni udjeli bruto i neto financiranja za poslovne subjekte u RH od 2000.do 2014. Prvi dio tablice pokazuje bruto financiranje, to jest doprinos financijskog i operativnog toka u financiranju realnih investicija (uključujući i zalihe) i financijskih investicija, a drugi dio pokazuje neto financiranje, tj. doprinos financijskog i operativnog toka u financiranju realnih investicija (bez zaliha).

Tablica 4-8: Neto i bruto financiranje investicija od 2000. do 2014.

Opis	2000-2003	2004-2007	2008-2011	2012-2014	2000-2014
I) BRUTO FINANCIRANJE					
a) INTERNA SREDSTVA	**61%**	**46%**	**56%**	**76%**	**59%**
DOBIT ILI GUBITAK	**16%**	**20%**	**12%**	**13%**	**15%**
AMORTIZACIJA	**45%**	**26%**	**44%**	**64%**	**43%**
b) EKSTERNA SREDSTVA	**39%**	**54%**	**44%**	**24%**	**41%**
BANKE I OSTALI ZAJMOVI	**29%**	**35%**	**43%**	**2%**	**29%**
TRGOVAČKI KREDITI	**5%**	**6%**	**-4%**	**5%**	**3%**
OBVEZNICE	**1%**	**1%**	**1%**	**6%**	**2%**
DIONICE I UDJELI	**-2%**	**5%**	**-14%**	**-7%**	**-5%**
POVEZANI PODUZETNICI	**2%**	**0%**	**11%**	**12%**	**6%**
OSTALO	**5%**	**7%**	**9%**	**6%**	**7%**
I) NETO FINANCIRANJE					
a) INTERNA SREDSTVA	**113%**	**69%**	**72%**	**99%**	**88%**
DOBIT ILI GUBITAK	**35%**	**30%**	**16%**	**16%**	**25%**
AMORTIZACIJA	**79%**	**39%**	**57%**	**82%**	**63%**
b) EKSTERNA SREDSTVA	**-9%**	**36%**	**29%**	**-2%**	**15%**
BANKE I OSTALI ZAJMOVI	**20%**	**39%**	**39%**	**-27%**	**21%**
TRGOVAČKI KREDITI	**-6%**	**-6%**	**-14%**	**8%**	**-6%**
OBVEZNICE	**-9%**	**-5%**	**2%**	**8%**	**-2%**
DIONICE I UDJELI	**-18%**	**7%**	**-19%**	**-8%**	**-9%**
POVEZANI PODUZETNICI	**-6%**	**-9%**	**9%**	**10%**	**0%**
OSTALO	**11%**	**10%**	**11%**	**8%**	**10%**

Tablica pokazuje velike oscilacije u doprinosu pojedinih izvora financiranja tijekom vremena. Ponajprije je razlog tomu snažan doprinos velikih poduzeća u pojedinoj godini. Primjerice, u 2002. godini, zbog promjena u poslovanju Hrvatskih šuma d.o.o., doprinos dionica i udjela iznosi - 98 %,, što je utjecalo na cjelokupan udio eksternog financiranja. Stoga je primjerenije proučavati prosjeke izvora financiranja tijekom duljih razdoblja.[40]

Tablica pokazuje da je glavni izvor financiranja realne i financijske imovine amortizacija poduzeća i neto dobit. Tijekom cijelog promatranog razdoblja prosječni udio internog financiranja iznosi 59 %. Od eksternog financiranja najveći je udio bankarskih kredita, 29 %. Trgovački krediti nisu veliki jer su obveze prema dobavljačima netirane za promjene potraživanja (bez zaliha). Zanimljivo je primijetiti da je doprinos obveznica znatno veći u posljednjem promatranom razdoblju (2012–2014), što je u skladu s teorijom financijskog ograničenja. Naime, očekuje se da će s većim stupnjem ograničenja poduzeća nastojati zamjenjivati bankarske kredite izdavanjem obveznica. Još veći doprinos zamjeni bankarskih kredita pruža financiranje povezanih poduzetnika. Dok se tim oblikom financiranja prije krize vrlo malo koristilo, nakon krize poprimio je vrijednosti od 12 % (uključujući kratkoročne i dugoročne obveze prema povezanim poduzetnicima). Može se zaključiti da su nakon financijske krize poduzeća financiranje bankarskim kreditima zamjenjivala drugim oblicima: dodatnim rastom internog financiranja, izdavanjem obveznica, korištenjem sredstvima povezanih poduzetnika.

Neto financiranje pokazuje veću volatilnost zbog utjecaja velikih poduzeća. Ako se iz uzorka uklone dvije neuobičajeno visoke opservacije u 2012. godini (Hrvatske šume d.o.o. i HEP d.o.o.), doprinos eksternog financiranja od 2000. do 2003. iznosi 17 %, a prosječni udio eksternog financiranja tijekom cijelog razdoblja 20 % (ispis izostavljen). Iako se udjeli mogu znatno razlikovati uklanjanjem ekstremnih vrijednosti, obrazac je ponašanja isti. Interno financiranje najvažniji je izvor financiranja realnih investicija (88 % u tablici, 80 % nakon uklanjanja dvaju spomenutih poduzeća). Iznosi od 88 % (80 %) u okviru su prosjeka drugih zemalja. Primjerice prema Mayermaher (1990), SAD ima udjele od 96 %, Japan 65 %, Njemačka 73 %, a UK 107 %.

Može se zaključiti da neto financiranje, kao i bruto financiranje, pokazuju smanjenje doprinosa eksternog financiranja nakon financijske krize te rast udjela nebankarskih izvora financiranja.

[40] Alternativno, volatilnost pokazatelja mogla bi se smanjiti eliminiranjem određenog broja percentila u distribuciji svakog pokazatelja. Međutim, time bi se uklonio utjecaj velikih poduzeća kojai najviše pridonose padu ili rastu investicija.

Interna su sredstva temeljni izvor financiranja investicija, što je u skladu s teorijom hijerarhije financiranja, prema kojoj se ona preferiraju zbog odsutnosti rizične premije (asimetričnosti informacija između dužnika i vjerovnika). Kada bi tvrtke posve izgubile pristup financijskim tržištima, kontrakcija u investicijama mogla bi biti najviše 40 %, koliko je u prosjeku udio eksternog financiranja. Očito je da se kontrakciju investicija ne može objasniti samo ograničavanjem ponude kapitala bankarskih institucija.

Slika 4-13 analizira ponašanje medijana stope investicija za poduzeća različita financijskog položaja. Financijski je položaj aproksimiran pokazateljima koeficijenta zaduženosti i pokrića troškova kamata. Poduzeća su podijeljena u tri skupine. U prvoj su skupini poduzeća čija je vremenski pomaknuta vrijednost koeficijenta zaduženosti ili pokrića troškova kamata manja od 15. percentila. U drugoj su skupini poduzeća čije je vrijednost pokazatelja između 40. i 60. percentila, a u trećoj ona iznad 85. percentila. Za svaku skupinu poduzeća izračunana je srednja vrijednost stope neto investicija.

Najviše investiraju srednje zadužena poduzeća. Slijede nisko zadužena poduzeća, koja pokazuju pozitivne vrijednosti medijana stope investicija do 2008. godine. Visoko zadužena poduzeća uopće ne investiraju. Ovakva hijerarhija investiranja za tri skupine poduzeća upućuje na oprez u tumačenju financijske ograničenosti. Financijska ograničenost ne znači odsutnost investicija za zaduženija poduzeća ili najveću stopu investicija za niskozadužena poduzeća. Niska zaduženost može biti rezultat financijske ograničenosti, to jest nemogućnosti prikupljanja eksternih sredstava, s jedne strane, i nedostatka investicijskih prilika s druge strane. Moguće je dakle da su poduzeća s vrlo niskom zaduženosti (ili bez duga) financijski ograničena. Dug dakle ima dvojaku ulogu. S jedne strane omogućuje financiranje profitabilnih projekata, a s druge strane stvara teret u budućem zaduživanju (efekt financijske poluge).

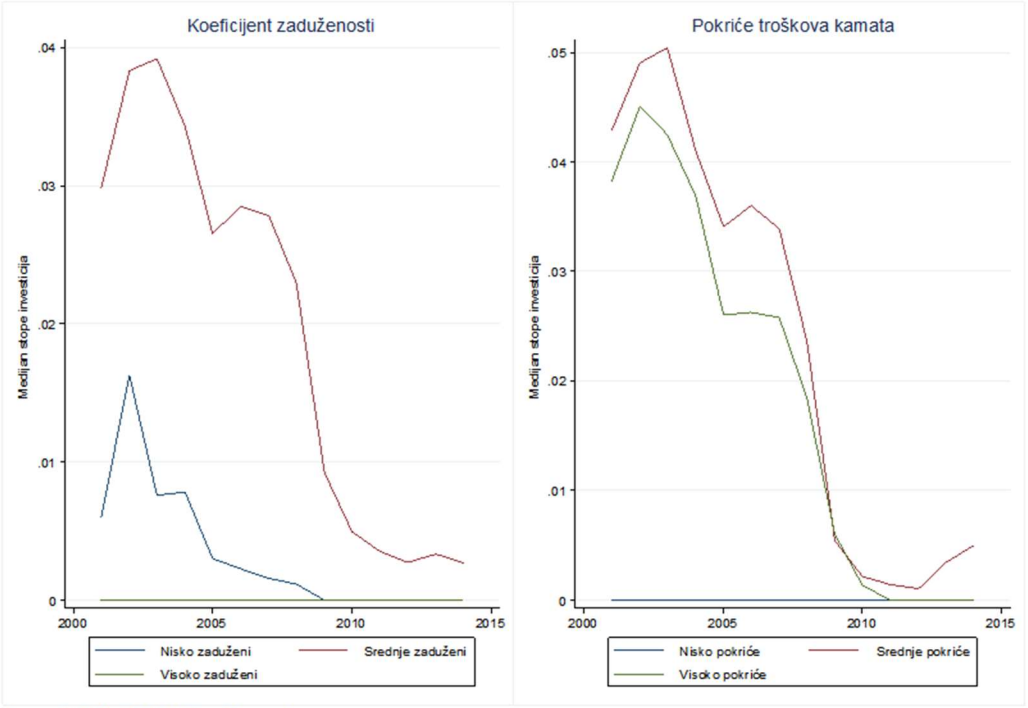

Izvor: FINA (2015), izračun autora

BILJEŠKA: Grafovi pokazuju medijane stope investicija (investicije podijeljene s vremenski pomaknutim vrijednostima imovine: $\boldsymbol{I_t/A_{t-1}}$) za različite interkvantilne razmake koeficijenta zaduženosti i pokrića troškova kamata. Koeficijent zaduženosti jednak je omjeru ukupnih obveza i ukupne imovine, a pokazatelj pokrića troškova kamata jednak je omjeru EBIT-a i ukupne imovine. Među nisko zaduženim poduzećima (nisko pokriće troškova kamata) ona su do 15. percentila vrijednosti pokazatelja, među srednje zaduženima od 40. do 60. percentila, a među visoko zaduženima su ona iznad 85. percentila.

Slika 4-13: Medijani stope investicija za poslovne subjekte različita financijskog položaja od 2001. do2014.

Drugi graf na slici 4-13 pokazuje da poduzeća s visokim ili srednje visokim omjerom EBIT-a i kamata najviše investiraju. Interpretacija ograničenosti razlikuje se prema prošlom primjeru. Očekuje se da su poduzeća s nižim pokrićem zaduženija od onih s visokim pokrićem troškova kamata. Graf je u skladu s teorijom o financijskom ograničenju. Poduzeća koja imaju nisku pokrivenost kamata imaju slabiju kreditnu sposobnost pa teže prikupljaju eksterni kapital. Međutim, moguće je da niže vrijednosti EBIT-a upućuju na slabiju buduću profitabilnost. Bez ekonometrijske analize nemoguće je razgraničiti je li riječ o slabijim investicijskim prilikama, ograničenju u ponudi kredita ili nekom drugom faktoru.

Na slici 4-14 prikazano je kretanje medijana intenziteta zaduženosti (odnos ukupnih obveza i imovine) po djelatnostima. Prikazane su samo djelatnosti sa znatnim udjelom u ukupnom BDP-u. Rezultati su vrlo slični ako se umjesto medijana, kao mjera centralne tendencije, upotrijebi

srednja vrijednost. Slika 4-14 pokazuje heterogenost stupnja zaduženosti po djelatnostima. Najmanje vrijednosti pokazatelja imaju djelatnosti Informacija i komunikacija, Stručne, znanstvene i tehničke djelatnosti te djelatnost Opskrbe vodom. Najveće pokazatelje zaduženosti imaju djelatnosti Poslovanja nekretninama i Pružanja smještaja i posluživanja hrane. Razliku u stupnju zaduženosti potonjih djelatnosti djelomično može objasniti raspoloživost opipljive imovine. Može se očekivati da sektori Informacija i komunikacija ili Znanstvene djelatnosti imaju mnogo manji udio opipljive imovine, a time i manji udio založenog dohotka. Dinamika pokazuje da je najveći rast zaduženosti zabilježenu djelatnostima Opskrbe električnom energijom, Nekretninama i Pružanju smještaja i posluživanja hrane.

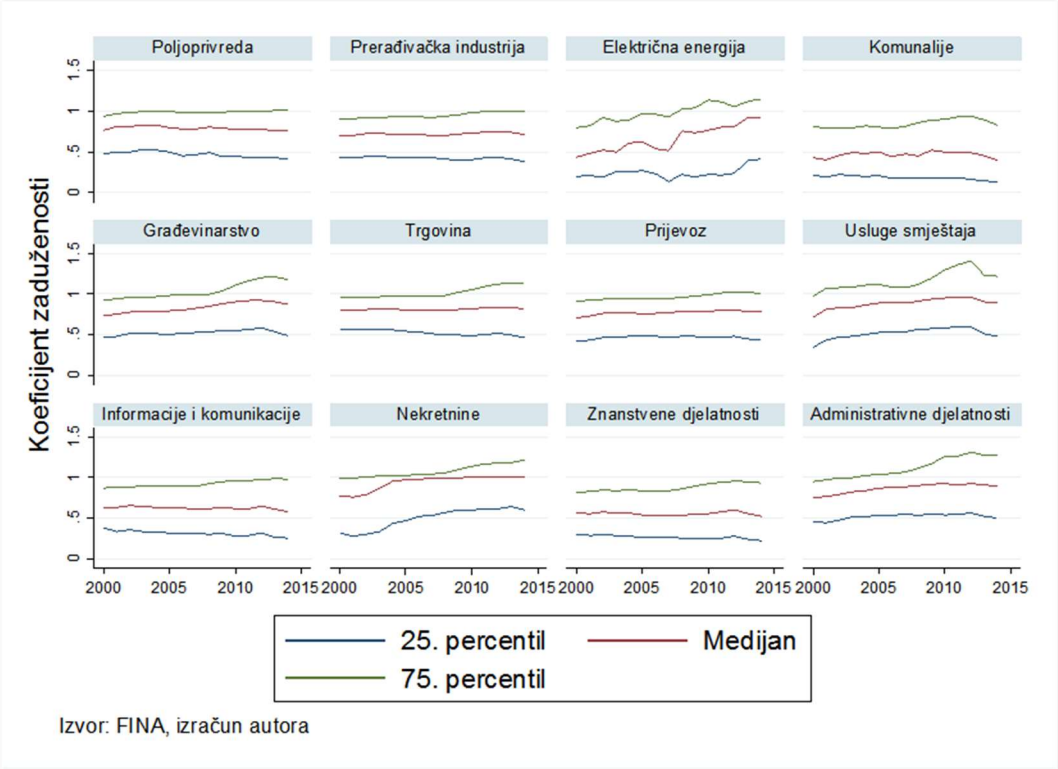

Slika 4-14: Medijan intenziteta zaduženosti po djelatnostima od 2000. do 2014.

Radi dobivanja uvida o raspodjeli pokazatelja kroz vrijeme, na slici 4-15 prikazane su distribucije pokazatelja koeficijenta zaduženosti za 2000., 2007. i 2014. godinu. Distribucija pokazatelja u 2000. godini pokazuje da je vrh distribucije viši od normalne, a najveća frekvencija pokazatelja nešto je manja od jedan. S rastom vrijednosti pokazatelja raste i frekventnost, na domeni 0 – 0,9. Pošto poprimi vrijednost 1, funkcija gustoće počne znatno opadati, što implicira postojanje financijskog i likvidnog ograničenja kada vrijednost obveza postane jednaka vrijednosti imovine. Oblik distribucije nije se znatno mijenjao do 2007.

godine. Međutim, nakon financijske krize i šest godina recesije, znatno se promijenio. Vrh se distribucije snizio, a lijevo od njega pokazuje se veći stupanj uniformnosti – s rastom vrijednosti pokazatelja ne mijenja se znatno i frekvencija podataka. Također, vrh distribucije blago se pomaknuo u desno ili, drukčije rečeno, površina ispod krivulje od točke jedan povećala se od 2007. do 2014. godine. Ako je vrijednost pokazatelja veća od jedan, vrijednost dugova veća je od vrijednosti imovne, što znači da je vrijednost kapitala negativna. Stoga se može zaključiti da se od 2007. do 2014. povećao udio poduzeća s negativnom vrijednošću kapitala. Točne su brojke sljedeće: 2000. godine 17,83 % poduzeća ima negativan kapital, 2007. 22,22 %, 2008. 24,02 %, a 2014. 31,01 % bilježi negativnu vrijednost knjigovodstvene vrijednosti kapitala.

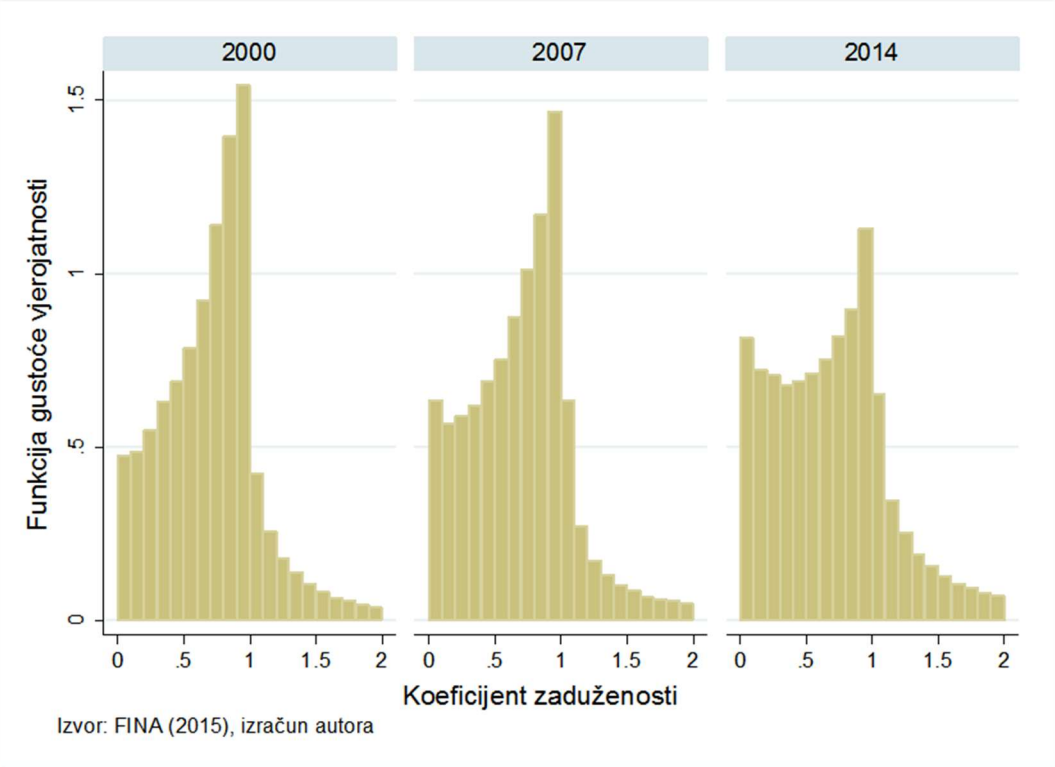

BILJEŠKA: Slika pokazuje distribuciju koeficijenta zaduženosti (omjer ukupnih obveza i imovine) za tri godine (2000., 2007., 2014.). Poslovni subjekti koji imaju vrijednost koeficijenta zaduženosti iznad 1 imaju negativnu vrijednost kapitala. Ukupna površina ispod krivulje iznosi 1.

Slika 4-15: Histogram pokazatelja intenziteta zaduženosti za 2000., 2007. i 2014. godinu.

Može se zaključiti da postoji heterogenost u iznosima financijske poluge, kako po djelatnosti, tako i u vremenu. Cijelom skupinom istraživanja pokušava se objasniti ta heterogenost, a rezultati upućuju na dva razloga (Tirole, 2006): 1) tvrtke koje su sigurnije imaju stabilnije novčane tokove i raspolažu imovinom koja se može upotrijebiti kao kolateral, imaju veće iznose

financijske poluge i 2) rizične tvrtke s velikim udjelom neopipljive imovine imaju manje iznose financijske poluge. Posljednja je tvrdnja važna jer potvrđuje odnos između solventnosti i stupnja zaduženosti. Tvrtke koje mogu upotrijebiti imovinu kao kolateral (sektor nekretnina, hoteli) imat će manji stupanj financijskog ograničenja.

Jesu li iznosi poluge za hrvatske tvrtke visoki i kakva je financijska pozicija prema nefinancijskim poduzećima u drugim zemljama? Kako bi se dobila predodžba o primjerenosti stupnja zaduženosti, u nastavku se omjeri uspoređuju s ostalim zemljama Europske unije. Izvještaj ECB-a (2013) daje pregled dinamike financijskih varijabli nefinancijskih poduzeća u EU od 2000. do 2012. Prosjek svih zemalja upućuje na rast financijske poluge (dug/BDP), od 69 % 1999. godine do 104 % u drugom tromjesečju 2010. godine te je ostao isti do četvrtog tromjesečja 2012. godine. Najveći rast dugova bio je u graditeljstvu i nekretninama. Akumulacija duga bila je najveća u Irskoj, Cipru, Malti i Španjolskoj. Odnos duga i imovine tvrtki pokazuju razduživanje od 2003. do 2007. te rast nakon financijske krize (trenutačno je na 38 %). Međutim, treba napomenuti da je takva dinamika rezultat promjene vrijednosti kapitala i dugova, a ne transakcija. Primjerice pad zaduženosti od 2003. do 2007. rezultat je porasta vrijednosti kapitala, a ne odluka tvrtke da smanjuju polugu. Ako se promatra samo transakcijska strana, postoji jasan ciklus rasta poluge (posebno u Španjolskoj i Italiji).

Udio kratkoročnih dugova u ukupnim dugovima iznosi između 24 % i 33 % (u RH oko 30 %). Smatra se da veći izvor kratkoročnog financiranja implicira veći rizik na izvanjske šokove (financijska frikcija refinanciranja), pa je u tom smislu najveći rizik u Belgiji (38 %), a najmanji u Finskoj (6 %). Zanimljivo je da se pokazatelj odnosa kratkotrajne financijske imovine i ukupne imovine povećao u vrijeme i nakon financijske krize, što implicira rast štednje iz preventivnih razloga. Pokazatelji likvidnosti također pokazuju veće vrijednosti nakon krize nego prije krize za sve promatrane zemlje.

Od financijskih trendova treba istaknuti rast udjela emitiranja dužničkih vrijednosnih papira. Dok je u pretkriznom razdoblju udio emitiranih dugovnih vrijednosnih papira iznosio 8 %, u kriznom razdoblju iznosio je 50 % izvora izvanjskog financiranja. Poduzeća su očito počela bankovne kredite zamjenjivati dužničkim vrijednosnim papirima. Razlog je vjerojatno u negativnom šoku na ponudu kapitala (banke). U kriznom razdoblju financijske su institucije smanjile kreditiranje nefinancijskih poduzeća, posebno u Grčkoj, Španjolskoj i Irskoj. Valja napomenuti da male i mlade tvrtke nemaju mogućnost izdavanja dužničkih instrumenata, pa se može indicirati veća financijska ograničenost malih i srednjih poduzeća.

Od ostalih izvora financiranja treba izdvojiti trgovačke kredite (10,5 % ukupnog eksternog financiranja). Dok su u 2009. trgovački krediti imali negativan predznak, nakon 2009. poprimaju sve veće vrijednosti što implicira da trgovački krediti, kao dio neto radnoga kapitala čine kontrolnu varijablu za prilagođavanje šokovima na izvore financiranja. Ovi iznosi kreditiranja najveći su u Španjolskoj i Italiji. Zanimljivo je zamijetiti da su trgovački krediti usko povezani s poslovnim ciklusima (ECB, 2013). U recesijama poduzeća smanjuju zalihe i kupovine općenito kako bi neutralizirala pad prihoda. Obrnuto se događa tijekom rasta ekonomske aktivnosti. Ovakav ciklus vrijedi za sve europske zemlje.

Zadržane su zarade u pretkriznom razdoblju fluktuirale između 9 % i 10 % BDP-a. Nastankom financijske krize, interna sredstva spustila su se na 8 % BDP-a. Zbog toga su tvrtke smanjile troškove zaposlenika i isplatu dividendi (ECB 2013). Nakon krize, zadržane zarade oporavile su se i ponovno prešle 10 % BDP-a. Važno je napomenuti da su se nefinancijske tvrtke nakon krize više oslanjale na interne izvore financiranja.

Ostala obilježja financijske strukture na temelju baze podataka Bureau van Dijk Amadeus jesu:

- otprilike trećina tvrtki nema dugova
- poluga (dug/imovina) je rasla s 30 % na 42 % od 2001.do 2008. te pala na 38 % nakon krize.
- poluga je opadajuća funkcija starosti tvrtke i prihoda te rastuća funkcija opipljive imovine i nelinearna funkcija profitabilnosti
- poluga je manja u tvrtkama s većim iznosom radnoga kapitala
- ekonometrijska analiza pokazuje da osjetljivost financijske poluge najbolje objašnjavaju likvidnost i opipljiva imovina.

Na kraju se pružaju nalazi analize iz predmetnog poglavlja. Analiza strukture financiranja pokazuje rast financijske poluge poduzeća u pretkriznom razdoblju mjereno računovodstvenim vrijednostima obveza i kapitala te stagnaciju i blagi rast nakon krize (slika 4-11). Tvrtke investicije u najvećem dijelu financiraju iz internih sredstava (tablica 4-8), a u eksternom zaduživanju većinom se koriste kreditima nerezidentnih trgovačkih društava (slika 4-12). Nakon krize raste udio izravna oblika vanjskog financiranja (emisija obveznica) i pozajmica od povezanih poduzetnika, što može indicirati kontrakciju ponude bankovnih kredita (tablica 4-7). Ovakva je dinamika u skladu s onom u ostalim zemljama Europske unije, posebno s iskustvom perifernih zemalja (ECB, 2013).

4.5 Međuodnos investicija i likvidnosti poslovnih subjekata

U ovom se poglavlju razmatra utjecaj likvidnosti na investicije. Teorijski modeli prezentirani u poglavlju 2.4. pretpostavljaju nelinearan odnos investicija i novčanog toka kao funkcije likvidnosti. Nelikvidna poduzeća dodatan novčani tok upotrebljavaju za uspostavljanje normirane likvidnosti. U nelikvidnih poslovnih subjekata očekuje se nulta osjetljivost investicija na novčane tokove ili čak negativna zbog monetizacije postojeće imovine (dezinvestiranje) radi ostvarivanja optimalne likvidnosti. U okviru investicijske regresijske jednadžbe (poglavlje 3.2.), očekuje se negativan ili nulti koeficijent uz novčane tokova za skupinu nelikvidnih poduzeća. U graničnim poduzećima koeficijent uz novčane tokove također bi trebao biti 0 jer su poduzeća indiferentna između rasta likvidnosti i investicija. Likvidna poduzeća upotrebljavaju novčani tok za nove investicije ako postoje investicijske prilike. Nakon određene razine, gomilanje likvidnosti postaje preskupo, pa dodani novčani tok ne povećava investicije. U ovoj jednostavnoj analizi dvije su ključne varijable za objašnjenje dinamike investicija i likvidnog ograničenja: novčani tokovi i stanje likvidnosti. Potonje je objašnjenje likvidnog ograničenja endogeno, za razliku od financijskog ograničenja koje je egzogeno. Egzogeno obilježje financijskog ograničenja proizlazi iz nesposobnosti uspostavljanja novih dužničko-vjerovničkih odnosa jer poduzeće ne uživa povjerenje financijskih institucija. Likvidno je ograničenje endogeno jer poduzeće samostalno bira iznose investicija iz novčanih tokova na temelju dostupne razine likvidnosti.

Na slici 4-16 prikazuje se kretanje novčanog toka, neto radnoga kapitala i novca kao elementa internih sredstava s jedne strane i investicija s druge strane. Vremenski su odsječci agregirane vrijednosti podijeljene s knjigovodstvenom vrijednosti imovine.

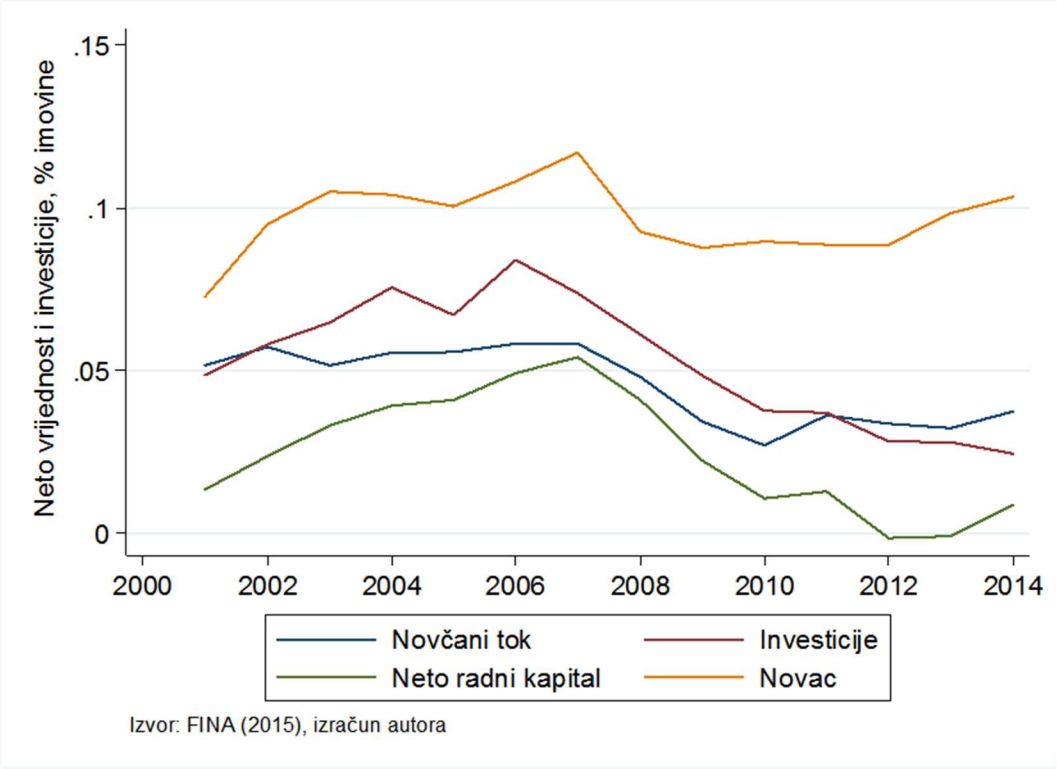

Slika 4-16: Dinamika neto investicija, neto radnoga kapitala, novčanog toka i novca u odnosu prema ukupnoj imovini od 2001. do 2014.

Novac u prosjeku iznosi 10 % ukupne imovine i pokazuje složenu godišnju stopu rasta od 10 % u pretkriznom razdoblju. Zanimljivo je primijetiti da se stopa gotovine počela oporavljati već 2012 godine te na kraju promatranog razdoblja postiže iste vrijednosti kao i prije krize (98 % vrijednosti iz 2008. godine). Očito je kako se na agregatnoj razini ne prepoznaje fenomen gomilanja novca (rasta stope gotovine tijekom cijelog razdoblja) koji je prisutan u nekim razvijenim zemljama (za SAD vidjeti Bates, Kahle, Stulz (2009), za UK pogledati Farrant i Rutkowska (2015)). Nominalna vrijednost neto radnoga kapitala u pretkriznom razdoblju raste uza složenu godišnju prosječnu stopu rasta od 34 % što je gotovo tri puta više od rasta investicija (12 %). Nakon krize stopa neto radnoga kapitala snažno pada. U 2012. i 2103. godini čak su zabilježene i negativne vrijednosti. Očito je kako stopa neto radnoga kapitala pokazuje najveće oscilacije tijekom poslovnog ciklusa. Može se pretpostaviti da rast neto radnoga kapitala ne odražava samo održavanje koeficijenta konstitucije (jednakog omjera kratkotrajne i dugotrajne imovine tijekom vremena) nego i prilagođavanje likvidnosti poduzeća. Veća fluktuacija neto radnoga kapitala upućuje na njegovu važnost u prilagođavanju likvidnim šokovima (pogledati Fazzari, Petersen, 1993). Novčani tokovi čine 5 % imovine tijekom pretkriznog razdoblja. Nakon 2007. godine novčani tokovi počinju opadati, ali se oporavak može primijetiti već nakon

2010. godine. U 2011. novčani tokovi postaju čak veći od investicija, što upućuje na dostatan izvor internog financiranja na agregatnoj razini.

Slika 4-16 pokazuje slične razine novčanih tokova i investicija (između 5 % i 7 imovine). Radi povećanja broja opservacija na grafikonu 4-17 prikazuje se dinamika novčanih tokova i investicija na razini izabranih županija u Republici Hrvatskoj kako bi se povećao stupanj heterogenosti i broj opservacija. Na slici 4-17 prikazan je visok stupanj kongruencije novčanih tokova i investicija. U većini opservacija investicije poprimaju slične vrijednosti kao i novčani tokovi, a u manjem broju slučajeva investicije su veće od novčanih tokova. Rijetki su slučajevi da su novčani tokovi veći od investicija.

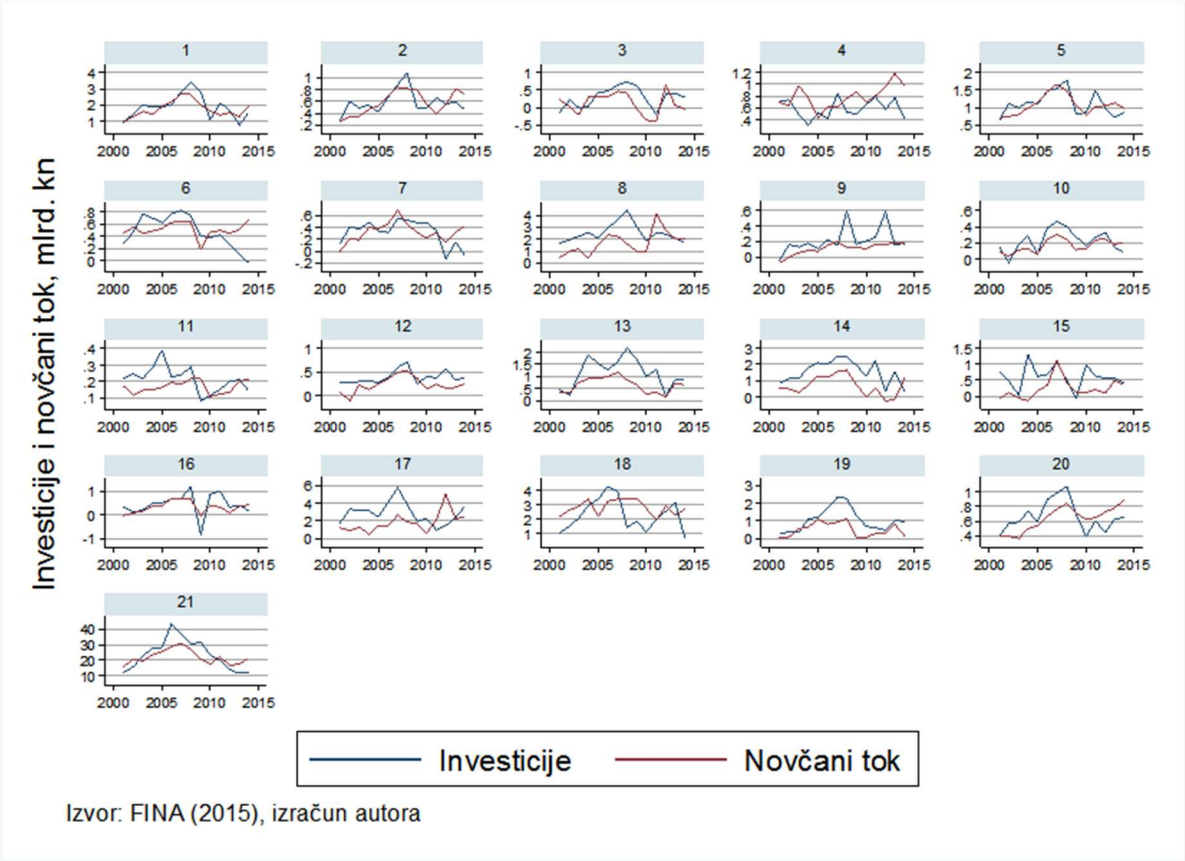

Slika 4-17: Dinamika investicija i novčanih tokova po županijama u Republici Hrvatskoj od 2001. do 2014.

Jasniju sliku korelacije između investicija i novčanih tokova na razini županija daje slika 4-18. Na slici su prikazane procijenjene vrijednosti dobivene iz regresije investicija na novčane tokove s kvalitativnim varijablama za svaku županiju (panel-fiksni efekti). Regresijski pravac označen crnom bojom rezultat je jednostavne regresije investicija na novčane tokove. Pri izradi grafikona iz uzorka je izbačen Grad Zagreb zbog neuobičajeno visokih vrijednosti u odnosu

prema drugim županijama, ali rezultati se ne mijenjaju njegovim uključivanjem u analizu. Vrijednost koeficijenta uz novčane tokove, u modelu s fiksnim efektima iznosi 1.529. Drugim riječima, povećanje novčanih tokova, a, primjerice, 1.000.000 kuna, u prosjeku povećava vrijednost investicija 1.529.000 kn ($p = 0.00$). Ako se izbaci jedan percentil ekstremnih vrijednosti, koeficijent uz novčane tokove iznosi 0,9295. Dakako, riječ je o vrlo jednostavnu modelu sa samo jednom nezavisnom varijablom. Ako se u nj doda varijabla agregatne potražnje, izračunane kao zbroj novododane vrijednosti za sve tvrtke koje posluju u županijama, i ukupni prihodi, također kao mjere potražnje, vrijednost koeficijenta uz novčane tokove iznosi 1.552 (ako se izbaci jedan percentil ekstremnih vrijednosti, koeficijent iznosi 1.4776). Ukratko, iz prethodnih dviju slika može se zaključiti da su tekući novčani tokovi među glavnim determinantama investicija u kratkom roku. Ovu empirijsku činjenicu potvrdili su brojni drugi radovi (pogledati poglavlje 3.2.) i neki teorijski modeli (poglavlje 2.3.4.).

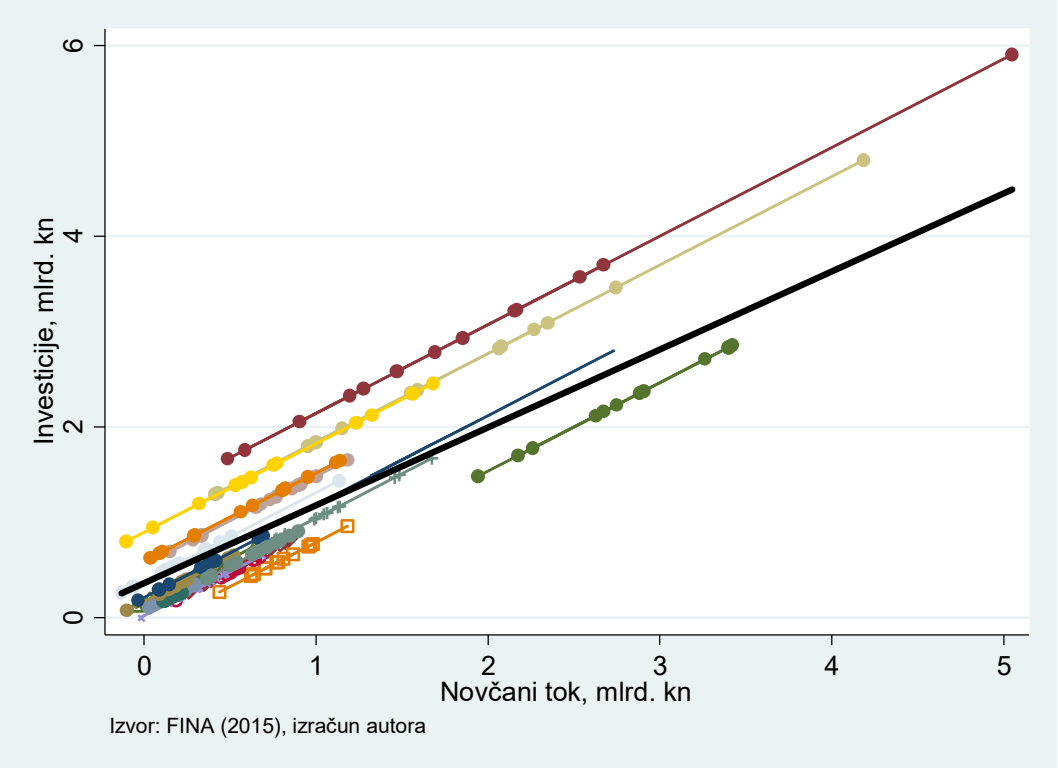

Slika 4-18: Regresija investicija na novčane tokove za 21 županiju u Republici Hrvatskoj (izuzev Zagreba)od 2001. do 2014.

Agregatne su veličine korisne, ali ne pružaju spoznaju o heterogenosti stupnja likvidnosti poduzeća tijekom vremena. U nastavku se stoga analiziraju pokazatelji tekuće likvidnosti kroz vrijeme. Na slici 4-19 prikazane su raspodjele pokazatelja tekuće likvidnosti za 2000., 2007. i 2014. godinu. Distribucija pokazatelja u 2000. godini pokazuje da je vrh distribucije viši od

normalnog. Najveća je frekvencija pokazatelja oko vrijednosti 1, što je u skladu očekivanjima. Vrijednosti niže od jedan impliciraju poteškoće u održavanju dužničko-vjerovničkih odnosa s vjerovnicima, a prevelike vrijednosti pokazatelja impliciraju visoke oportunitetne troškove. U uvjetima savršenih tržišta, s potpunim informacijama, očekivala bi se ista razina kratkotrajne imovine i kratkotrajnih obveza za sva poduzeća. Stoga je očekivano da najveći dio poduzeća održava vrijednosti omjera nešto više od 1. Pošto poprimi vrijednost 1, funkcija gustoće počinje eksponencijalno opadati. Oblik distribucije promijenio se od 2000. do 2007. godine. Vrh distribucije znatno se smanjio te ona u rasponu 0 – 1,5 poprima veći stupanj uniformnosti. Vrh distribucije blago se pomaknuo u desno ili, drukčije rečeno, površina ispod krivulje od točke jedan povećala se u od 2000. do 2007. godine. Povećao se i udio nelikvidnih poduzeća. Dakle, u pretkriznom razdoblju nastalo je raslojavanje: granično likvidna poduzeća postaju nelikvidna ili prelikvidna. Nakon financijske krize znatno se povećao udio nelikvidnih poduzeća. Najveći je udio nelikvidnih poduzeća čija je vrijednost tekućeg omjera manja od jedan. Međutim, povećava se i udio prelikvidnih poduzeća. Nakon financijske krize nastavljen je trend smanjenja granično likvidnih poduzeća i povećanja udjela nelikvidnih i prelikvidnih poduzeća

Promjenu distribucije nelikvidnih, likvidnih i prelikvidnih poduzeća oslikava i tablica 4-9. Tablica pokazuje udio broja poduzeća u pojedinom intervalu tekućeg omjera. Prva skupina primjerice pokazuje postotni udio broja subjekata koji imaju vrijednost tekućeg omjera manji od 0,5, druga pokazuje poduzeća koja imaju vrijednost tekućeg omjera između 0,5 i 1 itd. Subjekti iz prvih dviju skupina mogu se smatrati „nelikvidnima“, subjekti iz druge skupine „likvidnima“, a poduzeća iz treće skupine „prelikvidnima“.

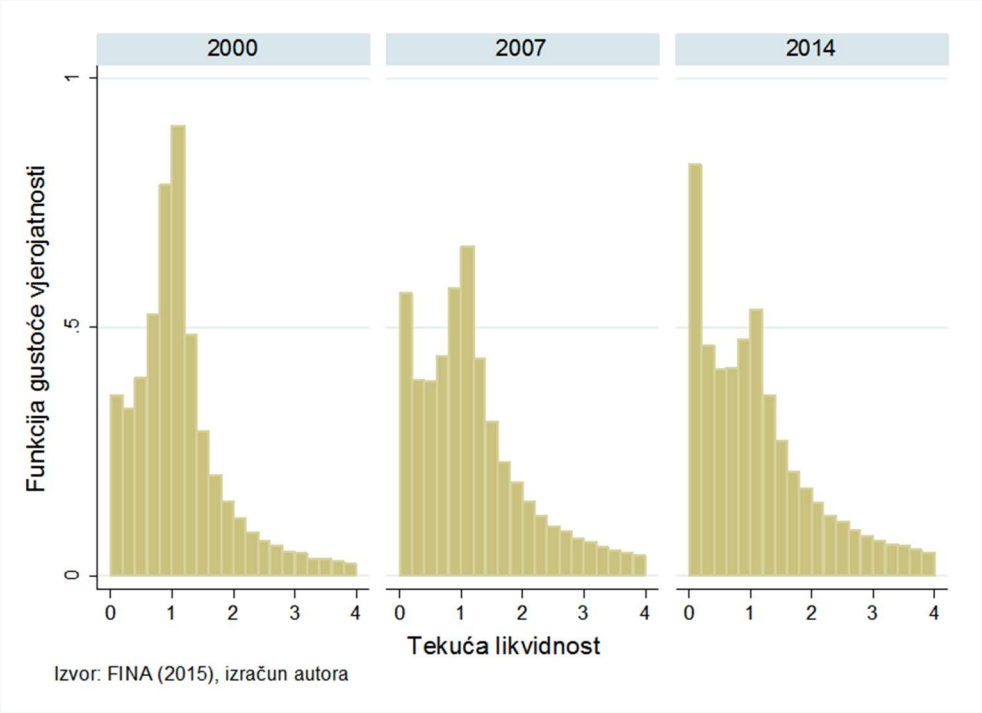

BILJEŠKA: Slika pokazuje distribuciju tekuće likvidnosti (kratkotrajna imovina / kratkotrajne obveze) za tri godine (2000., 2007., 2014.). Ukupna površina ispod krivulje iznosi 1.

Slika 4-19: Histogram pokazatelja tekućeg omjera za 2000., 2007. i 2014. godinu.

Udio poduzeća iz prve skupine (vrijednost tekućeg omjera manji od 0,5) povećao se sa 17 % na 26 % tijekom promatrana razdoblja. Najveći je rast bio poslije financijske krize, kada je udio nelikvidnih poduzeća narastao 7 postotnih bodova. Udio poduzeća u sljedećim dvama režimima smanjio se ukupno 19 postotnih bodova. Udio u četvrtoj skupini stabilan je kroz vrijeme, a udio se prelikvidnih poduzeća povećao s 18 % na 27 %. Pri tome se najveći rast dogodio prije financijske krize, a poslije Velike recesije udio je ostao stabilan. Dakle, prije financijske krize povećao se udio poduzeća s visokim vrijednostima tekućeg omjera, a nakon krize povećao se udio poduzeća s vrlo niskim vrijednostima tekućeg omjera.

Tablica 4-9: Broj tvrtki koje pripadaju pojedinim režimima pokazatelja tekućeg omjera, u postocima, za razdoblje od 2002. do 2014.

Režim	**'02**	**'03**	**'04**	**'05**	**'06**	**'07**	**'08**	**'09**	**'10**	**'11**	**'12**	**'13**	**'14**
$cr < 0.5$	17	17	18	18	19	19	19	20	21	23	24	25	26
$0.5 > cr < 1.0$	28	26	25	24	24	22	21	21	21	21	21	21	20
$1.0 > cr < 1.5$	29	28	27	26	24	23	23	22	20	19	18	18	18
$1.5 > cr < 2.0$	9	10	9	10	10	10	10	10	9	9	8	8	8
$cr > 2.0$	18	20	21	22	24	25	27	28	29	28	28	28	27

Izvor: FINA (2015.), autorov izračun

U poglavlju 4.3. prikazano je kretanje investicija za nezadužena, srednje zadužena i prezadužena poduzeća (slika 4.13). Na slici 4.20 provedena je ista analiza, samo se umjesto pokazatelja financiranja upotrebljavaju pokazatelji likvidnosti: tekuća likvidnost, stopa neto radnoga kapitala (omjer neto radnoga kapitala i imovine), stopa gotovine (odnos novca i imovine) i stopa novčanog toka (odnos novčanog toka i imovine). Točnije, pokazuje se kretanje medijana stope investicija za poduzeća u kojih je vremenski pomaknuta vrijednost pokazatelja manja od 15. percentila („nelikvidna“), između 40. i 60. percentila („likvidna“) i veća od 85. percentila („prelikvidna“). Prve su tri varijable razina (engl. *stock*), odnosno mjere stanje likvidnosti na kraju razdoblja, a novčani je tok varijabla toka, odnosno indicira promjenu likvidnosti.

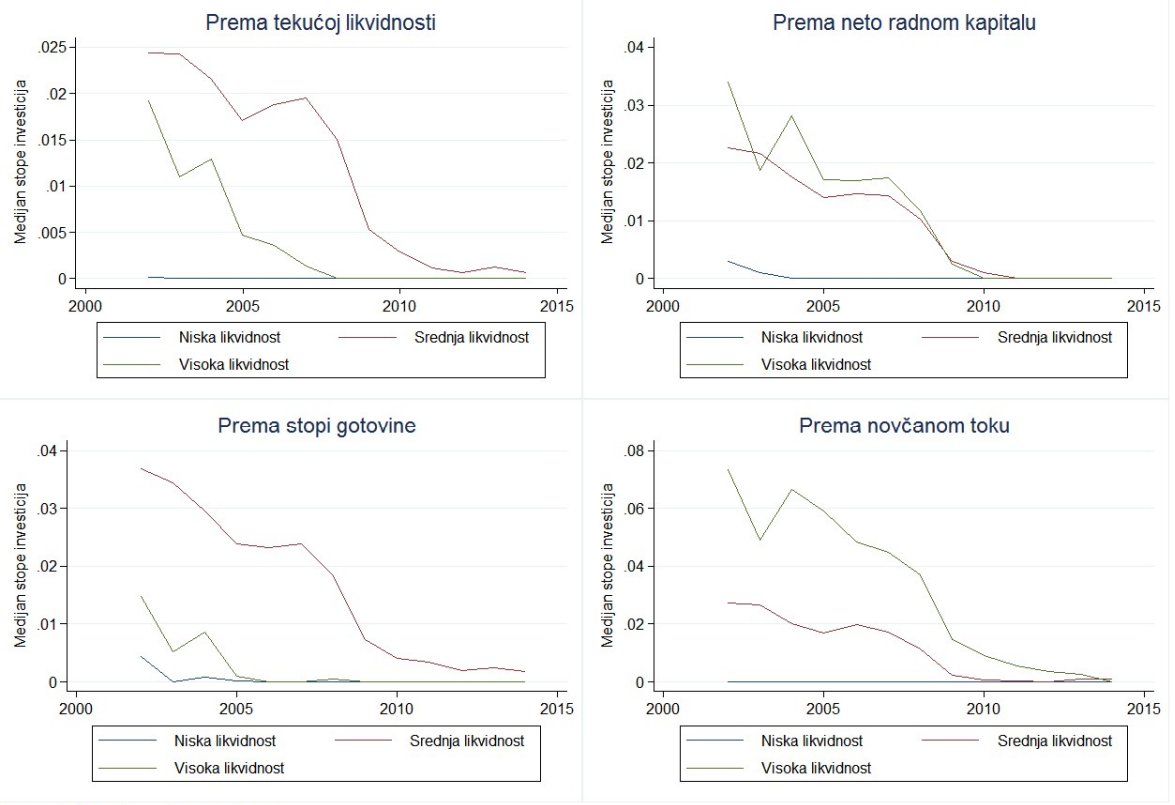

Izvor: Fina, izračun autora

BILJEŠKA: Grafovi pokazuju medijane stope investicija za različite interkvantilne razmake tekuće likvidnosti, stope neto radnoga kapitala, stope gotovine i stope novčanog toka. Tekuća je likvidnost jednaka omjeru kratkotrajne imovine i kratkotrajnih obveza, a stope neto radnoga kapitala, novca i novčanog toka podijeljene su s ukupnom imovinom. Stopa investicija jednaka je omjeru investicija i knjigovodstvene vrijednosti imovine. Grupa „nisko“ uključuje poduzeća do 15. percentila vrijednosti pokazatelja, „srednje“ od 40. do 60. percentila, a „visoko“ iznad 85. percentila vrijednosti pokazatelja.

Slika 4-20: Dinamika stope neto investicija za „nelikvidna“, „likvidna“ i „prelikvidna“ poduzeća

Svi grafovi pokazuju smanjivanje medijana stope neto investicija tijekom promatranog razdoblja (2001–2014.). Na prvom je grafu vidljivo da najviše investiraju „likvidne“, a zatim „prelikvidne“ tvrtke. Medijan stope investicija za „nelikvidne“ tvrtke iznosi nula ili je vrlo blizu nule. Iz rasprave u poglavlju 2.4.1. može se može se zaključiti da u skupini nelikvidnih poduzeća investiraju ona koja imaju vrlo veliki rast novčanih tokova ili poduzeća iz grupe Ponzieve sheme. Takva je dinamika investicija u skladu s istraživačkom hipotezom. Naime, nelikvidne tvrtke novi novčani tok upotrebljavaju za uspostavljanje primjerene likvidnosti, pa poduzeća iz te skupine ulažu samo uz velike pozitivne šokove na novčane tokove. Dodatno, prelikvidne tvrtke često gomilaju likvidnost zbog nedostatka investicijskih prilika, pa ni

dodatna agregatna potražnja ili pozitivan šok na novčane tokove ne utječu pozitivno na investicije kao u „likvidnih“ poduzeća.

Na drugom grafikonu slike 4-20, „prelikvidne“ tvrtke pokazuju nešto veće stope investicija od „likvidnih“, ali obrazac ponašanja investicija vrlo je sličan onima na prvom grafikonu. Treći grafikon pokazuje jasnu hijerarhiju između stope gotovine i stope neto investicija. Najviše investiraju poduzeća sa srednjom razinom stope gotovine. Slijede poduzeća s najvećom razinom, a ona koja ostvaruju niske razine novca u prethodnom razdoblju vrlo malo investiraju u sadašnjem razdoblju (posljednjih nekoliko godina medijan stope investicija iznosi 0). Iako je ovakva dinamika u skladu s hipotezom, interpretacija zahtijeva oprez jer grafikon pokazuje korelacije, ali ne i uzročnost. Moguće je da treća varijabla, poput očekivane profitabilnosti, ima signifikantan utjecaj na obje varijable. To potvrđuje posljednji grafikon koji najjasnije odražava hijerarhiju investiranja. Poduzeća koja ostvaruju najvišu razinu novčanog toka u prethodnom razdoblju pokazuju najvišu razinu neto investicija u sadašnjem razdoblju. Zanimljivo je da poduzeća koja pokazuju pad stope novčanog toka u prethodnom razdoblju ne investiraju u pretkriznom razdoblju, ali ni u razdoblju poslije krize.

5 EMPIRIJSKI MODEL UTJECAJA FINANCIJSKIH FRIKCIJA NA INVESTICIJSKU AKTIVNOST POSLOVNIH SUBJEKATA U REPUBLICI HRVATSKOJ

5.1 Metodološki okvir analize

Cilj je ovog poglavlja procjena stupnja financijskog i likvidnog ograničenja poduzeća u Republici Hrvatskoj. Za to je poslužila metoda granične regresije prema Hansen (1999) i Hansen (2000). *Threshold* regresija može se smatrati posebnim slučajem kompleksnijih statističkih modela, poput modela s promjenjivim režimom (engl. *switching models*), Markovih modela s promjenjivim režimom i glatkih tranzicijskih modela s promjenjivim režimom (engl. *smooth transition threshold models*). Metoda se primjenjuje kada različiti poduzorci ukupnog uzorka mogu pokazivati različite procijenjene koeficijente. Primjerice, različita veličina tvrtke može upućivati na različite odnose investicija i novčanih tokova. *Threshold* regresija nastoji identificirati granicu koja dijeli uzorak. Tako se uvodi dodatna dimenzija u objašnjavanju heterogenosti. Klasični modeli s fiksnim efektima odražavaju samo heterogenost u odsječcima (engl. *intercept*), a *threshold* regresija proširuje model i za promjenu u parametrima za različite vrijednosti *threshold* varijable.

Dvije su osnovne prednosti korištenja *threshold* regresijom za procjenu financijske i likvidne ograničenosti. Prvo, broj režima i svrstavanje poduzeća u pojedine režime nije određen apriorno već se procjenjuje na temelju pravilnosti sadržanih u podacima (engl. *data driven approach*). Drugo, svrstavanje poduzeća u određene režime nije fiksno, već se omogućuje prelazak iz jednog režima u drugi. Moguće je da poduzeće u jednom razdoblju pripada režimu nelikvidnih poduzeća, a u drugom režimu likvidnih ili prelikvidnih poduzeća.

U nastavku se prikazuje ekonometrijski model prema Hansen (1999). Riječ je o panel-modelu s fiksnim efektima, koji je linearan po dijelovima (engl. *piecewise-linear*). Prvo, valja istaknuti da panel-podaci moraju biti organizirani kao balansirani panel podaci, $\{y_{it}, q_{it}, x_{it}: 1 \leq i < n, 1 \leq t < T\}$. „Nepoznato je proširenje podataka na nebalansirani panel“ (Hansen 1999, str. 3). Indeks i označuje individuu (poduzeće), a indeks t vrijeme. Panel-*threshold* model ima sljedeću formu:

$$y_{it} = \mu_i + \beta_1' x_{it} 1(q_{it} \leq \gamma) + \beta_2' x_{it} 1(q_{it} > \gamma) + e_{it} \tag{117}$$

gdje je zavisna varijabla y_{it} skalar, regresor x_{it} $(1 \times k)$ vektor, threshold (tranzicijska) varijabla q_{it} skalar, a $1(\cdot)$ indikator funkcija. Opservacije su podijeljene u dva režima (klase) ovisno o tome je li *threshold* varijabla veća ili manja od granice γ. β_1' i β_2' su regresijski koeficijenti svakoga pojedinog režima. Varijabla μ_i nije promjenjiva s obzirom na režim. Alternativan način zapisivanja jednadžbe (124) jest:

$$y_{it} = \begin{cases} \mu_i + \beta_1' x_{it} + e_{it}, q_{it} \leq \gamma \\ \mu_i + \beta_2' x_{it} + e_{it}, q_{it} > \gamma \end{cases}$$

$$x_{it}(\gamma) = \begin{cases} x_{it} I\ (q_{it} \leq \gamma) \\ x_{it} I\ (q_{it} > \gamma) \end{cases}$$

Ako se uvede $\beta = (\beta_1' \beta_2')$, dobije se

$$y_{it} = \mu_i + \beta' x_{it}(\gamma) + e_{it} \tag{118}$$

Podrazumijeva se da se model može proširiti uvrštavanjem dodatnih egzogenih, kontrolnih varijabli.

Uvjet je procjene regresijskih koeficijenata da elementi od x_{it} variraju u vremenu (u okviru analize novčani tokovi variraju u vremenu). Granična varijabla također mora varirati u vremenu. Hansen (1999, 2000) pretpostavlja da su pogreške regresije e_{it} nezavisne, jednako distribuirane slučajne varijable (iid) s očekivanom vrijednošću 0 i varijancom σ^2, što isključuje mogućnost pomaknute zavisne varijable.

U literaturi se pojavljuju različiti procjenitelji parametara za dani γ. Hansen (1999) primjenjuje metodu najmanjih kvadrata s fiksnim efektima. Autor prvo preoblikuje jednadžbu (118) kako bi uklonio individualni efekt μ_{it}. Uzimanje prosjeka jednadžbe (118) daje:

$$\overline{y_i} = \mu_i + \beta' \overline{x_i}(\gamma) + \bar{e}_i \tag{119}$$

Gdje je $\overline{y_i} = T^{-1} \sum_{t=1}^{T} y_{it}$, $\bar{e}_i = T^{-1} \sum_{t=1}^{T} e_{it}$, i

$$\overline{x_i}(\gamma) = T^{-1} \sum_{t=1}^{T} x_{it}(\gamma) = \begin{pmatrix} T^{-1} \sum_{t=1}^{T} x_{it} 1(q_{it} \leq \gamma) \\ T^{-1} \sum_{t=1}^{T} x_{it} 1(q_{it} > \gamma) \end{pmatrix}$$

Oduzimanjem jednadžbe (119) i (118) dobiva se:

$$y_{it}^* = \beta' x_{it}^*(\gamma) + e_{it}^* \tag{120}$$

gdje je $y_{it}^* = y_{it} - \overline{y_i}$, $x_{it}^*(\gamma) = x_{it}(\mu) - \overline{x_i}(\gamma)$ i $e_{it}^* = e_{it} - \bar{e}_i$. Ako se s y_i^*, $x_i^*(\mu)$ i e_i^* označi stog podataka za individuu (poduzeće) s izbrisanim jednim razdobljem, tada Y^*, $X^*(\mu)$ i e^*označuju stog podataka za sve individue, npr.:

$$X^*(\mu) = \begin{bmatrix} x_1^*(\mu) \\ \vdots \\ x_i^*(\mu) \\ \vdots \\ x_n^*(\mu) \end{bmatrix}$$

Koristeći se potonjom notacijom, jednadžba (120) se može zapisati kao

$$Y^* = \beta X^*(\mu) + e^* \tag{121}$$

Desna strana jednadžbe može se zapisati i kao $X^*\theta + \beta X^*(\mu) + e^*$, gdje je X vektor regresora koji ne mora biti i granična varijabla. Procjenitelj β procjenjuje se metodom najmanjih kvadrata:

$$\hat{\beta}(\gamma) = \left(X^*(\mu)' X^*(\mu)\right)^{-1} X^*(\mu)' Y^* \tag{122}$$

Granica γ također se može procijeniti metodom najmanjih kvadrata:

$$\hat{\gamma} = arg\min_{\gamma} S_1(\gamma) \tag{123}$$

gdje je $S_1(\gamma)$ zbroj kvadrata pogrešaka:

$$S_1(\gamma) = \hat{e}^*(\gamma)'^{\hat{e}^*}(\gamma) = Y^{*\prime}(I - X^*(\mu)'\left(X^*(\mu)' X^*(\mu)\right)^{-1} X^*(\mu)')Y^* \tag{124}$$

Postoji vjerojatnost da granica bude procijenjena tako da premalo podataka dodjeljuje određenu režimu. Kako bi se to izbjeglo, zahtijeva se određeni minimalan broj podataka u određenom režimu. Pretpostavlja se i da granica γ pripada omeđenu skupu. Kada je granica $\hat{\gamma}$ procijenjena, procijenjeni koeficijent postaje $\hat{\beta} = \hat{\beta}(\hat{\gamma})$, rezidualni vektor $\hat{e}^* = \hat{e}^*(\hat{\gamma})$, a varijanca reziduala je jednaka:

$$\hat{\sigma}^2 = \frac{1}{n(T-1)} \hat{e}^{*\prime\hat{e}^*} = \frac{1}{n(T-1)} S_1(\gamma) \tag{125}$$

Valja napomenuti da je u slučaju $e^* \sim iid$, OLS procjenitelj jednak MLE procjenitelju.

U praksi, minimiziranje jednadžbe (123) podrazumijeva sljedeće korake:

1. Razvrstati po veličini različite vrijednosti opservacije *threshold* varijable q_{it}.
2. Ukloniti η% najmanjih i najvećih vrijednosti za neki $\eta > 0$.
3. Ostale N vrijednosti čine moguće vrijednosti γ koje se traže za $\hat{\gamma}$.
4. Za svaku od N vrijednosti procjenjuje se regresija (6) čime se dobiva zbroj kvadrata pogrešaka. Najmanja vrijednost potonjeg dovodi do procjenitelja $\hat{\gamma}$.

U trećem koraku, zbog velikog broja N vrijednosti, Hansen predlaže da se γ traži samo za određene kvantile. Primjerice može se primijeniti rešetka (engl. *grid*) $\{1{,}00\ \%, 1{,}25\ \%, 1.50\ \%, \dots, 99{,}0\ \%\}$. To uvelike smanjuje broj regresija koje se provode tijekom traženja procijenjenog parametra.[41]

U nastavku se opisuje procedura za provjeru hipoteza o postojanju režima. γ_0 je populacijski parametar koji nije poznat. Hansen (1999) je pokazao da je najbolji način za testiranje hipoteze $\gamma = \gamma_0$ formiranje intervala pouzdanosti upotrebljavajući „no rejection region“ metodu s omjerom vjerodostojnosti:

$$LR_1(\gamma) = \frac{S_1(\gamma) - S_1(\hat{\gamma})}{\hat{\sigma}^2} \xrightarrow{Pr} \xi \tag{126}$$

$$Pr(x < \xi) = (1 - e^{\frac{-x}{2}})^2$$

Za danu razinu signifikantnosti α, donja granica korespondira maksimalnoj vrijednosti u LR seriji, koja je manja od q kvantila, a gornja granica odgovara minimalnoj vrijednosti u LR seriji, koja je manja od q kvantila. Time q kvantil može biti izračunan pomoću inverza jednadžbe (126):

$$c(\alpha) = -2\log(1 - \sqrt{1 - \alpha}) \tag{127}$$

[41] U transformiranu modelu (5) regresori mogu biti korelirani s e^*. Problem endogenosti može se riješiti uvođenjem $l \times 1$ vektora instrumentalnih varijabli, $\left(z_{it_0}^* e_{it_0}^*, \dots, z_{iT}^* e_{iT}^*\right) = 0$, odnosno $E(e_{it}^* | z_{it}^*) = 0$. U Seo i Shin (2014) prikazane su dvije alternativne procjene. Ako je granična varijabla q_{it} endogena, autori razvijaju GMM procjenitelj u dva koraka (FD-GMM). Ako su granične varijable egzogene, a ispunjeno je uvjetno očekivanje $E(e_{it}^* | z_{it}^*) = 0$, autori razvijaju poboljšanu verziju GMM procjenitelja (FD-2SLS).

Na primjer, ako je $\alpha = 0{,}1$, vrijednost kvantila iznosi $q = 6{,}53$. Ako je $LR_1(\gamma)$ veći od $c(\alpha)$, odbacuje se H_0.

Testiranje hipoteze o nepostojanju granice identično je testiranju hipoteze da su koeficijenti isti u dva režima:

$$H_0: \beta_1 = \beta_2 \tag{128}$$

Hipoteza može biti testirana LR testom. Hansen predlaže *bootstrap* proceduru za simuliranje asimptotske distribucije LR testa, koji se temelji na testnoj statistici:

$$F_1 = \frac{S_0 - S_1(\gamma)}{\hat{\sigma}^2} \tag{129}$$

gdje S_0 i S_1 označavaju zbroj kvadrata pogrešaka za nultu i alternativnu hipotezu. Hansen predlaže *bootstrap* proceduru za dobivanje asimptotske distribucije i p vrijednosti.

Model (117) se može proširiti za višestruke granice. Primjerice, model s dvjema granicama (*threshold*), odnosno trima režimima ima oblik:

$$y_{it} = \mu_i + \beta_1' x_{it} 1(q_{it} \leq \gamma_1) + \beta_2' x_{it} 1(\gamma_1 < q_{it} < \gamma_2) + \beta_3' x_{it} 1(\gamma_2 < q_{it}) + e_{it} \tag{130}$$

Ukratko, *threshold* regresija omogućuje endogeno grupiranje poduzeća na financijski ograničena i neograničena prema određenim financijskim kriterijima (*threshold* varijablama). Pokaže li se da granice postoje, metoda će omogućiti procjenu regresijskih koeficijenata na novčane tokove za svaki režim.

5.2 Pregled podataka i izbor varijabli upotrijebljenih u analizi

U ovom se poglavlju pruža opis podataka i varijabli koji će se upotrijebiti u regresijskoj analizi. Svaka specifikacija modela koristit će se podskupom varijabli opisanih u poglavlju 4.1. U poglavlju 5.2.2. prikazuju se osnovne statističke veličine te se provodi deskriptivna analiza izabranih varijabli.

5.2.1 Prilagodba podataka za analizu financijskog i likvidnog ograničenja

Početna baza podataka sadržava nebalansirani uzorak sa svim dioničkim društvima i društvima s ograničenom odgovornošću u RH. U uzorku su i obrti koji su, u skladu sa zakonskim propisima, obvezni izrađivati i objavljivati godišnja financijska izvješća te prijavljivati porez na dobit. Riječ je o gotovo svim hrvatskim poduzećima,[42] sa svim financijskim podacima iz godišnjih financijskih izvještaja. Iako su varijable koje će se upotrijebiti u analizi već opisane u poglavlju 4.1., kako bi se olakšalo daljnje praćenje analize, u tablici 5-1 definirane su varijable upotrijebljene u analizi.

U pregledu empirijskih pristupa procjenjivanja financijskog i likvidnog ograničenja (poglavlje 3) nekoliko je puta naznačeno da najviše radova u uzorak uključuje samo tvrtke koje kotiraju na organiziranim tržištima kapitala (npr. Fazzari i Athey (1997), Fazzari i dr. (1988), Hoshi i dr. (1991) te ostali). Razlog je što za takve tvrtke postoje informacije o tržišnoj vrijednosti tvrtki. Jednadžba koja se procjenjuje najčešće ima oblik proširene neoklasične jednadžbe investicija, koja u sebi sadržava Tobinov q čije mjerenje zahtijeva raspolaganje tržišnim vrijednostima kompanija. Međutim, dionička društva pripadaju kategoriji srednjih i velikih poduzeća, pa je za njih izgledniji manji stupanj financijskog i likvidnog ograničenja.

Budući da društva s ograničenom odgovornošću čine najviše poduzeća u RH te da postoje razlike u funkcioniranju dioničkih društava i društava s ograničenom odgovornošću, u uzorak će se uključiti sve tvrtke, a ne samo one koje kotiraju na organiziranim tržištima kapitala.[43] Time je uklonjena mogućnost korištenja Tobinova q-a (*proxy* za granični q) kao nezavisne varijable u modelu (zbog nemogućnosti mjerenja za subjekte koji ne kotiraju na organiziranim tržištima kapitala), pa će se problem endogenosti rješavati dodavanjem drugih nezavisnih varijabli, što će se detaljnije objasniti u nastavku teksta.

[42] U uzorku nisu poduzeća koja nisu redovito predavala financijske izvještaje (iako ih je zakon na to obvezivao) te obrti koji su obveznici poreza na dohodak.

[43] U empirijskoj pregledu ovog rada pokazano je da je veličina poduzeća čest kriterij razgraničavanja financijski ograničenih i neograničenih poduzeća. Nekoliko je razloga zašto bi mala i srednje velika poduzeća trebala biti ograničenja od velikih: nemaju koristi od ekonomije razmjera i diversifikacije proizvodnog asortimana, ne raspolažu kolateralom, a nadzor kreditora je otežan.

Tablica 5-1: Tablica varijabli

Oznaka	Opis varijable
Ključne varijable	
$\boldsymbol{inv_t}$	Stopa investicija, gdje su investicije definirane kao: $(MI_t + A_t) - MI_{t-1}$, gdje je MI_t dugotrajna materijalna imovina, a A_t amortizacija. Investicije su podijeljene s vremenski pomaknutim vrijednostima imovine.
$\boldsymbol{cf_t}$	Stopa novčanog toka; zbroj neto dobiti i amortizacije podijeljenih s vremenski pomaknutom vrijednosti imovine.
Kontrolne varijable	
$\boldsymbol{nva_t}$	Stopa novododane vrijednosti; zbroj dobiti prije poreza, neto kamatnih rashoda i troškova osoblja, podijeljenih s vremenski pomaknutom vrijednosti imovine.
$\boldsymbol{rsg_t}$	Realna stopa rasta prihoda (korigirana za inflaciju).
$\boldsymbol{emp_t}$	Broj zaposlenih.
Threshold varijable	
$\boldsymbol{ten_t}$	Koeficijent zaduženosti; omjer ukupnih obveza i imovine; koristi se kao *threshold* varijabla pri procjeni financijskog ograničenja.
$\boldsymbol{icov_t}$	pokriće troškove kamata, omjer EBIT-a i bruto dobiti služi kao *threshold* varijabla pri procjeni financijskog ograničenja.
$\boldsymbol{size_t}$	veličina poduzeća, mjerena kao knjigovodstvena vrijednost imovine, služi kao *threshold* varijabla pri procjeni financijskog ograničenja.
$\boldsymbol{liq_t}$	Stopa likvidnosti; razlika između kratkotrajne imovine i kratkotrajnih obveza uvećana za tekuće novčane tokove, sve podijeljeno s vremenski pomaknutom vrijednosti imovine; služi kao *threshold* varijabla pri procjeni likvidnog ograničenja.
$\boldsymbol{cr_t}$	Tekuća likvidnost; omjer kratkotrajne imovine i kratkotrajnih obveza; služi kao *threshold* varijabla pri procjeni likvidnog ograničenja.
$\boldsymbol{wc_t}$	Neto radni kapital, razlika kratkotrajne imovine i kratkotrajnih obveza, služi kao *threshold* varijabla pri procjeni likvidnog ograničenja.

Ekonometrijska će se analiza provoditi na balansiranim panel-podacima jer upotreba statičke panel-*threshold* regresije prema (Hansen, 1999) zahtijeva balansirani panel. Dodatno, balansirani panel ne zahtijeva fiksno svrstavanje poduzeća u pojedine poduzorke, već

omogućuje praćenje financijskog ograničenja tvrtki kroz vrijeme. Zbog korištenja balansiranim panelom, ukupni se uzorak smanjuje s 1.234.464 opservacija na 331.995 opservacija.

Poduzeća u balansiranu panelu posluju u realnom sektoru (izuzet je bankarski sektor i sektor osiguranja). Većina radova u analizu uvrštava samo proizvodna poduzeća. Ovdje se primjenjuje drukčiji pristup, koji ne podrazumijeva fokusiranje samo na jednu, specifičnu NKD djelatnost. U uzorku su zadržane sve djelatnosti, osim onih koje su pod regulacijom države i nisu izložene tržišnom natjecanju te poduzeća koja pružaju financijske usluge, a to su: 1) sektor obrazovanja (osnovnoškolsko, srednjoškolsko i ostalo obrazovanje), 2) sektor javne uprave i obrane; obvezno socijalno osiguranje, 3) sektor novčarskog posredovanja, holding društava i uzajamnih fondova.[44.] Iz uzorka su izbačena poduzeća u državnom vlasništvu čime je iz uzorka izbačeno 6.617 opservacija. U analizi robusnosti posebno će se testirati ograničenje za javna poduzeća, ali će uzorak osnovnog modela uvijek sadržavati samo privatna poduzeća.

Nakon izbacivanja poduzeća iz pojedinih djelatnosti i poduzeća u državnom vlasništvu, u balansiranom su panelu učinjene dodatne prilagodbe koje su uobičajene za ovakvu vrstu istraživanja. Izbačene su opservacije u kojima se pojavljuju neuobičajeno visoke ili niske vrijednosti (engl. *outliers*) glavnih važnih varijabli kako bi se uklonile opservacije koje odražavaju spajanja i preuzimanja, neuobičajene šokove i pogreške pri bilježenju podataka. Točnije, iz uzorka su izbačene: 1) neaktivne tvrtke – opservacije u kojih je vrijednost prihoda ili imovine jednaka 0 kn. Ove tvrtke ne obavljaju poslovnu djelatnosti, pa ne mogu ni investirati u budućem razdoblju. Izbacivanjem neaktivnih tvrtki eliminirano je 4.195 opservacija; 2) opservacije u kojih nedostaju vrijednosti za stopu investicija, stopu novčanog toka i stopu rasta prihoda, čime je iz uzorka izbačeno 4.294 opservacija, 3) opažanja pri kojima je vrijednost stope novčanog toka, stope investicija, stope rasta prihoda i stope dodane nove vrijednosti manja od 1 percentila i veća od 99 percentila, čime je eliminirano 24.298 ekstremno visokih i niskih vrijednosti (engl. *outlier*s). Ovakvo smanjenja uzorka dio je gotovo svih istraživanja koja se koriste bazom podataka godišnjih financijskih izvještaja (Fazzari i dr. 1988; Ding, Guariglia i Knight, 2010; Ding, Guariglia i Knight, 2011, Guariglia, 2007; Cleary, Povel i Raith, 2007; Hubbard, 1999). U analizi robusnosti posebno će se proučavati utjecaj eliminiranja n-tog percentila visokih i niskih vrijednosti na rezultate modela.

[44] Broj varijabli koji je uklonjen: sektor obrazovanja – 3705 opservacija, sektor javne uprave 35 opservacija, sektor financijskih usluga, 93 opservacije.

Nakon izvršenih prilagodbi, balansirani panel za razdoblje od 2000.do 2014. sadržava ukupno 156.450 opservacija i 10.430 poduzeća. Investicijska jednadžba koja će se procjenjivati sadržavat će varijable pomaknute za jedno razdoblje, pa će se analiza provoditi nad balansiranim panelom podataka za razdoblje od 2002. do 2014. Ponašanje investicija konačnog uzorka pokazuje sličnu dinamiku kao i investicije na slici 4-4, koja pokazuje kretanje investicija za sva poduzeća. Investicije rastu sa 6,52 milijarde kuna 2000. godine na 13 milijardi kuna 2008. godine, a nakon krize padaju na 6,76 milijardi kuna 2014. godine. Može se zaključiti da uzorak u prosjeku uključuje oko 20 % vrijednosti ukupnih agregatnih investicija. Glavni je razlog ovako velikog smanjenja uzorka nužnost korištenja balansiranim panelom podataka. U analizi robusnosti, u poglavlju 5.6., upotrijebit će se nebalansirani panel podataka sa znatno više opservacija kako bi se testirala osjetljivost rezultata osnovnog modela na proširenje uzorka.

Zna se da balansirani panel može dovesti do „pristranosti preživljavanja". Naime, u predmetnoj su bazi podaci za razdoblje od 2000. do 2014. (2002–2014. uz primjenu pomaknutih varijabli). Zbog korištenja balansiranim panelom uzorak neće uključivati tvrtke koje su osnovane u posljednjih 15 godina. Također, uzorak neće sadržavati tvrtke koje su preuzete od drugih kompanija ili su postale neaktivne iz drugih razloga (stečaj, brisanje iz registra, likvidacija). Važno je naznačiti da korištenje balansiranog panela podataka može rezultirati pristranim procjeniteljima. Naime, može se očekivati da nove tvrtke (nastale između 2000. i 2014.) imaju veći stupanj financijskog i likvidnog ograničenja. Jednako se tako može očekivati da su subjekti koji su u međuvremenu prestali postojati (zbog likvidacije ili stečaja) također imali veći stupanj financijskog ograničenja.

Kako bi se dobio uvid u jačinu i smjer pristranosti zbog korištenja balansiranim panelom, u tablici 5-2 prikazane su razlike u vrijednostima izabranih pokazatelja između početnog, nebalansiranog panela i balansiranog panela. Prva kolona sadržava očekivanu vrijednost i medijan pokazatelja balansiranog panela, a druga kolona iste vrijednosti za nebalansirani panel podataka.

Balansirani panel čine poduzeća za koja postoje opservacije za svaku godinu od 2000. do 2014. nakon već opisanih prilagodbi. Nebalansirani panel uključuje sve tvrtke nakon izvršenih prilagodbi.[45] Vrijednost apsolutnih pokazatelja pokazuje da su poduzeća u balansiranom panelu veća od onih u nebalansiranom panelu (s obzirom na imovinu, ukupne prihode i zaposlenost).

[45] Iz nebalansiranog su panela izbrisane opservacije u kojih je vrijednost prihoda jednaka 0 te opservacije ispod 1. i iznad 99. percentila za sve pokazatelje prikazane u tablici.

Relativni pokazatelji ipak ne pokazuju znatnu razliku u vrijednostima. Novčani tok, nova dodana vrijednost i investicije prema aktivi vrlo su slični. Tvrtke u nebalansiranom panelu zaduženije su te imaju manje iznose neto radnoga kapitala i pokrivenosti troškova kamata što indicira i veći stupanj financijskog i likvidnog ograničenja. Važno je istaknuti da tablica ne odražava distribuciju pokazatelja po poduzećima i vremenu. Primjerice, podaci pokazuju znatno veći udio nelikvidnih tvrtki u nebalansiranu panelu, o čemu će više biti govora u poglavlju 5.6.

Tablica 5-2: Razlika u statističkim veličinama balansiranog i nebalansiranog panela

Pokazatelji	**Balansirani panel**		**Nebalansirani panel**	
	Aritmetička sredina	**Medijan**	**Aritmetička sredina**	**Medijan**
Ukupna imovina (kn)	15.400.000	1.197.537	4.170.780	578.758
Prihodi (kn)	16.400.000	1.746.781	4.391.434	696.458
Broj zaposlenih	21.31	4	9.30	2
Nova dodana vrijednost (kn)	2.687.793	3.302.50	729.685	128.810
Sadašnja vrij. kapitala (kn)	6.890.695	347.974	1.709.033	77.190
Investicije (kn)	854.261	21.975	246.279	6.900
Investicije / aktiva	0,08	0,02	0,10	0,01
Novčani tok / aktiva	0,14	0,10	0,11	0,07
DNV / aktiva	0,30	0,43	0,45	0,27
Neto radni kapital / aktiva	0,22	0,22	0,05	0,08
Koeficijent zaduženosti	0,59	0,60	0,75	0,73
Tekući omjer	3,79	1,45	2,55	1,14
Pokrivenost troškova kamata	29.934	8,51	6,14	4,16
N	156.450	156.450	990.908	990.908
T	15	15	15	15

BILJEŠKA: Tablica pokazuje aritmetičke sredine i medijane izabranih apsolutnih i relativnih pokazatelja. Definicija varijabli dana je u tablici 5-1. U nebalansiranu su panelu izvršene određene prilagodbe: izbrisane opservacije u kojih je vrijednost prihoda jednaka 0 te opservacije ispod 1. i iznad 99. percentila za sve pokazatelje prikazane u tablici. Oba se panela odnose na razdoblje od 2000. do 2014.

Ukratko, prednost je balansiranog panela pojednostavnjenje algebre transformacija i procjenitelja, a nedostatak je smanjivanje uzorka i isključivanje posrnulih i novih tvrtki iz uzorka, što može uzrokovati pristranost preživljavanja. Kako bi se ispitala robusnost rezultata na izbor nebalansirana uzorka, u poglavlju 5.6. provodi se panel-analiza nad nebalansiranim skupom podataka.

5.2.2 Sažetak osnovnih statističkih veličina

Baza podataka nefinancijskih poduzeća omogućuje raščlanjivanje poduzeća prema različitim kriterijima. Prema veličini, poduzeća u uzorku mogu se podijeliti na mala, srednja i velika poduzeća.[46] Tijekom cijelog vremena u uzorku prevladavaju male tvrtke, a udio svake skupine konstantan je tijekom cijelog promatranog razdoblja. U uzorku prevladavaju mala poduzeća (93,62 %), slijede srednje velika poduzeća (4,92 %), a najmanji je udio velikih poduzeća (1,46 %). Baza također sadržava podatke o strukturi vlasništva poduzeća. Moguće je razlikovati i poduzeća s domaćim ili stranim podrijetlom kapitala. Udio poduzeća sa stranim podrijetlom kapitala, za razdoblje za koje postoje podaci (2008–2014) iznosi oko 10 %. U radu će se posebno procjenjivati stupanj financijskog i likvidnog ograničenja za poduzeća s većinskim inozemnim podrijetlom kapitala i za javna poduzeća (poglavlje 5.4.3.).

Tablica 5-3: Sažetak osnovnih statičkih veličina balansiranog modela

Varijabla	Minimum	25% kvantil	Medijan	75% kvantil	Maksimum	Standardna devijacija
inv_t	-0.196	0.000815	0.0216	0.0900	1.590	0.172
cf_t	-0.766	0.0385	0.0968	0.196	1.218	0.175
emp_t	0	2	4	11	13,958	136.6

[46]Kriterij razlikovanja malih ,srednjih i velikih poduzeća preuzeti su iz Zakona o računovodstvu. Prema zakonu mali poduzetnici su oni koji ne prelaze dva od sljedeća tri uvjeta: 1) maksimalno 50 zaposlenih 2) maksimalna vrijednost prihoda 65 milijuna kn 3) maksimalna vrijednost ukupne aktive 32,50 milijuna kuna. Velika poduzeća ispunjavaju najmanje dva kriterija od sljedeća tri: 1) maksimalno 250 zaposlenih 2) maksimalna vrijednost prihoda 260 milijuna kn 3) maksimalna vrijednost ukupne aktive 250 milijuna kuna.

rsg_t	-96.11	-15.22	-0.931	15.73	582.3	44.57
wc_t	-29.19	0.00759	0.223	0.473	9.377	0.429
nva_t	-0.246	0.162	0.306	0.565	3.006	0.420
ten_t	7.45e-05	0.358	0.601	0.800	42.76	0.407
$icov_t$	-2.141*e7	1.212	8.513	350.0	1.479e+08	677,301
liq_t	-29.38	0.0863	0.338	0.636	9.561	0.509
cr_t	0	1.012	1.454	2.545	12,039	54.84
$cash_t$	-0.0639	0.0243	0.0773	0.194	1	0.170

Izvor: FINA (2015), autorov izračun

U nastavku je pružen pregled statističkih veličina za sve varijable koje će se upotrijebiti u analizi. Pregled je dan u tablici 5-3. Zanimljivo je primijetiti da medijan broja zaposlenih iznosi 5, a 75 % kvantil 12. Dakle, glavninu uzorka čine mikro i mala poduzeća. Medijan stope investicija iznosi 2,3 %, a medijan je stope novčanog toka 8,.9 %. Tekuća likvidnost i stopa neto radnoga kapitala pokazuju da je prema graničnom kriteriju većina poduzeća u uzorku likvidna, što može upućivati na manji stupanj likvidnog ograničenja za balansiran skup podataka. Medijan koeficijenta zaduženosti iznosi 63 %. Stopa ukupnih prihoda pokazuje visoku standardnu devijaciju – 1.683. Pojedina istraživanja eliminiraju opservacije koje imaju rast prihoda iznad određenog postotka kako bi se isključili efekti spajanja i preuzimanja, ali u predmetnoj analizi nije obavljena potonja prilagodba.

Poželjno je analizirati i korelacije za ključne važne varijable. Stopa novčanog toka pozitivno korelira sa stopom likvidnosti ($\rho = 0{,}59$). Koeficijent zaduženosti i stopa neto radnoga kapitala snažno su negativno korelirani ($\rho = -0{,}67$). Stopa investicija pokazuje najveću korelaciju sa stopom novčanog toka ($\rho = 0{,}33$) i stopom nove dodane vrijednosti ($\rho = 0{,}16$).

5.3 Specifikacija *threshold* regresijske investicijske jednadžbe

Metoda *threshold* regresije omogućuje da se umjesto apriorna određivanja ograničenih i neograničenih poduzeća različiti režimi ponašanja investicija i novčanih tokova identificiraju endogenim određivanjem granica koje ih razdvajaju. Pri tome je moguće upotrijebiti različite varijable kao *threshold* varijable. U ovom radu, za procjenu financijskog ograničenja upotrijebit će se tri varijable: koeficijent zaduženosti, pokrivenost troškova kamata i veličina poduzeća. Dodatno, unutar iste metodologije, za procjenu likvidnog ograničenja upotrijebit će se tri

pokazatelja: stopa likvidnosti, tekući omjer i omjer neto radnoga kapitala i pomaknute vrijednosti ukupne imovine.

Threshold investicijska regresija jednadžba s dvjema granicama ima formu (prilagođeno prema Arčabić, Tica, Lee i Sonora, 2018):

$$inv_{it} = \alpha_i + \mu_t + \begin{cases} \beta_1 cf_{it-1} + \delta_1 X_{it} + e_{1it} \; ako \; q_{it-1} \leq \gamma \\ \beta_2 cf_{it-1} + \delta_2 \, X_{it} + e_{2it} \; ako \; q_{it-1} > \gamma \end{cases} \tag{131}$$

gdje je inv_t stopa investicija, odnosno omjer investicija i ukupne aktive u prethodnu razdoblju, $inv_t = \frac{I_{it}}{A_{it-1}}$. Osnovna je važna varijabla stopa novčanog toka cf_{it-} , koja je jednaka omjeru novčanih tokova i ukupne aktive u prethodnu razdoblju, $cf = \frac{cf_{it}}{A_{it-1}}$; q_{it} označava *threshold* varijablu; a γ *threshold* parametar; matrica X_{it} je vektor kontrolnih varijabli; parametar α_i označava efekte tvrtke; μ_t označava efekt vremena; e_{it} su nezavisne, identično raspodijeljene pogreške relacije s očekivanom vrijednosti nula i konstantnom varijancom. Pretpostavlja se da su pogreške relacije i nezavisne varijable nezavisne kroz i i t.

U većini radova u nazivniku zavisne i temeljne nezavisne varijable (novčani tokovi) upotrebljava se pomaknuta vrijednost kapitala, ali u ovom se radu umjesto kapitala upotrebljava ukupna imovina jer postoji čak 30.640 opservacija u kojima kapital iznosi 0, pa bi korištenje kapitalom smanjilo uzorak jer bi nedostajali mnogi podaci. Naime moguće je da tek osnovana tvrtka nema dugotrajne materijalne imovine u strukturi aktive ili da priroda djelatnosti ne zahtijeva raspolaganje dugotrajnom imovinom. Međutim, investicijska jednadžba izvedena iz teorijskog modela (optimizacijskog problema) najčešće u nazivniku sadrži kapital (jer je kapital ključna varijabla stanja u optimizacijskom problemu), pa će se u analizi robusnosti procijeniti jednadžba u kojoj su investicije podijeljene s pomaknutom vrijednosti kapitala.

Iz jednadžbe je vidljivo da je omjer novčanog toka i aktive prethodnog razdoblja egzogena varijabla ovisna o režimu. Indikator funkcija pridružuje određenu financijsku varijablu (primjerice koeficijent zaduženosti) određenom režimu. Jednadžba (131) ima dva režima, međutim točan broj režima bit će određen poslije provedenih testova o postojanju određena broja granica, primjenom *threshold* regresije. Poduzeća mogu prelaziti iz jednog režima u drugi, što je važna prednost prema prijašnjim istraživanjima koja su se služila apriornom klasifikacijom, čime se implicitno pretpostavlja da je financijsko stanje poduzeća kroz vrijeme fiksno.

Kako je već spomenuto u poglavlju 3.2.2., osnovni je problem jednadžbe (131) problem endogenosti novčanih tokova. Naime, pozitivna korelacija novčanih tokova i investicija može upućivati na povećanje investicijskih prilika. Problem endogenosti pretežito se rješavao uvođenjem Tobinova q-a, koji, kako smo pokazali, treba kontrolirati za investicijske prilike (i ponašanje investicija općenito). Jednadžba (131) ne sadržava Tobinov q. Nekoliko je razloga za to. Prvo, brojni su radovi pokazali da je koeficijent uz Tobinov q u empirijskim testiranjima relativno nizak te da druge financijske i nefinancijske varijable objašnjavaju investicije osim q-a. Primjerice, Gala i Gomes (2014) su pokazali da temeljne varijable poput veličine tvrtke i varijable toka poput prihoda i operativnih profita teorijski i empirijski bolje objašnjavaju ponašanje investicija od Tobinova q-a. Drugo, Tobinov q može se izračunati samo za tvrtke čije dionice kotiraju na organiziranim tržištima kapitala. S obzirom na mali broj tvrtki, čijim se dionicama aktivno trguje na hrvatskoj burzi, upotreba Tobinova q-a znatno bi smanjila uzorak tvrtki. Čak i uz dostupnost podataka postoje problemi s mjerenjem tržišnih vrijednosti dugova i neopipljive imovine te pogrešnim evaluacijama dionica. Treće, u pregledu literature pokazano je da Tobinov q čak i uz postojanje podataka o tržišnim vrijednostima sadržava znatnu pogrešku u mjerenju jer je nesavršen *proxy* za investicijske prilike, pa je koeficijent uz novčane tokove pristran prema gore (Erickson i Whited, 2000). Zbog svega navedenog, umjesto Tobinova q-a u modelu se upotrebljavaju druge kontrolne varijable.

Matrica X_{it} sadržava kontrolne varijable, koje su, osim novčanog toka, bitne za objašnjenje investicija. Sve su varijable pomaknute za jedno razdoblje. Stopa rasta realnih prihoda (rsg_{it}) kontrolira za očekivan rast agregatnih učinaka poduzeća u budućnosti. Rast prihoda u prošlom razdoblju trebao bi pridonijeti većoj potražnji za investicijama u sadašnjem razdoblju. Druga je kontrolna varijabla udio dodane nove vrijednosti u ukupnoj imovini (nva_{it}), koja kontrolira za promjenu agregatne potražnje i konkurentne sposobnosti poduzeća. Obje se varijable mogu označiti kao potražne varijable jer bi trebale indicirati promjenu očekivane profitabilnosti na nesavršenom kompetitivnom tržištu. Time se uklanja interpretacija prema kojoj je pozitivna osjetljivost novčanih tokova i investicija rezultat potražnih faktora, a ne smanjenja ponude kredita. Sljedeća je kontrolna varijabla broj zaposlenih (emp_{it}), koji kontrolira za veličinu poduzeća. Očekuje se da veća poduzeća imaju manji stupanj financijskog ograničenja. Razlozi su u većoj diversifikaciji i transparentnosti, što smanjuje asimetričnost informacija između tvrtke i investitora.

U pokušaju da se umanji problem endogenosti, sve kontrolne varijable pomaknute su za jedno razdoblje (isti je pristup primijenjen u Hansen 1999; Ding, Guariglia i Knight, 2014; Wang 2015). Budući da se u brojnim istraživanjima čiji je predmet analize procjena financijskog ograničenja upotrebljavaju tekuće vrijednosti nezavisnih varijabli (Fazzari i dr., 1988; Fazzari, Petersen (1993); Guargilla i Espalier, 2009; Guargilla 2009; Almeida i dr. 2004; Alti, 2003), u analizi robusnosti (poglavlju 5.5.2.) koristit će se tekućim vrijednostima novčanih tokova i ostalih kontrolnih varijabli s desne strane regresijske jednadžbe. Također, za sve kontrolne i *threshold* varijable upotrijebljen je kvadratni izraz kako bi se testirao mogući nelinearni utjecaj tih varijabli na investicije. Međutim, u svim specifikacijama modela kvadratni se član nije pokazao statistički ili ekonomski važnim, osim u primjeru dodane nove vrijednosti, pa će se jedino on upotrijebiti u daljnjim specifikacijama modela. Podsjeća se da *threshold* regresija prema Hansen (1999) ne omogućuje upotrebu zavisne varijable pomaknute za jedno razdoblje s desne strane (nije dinamički *threshold* panel).

Više se pokazatelja može upotrijebiti kao *threshold* varijabla, pri čemu izbor *threshold* varijabli treba biti u skladu s ciljem istraživanja – procjenjuje li se financijska ili likvidna ograničenost poduzeća. Naime, financijska i likvidna ograničenja različito utječu na investicije. Hipoteza o financijskom ograničenju, u skladu s poznatom hipotezom FHP-a, pretpostavlja monotono rastuću osjetljivost investicija na novčane tokove kao funkciju varijable koja odražava stupanj asimetričnosti informacija na tržištima kapitala. Što je poduzeće zaduženije, manje ili ima manju pokrivenost troškova kamata, to mu je kreditna sposobnost niža, pa je veći stupanj financijskog ograničenja (racioniranja kredita). Istraživačka hipoteza o likvidnom ograničenju pretpostavlja da osjetljivost investicija na novčane tokove kao funkcija likvidnosti ima nelinearan oblik. Osjetljivost investicija na novčane tokove nulta je ili negativna za nelikvidne tvrtke, pozitivna za granično likvidne tvrtke te ponovno teži nuli za prelikvidne tvrtke. Važno je napomenuti da ovakva dinamika vrijedi kada se u investicijskoj regresijskoj jednadžbi (131) upotrebljava vremenski pomaknuta vrijednost novčanog toka. U nastavku se ukratko opisuju razlozi izbora pojedinih *threshold* varijabli.

Koeficijent zaduženosti pokazatelj je financiranja koji odražava značajku strukture kapitala kao važnog činitelja zaštite vlastitog kapitala. Veći iznos koeficijenta zaduženosti uvećava očekivan prinos portfelja projekata, ali i varijabilnost rezultata (rizik projekta). Stoga se očekuje da rastom zaduženosti raste i stupanj financijskog ograničenja, poduzeća s malim dugovima u ukupnoj imovini trebaju imati niske koeficijente uz novčane tokove, a visoko zadužena poduzeća trebaju imati visoke koeficijente uz novčane tokove. Teorijska razrada racioniranja

kredita dana je u poglavlju 2.3. Za pokrivenost troškova kamata i veličinu poduzeća vrijedi obrnuta interpretacija. Rastom vrijednosti pokazatelja stupanj ograničenosti trebao bi biti manji, pa bi i osjetljivost investicija na novčane tokove trebala biti monotono padajuća. Veća pokrivenost kamata podrazumijeva i manje rizike od nesposobnosti plaćanja financijskih obveza, a rast veličine poduzeća najčešće se povezuje s većom kreditnom sposobnošću i fleksibilnijim izborima financiranja.

Korištenje pokazateljima likvidnosti kao *threshold* varijablama, prema hipotezi, stvara nelinearnu vezu između investicija i novčanih tokova. Stanje likvidnosti aproksimira se pomoću triju pokazatelja: 1) tekuće likvidnosti, 2) stope neto radnoga kapitala i 3) stope likvidnosti. Sva tri pokazatelja nesavršena su mjera likvidnosti jer ne uzimaju u obzir alternativne instrumente zaštite od rizika likvidnosti: derivative i bankovne kreditne linije. Međutim, novac i neto radni kapital mogu se smatrati dovoljno prikladnom mjerom iz dvaju razloga. Prvo su Lins, Servaes i Tufano (2010), intervjuirajući financijske menadžere, pokazali da je novčana štednja glavni izvor zaštite od negativnih šokova na novčane tokove, a bankovne linije služe za financiranje novih poslovnih prilika. Drugo, istraživanja su pokazala da je novčana štednja glavni izvor zaštite od likvidnosti (Almeida i dr., 2014).

Prema postavljenoj hipotezi, u svim trima varijablama likvidnosti odnos je investiranja i novčanih tokova je nelinearan. Nelikvidna poduzeća novčani tok upotrebljavaju za podmirivanje dospjelih dugova, pa ne bi trebala postojati pozitivna osjetljivost investicija na novčane tokove. Nakon ulaska u zonu likvidnosti osjetljivost bi trebala biti pozitivna. Riječ je o ograničenim poduzećima, koja su na rubu likvidne ograničenosti. Nakon određene razine osjetljivost investicija na novčane tokove trebala bi težiti nuli jer poduzeće ima dovoljno novca za potencijalne investicijske pothvate. Detaljna teorijska razrada odnosa likvidnog ograničenja i investicija dana je u poglavlju 2.4..

Pojedini autori upućuju na problem endogenosti *threshold* varijable i kontrolnih varijabli općenito. Angrist i Pischke (2009) kontrolne varijable koje i same mogu biti endogene nazivaju „lošim“ kontrolnim varijablama. Zato je za valjanu specifikaciju modela potrebno odgovoriti na pitanje: je li tekuća likvidnost endogena varijabla? Može se pretpostaviti da je varijabla endogena prema dolje. Model ACW iz poglavlja 3.2.2. i istraživanje Bruinshoofd i Kool (2006) potvrđuju ovu tvrdnju. Poduzeće relativno lako može smanjiti tekuću likvidnost. Međutim, reverzibilnost je u suprotnu smjeru otežana. Teško je zamisliti zašto bi poduzeće namjerno uspostavilo stanje nelikvidnosti. Dodatno, kao nezavisna varijabla upotrebljava se neto radni

kapital s jednim pomakom unatrag. Poduzeće u tekućoj godini ne može kontrolirati likvidnost iz prethodna razdoblja. Također, treba upozoriti na još jednu mogućnost. Uspostavljanje likvidnosti oko omjera 1,3 (prosjek razvijenih zemalja, Tintor 2009) može se smatrati razumnim i primjerenim za uspješno poslovanje. Pretjerana likvidnost može jednostavno značiti probleme u upravljanju i identificiranju novih poslovnih prilika za investiranje. Međutim, kvalitetu menadžmenta teško je identificirati pa se može samo nagađati o važnosti ove nedostajuće varijable na empirijski rezultat. Visoki omjeri mogu biti i rezultat zahtjeva kreditora za održavanjem viših razina likvidnosti.

Jednadžba (131) je procijenjena metodom najmanjih kvadrata. Kod je preuzet od Wanga (2015), a može se preuzeti i primijeniti pomoću statističkog softvera Stata.

5.4 Rezultati analize investicijskoga kanala financijskih frikcija mjerenjem osjetljivosti investicija na novčane tokove

U ovom se poglavlju donose rezultati procijenjene *threshold* regresije. Prvo se prikazuju rezultati procjene financijskog ograničenja, to jest modela u kojem se kao *threshold* varijable upotrebljavaju pokazatelji financiranja i kreditne sposobnosti. U poglavlju 5.5.2. dani su rezultati procjene likvidnog ograničenja, odnosno modela s pokazateljima likvidnosti kao *threshold* varijablom. Konačno, u poglavlju 5.5.3. pokazuje se heterogenost u stupnju financijskog i likvidnog ograničenja poslovnih subjekata u Republici Hrvatskoj s obzirom na udjel javnog i inozemnog kapitala.

5.4.1 Rezultati analize financijskog ograničenja poslovnih subjekta

U ovom poglavlju prikazuju se rezultati nedinamičkog panel *threshold* regresijskog modela (jednadžba 137). Zbog upotrebe šest različitih *threshold* varijabli postoji i šest različitih specifikacija modela. U prvom dijelu analize prikazuju se rezultati testova o postojanju jedne ili dviju granica, to jest dvaju ili triju režima. Kada se utvrdi broj i vrijednosti granica, prikazuju se vrijednosti procijenjenih parametara modela. Osobito je važna osjetljivost investicija na novčane tokove za različite režime. Prvo će se testirati postojanje i stupanj financijskog ograničenja (poglavlje 5.4.1.), a potom, u poglavlju 5.4.2., istraživačka hipoteza o postojanju likvidnog ograničenja.

U tablici 5-4 prikazani su rezultati testova o postojanju jedne i dviju granica, odnosno o postojanju dvaju ili triju režima. Test na jednu granicu pretpostavlja testiranje hipoteze o postojanju dvaju režima, odnosno $H_0: \beta_1 = \beta_2$. Test o postojanju dviju granica pretpostavlja testiranje hipoteze o postojanju triju režima. U tablici su prikazane „bootstrap“ p vrijednosti i intervali pouzdanosti uz razinu signifikantnosti 95 %, za testove na jednu i dvije granice, za skup varijabli koje odražavaju financijsko i likvidno stanje poslovnih subjekata.

Tablice 5-5 i 5-6 prikazuju procijenjene koeficijente uz novčane tokove i kontrolne varijable u modelima s jednom i dvjema granicama. Najvažnija je razlika u osjetljivosti investicija na novčane tokove za različite režime. Oznaka pojedinog koeficijenta odgovara nazivu pojedinog režima: visoki, srednji i niski. Koeficijent cf_{it-1}^{nisko} odražava granični utjecaj novčanog toka na investicije za opservacije u prvom režimu. Koeficijent $cf_{it-1}^{srednje}$ pokazuje osjetljivost investicija na novčane tokove za srednje zadužena ili likvidna poduzeća. Treći režim pokazuje međuovisnost investicija i novčanog toka za visoko zadužena ili prelikvidna poduzeća.

Tablica 5-7 pokazuje kretanje broja poduzeća koja pripadaju pojedinom režimu, za svaku promatranu godinu. Tablica omogućuje identificiranje važnosti financijskog i likvidnog ograničenja prateći postotni udio broja poduzeća koja pripadaju skupini prezaduženih ili prelikvidnih poduzeća. Također, moguće je pratiti dinamiku financijskog i likvidnog ograničenja kroz vrijeme. U nastavku opisujemo rezultate panel *threshold* regresije pomoću triju navedenih tablica.

Rezultati *threshold* regresije s koeficijentom zaduženosti kao *threshold* varijablom pokazuju postojanje dviju granica. Test o postojanju jedne granice pokazuje jaku signifikantnost u prilog odbacivanju nulte hipoteze (linearni model). Test o postojanju dviju granica također pokazuje jaku signifikantnost u prilog odbacivanju nulte hipoteze (jedna granica). Dakle, može se prihvatiti model s dvjema granicama.

Prvi režim obuhvaća opservacije čija je vrijednost ukupnih obveza do 69,4 % knjigovodstvene vrijednosti imovine. Drugi režim obuhvaća opservacije čija je vrijednost pokazatelja koeficijenta zaduženosti u intervalu 69,4 % – 87,3 %. Treći režim obuhvaća opservacije s koeficijentom zaduženosti iznad 87,3 %. Za identificirane režima upotrebljavaju se nazivi: nezadužena poduzeća, umjereno zadužena poduzeća i prezadužena poduzeća. F statistika za prvu granicu iznosi 189.54, a kritične vrijednosti, uz razinu signifikantnosti 1 %, 5 % i 10 % iznose 43, 30 i 26. F statistika za drugu granicu iznosi 75,70, a kritične vrijednosti, uz razinu

signifikantnosti 1 %, 5 % i 10 % iznose 43, 31 i 27. Više informacija o *threshold* varijablama može se dobiti pogledom na sliku 5-2, koja prikazuje funkciju omjera vjerodostojnosti (LR funkcija) za dvije granice. Procijenjene *threshold* vrijednosti odgovaraju vrijednosti na grafu gdje omjer vjerodostojnosti presijeca isprekidanu liniju koja označava kritičku vrijednost uz razinu signifikantnosti od 95 %.

Tablica 5-4: Rezultati testova o postojanu granica za skup financijskih i likvidnih threshold varijabli uz 95 % interval pouzdanosti

***Threshold* varijabla (q)**	p	γ_1, γ_2	**Donja granica**	**Gornja granica**
Koeficijent zaduženosti (ten_{t-1})				
Test na jednu granicu	0.000	0.694	0.686	0.696
Test na dvije granice	0.000	0.694	0.686	0.696
	0.000	0.873	0.867	0.876
Pokrivenost kamata ($icov_{t-1}$)				
Test za jednu granicu	0.0000	0.975	0.940	0.999
Test na dvije granice	0.0000	0.975	0.951	0.999
	0.0000	−2.639	−3.628	−2.242
Veličina ($size_{t-1}$)				
Test za jednu granicu	0.0000	521,876	510,228	527,926
Test na dvije granice	0.0000	521,839	510,075	527,915
	0.0020	2,111,098	1,975,672	2,138,810
Likvidnost (liq_{t-1})				
Test za jednu granicu	0.0000	0.299	0.294	0.302
Test na dvije granice	0.0000	0.299	0.294	0.302
	0.0000	− 0.139	−0.149	−0.133
Tekući omjer (cr_{t-1})				
Test za jednu granicu	0.0000	0.888	0.877	0.893
Test na dvije granice	0.000	0.866	0.853	0.877
	0.000	1.554	1.537	1.561
Radni kapital (wc_{t-1})				
Test za jednu granicu	0.0000	−0.071	−0.078	−0.064
Test na dvije granice	0.0000	−0.106	−0.117	−0.0103
	0.0000	0.306	0.297	0.308

BILJEŠKA: U tablici su prikazani rezultati testova o postojanju jedne ili dviju granica za skup *threshold* varijabli. Test na jednu granicu pretpostavlja testiranje hipoteze o postojanju dvaju režima ($H_0 : q = 1$) nasuprot linearnome modelu ($H_0 : q = 0$). Test na dvije granice pretpostavlja testiranje hipoteze o postojanju triju režima ($H_0 : q = 2$) nasuprot dvama režima ($H_0 : q = 1$). Oznaka p „bootstrap“ je vrijednosti na temelju 500 „bootstrap“ replikacija; γ_1, γ_2 predstavljaju vrijednosti granica – jedna u testu na jednu granicu i dvije u testu na dvije granice. Oznake „donja granica“ i „gornja granica“ odnose se na interval pouzdanosti uz razinu signifikantnosti od 95 %. Pri procjeni je upotrijebljeno 1 % skraćivanje (engl. *trimm*).

Tablica 5-5: Procijenjeni parametri statičke threshold regresije na balansiranu uzorku poslovnih subjekata s trima režimima

Model	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***
Zavisna varijabla	inv_{it}	inv_{it}	inv_{it}	inv_{it}	inv_{it}	inv_{it}
Fiksni efekti za tvrtke	DA	DA	DA	DA	DA	DA
Fiksni efekti za godine	DA	DA	DA	DA	DA	DA
Režim $q_{\{it\}} \leq \gamma_1$						
cf_{it-1}^{nisko}	0.007	-0.093^{***}	0.004	-0.075^{***}	-0.004	-0.006
	(0.005)	(0.0011)	(0.005)	(0.009)	(0.008)	(0.007)
emp_{it-1}	-0.000^{***}	-0.000^{***}	0.005^{***}	-0.000^{***}	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	-0.000	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.122^{***}	0.107^{***}	0.129^{***}	0.029^{***}	0.046^{***}	0.050^{***}
	(0.004)	(0.009)	(0.005)	(0.008)	(0.007)	(0.007)
nva_{it-1}^2	-0.031^{***}	-0.029^{***}	-0.033^{***}	0.014^{***}	0.001	-0.002
	(0.002)	(0.006)	(0.002)	(0.005)	(0.004)	(0.004)
Režim $\gamma_1 < q_{\{it\}} \leq \gamma_2$						
$cf_{it-1}^{srednje}$	0.038^{***}	-0.082^{***}	0.036^{***}	-0.037^{***}	0.028^{***}	0.028^{***}
	(0.008)	(0.006)	(0.008)	(0.009)	(0.006)	(0.006)

emp_{it-1}	-0.000^{***}	-0.000^{***}	0.000	-0.000^{***}	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.064^{***}	0.107^{***}	0.090^{***}	0.089^{***}	0.090^{*}	0.083^{***}
	(0.006)	(0.009)	(0.006)	(0.006)	(0.005)	(0.005)
nva_{it-1}^2	-0.007^{**}	0.015^{***}	-0.024^{***}	-0.017^{***}	-0.019^{***}	-0.013^{***}
	(0.003)	(0.006)	(0.003)	(0.004)	(0.003)	(0.003)
Režim $q_{\{it\}} > \gamma_2$						
cf_{it-1}^{visoko}	-0.025^{***}	0.028^{***}	0.095^{***}	0.016^{***}	-0.002	0.000
	(0.008)	(0.005)	(0.009)	(0.005)	(0.005)	(0.005)
emp_{it-1}	-0.000^{***}	-0.000^{**}	-0.000^{***}	0.000^{***}	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{**}	0.000^{***}	0.000^{***}	0.000	0.000^{*}	0.000
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.058^{***}	0.108^{***}	-0.016^{**}	0.120^{***}	0.130^{***}	0.129^{***}
	(0.008)	(0.004)	(0.008)	(0.005)	(0.005)	(0.005)
nva_{it-1}^2	0.002	-0.027^{***}	0.012^{**}	-0.031^{***}	-0.032^{***}	-0.034^{***}
	(0.004)	(0.002)	(0.005)	(0.002)	(0.002)	(0.002)
$q_{\{it\}}$	**Koeficijent zaduženosti**	**Pokriće trošk. kamata**	**Veličina**	**Stopa likvidnosti**	**Tekući omjer**	**NRK/imovina**

Broj opservacija	146020	146020	146020	146020	146020	146020
RSS	3306	3300	3296	3300	3304	3303
F statistika	75.70	61.16	254.90	137.14	86.70	117.07

BILJEŠKA: Zavisna je varijabla stopa investicija, $inv_{it} = \frac{I_{it}}{A_{it-1}}$, gdje su investicije, I_{it}, jednake razlici zbroja materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju, a A_{it-1} je vrijednost imovine pomaknuta za jedno razdoblje. Koeficijent zaduženosti ten_{t-1} izračunan je kao omjer ukupnog duga i imovine. Pokriće troškova kamata $icov_{t-1}$ jednako je omjeru EBIT-a i troškova kamata. Veličina, $size_{t-1}$ jednaka je knjigovodstvenoj vrijednosti imovine poduzeća. Stopa likvidnosti liq_{t-1} računa se kao omjer neto radnoga kapitala uvećana za tekuće novčane tokove i imovine. Tekuća likvidnost cr_{t-1} jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Stopa neto radnoga kapitala, wc_{t-1}, računa se kao odnos neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Osnovna važna varijabla stopa je novčanog toka, koja je jednaka omjeru novčanog toka (dobit + amortizacija) i vremenski pomaknute vrijednosti imovine. Kontrolna varijabla emp_{it-1} označuje broj zaposlenih; rsg_{it-1} realnu stopu rasta prihoda; nva_{it-1} stopu dodane nove vrijednosti. U zagradi su dane standardne pogreške. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Tablica 5-6: Procijenjeni parametri statičke threshold regresije na balansiranu uzorku poslovnih subjekata s dvama režimima

Model	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***
Zavisna varijabla	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}
Fiksni efekti za tvrtke	DA	DA	DA	DA	DA	DA
Fiksni efekti za godine	DA	DA	DA	DA	DA	DA
Režim $q_{\{it\}} \leq \gamma_1$						
cf_{it-1}^{nisko}	0.006	-0.109^{***}	0.003	-0.045^{***}	-0.003	-0.001
	(0.005)	(0.0081)	(0.005)	(0.007)	(0.007)	(0.007)
emp_{it-1}	-0.000^{***}	-0.000^{***}	0.003^{***}	-0.000^{***}	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.120^{***}	0.071^{***}	0.122^{***}	0.073^{***}	0.053^{***}	0.058^{***}
	(0.004)	(0.006)	(0.005)	(0.006)	(0.007)	(0.006)
nva_{it-1}^2	-0.030^{***}	-0.005	-0.030^{***}	-0.009^{***}	-0.002	-0.005
	(0.002)	(0.004)	(0.002)	(0.003)	(0.004)	(0.004)
Režim $q_{\{it\}} > \gamma_2$						
cf_{it-1}^{visoko}	0.010^{*}	0.028^{***}	0.053^{***}	0.016^{***}	0.012^{***}	0.012
	(0.006)	(0.004)	(0.006)	(0.005)	(0.004)	(0.007)

emp_{it-1}	-0.000^{***}	-0.000^{***}	-0.000^{***}	-0.000^{***}	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000^{***}	0.000^{***}	0.000	0.000^{**}	0.000^{**}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.065^{***}	0.108^{***}	0.058^{***}	0.116^{***}	0.113^{***}	0.058^{***}
	(0.005)	(0.004)	(0.006)	(0.005)	(0.004)	(0.006)
nva_{it-1}^2	-0.005^{*}	-0.027^{***}	-0.011^{***}	-0.029^{***}	-0.027^{***}	-0.027^{***}
	(0.003)	(0.002)	(0.003)	(0.002)	(0.002)	(0.002)
$\boldsymbol{q_{\{it\}}}$	**Koeficijent zaduženosti**	**Pokriće trošk. kamata**	**Veličina**	**Stopa likvidnosti**	**Tekući omjer**	**NRK/imovina**
Broj opservacija	146020	146020	146020	146020	146020	146020
RSS	3306	3301	3302	3303	3305	3305
F statistika	189.54	418.43	392.97	354.92	234.58	213.88

BILJEŠKA: Zavisna je varijabla stopa investicija, $inv_{it} = \frac{I_{it}}{A_{it-1}}$, gdje su investicije, I_{it}, jednake razlici zbroja materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju, a A_{it-1} je vrijednost imovine pomaknuta za jedno razdoblje. Koeficijent zaduženosti ten_{t-1} izračunan je kao omjer ukupnog duga i imovine. Pokriće troškova kamata $icov_{t-1}$ jednako je omjeru EBIT-a i troškova kamata. Veličina, $size_{t-1}$, jednaka je knjigovodstvenoj vrijednosti imovine poduzeća. Stopa likvidnosti liq_{t-1} računa se kao omjer neto radnoga kapitala uvećanog za tekuće novčane tokove i imovine. Tekuća likvidnost cr_{t-1} jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Stopa neto radnoga kapitala, wc_{t-1}, računa se kao odnos neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Osnovna važna varijabla stopa je novčanog toka, koja je jednaka omjeru novčanog toka (dobit + amortizacija) i vremenski pomaknute vrijednosti imovine. Kontrolna varijabla emp_{it-1} označuje broj zaposlenih; rsg_{it-1} realnu stopu rasta prihoda; nva_{it-1} stopu dodane nove vrijednosti. U zagradi su dane standardne pogreške. Oznake $*$, $**$, $***$ skraćene su oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Tablica 5-7: Postotak tvrtki koje pripadaju pojedinim režimima od 2002. do 2014.

Režim	'02	'03	'04	'05	'06	'07	'08	'09	'10	'11	'12	'13	'14
$ten < 0.69$	54	54	57	59	62	63	64	66	66	66	63	61	64
$0.69 < ten < 0.87$	28	28	27	25	24	24	24	22	21	20	20	21	18
$0.87 < ten$	18	18	16	15	14	13	12	12	13	14	17	18	18
$icov < -2.69$	5	5	5	6	5	5	5	5	10	12	12	14	14
$-2.69 > icov < 0.97$	8	11	13	13	12	12	12	15	18	19	20	20	18
$0.97 < icov$	85	84	82	81	83	83	83	80	72	69	68	67	68
$size < 0.5$	40	37	34	33	31	31	29	28	29	30	31	32	32
$0.5 > size < 2.1$	30	30	31	30	30	29	29	28	28	27	27	27	27
$2.1 < size$	30	33	35	37	39	30	42	44	43	43	42	41	41
$liq < -0.14$	10	9	9	9	9	8	8	8	10	11	12	14	14
$-0.14 > liq < 0.29$	38	36	35	36	35	34	33	34	37	36	36	37	34
$0.29 < liq$	52	55	56	55	56	58	59	58	53	53	52	49	52
$cr < 0.86$	19	18	16	16	16	15	15	15	16	17	18	19	19
$0.86 > cr < 1.55$	47	44	43	40	38	37	36	34	33	31	31	32	29
$1.55 < cr$	34	38	41	44	46	48	50	51	51	51	51	49	52
$wc < -0.11$	18	17	15	15	15	14	13	13	13	14	16	17	17
$-0.11 > wc < 0.30$	49	46	45	45	45	43	42	43	42	44	40	41	38
$0.30 < wc$	33	37	40	40	41	43	45	44	45	42	44	42	45

Ključan dio rezultata označava osjetljivost investicija na novčane tokove za svaki režim. Prva kolona tablice 5-5 pokazuje da se može odbaciti postavljena istraživačka hipoteza o monotono rastućoj osjetljivosti investicija na novčane tokove. Koeficijent uz novčane tokove u prvom režimu ($ten < 69\%$) iznosi $cf_{t-1}^{nisko} = 0{,}007$ i nesignifikantan je uz razinu značajnosti od 10 %. Za poduzeća iz režima srednje zaduženih ($69\,\% > ten < 87\,\%$) koeficijent iznosi $cf_{t-1}^{srednje} = 0{,}038$. Za opservacije iz trećeg režima ($ten > 87\%$), koeficijent je uz novčani tok negativan i iznosi $cf_{t-1}^{visoko} = -0{,}025$. Procijenjeni koeficijenti u drugom i trećem režimu statistički su signifikantni (p vrijednosti iznose 0,000). Koeficijenti u prvim dvama režimima u skladu su s postavljenom hipotezom. Nisko zadužena poduzeća kreditno su sposobna, pa se mogu koristiti eksternim financiranjem za investicijske pothvate. Stvaranje novčanog toka stoga u manjem stupnju utječe na realne investicije. S druge strane, dio srednje zaduženih

poduzeća financijski je ograničen pa može financirati projekte jedino rastom internih izvora financiranja, to jest iz stvorene dobiti. To potvrđuje i koeficijent uz novčani tok koji je za srednje zadužena poduzeća 0,03 veći od procijenjena koeficijenta za nisko zadužena poduzeća. Vrijednost koeficijenta u trećem režimu poprima vrijednosti suprotne prvoj hipotezi.

Prema teorijskim modelima i nalazima prethodnih istraživanja o osjetljivosti investicija na novčane tokove za različite, apriorno klasificirane skupine poduzeća, koeficijent uz novčane tokove trebao bi biti veći čak i od koeficijenta u drugom režimu jer su poduzeća u trećem režimu zaduženija, a time i financijski ograničenija. Suprotno postavljenoj hipotezi, najzaduženija poduzeća pokazuju ne samo najmanju nego i negativnu osjetljivost investicija na novčane tokove. Razlog može biti u tome što ona pripadaju skupini financijsko ugroženih poduzeća, koja su najčešće i nelikvidna, pa novi novčani tok služi za uspostavljanje primjerene likvidnosti i minimiziranje dugova, a ne investicija (ova će se teza detaljnije analizirati za likvidno ograničenje).

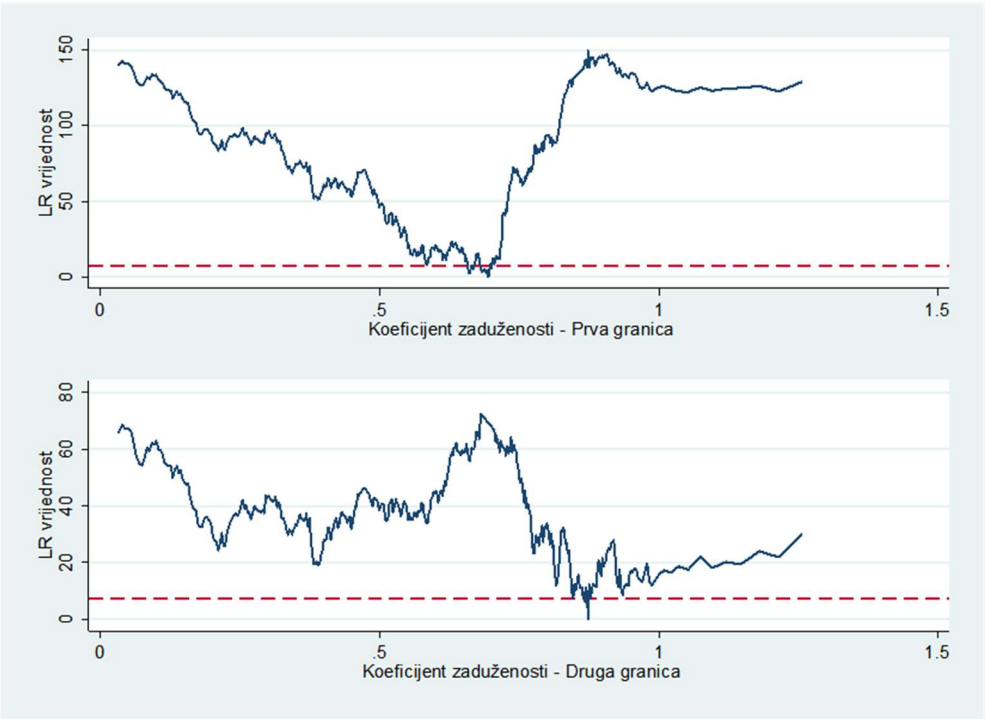

Slika 5-1: LR statistika za dvije granice s koeficijentom zaduženosti kao threshold varijablom

Cilj je procjene odrediti i broj financijski ograničenih tvrtki i dinamiku kretanja tijekom vremena. Ovu analizu omogućuju podaci u tablici 5-7. Ako se prihvati teza da ekonomski i statistički signifikantna osjetljivost investicija na novčane tokove odražava stupanj financijskog

ograničenja, onda podaci pokazuju da u prosjeku najviše hrvatskih poduzeća pripada skupini nisko zaduženih. Dinamika je također zanimljiva. Prema podacima, tijekom cijelog razdoblja raste broj nisko zaduženih poduzeća, čak i nakon financijske krize, međutim, raste i broj visoko zaduženih poduzeća, a broj srednje zaduženih smanjuje se tijekom cijelog razdoblja. Može se indicirati dvojak fenomen nakon financijske krize: sve više financijski ograničenih poduzeća i sve veći udio poduzeća s manjim udjelom duga u ukupnoj imovini.

Druga specifikacija kao *threshold* varijablu sadržava pokrivenost kamata. Prvo je uz jaku signifikantnost odbačena nulta hipoteza o linearnome modelu. Potom je uz razinu značajnosti od 1 % odbačena nulta hipoteza o postojanju 1 granice (p za drugu granicu iznosi 0,000). Testom na treću granicu prihvaća se nulta hipoteza o postojanju dviju granica. Dakle, prihvaća se model s dvjema granicama i trima režimima. Funkcija omjera vjerodostojnosti (LR funkcija) za dvije granice dana je na slici 5-3. Prva granica ima vrijednost 0,975 (F statistika iznosi 418.43, a kritična vrijednost uz razinu signifikantnosti 1 % iznosi 19). Druga granica iznosi -2,639 (F statistika iznosi 61,16, a kritična vrijednost uz razinu signifikantnosti 1 % iznosi 27). Na grafikonu granice izgledaju vrlo blizu jedna drugoj zbog velikog raspona vrijednosti pokrića troškova kamata. Iako su granice blizu, u prosjeku 15 % poduzeća pripada srednjem režimu (tablica 5-7). Svi koeficijenti uz novčane tokove statistički su signifikantni (p vrijednost iznosi 0,000). U prvom režimu, vrijednost je koeficijenta negativna i iznosi$cf_{t-1}^{nisko} = -0{,}093$. U drugom režimu koeficijent ima vrijednost $cf_{t-1}^{srednje} = -0{,}082$, a u trećem režimu $cf_{t-1}^{visoko} = 0{,}028$. Procijenjeni koeficijenti nisu u skladu s postavljenom hipotezom. Poduzeća koja ostvaruju veći iznos pokrića kamata imaju i veću kreditnu sposobnost, pa nove investicije mogu financirati iz izvanjskih izvora. S rastom kamatnih tereta raste i stupanj financijske ograničenosti jer financijske institucije zbog rasta rizika smanjuju ponudu kredita (racioniranje kredita). Stoga bi se očekivalo da poduzeća u trećem režimu imaju najmanju ili nultu osjetljivost investicija na novčane tokove, a poduzeća u prvom režimu imaju najveću osjetljivost investicija na novčane tokove. Međutim, rezultati su upravo suprotni. Rastom pokazatelja raste i osjetljivost investicija na novčane tokove. Ovakva dinamika može biti rezultat poznatog problema endoegenosti u investicijskoj jednadžbi, to jest korelacije novčanih tokova i buduće profitabilnosti.

Dinamika kroz vrijeme pokazuje vrlo zanimljiv trend. Broj poduzeća u prvom režimu, uz blage oscilacije, stalno raste tijekom cijeloga promatranog razdoblja. Podsjetimo da su u prvom režimu poduzeća koja ostvaruju zaradu prije kamata i poreza nižu od troškova kamata. Broj

poduzeća u ovom režimu utrostručio se u promatranu razdoblju. Iznenađujuće, ova je skupina poduzeća (prezadužena skupina), prema osjetljivosti investicija i novčanih tokova najmanje zadužena. Istodobno može se primijetiti da se udio nisko zaduženih poduzeća (visoke vrijednosti pokazatelja pokrića kamata) smanjio s 85 % na 68 %. Dinamika dakle pokazuje rast visoko zaduženih poduzeća u ukupnom uzorku.

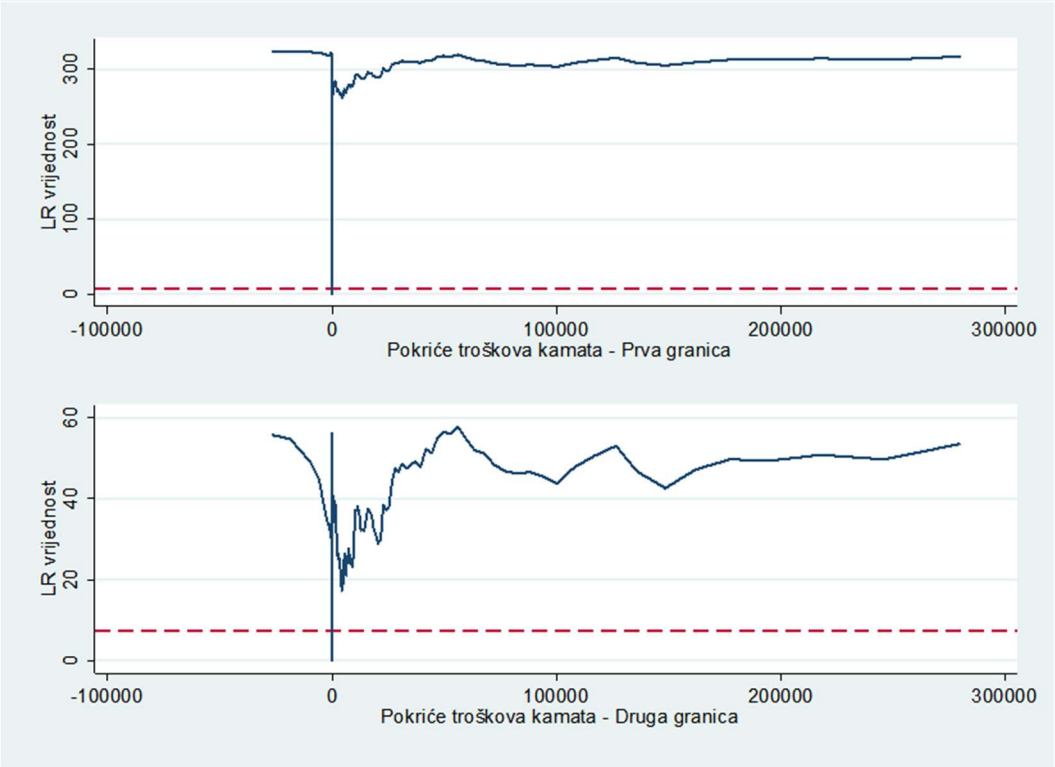

Slika 5-2: LR statistika za dvije granice s pokrićem troškova kamata kao threshold varijablom

Korištenje veličinom poduzeća (razina knjigovodstvene vrijednosti imovine) kao *threshold* varijablom zahtijeva drukčiju interpretaciju rezultata analize. Naime, očekuje se da se rastom poduzeća smanjuje osjetljivost investicija na novčane tokove (veća poduzeća imaju manji stupanj financijskog ograničenja). Ova se varijabla u literaturi vrlo često upotrebljava kao kriterij razgraničavanja financijski ograničenih poduzeća. Rezultati pokazuju prihvaćanje modela s trima režimima. Prva granica ima vrijednost 0,52 mil. kn (signifikantnost uz razinu značajnosti od 1 %). Druga granica ima vrijednost 2,11 mil. kn (signifikantna uz razinu značajnosti od 1 %). Koeficijenti uz novčane tokove pokazuju monoton pad kroz režime. Osjetljivost investicija na novčane tokove u prvom režimu nije različita od nule (prihvaća se nulta hipoteza). U drugom je režimu pozitivna, $cf_{t-1}^{srednje} = 0{,}036$, a u trećem režimu koeficijent iznosi $cf_{t-1}^{visoko} = 0{,}095$ (koeficijenti u zadnjim dvama režimima signifikantni su uz

razinu značajnosti od 1 %). Ovakvi rezultati nisu u skladu s istraživačkom hipotezom. Najveća bi poduzeća trebala imati najmanju osjetljivost novčanih investicija na novčane tokove, a u procjeni to nije tako. U prosjeku, oko 28 % poduzeća pripada srednje velikim poduzećima, 32 % malim poduzećima, a 38 % velikim poduzećima. Pri tome broj velikih poduzeća raste tijekom cijelog razdoblja, a broj se srednjih i malih smanjuje.

Slika 5-3: LR statistika za dvije granice s veličinom poduzeća kao threshold varijablom.

Testovi o nelinearnosti u osjetljivosti investicija na novčane tokove za različite *threshold* varijable i vrijednosti procijenjenih koeficijenata potvrđuju odbacivanje istraživačke hipoteze o monotonu rastu stupnja financijskog ograničenja rastom zaduženosti poduzeća. Vrijednosti koeficijenata ne pokazuju monoton rast osjetljivosti kroz režime. Većina poduzeća u uzorku pokazuje pozitivne koeficijente uz pomaknute novčane tokove (u odnosu prema drugim, režimski neovisnim varijablama). Primjerice, u prvoj specifikaciji oko 80 % poduzeća pokazuje pozitivnu osjetljivost investicija na novčane tokove, u drugoj specifikaciji vrijednost koeficijenta za visoki režim iznosi 0,038, a u trećoj specifikaciji u dvama režimima zabilježena je pozitivna osjetljivost investicija na novčane tokove. Dakle, koeficijenti su općenito visoki, ali ne služe kao odgovarajući test za procjenu financijske ograničenosti poslovnih subjekata u Republici Hrvatskoj. Važno je primijetiti da rezultati testa ne mogu biti dokaz nepostojanja

financijskih ograničenja. Mnogo je vjerojatnije da empirijski dizajn koji se oslanja na mjerenje osjetljivosti investicija na novčane tokove za različite skupine poduzeća, a koji je započeo s radom FHP, ne može pouzdano i točno odrediti stupanj financijskog ograničenja tvrtki. Također, zanimljivo je primijetiti negativnu osjetljivost investicija na novčane tokove za visoko zadužena poduzeća u prvim dvjema specifikacijama. Može se indicirati podudaranje rezultata s heurističkim prikazom u poglavlju 2.4.1.. Detaljnija analiza ovakve vrijednosti koeficijenta bit će dana u nastavku.

5.4.2 Rezultati analize likvidnog ograničenja poslovnih subjekta

Analiza likvidnog ograničenja započinje predočavanjem rezultata *threshold* regresije sa stupnjem likvidnosti kao *threshold* varijablom. Stopa likvidnosti jednaka je neto radnom kapitalu uvećanom za tekući novčani tok i podijeljenim s pomaknutom vrijednosti imovine. Rezultati testova i procijenjenih parametara dani su u tablicama 5-4, 5-5, 5-6 i 5-7.

U tablici 5-4 prikazane su procijenjene *threshold* vrijednosti te asimptotski 95 % intervali pouzdanosti. Testom o postojanju jedne granice odbačena je nulta hipoteza o linearnome modelu (signifikantno uz razinu pouzdanosti od 1 %). U drugom je koraku testirana hipoteza o postojanju dviju granica. Testom se odbacuje nulta hipoteza o postojanju jedne granice. Test na treću granicu pokazuje „bootstrap“ p vrijednost jednaku 0,904, pa se prihvaća model s dvjema granicama (trima režimima).

Prva *threshold* vrijednost (prva granica) iznosi - 0,139, a druga procijenjena *threshold* vrijednost iznosi 0,299. Iz tablice 5-4 vidljivo je da su intervali pouzdanosti vrlo blizu procijenjenih vrijednosti, pa se vrijednosti granica mogu smatrati pouzdanima. Dakako, mali intervali pouzdanosti rezultat su velikog uzorka. Na slici 5-5 prikazana je funkcija omjera vjerodostojnosti i vrijednost kritične granice.

Granice raspodjeljuju uzorak na tri režima. U prvom režimu ($liq < -0{,}139$) postoji negativan odnos novčanih tokova i investicija, $cf_{t-1}^{nisko} = -0.075$ (signifikantno uz razinu značajnosti 1 %). U drugom režimu ($-0{,}13 < liq < 0{,}30$), osjetljivost je investicija na novčane tokove negativna, $cf_{t-1}^{srednje} = -0{,}037$, ali manja od razine koeficijenta u prvom režimu (bliže nuli). U trećem je režimu vrijednost koeficijenta pozitivna i iznosi $cf_{t-1}^{visoko} = 0{,}016$, signifikantno uz razinu značajnosti od 1 %. Subjekti u režimima mogu se označiti kao nelikvidni, likvidni i

prelikvidni. Procijenjeni koeficijenti djelomično su u skladu s istraživačkom hipotezom o nelinearnoj povezanosti osjetljivosti investicija na novčane tokove i pokazatelja likvidnosti kao *threshold* varijablom. Nelikvidna poduzeća ne koriste se novčanim tokom za nove investicije. U kontekstu već prikazanih teorijskih modela ova je skupina poduzeća doživjela određen likvidni šok, pa stvoreni novčani tokovi služe za uspostavljenje primjerene likvidnosti i održavanje postojećih projekata. Štoviše, koeficijenti pokazuju negativne vrijednosti čime se indicira dezinvestiranje radi oslobađanja novčanih tokova monetizacijom sredstava. Poduzeća u drugom režimu također se mogu smatrati nelikvidnima jer je vrijednost stope likvidnosti vrlo niska. Ova skupina poduzeća ipak ima manju negativnu vrijednost osjetljivosti investicija na novčane tokove. Kako razina likvidnosti raste, očekuje se da nakon određene razine osjetljivosti na novčane tokove ima vrijednost nula. Treća skupina poduzeća pokazuje pozitivnu osjetljivost investicija na novčane tokove. Može se zaključiti da su koeficijenti u skladu s postavljenom hipotezom. Međutim, kada bi bio identificiran dodatan režim s izrazito likvidnim poduzećima koja imaju nultu osjetljivost investicija na novčane tokove, investicije bi se ponašale posve u skladu s hipotezom.

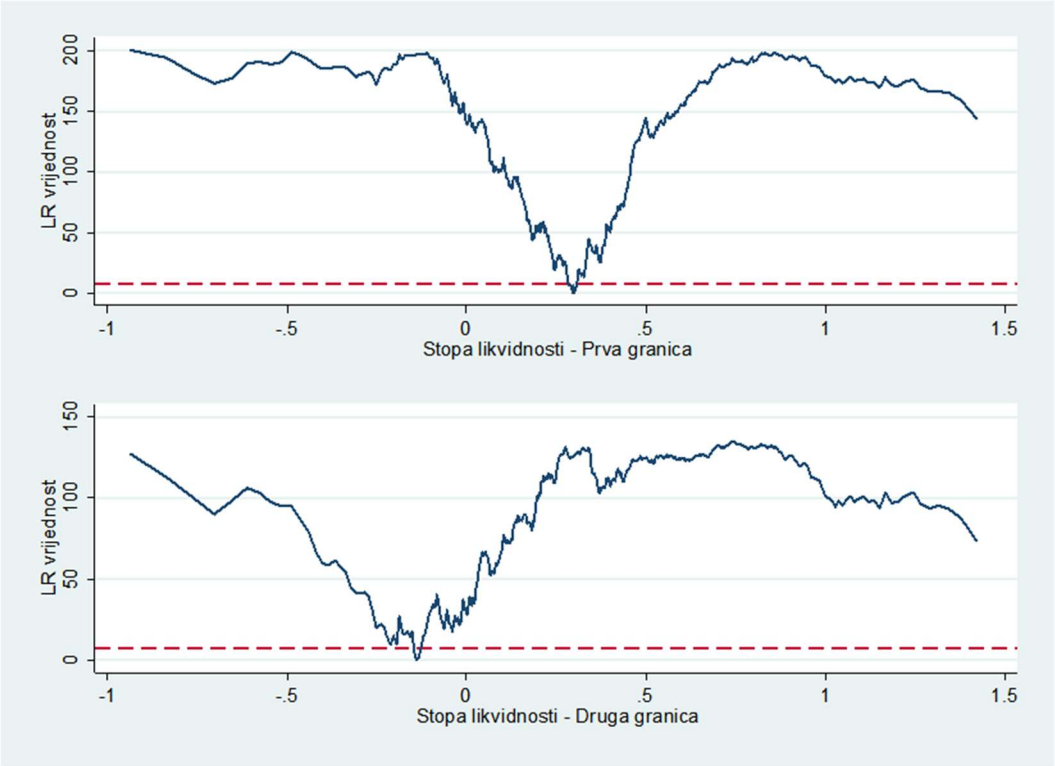

Slika 5-4: LR statistika za dvije granice sa stopom likvidnosti poduzeća kao threshold varijablom.

Struktura po kriteriju broja poduzeća, po režimima, ostaje relativno stabilna tijekom promatrana razdoblja. Najveći je udio „prelikvidnih“ poduzeća (54 %), a manji udjel imaju „nelikvidna“ (10 %) i „likvidna“ poduzeća (35 %). Dinamika pokazuje rast nelikvidnih poduzeća od 2007. do 2014. (rast od 4 postotna boda od 2010. do 2014.). Ipak najveći broj poduzeća pripada skupini „prelikvidnih“ poduzeća. Tablica dakle pokazuje rast udjela likvidno ograničenih i prelikvidnih poduzeća nakon financijske krize.

Sljedeća specifikacija kao *threshold* varijablu upotrebljava tekuću likvidnost (omjer kratkotrajne imovine i kratkotrajnih obveza). Ponovno se prihvaća model s dvjema granicama. Prvo se ne prihvaća nulta hipoteza o linearnome modelu (p vrijednost iznosi 0,000). Potom test na dvjema granicama pokazuje postojanje dviju granica: 0,72 i 1,55. Radi boljeg uvida, na slici 5-6 prikazuje se funkcija omjera vjerodostojnosti (LR funkcija) za dvije granice. Na temelju prikazanih rezultata testova i grafa slike 5-6 može se ustanoviti da postoje tri režima. Pri tome je osjetljivost investicija na novčane tokove u prvom režimu nesignifikantna, a u drugom je režimu signifikantna i iznosi $cf_{t-1}^{srednje} = 0{,}028$. Ovakva dinamika odnosa investicija i novčanih tokova u skladu je s drugom hipotezom: likvidno ograničena poduzeća ne koriste se dodatnim novčanim tokom za investiranje, a likvidno se ograničena poduzeća koriste. Naime, prema hipotezi, tvrtke s nižim stupnjem likvidnosti pokazuju manji stupanj osjetljivosti investicija na novčane tokove. Poduzeća u trećem režimu ponovno pokazuju nultu osjetljivost investicija na novčane tokove. Ovakva vrijednost koeficijenta u skladu je s istraživačkom hipotezom jer „prelikvidna“ poduzeća imaju dostatan iznos internih sredstava, pa im dodatan novčani tok nije važan za pokretanje novih projekata (investicijske aktivnosti). Gomilanje likvidnosti nakon određene razine postaje preskupo jer stvara visoke oportunitetne troškove. Dakle, nakon određene razine stupnja likvidnosti može se očekivati neosjetljivost ili vrlo mala osjetljivost investicija na novčane tokove.

Posljednja specifikacija kao *threshold* varijablu rabi omjer neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Cilj je opet testirati hipotezu o likvidnom ograničenju poduzeća u RH. U prvom je koraku odbačena nulta hipoteza o linearnome modelu. *Threshold* vrijednosti iznose - 0,11 i 0,31. Obje su granice signifikantne uz razinu značajnosti 1 %. Testom na treću granicu prihvaća se nulta hipoteza o postojanju dviju granica (p vrijednost za treću granicu iznosi 0.,660). Dakle, *threshold* model prepoznaje postojanje triju režima.

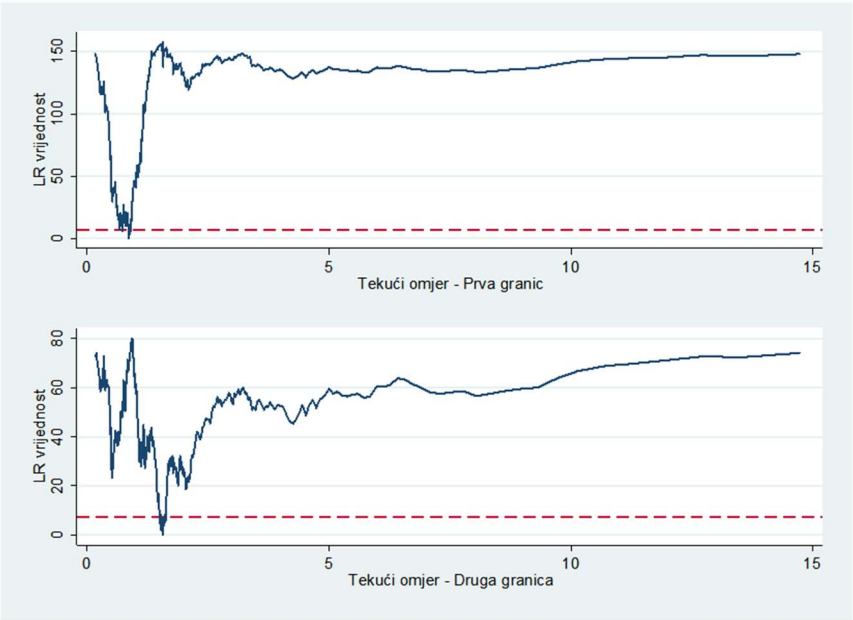

Slika 5-5: LR statistika za dvije granice s tekućom likvidnosti kao threshold varijablom

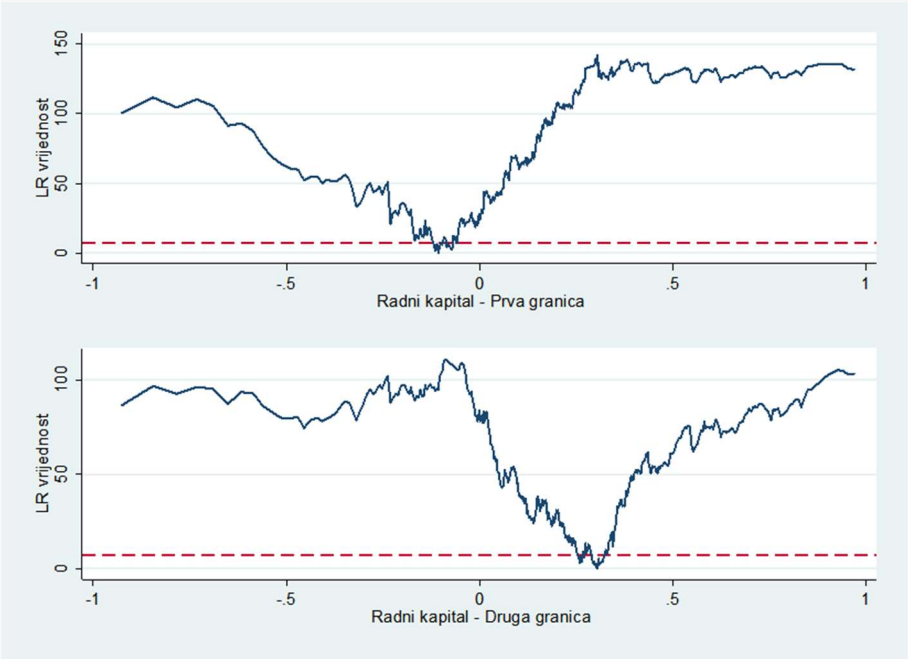

Slika 5-6: LR statistika za dvije granice sa stopom neto radnoga kapitala kao threshold varijablom

Koeficijenti pokazuju isti smjer povezanosti između investicija i novčanih tokova po režimima kao i u modelu s tekućom likvidnosti kao *threshold* varijablom. U prvom režimu vrijednost je

procijenjenog parametra nesignifikantna, odnosno investicije nisu osjetljive na rast novčanih tokova. U drugom režimu vrijednost koeficijenta iznosi $cf_{t-1}^{srednje} = 0{,}028$ (signifikantan uz razinu značajnosti od 1 %). Vrijednost koeficijenta uz novčane tokove u trećem je režimu nesignifikantna uz razinu značajnosti od 10 %. Ovakvo ponašanje investicija potvrđuje postavljenu hipotezu o nelinearnoj vezi investicija i novčanih tokova. Skupina „nelikvidnih" poduzeća ($wc < -0{,}10$), dodatnim se novčanim tokom služi za uspostavljanje primjerene likvidnosti, a ne za investicije. Skupina „likvidnih" poduzeća novčanim se tokom djelomično koristi i za investiranje, a investicije „prelikvidnih" poduzeća nisu osjetljive na promjene u novčanim tokovima.

Broj pojedinih poduzeća po režimima kroz vrijeme pokazuje rast udjela poduzeća u trećem režimu s 33 % na 45 %. Zanimljivo je da se broj prelikvidnih poduzeća povećava tijekom cijelog promatranog razdoblja, čak i nakon financijske krize. Postavljanje pitanja o razlozima ovakve strukture upućuje na poznati problem zasićenosti štednjom. Zasićenost štednjom situacija je u kojoj je željena štednja veća od željenih investicija. Na razini poduzeća problem je poznat kao nagomilavanje novca (engl. *cash hoarding*). Poduzeća se, prema toj teoriji, u nedostatku poslovnih prilika odlučuju za nagomilavanje likvidnosti. Razlog može biti u nedostajanju poslovnih prilika i nagomilavanju likvidnosti radi rasta neizvjesnosti.

Testovi o nelinearnosti u osjetljivosti investicija na novčane tokove za različite bilančne varijable i vrijednosti procijenjenih koeficijenata potvrđuju istraživačku hipotezu o nelinearnoj povezanosti stupnja likvidnog ograničenja i osjetljivosti investicija na novčane tokove ako se kao *threshold* varijabla upotrijebe tekuća likvidnost i stopa neto radnoga kapitala. Izrazito nelikvidna poduzeća pokazuju negativnu osjetljivost investicija na novčane tokove jer prodaju imovinu radi ostvarivanja primjerene likvidnosti (novčani tok nije dostatan za pokrivanje fiksnih tereta). U jednom trenutku koeficijent uz novčane tokove poprima vrijednost 0. Likvidna poduzeća imaju pozitivne koeficijente uz novčane tokove jer su oportunitetni troškovi držanja novca visoki. U svim trima specifikacijama vrijednost koeficijenta u drugom režimu iznosi 0,044. S rastom likvidnosti osjetljivost investicija na novčane tokove ponovno se smanjuje , što je također u skladu s istraživačkom hipotezom. Prelikvdne tvrtke investiraju kada se pojavi investicijska prilika (pozitivan šok produktivnosti). Drugim riječima, investicije ne ovise o internim sredstvima. Kada se kao *threshold* varijabla upotrebljava stopa likvidnosti, identificirana su tri režima, ali je osjetljivost investicija na novčane tokove monotono rastuća. Međutim, osjetljivost investicija na novčane tokove konzistentno je niža za tvrtke s manjim stupnjem likvidnosti. Konačan zaključak o vezi novčanih tokova i investicija kao funkciji

likvidnosti donijet će se nakon analize robusnosti u poglavlju 5.5. i posebno panel-analize na nebalansiranu uzorku u poglavlju 5.6. Za sada se može ustanoviti da korištenje stopom likvidnosti i stopom neto radnoga kapitala dovodi do odnosa u obliku slova U, što je u skladu s rezultatima Clearyja, Povela i Raitha (2007). Temeljni je cilj poslovanja održavanje primjerene likvidnosti. Sekundarni je cilj uspostavljanje ekonomična poslovanja i održavanja supstancije poduzeća (nove investicije). Nove su investicije na neki način rezidualna stavka nakon uspostavljanja likvidnosti stvaranjem novčanog toka.

Na kraju ovog poglavlja ukratko se interpretiraju koeficijenti uz ostale režimski ovisne varijable. Smjer i jakost povezanosti vrlo su slični kroz različite specifikacije, što omogućuje jedinstvenu interpretaciju za sve specifikacije. Gotovo svi procijenjeni parametri statistički su signifikantni uz razinu značajnosti 1 %. Razlog je u vrlo velikom uzorku, koji rezultira vrlo malim standardnim pogreškama. Poznato je da je t omjer u takvim okolnostima neprimjerena statistika jer ide previše u prilog alternativnoj hipotezi. Stoga je važnije u ovom slučaju interpretirati ekonomsku signifikantnost procijenjenih parametara.

Za sve je specifikacije utjecaj zaposlenosti statistički signifikantan (s negativnim predznakom), ali ekonomski nesignifikantan (procijenjeni parametri iznose oko 0,0004). Očito je kako rast broja zaposlenih u prošlom razdoblju ne utječe na promjene investicija u sadašnjem razdoblju. Koeficijent uza stopu rasta prihoda također nije ekonomski signifikantan. Druga potražna varijabla, nova dodana vrijednost, ima statistički i ekonomski signifikantan utjecaj na investicije. Prema autorovim spoznajama, ovo je prvi put da se ova varijabla upotrebljava za kontroliranje potražnih faktora u investicijskoj jednadžbi. Veza između dodane nove vrijednosti i investicija konzistentno je snažna kroza sve specifikacije, pa se preporučuje njezino korištenje i u budućim istraživanjima. Vrijednost procijenjenog koeficijenta uz član nva_{t-1} iznosi u prosjeku 0,8, a kvadratni član ima vrijednost $nva_{t-1}^2 = -0{,}036$, što podrazumijeva konkavan odnos između dodane nove vrijednosti i investicija.

5.4.3 Analiza heterogenosti u stupnju financijskog i likvidnog ograničenja poslovnih subjekata

Prema nalazima dosadašnjih istraživanja, javne bi tvrtke trebale pokazivati manji stupanj financijskog ograničenja od privatnih tvrtki (Mizen i Vermeulen, 2005, Moore, 2009). Javne su tvrtke često strateški važne pa je njihovo preživljavanje tvrtki ne samo ekonomsko nego i

političko pitanje. Drugim riječima, tvrtke u državnom vlasništvu karakterizira meko budžetsko ograničenje (engl. *soft budget constraint*). Također, istraživanja su pokazala da politički utjecaj olakšava pribavljanje inozemnog financiranja. Zbog potonjih razloga očekuje se manji stupanj financijskog i likvidnog ograničenja za tvrtke u javnom vlasništvu. Drugim riječima, očekuje se da se testovima unutar *threshold* regresije prihvati nulta hipoteza o linearnome modelu.

Kako bi se testirala hipoteza o odsutnosti financijskog i likvidnog ograničenja za javna poduzeća, ponovljena je analiza iz prethodnog poglavlja, ali na uzorku javnih poduzeća. Pri tome su provedene iste prilagodbe kao i u prethodnim koracima, to jest uzorak je skraćen za vrijednosti iznad 99. i ispod 1. percentila za varijable stope investicija, stope novčanog toka, stope rasta prihoda i stope dodane nove vrijednosti. Uključivanje samo javnih poduzeća znatno smanjuje uzorak. Nakon izbacivanja neuobičajenih i ekstremnih vrijednosti u uzorku ostaje 1963 opservacija. Rezultati procjene dani su u tablici 5-8. Prva dva retka tablice prikazuju procijenjene *threshold* vrijednosti. Test o postojanju dviju granica proveden je ako je prvi test pokazao postojanje jedne granice. Potom su prikazani koeficijenti uz novčane tokove za identificirane režime.

Prvo se procjenjuje stupanj financijskog ograničenja, odnosno kao *threshold* varijable služe koeficijent zaduženosti, pokriće troškova kamata i veličina poduzeća. Rezultati *threshold* regresije s koeficijentom zaduženosti kao *threshold* varijablom potvrđuju postojanje linearnog modela. Sva poduzeća pokazuju istu osjetljivost investicija na novčane tokove bez obzira na razinu zaduženosti: $cf_t = 0{,}141$. Rezultati su u skladu s hipotezom o odsutnosti financijskog ograničena za javna poduzeća. Kada se kao *threshold* varijabla upotrijebe pokriće troškova kamata i veličina poduzeća, model identificira jednu granicu, u oba slučaja uz razinu značajnosti 5 %. Međutim, ne može se odbaciti nulta hipoteza prema kojoj su vrijednosti koeficijenta uz novčane tokove jednaki 0. Može se zaključiti da u oba režima investicije nisu osjetljive na novčane tokove, odnosno da ne postoji monotono rastuća osjetljivost investicija na novčane tokove. Također, važno je napomenuti da u drugome modelu (pokriće troškova kamata kao *threshold* varijabla), samo 2 % poduzeća pripada prvom režimu, pa se može zaključiti da većina poduzeća pokazuje pozitivne koeficijente uz novčane tokove, što je u skladu s prvim modelom. Ukratko, može se zaključiti da javna poduzeća ne pokazuju heterogenost u osjetljivosti investicija na novčane tokove kada se kao threshold varijable upotrijebe varijable koje odražavaju financijski položaj poduzeća.

Tablica 5-8: Rezultati threshold regresije za javna poduzeća u Republici Hrvatskoj od 2001. do 2014.

Model	**Statički FE *threshold***	**Statički FE *thresh***	**Statički FE *thresh***	**Statički FE *thresh***	**Statički FE *thresh***	**Statički FE *thresh***
Zavisna	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}
Efekti tvrtke	DA	DA	DA	DA	DA	DA
Efekti godine	DA	DA	DA	DA	DA	DA
γ_1	–	-77294^{**}	$3.83\ mil^{**}$	-0.496^{***}	–	-0.426^{*}
γ_2	–	–	–	–	–	–
Režim $q_{\{it\}} \leq \gamma_1$						
cf_t^{nisko}	–	0.546	−0.044	0.319	–	-0.556^{*}
	–	(0.720)	(0.061)	(0.230)	–	(0.070)
Režim $q_{\{it\}} > q_{\{it\}} \leq \gamma_2$						
$cf_t^{srednje}$	0.141^{***}	–	–	–	0.141^{***}	–
	(0.049)	–	–	–	(0.052)	–
Režim $q_{\{it\}} > \gamma_2$						
$cf_t^{srednje}$	–	−0.052	−0.094	−0.082	–	−0.088
	–	(0.054)	(0.111)	(0.055)	–	(0.054)
$q_{\{it\}}$	**Koeficijent zaduž.**	**Pokriće troš. kam.**	**Veličina**	**Stopa likvidn.**	**Tekući omjer**	**NRK/imovina**
N	1.963	1.963	1.963	1.963	1.963	1.963
RSS	28	28	28	27	28	28
F statistika	32.85	43.67	48.79	46.20	24.01	31.44
				25.36		

BILJEŠKA: Zavisna je varijabla stopa investicija, $inv_{it} = \frac{I_{it}}{A_{it-1}}$, gdje su investicije, I_{it}, jednake zbroju materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju, a A_{it-1} je vrijednost imovine pomaknuta za jedno razdoblje. Koeficijent zaduženosti ten_{t-1} izračunan je kao omjer ukupnog duga i imovine. Pokriće troškova kamata, $icov_{t-1}$, jednako je omjeru EBIT-a i troškova kamata. Veličina, $size_{t-1}$, jednaka je knjigovodstvenoj vrijednosti imovine poduzeća. Stopa likvidnosti, liq_{t-1}, računa se kao omjer neto radnoga kapitala uvećana za tekuće novčane tokove i imovine. Tekuća likvidnost, cr_{t-1}, jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Stopa neto radnoga kapitala, wc_{t-1}, računa se kao odnos neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Osnovna važna varijabla stopa je novčanog toka, koja je jednaka omjeru novčanog toka (dobit + amortizacija) i vremenski pomaknute vrijednosti imovine. Kontrolna su varijable emp_{it-1}, rsg_{it-1} i nva_{it-1}. U zagradi su dane standardne pogreške. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Procjenjivanje likvidnog ograničenja metodom *threshold* regresije daje različite rezultate, ovisno o tome koji se pokazatelj likvidnosti upotrebljava kao *threshold* varijabla. Ne može se odbaciti hipoteza o postojanju linearnog modela kada se kao *threshold* varijabla upotrijebi stopa neto radnoga kapitala. U modelu sa stupnjem likvidnosti i tekućom likvidnosti kao *threshold* varijablom identificirana je jedna granica, ali samo nekoliko opservacija pripada prvom režimu (u prosjeku tri opservacije). Može se zaključiti da javna poduzeća u RH nisu financijski ni likvidno ograničena. Iako je u modelima s neto radnim kapitalom i stopom likvidnosti kao *threshold* varijablom identificirana jedna granica, za glavninu uzorka (99 %) koeficijent je novčane tokove pozitivan, za razliku od osnovnog modela u kojem su identificirana tri režima i nelinearnost u osjetljivosti novčanih tokova i investicija.

Smanjen stupanj financijske i likvidne ograničenosti očekuje se i za poduzeća s većinskim inozemnim podrijetlom kapitala. Nekoliko je razloga za to. Poduzeća s inozemnim podrijetlom kapitala mogu dobivati financijsku pomoć od poduzeća majki. Stupanj povjerenja u izvršenje obveza može biti veći i zbog imidža kompanije. Također, poduzeća s većinskim inozemnim podrijetlom kapitala vjerojatno se mogu lakše zadužiti na stranom tržištu.

Ako se u uzorak uvrste samo poduzeća u stranom vlasništvu (inozemno podrijetlo kapitala), nakon izbacivanja opservacija iznad 99. i ispod 1. percentila za glavne važne varijable u uzorku ostaju 3562 opservacije. Rezultati *threshold* regresija dani su u tablici 5-8. Model s koeficijentom zaduženosti pokazuje postojanje linearnog modela. Drugim riječima, ne mogu se identificirati različiti režimi osjetljivosti investicija na novčane tokove kada se kao *threshold* varijabla upotrijebi koeficijent zaduženosti. Ako se kao *threshold* varijabla upotrijebi pokriće troškova kamata, test potvrđuje postojanje dviju granica (obje su signifikantne uz razinu značajnosti 5 %). Međutim, drugom režimu pripadaju samo dvije opservacije, a koeficijenti uz novčane tokove u preostalim dvama režimima jednaki su 0. Drugim riječima, posrijedi je nemonotono rastuća osjetljivost investicija i novčanih tokova. U trećem modelu (veličina poduzeća kao *threshold* varijabla) identificirana su dva režima, pri čemu velika poduzeća pokazuju veću osjetljivost investicija na novčane tokove od malih poduzeća, što je suprotno postavljenoj hipotezi.

Tablica 5-9: Rezultati threshold regresije za javna poduzeća u Republici Hrvatskoj od 2001. do 2014.

Model	**Statički FE *threshold***	**Statički FE *thresh***	**Statički FE *thresh***	**Statički FE *thresh***	**Statički FE *thresh***	**Statički FE *thresh***
Zavisna	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}
Efekti firme	DA	DA	DA	DA	DA	DA
Efekti godine	DA	DA	DA	DA	DA	DA
γ_1	–	1182^{**}	$2.2\ mil$	–	0.153^{**}	-1.240^{*}
γ_2	–	1841^{**}	–	–	–	–
Režim $q_{\{it\}} \leq \gamma_1$						
cf_t^{nisko}	–	-0.005	0.045	–	1.184^{***}	0.624^{*}
	–	(0.720)	(0.030)	–	(0.191)	(0.166)
Režim $q_{\{it\}} > q_{\{it\}} \leq \gamma_2$						
$cf_t^{srednje}$	0.138^{***}	2.431^{***}	–	0.138^{***}	–	–
	(0.049)	0.260	–	(0.046)	–	–
Režim $q_{\{it\}} > \gamma_2$						
$cf_t^{srednje}$	–	-0.090	0.098^{*}	–	0.011	0.013
	–	(0.054)	(0.111)	–	(0.027)	(0.027)
$q_{\{it\}}$	**Koeficijent zaduž.**	**Pokriće troš. kam.**	**Veličina**	**Stopa likvidn.**	**Tekući omjer**	**NRK/imovina**
N	3.562	3.562	3.562	3.562	3.562	3.562
RSS	42	41	41	42	41	42
F statistika	34.91	59.25	128.11	26.41	68.95	38.36

BILJEŠKA: Zavisna je varijabla stopa investicija, $inv_{it} = \frac{I_{it}}{A_{it-1}}$, gdje su investicije, I_{it}, jednake zbroju materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju, a A_{it-1} je vrijednost imovine pomaknuta za jedno razdoblje. Koeficijent zaduženosti, ten_{t-1}, izračunan je kao omjer ukupnog duga i imovine. Pokriće troškova kamata, $icov_{t-1}$, jednako je omjeru EBIT-a i troškova kamata. Veličina, $size_{t-1}$, jednaka je knjigovodstvenoj vrijednosti imovine poduzeća. Stopa likvidnosti, liq_{t-1}, računa se kao omjer neto radnoga kapitala uvećanog za tekuće novčane tokove i imovine. Tekuća likvidnost, cr_{t-1}, jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Stopa neto radnoga kapitala, wc_{t-1}, računa se kao odnos neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Osnovna je važna varijabla stopa novčanog toka, koja je jednaka omjeru novčanog toka (dobit + amortizacija) i vremenski pomaknute vrijednosti imovine. Kontrolne su varijable emp_{it-1}, rsg_{it-1} i nva_{it-1}. U zagradi su dane standardne pogreške. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Ako se kao *threshold* varijabla upotrijebi stopa likvidnosti, ne može se odbaciti nulta hipoteza o linearnome modelu (ne postoji linearno ograničenje). Ako se kao *threshold* varijable upotrijebe tekuća likvidnost i stopa neto radnoga kapitala, prihvaća se model s jednom granicom, odnosno dvama režimima, pri čemu prvom režimu pripada samo nekoliko poduzeća. Može se zaključiti da u poduzeća s inozemnim podrijetlom kapitala ne postoji problem likvidnog ograničenja kao za ostala privatna poduzeća

Ukratko, može se zaključiti da javna poduzeća ne pokazuju znakove financijskog ograničenja, barem ako se prihvati njihovo procjenjivanje pomoću osjetljivosti investicija na novčane tokove. Za izrazito mali broj opservacija prepoznata je heterogenost s obzirom na stupanj likvidnost (kada se kao *threshold* varijable upotrijebe stopa likvidnosti i neto radni kapital). Rezultati za poduzeća s inozemnim podrijetlom kapitala odgovaraju onima za javna poduzeća. Dakle, treća je hipoteza o heterogenosti s obzirom na oblik vlasništva i izvor kapitala potvrđena. Postoji heterogenost s obzirom na oblik vlasništva (javno/privatno) i s obzirom na podrijetlo kapitala (domaće/inozemno) pri procjeni financijskog i likvidnog ograničenja.

5.5 Analiza robusnosti

5.5.1 Izbor različitih specifikacija modela

Cilj je ovog poglavlja testiranje osjetljivosti rezultata na promjene u specifikaciji modela. Regresijska jednadžba ima isti formalni oblik (jednadžba 137), ali se mijenja uzorak ili pojedina varijabla u modelu. Rezultati analize robusnosti prikazani su u tablici 5-8. Pod brojem jedan rezultati su standardnog modela na uzorku proizvodnih poduzeća. Druga specifikacija kao mjeru neto vrijednosti, umjesto novčanog toka, upotrebljava stopu gotovine. Treća specifikacija umjesto ukupne imovine upotrebljava pomaknutu vrijednost kapitala u nazivniku zavisne i određenih nezavisnih varijabli. U četvrtoj se specifikaciji kao mjera investicija upotrebljava bruto kapitalna formacija. U petoj su specifikaciji ukupne obveze umanjene za obveze prema povezanim poduzetnicima. Za ispitivanje stupnja financijskog ograničenja kao *threshold* varijabla upotrebljava se koeficijent zaduženosti, a za procjenu likvidnog ograničenja stopa likvidnosti.

Istraživanja o financijskom ograničenju u uzorak najčešće uključuju samo proizvodna poduzeća. Uzorak u ovom radu sadržava sav realni sektor. Kako bi se postigla usporedivost

rezultata s ostalim provedenim istraživanjima, u prvoj su specifikaciji provedeni isti testovi i procjene kao u temeljnome modelu, ali je uzorak sužen na proizvodna poduzeća. Izbačene su opservacije u kojima se pojavljuju neuobičajeno visoke ili niske vrijednosti.[47] Proizvodna su poduzeća ona iz prerađivačke industrije. Konačni uzorak sadržava 21.070 poduzeća. Pri procjeni financijskog ograničenja odbacuje se hipoteza o postojanju linearnog modela. Prihvaća se model s dvama režimima, a vrijednosti koeficijenata uz novčane tokove pokazuju drukčije vrijednosti kroz režime u odnosu prema rezultatima iz poglavlja 5.5.1. Osjetljivost investicija na novčane tokove veća je u drugom režimu, u kojem su zaduženija poduzeća, što je u skladu s hipotezom prema kojoj bi zaduženija poduzeća trebala pokazivati veću osjetljivost investicija na novčane tokove. *Threshold* vrijednost za drugu *threshold* varijablu nije bila signifikantna, pa se u tablici 5-10 i ne navodi. Drugi model kao *threshold* varijablu upotrebljava stopu likvidnosti. Testovi o postojanju jedne i dviju granica potvrđuju postojanje triju režima. Granice iznose 0,288 i 1,132. Vrijednost koeficijenta u prvom režimu statistički je nesignifikantna, a koeficijent u drugom režimu ima pozitivnu vrijednosti, $cf_{t-1}^{visoko} = 0{,}78$ (signifikantno uz razinu značajnosti 1 %). U trećem je režimu vrijednost koeficijenta statistički nesignifikantna. Vrijednosti granica i vrijednosti koeficijenta u svim trima režimima ponašaju se isto kao i u temeljnome modelu.

Primjena metode *threshold* regresije na uzorku proizvodnih poduzeća pridonosi drukčijoj interpretaciji pri procjeni financijskog ograničenja. Postoji monotono rastuća osjetljivost investicija na novčane tokove kao funkcije rasta koeficijenta zaduženosti. Međutim, rezultati su isti kao i u temeljnome modelu, kada se kao *threshold* varijabla upotrebljava stopa likvidnosti.

Druga specifikacija kao mjeru neto vrijednosti koristi se stopom gotovine (omjer novca i ukupne imovine). Dok je novčani tok varijabla toka, stopa gotovine varijabla je razine (engl. *stock*). Rast novčanog toka u jednom razdoblju ne mora nužno značiti i rast raspoloživih sredstava za investiranje u istom razdoblju. Razlog može biti u isplati dobiti ili rastu duga. Stopa rasta novca s druge strane uzima u obzir i iznos novčanog toka u tekućoj godini i dinamiku novca svih prethodnih godina. Druga kolona u tablici 5-10 otkriva razlike u procjeni predmetnog modela prema temeljnome modelu. U modelu s koeficijentom zaduženosti kao graničnom varijablom potvrđuje se postojanje dviju granica (0,069, 0,082), a koeficijenti uz

[47] Provedene su iste prilagodbe kao i u temeljnome modelu: izbačene su opservacije iznad 99. percentila i ispod 1. percentila za varijable stope invesicija, stope novčanog toka, stope nove dodane vrijednosti i stope rasta prihoda.

novčane tokove pozitivni su u svim režimima i veći od koeficijenata uz novčane tokove u temeljnome modelu. Valja primijetiti kako su svi procijenjeni koeficijenti uz novčani omjer jednaki po intenzitetu, pa se može zaključiti da ne postoji razlika u osjetljivosti investicija na stopu gotovine.

Model sa stopom likvidnosti kao graničnom varijablom pokazuje postojanje dviju granica (triju režima). Prva granica iznosi 0,295, a druga 1443 i obje su statistički signifikantne uz razinu značajnosti od 1 %. Vrijednost koeficijenata monotono je padajuća, odnosno s rastom stope gotovine opada osjetljivost investicija na novčane tokove. Može se zaključiti da s rastom stope gotovine opada granična vrijednost likvidnosti, pa dodatan novčani tok sve manje utječe na investicije. Opadanje osjetljivosti investicija na novčane tokove kao funkcije rasta stope gotovine u skladu je s hipotezom o likvidnom ograničenju, ali *threshold* regresijom nije identificirana skupina nelikvidnih poduzeća. Drugim riječima, nije identificirana nelinearna veza između važnih varijabli. Rezultati se ne razlikuju od temeljnog modela. Ne može se prihvatiti hipoteza o monotono rastućoj osjetljivosti investicija na novčane tokove pri procjeni financijskog ograničenja, ali se može djelomično prihvatiti istraživačka hipoteza o heterogenosti ponašanja investicija s obzirom na stanje likvidnosti.

Tablica 5-10: Analiza osjetljivosti rezultata na promjene specifikacije modela

	1		2		3		4		5	
	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$
γ_1	0.551^{*}	0.288^{***}	0.069^{***}	0.295^{***}	0.587^{***}	0.402^{***}	0.414^{**}	0.304^{***}	0.583^{***}	-0.048^{***}
γ_2	$-$	1.132^{**}	0.082^{***}	1.443^{***}	1.103^{***}	1.856^{***}	0.427^{**}	1.415^{***}	0.873^{***}	0.297^{**}
Režim $q_{it} \leq \gamma_1$										
$\boldsymbol{cf_{t-1}^{nisko}}$	-0.008	0.138	0.082^{***}	0.093^{***}	-0.047^{***}	-0.128^{***}	-0.031^{***}	0.002	0.001	-0.118^{***}
	(0.016)	(0.018)	(0.004)	(0.006)	(0.005)	(0.008)	(0.011)	(0.004)	(0.005)	(0.013)
Režim $\gamma_1 < q_{it} \leq \gamma_2$										
$\boldsymbol{cf_{t-1}^{srednje}}$	$-$	0.078^{***}	0.086^{***}	0.081^{***}	0.010^{**}	-0.027^{*}	-0.359^{***}	0.036^{***}	0.036^{***}	-0.100^{***}
		(0.030)	(0.007)	(0.004)	(0.005)	(0.007)	(0.007)	(0.003)	(0.007)	(0.015)
Režim $q_{it} > \gamma_2$										
$\boldsymbol{cf_{t-1}^{visoko}}$	0.081^{***}	-0.129	0.088^{***}	0.047^{**}	-0.116^{***}	-0.056^{***}	-0.007	0.046^{***}	-0.023^{***}	0.004
	(0.014)	(0.016)	(0.018)	(0.011)	(0.014)	(0.005)	(0.008)	(0.009)	(0.008)	(0.008)
N	21.070	21.070	155.694	155.694	145.600	145.600	159.306	159.306	146.020	146.020
RSS	382	382	3789	3786	1220	1210	1080	1.625	3305	3300
F	53.19	32.22	48.36	113.54	122.34	603.40	120.17	37.89	79.01	133.11

BILJEŠKA: Oznake γ_1 i γ_2 označuju vrijednost procijenjenih granica. cf_{t-1}^{nisko}, $cf_{t-1}^{srednje}$ i cf_{t-1}^{visoko} označavaju vrijednost koeficijenta u prvom, drugom i trećem režimu, a u zagradi ispod procijenjenih koeficijenata uz novčane su tokove standardne pogreške. Vrijednost je koeficijenta izostavljena ako testovi pokazuju postojanje manje od tri režima. N, P, T i R^2 označuju broj opservacija, broj poduzeća, vrijeme i cjelokupan R^2. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Treća specifikacija normalizira varijable dijeleći ih s pomaknutom vrijednosti kapitala, za razliku od standardnog modela u kojem su varijable normalizirane dijeljenjem s vrijednošću ukupne imovine. Dva su razloga za promatranje ove specifikacije. Prvo, jednadžba investicija izvedena iz teorijskog modela ponašanja tvrtke (optimizacija funkcije profita uz dana ograničenja) i strukturni ekonometrijski modeli izražavaju varijable u odnosu prema pomaknutim vrijednostima kapitala. Takva je specifikacija rezultat optimizacijskog problema u kojem je kapital osnovna varijabla stanja (engl. *state variable*). Drugi je razlog postizanje usporedivosti. Većima radova koja proučava ponašanje investicija varijable u modelu dijeli s pomaknutom vrijednosti kapitala.

Pri procjeni financijskog ograničenja prihvaća se model s dvjema granicama. Prva granica iznosi 58 %, a druga 103 %. Obje su granice signifikantne uz razinu značajnosti 1 %. Vrijednost je koeficijenta uz novčane tokove negativna u prvom i trećem režimu, a pozitivna samo u drugom režimu. Naknadnom analizom osjetljivosti j ustanovljeno je da je osnovni razlog negativnog predznaka uz novčane tokove uključivanje pomaknute vrijednosti dodane nove vrijednosti u investicijsku jednadžbu. Ako se iz regresijske jednadžbe izbaci stopa dodane nove vrijednosti, koeficijenti uz novčane tokove poprimaju sljedeće vrijednosti: $cf_{t-1}^{nisko} = 0{,}150$, $cf_{t-1}^{srednje} = 0{,}149$ i $cf_{t-1}^{visoko} = 0{,}036$. Svi su procijenjeni parametri signifikantni uz razinu značajnosti 1 %. Vrijednosti koeficijenata po režimima, u specifikacijama, s novom dodanom vrijednosti i bez nje, potvrđuju rezultate iz bazičnog modela. Valja primijetiti da visoko zadužene tvrtke imaju najmanje vrijednosti koeficijenta uz novčane tokove. Čak i ako tvrtka ostvaruje pozitivan šok na novčane tokove (primjerice pozitivan šok produktivnosti) u prošlom razdoblju, ne investira u tekućem razdoblju. Ovakvo je ponašanje investicija već objašnjeno. Riječ je najvjerojatnije o tvrtkama koje su u financijskim poteškoćama, pa se novi novčani tok upotrebljava za minimiziranje dugova i uspostavljanje primjerene likvidnosti. Drugim riječima, odbija se istraživačka hipoteza o monotono rastućoj osjetljivosti investicija na novčane tokove za različite režime.

Kada se kao *threshold* varijabla upotrijebi stopa likvidnosti, testovi pokazuju postojanje dvije granice. Vrijednosti granica iznose 0,402 i 1,85 i obje su signifikantne uz razinu značajnosti 1 %. Vrijednosti koeficijenata u svim su režimima negativne. U prvom režimu vrijednost koeficijenta uz novčane tokove iznosi $cf_{t-1}^{nisko} = -0{,}128$, u drugom, $cf_{t-1}^{srednje} = -0{,}027$, a u trećem $cf_{t-1}^{visoko} = -0{,}056$. Ako se iz investicijske jednadžbe izbaci stopa nove dodane vrijednosti, procijenjeni parametri poprimaju sljedeće vrijednosti: $cf_{t-1}^{nisko} = -0{,}009$,

$cf_{t-1}^{srednje} = -0{,}174$ i $cf_{t-1}^{visoko} = -0{,}129$, pri čemu je prvi koeficijent nesignifikantna uz razinu značajnosti 10 %. Rezultati potvrđuju hipotezu o nelinearnoj vezi novčanih tokova i investicija kao funkcije stanja likvidnosti.

Četvrta specifikacija kao zavisnu varijablu sadržava stopu bruto kapitalne formacije, za razliku od temeljnog modela koji kao zavisnu varijablu sadržava stopu investicija. Pokazatelj bruto kapitalne formacije računa Državni zavod za statistiku za potrebe računanja BDP-a. Prije interpretacije rezultata važno je upozoriti na dvije ključne razlike u distribuciji pokazatelja. Prvo, bruto kapitalna formacija ne može poprimiti negativne vrijednosti. Drugo, distribucija pokazatelja sadržava velik broj opservacija s vrijednosti 0 (47 % svih opservacija).

Zbog razlike u distribuciji pokazatelja, investicije se ponašaju drukčije nego u temeljnome modelu. U modelu s koeficijentom zaduženosti kao *threshold* varijablom testovi pokazuju postojanje triju režima. Vrijednosti su granica 0,414 i 0,427 (obje su granice signifikantne uz razinu značajnosti 5 %), međutim drugom režimu pripada 1 % ukupnih opservacija. Svi su procijenjeni koeficijenti uz novčane tokove negativni, pri čemu postoji nelinearnost. U drugom je režimu vrijednost koeficijenta manja od vrijednosti u prvom režimu, a u trećem je režimu vrijednost nesignifikantna. Rezultati su ponovno u suprotnosti s istraživačkom hipotezom jer je koeficijent u trećem režimu nesignifikantan uz razinu značajnosti 10 %, a prema teoriji financijskog ograničenja trebao bi biti pozitivan. Također, vrijednost koeficijenta u drugom režimu trebala bi biti veća od koeficijenta u prvom režimu. U modelu sa stopom likvidnosti kao *threshold* varijablom testovi pokazuju postojanje triju režima. Prva granica iznosi - 0,048 (signifikantno uz razinu značajnosti 1 %), a druga 0,297 (signifikantno uz razinu značajnosti 5 %). Koeficijenti su uz novčane tokove u prvom i drugom režimu negativni, a u trećem režimu nesignifikantni, s time da je vrijednost koeficijenta u drugom režimu dvostruko veća od vrijednosti koeficijenta u prvom režimu. Rezultati su u skladu s temeljnim modelom. Postoji monoton pad osjetljivosti novčanih tokova na investicije kako raste stopa likvidnosti. Ako se umjesto stope likvidnosti kao *threshold* varijabla upotrijebi tekuća likvidnost, prepoznati rezultati identični su temeljnome modelu i u skladu su s hipotezom.

U posljednjoj specifikaciji učinjene su prilagodbe u mjerenju stope likvidnosti i koeficijenta zaduženosti poduzeća. U poglavlju 4.3. prikazana je agregatna struktura obveza za svaku poslovnu godinu. Nakon Velike recesije postoji jasan trend rasta obveza prema povezanim poduzećima. Budući da je riječ o obvezama prema vlasnicima poduzećima, one imaju više obilježja kapitala nego duga. Stoga je primjerenije iznos obveza umanjiti za obveze prema

povezanim poduzećima. Točnije, pri mjerenju koeficijenta zaduženosti ukupne su obveze umanjene za dugoročne i kratkoročne obveze prema povezanima poduzetnicima, a pri mjerenju stope likvidnosti kratkoročne su obveze umanjene za kratkoročne obveze prema povezanim poduzetnicima. Također, kratkotrajna je imovina uvećana za odrednicu „plaćeni troškovi budućeg razdoblja i obračunani prihodi“, a umanjenja za „odgođeno plaćanje troškova i prihod budućeg razdoblja“. Nakon prilagodbe, rezultati pokazuju slične rezultate kao i u temeljnome modelu. Procjena financijskog ograničenja potvrđuje prijašnje rezultate o postojanju triju režima. Osjetljivost novčanih tokova raste prelaskom iz prvog u drugi režim, ali treći režim ponovno pokazuje smanjenje osjetljivosti. Procjena likvidnog ograničenja također potvrđuje prijašnje rezultate. „Nelikvidna“ poduzeća pokazuju negativnu osjetljivost novčanih tokova i investicija. S rastom likvidnosti raste i koeficijent uz novčani tok. Ipak, 5. specifikacija ne identificira pad osjetljivosti s rastom likvidnosti, pa odnos nije posve nelinearan. U ukupnom uzorku, 54 % poduzeća je „nelikvidno“, 22 % „likvidno“, a 24 % „prelikvidno“.

Može se zaključiti da analiza robusnosti potvrđuje rezultate temeljnog modela. Odbacuje se istraživačka hipoteza o monotono rastućoj osjetljivosti investicija na novčane tokove kao funkcija rasta duga. S druge strane, potvrđuje se istraživačka hipoteza o nelinearnoj osjetljivosti investicija na novčane tokove kao funkciji rasta likvidnosti. Treba također napomenuti da najviše poduzeća pokazuje statistički i ekonomski signifikantnu osjetljivost novčanih tokova i investicija.

5.5.2 Osjetljivost na ekstremne vrijednosti, izbor nezavisnih varijabli, korištenje novčanih tokova u tekućem razdoblju i korištenje režimski ovisnih zavisnih varijabli

U ovom dijelu analize robusnosti testira se osjetljivost rezultata na uklanjanje određenog percentila ekstremnih vrijednosti, izbor različitih nezavisnih varijabli te na uključivanje tekuće vrijednosti novčanih tokova u ekonometrijsku jednadžbu.

Budući da je ekonometrijska analiza provedena na velikom uzorku poduzeća, uključivanje ili izbacivanje ekstremnih vrijednosti može imati veliki učinak na procijenjene parametre. To posebno vrijedi za nefinancijska poduzeća iz različitih sektora i različitih veličina, koja mogu imati znatnu varijaciju u opaženim vrijednostima investicija i novčanog toka (pogledati Veradi i Wagner (2011); Temouri i Wagner, 2013). Robusnost rezultata na eliminiranje različitih

percentila ekstremnih vrijednosti prikazana je u tablici 5-11, koja je slična tablici 5-10, s jedinom razlikom što su specifikacije modela različiti uzorci upotrijebljeni u analizi. Tako prva kolona uključuje cijeli uzorak, druga kolona uzorak u kojem je eliminiran 1. percentil ekstremnih vrijednosti, treća kolona model u kojem su isključena 2 percentila ekstremnih vrijednosti itd.

Prva kolona pokazuje nesignifikantne procjenitelje uz novčane tokove u svim režimima. Ovoj koloni ne bi trebalo pridavati mnogo pozornosti jer su rezultati pod utjecajem nekoliko ekstremnih vrijednosti. Druga kolona predstavlja osnovnu specifikaciju iz točaka 5.5.1. i 5.5.2. pa se neće posebno komentirati. Treća kolona prikazuje rezultate uz eliminiranje dvaju percentila ekstremnih vrijednosti. Valja primijetiti da je uzorak znatno manji od bazičnog modela. Pri procjeni likvidnog ograničenja prepoznate su dvije granice. Osjetljivost investicija na novčane tokove opet pokazuje nelinearnost. Razlika je jedino u tome što su u svim režimima koeficijenti uz novčane tokove pozitivni. Kada se kao *threshold* varijabla upotrijebi koeficijent zaduženost, rezultati se podudaraju s onima iz osnovnog modela. Ako se iz uzorka uklone 3 i 4 percentila ekstremnih vrijednosti te potom napravi balansirani panel, rezultati su drukčiji. Pri procjeni likvidnog ograničenja, procijenjeni parametri pokazuju monotono padajuću osjetljivost investicija na novčane tokove. Kada se kao *threshold* varijabla upotrijebi koeficijent zaduženosti, postoje samo dva režima i rezultati su identični prijašnjima. Može se zaključiti da uklanjanje većeg percentila ekstremnih vrijednosti pridonosi drukčijim zaključcima o postojanju financijskog i likvidnog ograničenja. To je rezultat velikog smanjenja uzorka (samo 39 %, odnosno 26 % opservacija standardnog modela). Uklanjanje većeg broja percentila ostavlja u uzorku stabilnija poduzeća (u zadnjoj specifikaciji postoji samo 1361 opservacija s tekućim omjerom manjim od 0,6) te poduzeća koja nisu investirala u tekućem razdoblju. Ako se tome pridoda prijašnja napomena o mogućem fenomenu nepristrana izbora zbog balansirana panela, može se objasniti nedostatak nesignifikantnih ili negativnih koeficijenta u prvom režimu pri procjeni likvidnog ograničenja.

Tablica 5-11: Osjetljivost rezultata na eliminaciju n-tog percentila ekstremnih vrijednosti

Opis	**Kompletan uzorak**		**1 percentil**		**2 percentila**		**3 percentila**		**4 percentila**	
	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$	$\boldsymbol{ten_{t-1}}$	$\boldsymbol{liq_{t-1}}$
γ_1	0.021^{*}	-0.275^{**}	0.694^{***}	0.299^{***}	0.374^{***}	-0.020^{***}	0.393^{***}	-0.136^{***}	–	–
γ_2	–	-0.266^{**}	0873^{***}	-0.139^{***}	0.706^{***}	0.291^{***}	0.706^{***}	0.191^{***}	–	–
$\boldsymbol{cf_{t-1}^{nisko}}$	103.24^{***}	1.743^{***}	0.007	-0.075^{***}	-0.010	-0.009	-0.021^{**}	0.019	–	–
	(21.52)	(0.271)	(0.005)	(0.009)	(0.008)	(0.011)	(0.010)	(0.020)		
$\boldsymbol{cf_{t-1}^{srednje}}$	–	-2214.3^{***}	0.038^{***}	-0.037^{***}	0.034^{***}	-0.008	0.046^{***}	0.012	0.128^{***}	0.128^{***}
		(80.94)	(0.008)	(0.009)	(0.007)	(0.011)	(0.008)	(0.014)	(0.008)	(0.009)
$\boldsymbol{cf_{t-1}^{visoko}}$	0.015	-0.231	-0.025^{***}	0.016^{***}	0.067	0.025^{***}	0.085	0.027^{***}	–	–
	(0.017)	(0.658)	(0.008)	(0.005)	(0.008)	(0.006)	(0.010)	(0.007)		
N	247.030	247.030	146.020	146.020	90.202	90.202	53.963	53.963	32.424	32.424
RSS	239000	238.000	3306	3300	1151	1151	448	448	198	198
F statistika	24.95	48.40	75.70	137.14	61.08	69.28	52.22	34.95	46.08	34.46

BILJEŠKA: Oznake γ_1 i γ_2 označuju vrijednost procijenjenih granica. cf_{t-1}^{nisko}, $cf_{t-1}^{srednje}$ i cf_{t-1}^{visoko} označavaju vrijednost koeficijenta u prvom, drugom i trećem režimu, a u zagradi su ispod procijenjenih koeficijenata uz novčane tokove su standardne pogreške. Vrijednost je koeficijenta izostavljena ako testovi pokazuju postojanje manje od triju režima. N, P, T i R^2 označuju broj opservacija, broj poduzeća, vrijeme i cjelokupan R^2. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Analiza robusnosti zahtijeva i ispitivanje osjetljivosti rezultata na dodavanje nezavisnih varijabli. Ispunjenje ovog zahtjeva dano je u tablici 5-12. Robusna se analiza se ponovno testira za dvije *threshold* varijable: stupanj likvidnosti i koeficijent zaduženosti. Iako se vrijednosti koeficijenata uz novčane tokove smanjuju s dodavanjem nezavisnih varijabli, odnosi između režima ostaju nepromijenjeni. Pri procjeni financijskog ograničenja srednji režim pokazuje veću osjetljivost investicija na novčane tokove od prvog režima, a treći režim pokazuje najmanju osjetljivost investicija na novčane tokove. Pri procjeni likvidnog ograničenja postoji jasna nelinearnost u osjetljivosti investicija na novčane tokove kao funkcije likvidnosti.

Tablica 5-12 potvrđuje opravdanost uključivanja pomaknute dodane nove vrijednosti u investicijsku jednadžbu. Vidljivo je da ova varijabla najviše utječe na smanjenje koeficijenta uz novčane tokove. Drugim riječima, nakon kontroliranja za promjenu u dodanoj novoj vrijednosti, koja odražava agregatnu potražnju na razini tvrtke, novčani tok znatno manje utječe na investicije kroza sve režime. Zato se i u budućim istraživanjima preporučuje dodavanje ove varijable u investicijsku jednadžbu.

Panel-*threshold* regresija (131) koristi se pomaknutim vrijednostima nezavisnih varijabli. Brojna istraživanja, koja procjenjuju stupanj financijskog ograničenja osjetljivošću investicija na novčane tokove, koriste se tekućim vrijednostima nezavisnih varijabli. To se posebno odnosi na novčane tokove jer su se tekući novčani tokovi pokazali najpouzdanijim prediktorom tekućih investicija u mnogim istraživanjima (poglavlje 3.2). U tablici 5-13 u prikazani su rezultati procijenjene *threshold* regresije s tekućim novčanim tokovima kao ključnom nezavisnom varijablom. Kao i u prijašnjim testovima, cilj je procijeniti osjetljivost investicija na novčane tokove u različitim, endogeno određenim režimima, pri čemu varijabla novčanog toka nije pomaknuta za jedno razdoblje.

Tablica 5-12: Analiza osjetljivosti rezultata na dodavanje nezavisnih varijabli

Model	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***
Zavisna varijabla	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}
Fiksni efekti za tvrtke	DA	DA	DA	DA	DA	DA
Fiksni efekti za godine	DA	DA	DA	DA	DA	DA
Režim $q_{\{it\}} \leq \gamma_1$						
cf_{it-1}^{nisko}	0.098^{***}	0.089^{***}	0.007	0.073^{***}	0.063^{***}	-0.075^{***}
	(0.003)	(0.004)	(0.005)	(0.004)	(0.004)	(0.009)
emp_{it-1}	$-$	-0.000^{***}	-0.000^{***}	$-$	-0.000^{***}	-0.000^{***}
		(0.000)	(0.000)		(0.000)	(0.000)
rsg_{it-1}	$-$	0.000^{***}	0.000^{***}	$-$	0.000^{***}	0.000^{***}
		(0.000)	(0.000)		(0.000)	(0.000)
nva_{it-1}	$-$	$-$	0.122^{***}	$-$	$-$	0.029^{***}
			(0.004)			(0.008)
nva_{it-1}^2	$-$	$-$	-0.031^{***}	$-$	$-$	0.014^{***}
			(0.002)			(0.005)
Režim $\gamma_1 < q_{\{it\}} \leq \gamma_2$						

$cf_{it-1}^{srednje}$	0.052^{***}	0.040^{***}	0.038^{***}	-0.012^{***}	0.113^{***}	-0.037^{***}
	(0.003)	(0.007)	(0.008)	(0.005)	(0.005)	(0.009)
emp_{it-1}	–	-0.000^{***}	-0.000^{***}	–	-0.000	-0.000^{***}
		(0.000)	(0.000)		(0.000)	(0.000)
rsg_{it-1}	–	0.000^{***}	0.000^{***}	–	0.000	0.000^{***}
		(0.000)	(0.000)		(0.000)	(0.000)
nva_{it-1}	–	–	0.064^{***}	–	–	0.089^{***}
			(0.006)			(0.006)
nva_{it-1}^2	–	–	-0.007^{**}	–	–	-0.017^{***}
			(0.003)			(0.004)
Režim $q_{\{it\}} > \gamma_2$						
cf_{it-1}^{visoko}	-0.002	-0.011	-0.025^{***}	0.078^{***}	0.071^{***}	0.016^{***}
	(0.011)	(0.011)	(0.008)	(0.004)	(0.005)	(0.005)
emp_{it-1}	–	-0.000^{*}	-0.000^{***}	–	-0.000	0.000^{***}
		(0.000)	(0.000)		(0.000)	(0.000)
rsg_{it-1}	–	0.000^{***}	0.000^{**}	–	0.000	0.000
		(0.000)	(0.000)		(0.000)	(0.000)
nva_{it-1}	–	–	0.058^{***}	–	–	0.120^{***}
			(0.008)			(0.005)
nva_{it-1}^2	–	–	0.002	–	–	-0.031^{***}
			(0.004)			(0.002)

$q_{\{it\}}$	**Koeficijent zaduženosti**	**Koeficijent zaduženosti**	**Koeficijent zaduženosti**	**Stopa likvidnosti**	**Stopa likvidnosti**	**Stopa likvidnosti**
Broj opservacija	146.020	146.020	146.020	146.020	146.020	146.020
RSS	3332	3332	3296	3332	3332	3300
F statistika	17.96	17.96	254.90	17.96	17.96	137.14

BILJEŠKA: Zavisna je varijabla stopa investicija, $inv_{it} = \frac{I_{it}}{A_{it-1}}$, gdje su investicije, I_{it}, jednake zbroju materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju, a A_{it-1} je vrijednost imovine pomaknuta za jedno razdoblje. Koeficijent zaduženosti, ten_{t-1}, izračunan je kao omjer ukupnog duga i imovine. Pokriće troškova kamata, $icov_{t-1}$, jednako je omjeru EBIT-a i troškova kamata. Veličina, $size_{t-1}$, jednaka je knjigovodstvenoj vrijednosti imovine poduzeća. Stopa likvidnosti, liq_{t-1}, računa se kao omjer neto radnoga kapitala uvećanog za tekuće novčane tokove i imovine. Tekuća likvidnost, cr_{t-1}, jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Stopa neto radnoga kapitala, wc_{t-1}, računa se kao odnos neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Osnovna važna varijabla stopa je novčanog toka, koja je jednaka omjeru novčanog toka (dobit + amortizacija) i vremenski pomaknute vrijednosti imovine. Kontrolna varijabla emp_{it-1} označuje broj zaposlenih; rsg_{it-1} realnu stopu rasta prihoda, $a\ nva_{it-1}$ stopu dodane nove vrijednosti U zagradi su dane standardne pogreške. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Tablica 5-13: Procjena threshold regresije s tekućim novčanim tokovima

Model	**Statički FE *threshold***	**Statički FE *threshold***
Zavisna varijabla	i_{it}	i_{it}
Fiksni efekti za tvrtke	DA	DA
Fiksni efekti za godine	DA	DA
	Režim $q_{\{it\}} \leq \gamma_1$	
cf_{it-1}^{nisko}	0.218^{***}	0.112^{***}
	(0.005)	(0.009)
emp_{it-1}	-0.000^{**}	-0.000^{**}
	(0.000)	(0.000)
rsg_{it-1}	0.000^{**}	0.000^{**}
	(0.000)	(0.000)
nva_{it-1}	0.073^{***}	-0.025^{***}
	(0.005)	(0.008)
nva_{it-1}^2	-0.024^{***}	0.027^{***}
	(0.005)	(0.004)
	Režim $\gamma_1 < q_{\{it\}} \leq \gamma_2$	
$cf_{it-1}^{srednje}$	0.306^{***}	0.244^{***}
	(0.005)	(0.006)
emp_{it-1}	-0.000^{**}	-0.000^{**}
	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000^{**}
	(0.000)	(0.000)
nva_{it-1}	-0.005	-0.007
	(0.005)	(0.005)
nva_{it-1}^2	0.013^{***}	0.017^{***}
	(0.002)	(0.003)
	Režim $q_{\{it\}} > \gamma_2$	
cf_{it-1}^{visoko}	0.078^{***}	0.264^{***}
	(0.010)	(0.005)

emp_{it-1}	-0.000 (0.000)	-0.000^{**} (0.000)
rsg_{it-1}	0.000^{***} (0.000)	0.000^{**} (0.000)
nva_{it-1}	0.023^{***} (0.009)	-0.052^{***} (0.004)
nva_{it-1}^2	0.001 (0.005)	-0.018^{***} (0.002)
$\boldsymbol{q_{\{it\}}}$	**Koeficijent zaduženosti**	**Stopa likvidnosti**
Broj opservacija	146.020	146.020
RSS	3129	3131
F statistika	418.45	295.87

BILJEŠKA: Zavisna je varijabla stopa investicija, $inv_{it} = \frac{I_{it}}{A_{it-1}}$, gdje su investicije, I_{it}, jednake zbroju materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju, a A_{it-1} je vrijednost imovine pomaknuta za jedno razdoblje. Koeficijent zaduženosti, ten_{t-1}, izračunan je kao omjer ukupnog duga i imovine. Pokriće troškova kamata, $icov_{t-1}$, jednako je omjeru EBIT-a i troškova kamata. Veličina, $size_{t-1}$, jednaka je knjigovodstvenoj vrijednosti imovine poduzeća. Stopa likvidnosti, liq_{t-1}, računa se kao omjer neto radnoga kapitala uvećanog za tekuće novčane tokove i imovine. Tekuća likvidnost, cr_{t-1}, jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Stopa neto radnoga kapitala, wc_{t-1}, računa se kao odnos neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Osnovna važna varijabla stopa je novčanog toka, koja je jednaka omjeru novčanog toka (dobit + amortizacija) i vremenski pomaknute vrijednosti imovine. Kontrolna varijabla emp_{it-1} označuje broj zaposlenih; rsg_{it-1} realnu stopu rasta prihoda, a nva_{it-1} stopu dodane nove vrijednosti. U zagradi su dane standardne pogreške. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Obje kolone u tablici 5-13 pokazuju veće koeficijente uz novčane tokove, što je u skladu s drugim istraživanjima. Tekući novčani tokovi bolji su prediktor tekućih investicija od pomaknutih novčanih tokova. To se može vidjeti i po većem R^2-u. Iako su vrijednosti koeficijenta veće, procjena kroz režime ista je kao i u prethodnim specifikacijama. Jedina je razlika u tome što je pri procjeni likvidnog ograničenja vrijednost koeficijenta u drugom režimu manja od koeficijenta u trećem režimu. Treba također napomenuti da korištenje tekućim novčanim tokovima može pridonijeti pristranosti simultanosti (engl. *simultaneity bias*). Moguće je da rast investicija utječe na rast tekućih novčanih tokova, a ne obrnuto. Također je moguće da se unutar godine dana stvori pozitivna povratna petlja tako da rast novčanih tokova pridonese rastu investicija što ponovno pridonosi rastu novčanih tokova i tako dalje. Ipak, čak i uz ovu mogućnost, „likvidna“ poduzeća pokazuju 26 % veći rast investicija uz isto povećanje novčanih tokova.

Na kraju analize robusnosti prikazuju se rezultati *threshold* modela s vremenski pomaknutom zavisnom varijablom. Već je istaknuto da se *threshold* model prema Hansen (1999) odnosi na statički *threshold* model. Međutim, radi dobivanja uvida o mogućem utjecaju dodavanja vremenski pomaknute zavisne varijable na procijenjene parametre, u ovom se dijelu temeljni model proširuje na dinamični panel. U tablici 5-14 prikazani su s dvjema granicama (trima režimima), a u tablici 5-15 prikazani su rezultati s jednom granicom (dvama režimima). Pri procjeni financijskog ograničenja, 1. kolona (koeficijent zaduženosti kao *threshold* varijabla) i 2. kolona (pokriće troškova kamata kao *threshold* varijabla) pokazuju nemonotonost osjetljivosti investicija na novčane tokove, a u 3. koloni (veličina poduzeća kao *threshold* varijabla) postoji monotono rastuća odjeljivost investicija na novčane tokove kao funkcija rasta broja poduzeća (prema hipotezi bi trebalo biti suprotno). Za likvidno ograničenje, 4. kolona (stopa likvidnosti kao *threshold* varijabla) pokazuje monotono padajuću osjetljivost investicija na novčane tokove, a preostale dvije kolone pokazuju nemonotonost odjeljivosti (negativna osjetljivost za „nelikvidna“ poduzeća, pozitivna za „likvidna“ i nesignifikantna za „prelikvidna“). Može se zaključiti da su rezultati isti kao i u temeljnome modelu. Ponovno se ističe da je threshold regresija u ovom radu statička i da je dinamički panel prikazan u tablicama 5-13 i 5-14 orijentir o robusnosti rezultata na proširenje na dinamički panel. Ovo posebno vrijedi onda kada je vremenska dimenzija (T) relativno kratka.

Tablica 5-14: Procijenjeni parametri statičke threshold regresije na balansiranu uzorku poslovnih subjekata s trima režimima

Model	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE threshold**
Zavisna varijabla	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}
Fiksni efekti za tvrtke	DA	DA	DA	DA	DA	DA
Fiksni efekti za godine	DA	DA	DA	DA	DA	DA
Režim $q_{\{it\}} \leq \gamma_1$						
cf_{it-1}^{nisko}	0.013^{***}	-0.097^{***}	0.015^{***}	-0.063^{***}	-0.003	0.008
	(0.005)	(0.011)	(0.005)	(0.010)	(0.009)	(0.008)
emp_{it-1}	-0.000^{***}	-0.000^{***}	0.011	-0.000^{***}	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.122^{***}	0.108^{***}	0.130^{***}	0.043^{***}	0.048^{***}	0.060^{***}
	(0.004)	(0.009)	(0.005)	(0.008)	(0.008)	(0.007)
nva_{it-1}^2	-0.031^{***}	-0.030^{***}	-0.032^{***}	0.011^{**}	0.005	-0.004
	(0.002)	(0.006)	(0.002)	(0.005)	(0.005)	(0.004)
i_{it-1}	-0.026^{***}	-0.014^{***}	-0.057^{***}	-0.004	-0.033	-0.035^{***}
	(0.004)	(0.011)	(0.004)	(0.006)	(0.005)	(0.005)
Režim $\gamma_1 < q_{\{it\}} \leq \gamma_2$						

$cf_{it-1}^{srednje}$	0.066^{***}	-0.048^{***}	0.044^{***}	-0.022^{***}	0.044^{***}	0.044^{***}
	(0.008)	(0.016)	(0.008)	(0.010)	(0.006)	(0.007)
emp_{it-1}	-0.000^{***}	-0.000^{***}	0.000	-0.000^{***}	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.065^{***}	0.049^{***}	0.131^{***}	0.089^{***}	0.088^{***}	0.082^{***}
	(0.006)	(0.008)	(0.005)	(0.006)	(0.005)	(0.005)
nva_{it-1}^2	-0.031^{***}	0.012^{***}	-0.024^{***}	-0.015^{***}	-0.017^{***}	-0.012^{***}
	(0.002)	(0.005)	(0.003)	(0.004)	(0.003)	(0.003)
i_{it-1}	-0.025^{***}	-0.066^{***}	-0.034	-0.035^{***}	-0.038^{***}	-0.040^{***}
	(0.004)	(0.007)	(0.005)	(0.005)	(0.004)	(0.005)
Režim $q_{\{it\}} > \gamma_2$						
cf_{it-1}^{visoko}	-0.040^{***}	0.038^{***}	0.097^{***}	0.023^{***}	0.001	0.003
	(0.009)	(0.005)	(0.009)	(0.005)	(0.006)	(0.005)
emp_{it-1}	-0.000^{***}	0.000^{**}	-0.000^{***}	0.000	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000^{***}	0.000^{***}	0.000	0.000^{**}	0.000
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.069^{***}	0.110^{***}	-0.016^{***}	0.119^{***}	0.129^{***}	0.128^{***}
	(0.009)	(0.004)	(0.008)	(0.005)	(0.005)	(0.005)

nva_{it-1}^2	-0.002^{***}	-0.027^{***}	0.012^{**}	-0.031^{***}	-0.032^{***}	-0.033^{***}
	(0.005)	(0.002)	(0.005)	(0.002)	(0.002)	(0.002)
i_{it-1}	-0.025	-0.035^{***}	-0.012^{***}	-0.023	-0.021	-0.015
	(0.008)	(0.003)	(0.004)	(0.004)	(0.005)	(0.005)
$\boldsymbol{q_{\{it\}}}$	**Koeficijent zaduženosti**	**Pokriće trošk. kamata**	**Veličina**	**Stopa likvidnosti**	**Tekući omjer**	**NRK/imovina**
Broj opservacija	146006	146006	146020	146020	146020	146020
RSS	3300	3294	3291	3297	3300	3300
F statistika	102.36	82.66	261.12	108.92	82.09	96.42

BILJEŠKA: Zavisna je varijabla stopa investicija, $inv_{it} = \frac{I_{it}}{A_{it-1}}$, gdje su investicije, I_{it}, jednake zbroju materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju, a A_{it-1} je vrijednost imovine pomaknuta za jedno razdoblje. Koeficijent zaduženosti, ten_{t-1}, izračunan je kao omjer ukupnog duga i imovine. Pokriće troškova kamata, $icov_{t-1}$, jednako je omjeru EBIT-a i troškova kamata. Veličina, $size_{t-1}$, jednaka je knjigovodstvenoj vrijednosti imovine poduzeća. Stopa likvidnosti, liq_{t-1}, računa se kao omjer neto radnoga kapitala uvećana za tekuće novčane tokove i imovine. Tekuća likvidnost, cr_{t-1}, jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Stopa neto radnoga kapitala, wc_{t-1}, računa se kao odnos neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Osnovna važna varijabla stopa je novčanog toka, koja je jednaka omjeru novčanog toka (dobit + amortizacija) i vremenski pomaknute vrijednosti imovine. Kontrolna varijabla emp_{it-1} označuje broj zaposlenih; rsg_{it-1} realnu stopu rasta prihoda, a nva_{it-1} stopu dodane nove vrijednosti. U zagradi su dane standardne pogreške. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

Tablica 5-15: Procijenjeni parametri statičke threshold regresije na balansiranu uzorku poslovnih subjekata s dvama režimima

Model	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE *threshold***	**Statički FE threshold**
Zavisna varijabla	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}	i_{it}
Fiksni efekti za tvrtke	DA	DA	DA	DA	DA	DA
Fiksni efekti za godine	DA	DA	DA	DA	DA	DA
Režim $q_{\{it\}} \leq \gamma_1$						
cf_{it-1}^{nisko}	0.011^{**}	-0.102^{***}	0.015^{***}	-0.031^{***}	0.008	0.032
	(0.005)	(0.009)	(0.005)	(0.007)	(0.008)	(0.005)
emp_{it-1}	-0.000^{***}	-0.000^{***}	0.004^{***}	-0.000^{***}	-0.000^{***}	-0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}	0.000^{***}
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.119^{***}	0.077^{***}	0.124^{***}	0.078^{***}	0.060^{***}	0.078^{***}
	(0.004)	(0.007)	(0.005)	(0.006)	(0.007)	(0.005)
nva_{it-1}^2	-0.030^{***}	-0.006^{***}	-0.030^{***}	-0.009^{***}	-0.002^{***}	-0.010^{***}
	(0.002)	(0.004)	(0.002)	(0.003)	(0.004)	(0.002)
i_{it-1}	-0.026^{***}	-0.049^{***}	-0.058^{***}	-0.041^{***}	-0.036	-0.042^{***}
	(0.003)	(0.006)	(0.004)	(0.004)	(0.004)	(0.003)
Režim $q_{\{it\}} > \gamma_2$						

cf_{it-1}^{visoko}	0.024^{***}	0.038^{***}	0.058^{***}	0.022^{***}	0.021^{***}	0.003
	(0.006)	(0.005)	(0.006)	(0.005)	(0.004)	(0.005)
emp_{it-1}	-0.000^{***}	-0.000^{***}	-0.000^{***}	-0.000^{***}	-0.000^{***}	0.000
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
rsg_{it-1}	0.000^{***}	0.000^{***}	0.000^{***}	0.000	0.000^{**}	0.000
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
nva_{it-1}	0.070^{***}	0.076^{***}	0.058^{***}	0.078^{***}	0.113^{***}	0.125^{***}
	(0.005)	(0.006)	(0.005)	(0.005)	(0.004)	(0.005)
nva_{it-1}^2	-0.005^{***}	-0.006^{***}	-0.011^{***}	-0.029^{***}	-0.027^{***}	-0.031^{***}
	(0.002)	(0.004)	(0.003)	(0.002)	(0.002)	(0.002)
i_{it-1}	-0.041^{***}	-0.035^{***}	-0.023^{***}	-0.023^{***}	-0.030	-0.014
	(0.003)	(0.003)	(0.003)	(0.004)	(0.003)	(0.004)
$\boldsymbol{q_{\{it\}}}$	**Koeficijent zaduženosti**	**Pokriće trošk. kamata**	**Veličina**	**Stopa likvidnosti**	**Tekući omjer**	**NRK/imovina**
Broj opservacija	146006	146006	146006	146006	146006	146006
RSS	3302	3294	3296	3298	3302	3302
F statistika	164.93	434.96	427.27	316.92	178.95	183.16

BILJEŠKA: Zavisna je varijabla stopa investicija, $inv_{it} = \frac{I_{it}}{A_{it-1}}$, gdje su investicije, I_{it}, jednake zbroju materijalne imovine i amortizacije u sadašnjem razdoblju i materijalne imovine u prethodnom razdoblju, a A_{it-1} je vrijednost imovine pomaknuta za jedno razdoblje. Koeficijent zaduženosti, ten_{t-1}, izračunan je kao omjer ukupnog duga i imovine. Pokriće troškova kamata, $icov_{t-1}$, jednako je omjeru EBIT-a i troškova kamata. Veličina, $size_{t-1}$, jednaka je knjigovodstvenoj vrijednosti imovine poduzeća. Stopa likvidnosti, liq_{t-1}, računa se kao omjer neto radnoga kapitala uvećana za tekuće novčane tokove i imovine. Tekuća likvidnost, cr_{t-1}, jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Stopa neto radnoga kapitala, wc_{t-1}, računa se kao odnos neto radnoga kapitala i vremenski pomaknute vrijednosti imovine. Osnovna važna varijabla stopa je novčanog toka, koja je jednaka omjeru novčanog toka (dobit + amortizacija) i vremenski pomaknute vrijednosti imovine. Kontrolna varijabla emp_{it-1} označuje broj zaposlenih; rsg_{it-1} realnu stopu rasta prihoda, a nva_{it-1} stopu dodane nove vrijednosti. U zagradi su dane standardne pogreške. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$.

5.6 Analiza financijskog i likvidnog ograničenja na nebalansiranu panel-uzorku

Korištenje balansiranog panela podataka o poslovnim subjektima za dugo razdoblje može uzrokovati problem pristranosti preživljavanja. Očekuje se da samo uspješne, profitabilne tvrtke mogu opstati na tržištu 15 godina (uzorak 2000–2014). Za takve se tvrtke očekuje manji stupanj financijskog ograničenja jer, zbog svoje dugovječnosti, vjerojatno uživaju bolji bonitet u investitora i financijskih institucija. Očekuje se i manji stupanj likvidnog ograničenja jer dugoročna nelikvidnost narušava supstanciju poduzeća i smanjuje vjerojatnost njegova opstanka. Tvrtke koje su u navedenu razdoblju bile financijski i likvidno ograničene, vjerojatno su ugašene jer nisu uspjele prebroditi likvidne šokove (posebice u vrijeme Velike recesije). Ovakve subjekte moguće je pratiti samo u nebalansiranu panelu pa se u ovom poglavlju analizira osjetljivost rezultata o financijskom i likvidnom ograničenju na izbor nebalansirana panela podataka. *Threshold* regresija iz prethodna poglavlja zahtijeva balansirane panel-podatke, pa se ona ne može primijeniti. Hansen u svom radu ističe: „Nepoznato je proširenje podataka na nebalansiran panel“ (Hansen 1999, str. 3). Dakle, zbog korištenja nebalansiranim panelom podataka nemoguće je upotrijebiti dosadašnji model, *threshold* regresiju prema Hansen (1999). Stoga se u ovom poglavlju upotrebljavaju statički i dinamički linearni panel-fiksni efekti.

U poglavljima 5.6.1. i 5.6.2. opisuje se prilagodba podataka za analizu te se objašnjava regresijska investicijska jednadžba koja će se procjenjivati nad nebalansiranim panelom podataka. U poglavlju 5.6.3. opisuju se rezultati modela te se ispituje postoji li konzistentnost s postojećim rezultatima o financijskom i likvidnom ograničenju analiziranima u prethodnim poglavljima.

5.6.1 Opis varijabli

Početna baza podataka financijskih izvještaja i statističkih podataka poslovnih subjekata već je opisana u poglavljima 4.1. i 5.2. Prema dosadašnjoj analizi, u ovom se poglavlju upotrebljava nebalansiran panel podataka, što će povećati udio poslovnih subjekata s financijskim i likvidnim poteškoćama. Nad nebalansiranim su panelom obavljene prilagodbe opisane u poglavlju 5.2.1. (izbačeni su subjekti u većinskom državnom vlasništvu i subjekti iz „netržišnih“ sektora). Jedina je razlika u vrijednosti percentila koji označuju granice za

uklanjanje ekstremnih opservacija. Zbog većeg uzorka i veće varijacije uklonjen je veći broj opservacija nego u poglavlju 5.2.. U tablici 5-16 opisana je procedura primijenjena na početni uzorak radi uklanjanja ekstremnih vrijednosti. Primjerice, prvi redak pokazuje da su uklonjene opservacije stope investicija ispod 1. percentila i iznad 95. percentila. Pri uklanjanju percentila u obzir je uzimana raspodjela varijabli i utjecaj na konačan rezultat.

Tablica 5-16: Eliminirani percentili u početnom uzorku

Varijable	Donja granica	Gornja granica
inv_t	0.02	0.95
cf_t	0.02	0.95
$sales_t$	0.02	0.95
nva_t	0.02	0.97
liq_t	0.02	0.97

Sve kontinuirane varijable podijeljene su s pomaknutom vrijednosti kapitala, za razliku od temeljnog modela u poglavlju 5.3., u kojem su dijeljenje s vremenski pomaknutom vrijednosti imovine. Iz uzorka su uklonjene opservacije u kojih je godišnja vrijednost prihoda manja od 50 tisuća kuna. Dodatno, u uzorku su ostavljena samo poduzeća za koja postoje opservacije za tri uzastopna razdoblja. Tri se razdoblja zahtijevaju zbog korištenja pomaknutim vrijednostima u regresijskoj jednadžbi i metode panel-fiksnih efekata koja zahtijeva postojanje najmanje dvaju razdoblja. Sve spomenute prilagodbe smanjuju uzorak s 1.234.335 opservacija od 2000. do 2014. (kompletan uzorak) na 439.012 opservacija od 2002. do 2014. Od toga se samo 12,96 % uzorka odnosi na poduzeća za koja postoje opažanja za sva razdoblja (poduzeća koja bi činila balansiran panel).

Ponašanje investicija konačnog uzorka pokazuje sličnu dinamiku kao i investicije na slici 4-4, s kretanjem investicija za sva poduzeća. Investicije rastu sa 16,3 milijardi kuna 2002. godine na 35,.4 milijarde kuna 2008. godine, a nakon krize padaju na 15,9 milijardi kuna (2014. godina). Može se zaključiti da uzorak u prosjeku ima oko 58 % vrijednosti ukupnih investicija neobrađena uzorka.

Sažetak statističkih veličina za varijable korištene u uzorku dan je u tablici 5-17. Uzorak sadržava 53.539 poduzeća. U njemu se ne pojavljuju nedostajuće vrijednosti (engl. *missing values*). Tekuća likvidnost, koeficijent zaduženosti i broj zaposlenih imaju očekivane minimalne vrijednosti. Valja istaknuti da je maksimalna vrijednost investicija relativno visoka te da postoje čak 62.523 opservacije u kojih je vrijednost investicija jednaka nuli (14,12 % uzorka). Sve varijable pokazuju značajnu varijabilnost unutar vremena za ista poduzeća.

Drugim riječima, varijable pokazuju dostatnu *within* varijaciju za korištenje metode fiksnih efekata.

Tablica 5-17: Sažetak statističkih veličina

VARIJABLE	(1) N	(2) Očekivana vrijednost	(3) Standardna devijacija	(4) min	(5) max
Zaposlenost	439,012	16.27	115.6	0	13,958
Stopa investicija	439,012	0.139	0.282	-0.282	1.998
Novčani tok	439,012	0.203	0.325	-2.452	2.280
Neto radni kapital	439,012	0.226	0.800	-4.856	5.651
Nova dodana vrijednost	439,012	0.725	0.771	-0.262	4.435
Prodaja	439,012	3.383	3.788	0.0840	24.85
koeficijent zaduženosti	439,002	1.786	337.4	0	158,457
tekuća likvidnost	438,358	3.663	235.3	0	130,633
Broj poduzeća	53,539				

Procjena financijskog i likvidnog ograničenja podrazumijeva različito ponašanje investicija za ograničena i neograničena poduzeća. Stoga se uzorak dijeli na poduzorke kako bi se ispitala hipoteza o različitu ponašanju osjetljivosti investicija na novčane tokove za različite poduzorke. Ovakav je pristup uobičajen u radovima koji su financijsko ograničenje testirali osjetljivošću investicija na novčane tokove (pogledati poglavlje 3.2.). Pri tome je naglasak na međuovisnosti financijskog i likvidnog ograničenja na investicije poduzeća. To implicira korištenje dvjema skupinama varijabli za razgraničavanje poduzeća: jedna ili više varijabli koje odražavaju likvidnu poziciju i jedna ili više varijabli koje odražavaju stupanj financijskog ograničenja.

Poduzeća će se dijeliti u poduzorke s obzirom na dvije varijable: stopu likvidnosti i koeficijent zaduženosti. Prva varijabla služi za ispitivanje likvidnog ograničenja, a druga za ispitivanje financijskog ograničenja. Granice koje dijele uzorak odgovaraju procijenjenim granicama u poglavlju 5.4. Budući da su različiti modeli u osnovnoj analizi i analizi robusnosti u poglavlju 5.4., pokazivali različite vrijednosti, kao granice su određene prosječne vrijednosti za svaku varijablu. Granice koje dijele uzorak prikazane su u tablici 5-18. Prvi redak pokazuje granice za varijablu koeficijenta zaduženosti. Prvom režimu pripadaju opservacije u kojima je vremenski pomaknuta vrijednost koeficijenta zaduženosti ispod 0,5. Drugom režimu pripadaju opservacije između 0,5. i 1. Trećem režimu pripadaju poduzeća u kojima je vrijednost obveza veća od kapitala. Poduzeća se mogu označiti kao „nisko zadužena“, „srednje zadužena“ i „visoko zadužena“. Slična je interpretacija tablice i za varijablu stope likvidnosti.

Tablica 5-18: Popis varijabli koje dijele uzorak i vrijednosti granica za svaki režim

Varijabla koja dijeli uzorak	Režimi
Koeficijent zaduženosti, ten_t	$ten_{t-1} < 0.5$ $0.5 \geq ten_{t-1} < 1$ $ten_{t-1} > 1$
Stopa likvidnosti, liq_t	$liq_t < -0.1$ $-0.1 \geq liq_t < 1.5$ $liq_t > 1.5$

5.6.2 Opis ekonometrijskog pristupa

Ekonometrijska analiza panel-podataka poduzeća uobičajeno se provodi upotrebom panel-fiksnih efekata (engl. *fixed effects*) ili slučajnih efekata (engl. *random effects*). Izbor između dvaju modela može se donijeti pomoću Hausmanova testa. Nulta hipoteza testa kaže da je primjereni model slučajnih efekata, a alternativna hipoteza tvrdi da je primjereniji model fiksnih efekata. Ukratko, test provjerava koreliraju li pogreške s regresorima. Nulta hipoteza tvrdi da ne koreliraju. Rezultati Hausmanova testa na nebalansiranu uzorku poduzeća idu u prilog odbacivanja nulte hipoteze (p vrijednost iznosi 0,000). Dakle, test pokazuje da je primjerenija upotreba fiksnih efekata. Podsjećamo da u ovom poglavlju ne upotrebljavamo *threshold* regresiju jer ona prema Hanses (1999) nije primjenjiva na nebalansiran panel. U fiksnim je efektima konzistentna procjena parametara moguća i ako su endogeni regresori korelirani s vremenski invarijantnom komponentom pogrešaka relacije. Nedostatak je nemogućnost procjene vremenski invarijantnih regresora. Također, procjenitelji će biti nepouzdani ako regresori vrlo malo variraju tijekom vremena (Cameron i Trivedi, 2009). Regresijska jednadžba koja se procjenjuje ima sljedeći oblik:

$$inv_{it} = \mu_i + \beta cf_{i,t-1} + \boldsymbol{\delta x'_{it}} + \alpha_i + \mu_t + u_{it}, \qquad i = 1, \dots, N, \qquad t = 1, \dots, T \qquad (138)$$

gdje je inv_{it} stopa investicija (investicije podijeljene s pomaknutim ukupnim kapitalom), $cf_{i,t-1}$ pomaknuta vrijednost stope novčanog toka, $\boldsymbol{x_{it}}$ vektor ostalih eksplanatornih varijabli, uključujući i konstantni član, $\boldsymbol{\delta}$ je vektor konstanti, α_i i μ_t su neopaženi individualni i vremenski specifični efekti (engl. *unobserved individual and time specific effects*), za koje se pretpostavlja da su konstantni za dani i i različite t te za dani t, a različite i. Član u_{it} odražava efekte neopaženih varijabli koje variraju kroz i i t.

Kontrolne varijable u modelu uključuju stopu prihoda (prihodi podijeljeni s vremenski pomaknutom vrijednosti kapitala), broj zaposlenih, koeficijent zaduženosti i stopu dodane nove vrijednosti. Sve varijable, osim broja zaposlenih i intenziteta zaduženosti, podijeljene su s pomaknutim kapitalom kako bi se postigla usporedivost s rezultatima drugih istraživanja.

Osnovna je hipoteza ista kao i u prethodnoj analizi. Očekuje se da likvidno i financijsko ograničena poduzeća pokazuju manju osjetljivost investicija na novčane tokove od neograničenih poduzeća. Pri tome je veza različita. U financijskim se ograničenjima očekuje monotono rastuća osjetljivost, a u likvidnim ograničenjima nelinearan odnos tekućeg omjera i osjetljivosti investicija na novčane tokove. Procjena je izvršena u statističkom programu Stata, a kodovi su dostupni na zahtjev.

5.6.3 Rezultati analize financijskog i likvidnog ograničenja na nebalansiranu uzorku

U nastavku se prikazuju rezultati procjene jednadžbe (138) za različite specifikacije modela (različite kontrolne varijable) i različite poduzorke ukupnog uzorka. Prvo se u tablici 5-19 prikazuju rezultati modela panel-fiksnih efekata na cjelokupnu uzorku. U prve tri kolone upotrebljavaju se pomaknute vrijednosti nezavisnih varijabli, a u sljedeće tri dodaju se i tekuće vrijednosti nezavisnih varijabli. Posebno se ispituje utjecaj dodavanja stope dodane nove vrijednosti i stope likvidnosti kao kontrolne varijable tako da se posebno pokazuju rezultati s modelom koji sadržava ove dvije kontrolne varijable (kolone 2, 3, 5 i 6) i rezultati koji ne sadržavaju dodanu novu vrijednost i stopu likvidnosti kao kontrolne varijable. Presudna je vrijednost procijenjena parametra uz novčane tokove.

Prva kolona pokazuje pozitivan utjecaj vremenski pomaknutih novčanih tokova (cf_{t-1}) na stopu investicija (inv_t). Koeficijent iznosi 0,032 i statistički je signifikantan uz razinu značajnosti 1 %. Dodavanjem stope likvidnosti (liq_{t-1}) u investicijsku jednadžbu koeficijent postaje negativan i statistički nesignifikantan uz razinu značajnosti 1 %. Uključivanje dodane nove vrijednosti kao kontrolne varijable dodatno umanjuje vrijednost koeficijenta uz novčane tokove, odnosno koeficijent postaje negativan. Ako se prihvati pretpostavka da nova dodana vrijednost kontrolira za agregatnu potražnju, novčani tok nema pozitivan utjecaj na investicije na uzorku svih poduzeća (uzorak je čak negativan). Treba istaknuti da se u drugim istraživanjima ne upotrebljavaju dodana nova vrijednost i stopa likvidnosti kao kontrolna varijabla i da su koeficijenti uz novčane tokove u prosjeku veći nego u predmetnoj analizi (npr.

oko 0,19 u istraživanju Tarassowa (2017) na uzorku njemačkih tvrtki). Kolone 3., 4. i 5. pokazuju znatno veći koeficijent uz *tekuće* novčane tokove, što je također u skladu s drugim istraživanjima. Koeficijent uz tekuće novčane tokove (cf_t) ekonomski je signifikantan u svim trima specifikacijama. Valja istaknuti da je koeficijent uz vremenski pomaknutu vrijednost stope likvidnosti znatno veći od svih drugih vremenski pomaknutih varijabli.

Tablica 5-20 pokazuje rezultate Arellano-Bond GMM modela s vremenski pomaknutom zavisnom varijablom s desne strane investicijske jednadžbe. Prve tri kolone pokazuju izrazito negativne koeficijente uz novčane tokove, nakon uključivanja pomaknutih investicija u regresijsku jednadžbu. Za razliku od drugih istraživanja, koeficijent je uz novčane tokove negativan i statistički signifikantan uz razinu značajnosti 1 %. Koeficijent je negativan čak i u prvoj koloni, koja ne sadržava dodatne kontrolne varijable. Ako se u model dodaju tekuće vrijednosti nezavisnih varijabli (kolone 4., 5. i 6.), koeficijent uz tekuće novčane tokove poprima pozitivne vrijednosti, a one su od 0,15 do 0,55, ovisno o uključenim kontrolnim varijablama.

Može se dakle zaključiti da vremenski pomaknuta vrijednost novčanog toka nema pozitivan utjecaj na investicije ako se kontrolira za promjenu vremenski pomaknute vrijednosti stope investicija, stope dodane nove vrijednosti i/ili stope neto radnoga kapitala, ali da tekući novčani tokovi imaju najveći utjecaj na rast investicija od svih varijabli.

Osnovna je svrha ovog poglavlja ispitivanje heterogenosti u odnosu novčanih tokova i investicija za različite, apriorno određene, skupine poduzeća kako bi se neizravno testirala važnost financijskog i likvidnog ograničenja na investicije poduzeća. Cilj je dakle ispitati hipotezu o monotono rastućoj osjetljivosti investicija na novčane tokove pri financijskom ograničenju i hipotezu o nelinearnu odnosu novčanih tokova i investicija pri procjeni likvidnog ograničenja. Za procjenu parametara panel-regresijskog modela upotrijebit će se panel-fiksni efekti i Arellano-Bond GMM procjenitelji.

Tablica 5-19: Rezultati procjene modela fiksnih efekata na cjelokupnom uzorku hrvatskih nefinancijskih poduzeća od 2002. do 2014.

VARIJABLE	(1) inv_t	(2) inv_t	(3) inv_t	(4) inv_t	(5) inv_t	(5) inv_t
$\boldsymbol{cf_{t-1}}$	**0.0325*** **	**-0.0437*** **	**-0.0811*** **	**0.0296*** **	**-0.167*** **	**-0.190*** **
	(0.00229)	**(0.00314)**	**(0.00337)**	**(0.00225)**	**(0.00369)**	**(0.00393)**
$sales_{t-1}$	0.0183***	0.0171***	0.0124***	0.00223***	0.000237	-0.00274***
	(0.000321)	(0.000326)	(0.000362)	(0.000367)	(0.000350)	(0.000385)
emp_{t-1}	-0.000119***	-0.000123***	-0.000136***	-0.000292***	-0.000276***	-0.000283***
	(3.75e-05)	(3.97e-05)	(4.46e-05)	(5.84e-05)	(5.79e-05)	(6.07e-05)
ten_{t-1}	-3.36e-05	1.97e-06	4.36e-06	-5.63e-05**	-6.29e-05**	-6.36e-05**
	(2.58e-05)	(3.11e-05)	(2.89e-05)	(2.22e-05)	(2.63e-05)	(2.60e-05)
wc_{t-1}		0.0519***	0.0484***		0.172***	0.168***
		(0.00141)	(0.00141)		(0.00238)	(0.00237)
nva_{t-1}			0.0567***			0.0366***
			(0.00199)			(0.00202)
$\boldsymbol{cf_t}$				**0.159*** **	**0.554*** **	**0.539*** **
				(0.00309)	**(0.00614)**	**(0.00647)**
$sales_t$				0.0261***	0.0262***	0.0244***
				(0.000484)	(0.000457)	(0.000489)
emp_t				0.000217***	0.000205***	0.000202***
				(4.40e-05)	(4.54e-05)	(4.47e-05)
ten_t				3.68e-07	-4.29e-07	-3.73e-07
				(7.30e-07)	(5.97e-07)	(6.48e-07)
wc_t					-0.239***	-0.240***
					(0.00298)	(0.00297)
nva_t						0.0184***
						(0.00244)
$cons$	0.124***	0.132***	0.112***	0.0206***	0.0116***	-0.00527**
	(0.00263)	(0.00266)	(0.00270)	(0.00282)	(0.00261)	(0.00265)
N	380,586	380,586	380,586	380,577	380,577	380,577
R^2	0.095	0.103	0.107	0.161	0.266	0.269
P	53,539	53,539	53,539	53,539	53,539	53,539

BILJEŠKA: U tablici su prikazane vrijednosti procijenjenih parametara modela panel-fiksnih efekata. Zavisna je varijabla stopa investicija, $inv_t = \frac{I_{it}}{K_{it-1}}$. Nezavisne su varijable stopa prihoda, broj zaposlenih, koeficijent zaduženosti i nova dodana vrijednost. Oznake $*$, $**$, $***$ skraćene su oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$. U zagradi su dane robusne standardne pogreške. N označuje broj opservacija. P označuje broj poduzeća.

Tablica 5-20: Rezultati procjene Arellano-Bond GMM modela na cjelokupnu uzorku hrvatskih nefinancijskih poduzeća od 2002. do 2014.

VARIJABLE	(1) inv_t	(2) inv_t	(3) inv_t	(4) inv_t	(5) inv_t	(5) inv_t
inv_{t-1}	**0.0777*** **	**0.135*** **	**0.130*** **	**0.0348*** **	**0.0439*** **	**0.0426*** **
	(0.00292)	**(0.00336)**	**(0.00340)**	**(0.00263)**	**(0.00263)**	**(0.00268)**
$\boldsymbol{cf_{t-1}}$	-0.0589***	-0.386***	-0.399***	0.00780***	-0.179***	-0.187***
	(0.00328)	(0.00630)	(0.00659)	(0.00278)	(0.00445)	(0.00468)
$sales_{t-1}$	-0.00346***	-0.00722***	-0.00857***	0.00254***	-0.000262	-0.00315***
	(0.000561)	(0.000572)	(0.000610)	(0.000528)	(0.000505)	(0.000533)
emp_{t-1}	-0.000262***	-0.000268***	-0.000280***	-0.000260***	-0.000227***	-0.000241***
	(5.57e-05)	(5.97e-05)	(6.22e-05)	(5.29e-05)	(5.06e-05)	(5.55e-05)
ten_{t-1}	-4.80e-05**	7.19e-06	8.78e-06	-5.84e-05**	-4.32e-05*	-5.60e-05**
	(1.97e-05)	(9.04e-06)	(8.50e-06)	(2.31e-05)	(2.31e-05)	(2.54e-05)
wc_{t-1}		0.220***	0.218***		0.166***	0.159***
		(0.00338)	(0.00338)		(0.00274)	(0.00272)
nva_{t-1}			0.0222***			0.0260***
			(0.00323)			(0.00262)
$\boldsymbol{cf_t}$				**0.117*** **	**0.508*** **	**0.427*** **
				(0.00375)	**(0.00762)**	**(0.00823)**
$sales_t$				0.0615***	0.0568***	0.0480***
				(0.000812)	(0.000758)	(0.000772)
emp_t				1.93e-05	2.10e-05	-3.43e-05
				(2.69e-05)	(2.46e-05)	(3.00e-05)
ten_t				2.42e-07	1.00e-07	3.32e-07
				(6.71e-07)	(9.11e-07)	(9.59e-07)
wc_t					-0.229***	-0.233***
					(0.00382)	(0.00380)
nva_t						0.114***
						(0.00360)
$cons$	0.304***	0.321***	0.313***	-0.134***	-0.0845***	-0.163***
	(0.00400)	(0.00415)	(0.00423)	(0.00487)	(0.00418)	(0.00457)
N	322,161	322,161	322,161	322,152	322,152	322,152
P	53,539	53,539	53,539	53,536	53,536	53,536

BILJEŠKA: U tablici su prikazane vrijednosti procijenjenih parametara modela panel-fiksnih efekata. Zavisna je varijabla stopa investicija, $inv_t = \frac{I_{it}}{K_{it-1}}$. Nezavisne su varijable stopa prihoda, broj zaposlenih, koeficijent zaduženosti i nova dodana vrijednost. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10, p < 0.05, p < 0.01$. U zagradi su dane robusne standardne pogreške. N označuje broj opservacija. P označuje broj poduzeća.

U tablici 5-21 prikazani su procijenjeni parametri za tri skupine poduzeća, pri čemu se kao varijabla razgraničavanja uzorka upotrijebio pokazatelj koeficijenta zaduženosti. Prve tri kolone pokazuju rezultate procjene panel-fiksnih efekata za pomaknute vrijednosti nezavisnih varijabli. Kao i u cijelom uzorku, koeficijenti uz novčane tokove poprimaju negativne vrijednosti. Razlog je ponovno u dodavanju stope nove dodane vrijednosti kao kontrolnih varijabli. Svi su procijenjeni parametri signifikantni uz razinu značajnosti 1 %. Rezultati nisu u skladu s postojećim istraživanjima jer su svi procijenjeni koeficijenti negativni, a u drugim su istraživanjima 0 ili pozitivni. Osjetljivost je investicija na novčane tokove izraženija za nisko zadužena poduzeća, što nije u skladu s hipotezom. Stopa investicija nisko zaduženih poduzeća ne bi trebala ovisiti o promjeni novčanih tokova. Potonji nalazi još su izraženiji promatraju li se posljednje tri kolone u kojima se rabe tekuće vrijednosti zavisnih varijabli. Posljednja bi skupina poduzeća prema teoriji FHP trebala pokazivati najveću vrijednost koeficijenta uz tekuće novčane tokove, a u predmetnoj specifikaciji ona je najmanja. Tablica 5-22 prikazuje GMM procjenitelje za iste poduzorke kao i prethodna tablica. Iako je vrijednost svih koeficijenata manja zbog uključivanja vremenski pomaknute zavisne varijable, mijenjanje vrijednosti koeficijenata uz novčane tokove kroz režime vrlo je slična ponašanju u tablici 5-21. Osjetljivost investicija na novčane tokove monotono je padajuća, upravo suprotno prvoj postavljenoj hipotezi.

Tablica 5-23 konstruirana je na isti način kao i prethodna, ali je kao varijabla razgraničavanja poduzeća poslužila stopa likvidnosti. Za razliku od analize u prethodnim poglavljima, granica je određena apriorno, a ne na temelju podataka (engl. *data driven*) upotrebom *threshold* regresije. Rezultati za prve tri kolone ponovno pokazuju male ili negativne vrijednosti koeficijenta uz novčane tokove zbog uključivanja dodane nove vrijednosti u investicijsku jednadžbu. Radi usporedbe s prijašnjim istraživanja, primjereno je usporediti rezultate uz izostanak potonje varijable. Tada su vrijednosti sljedeće: $\mathrm{cf}_{t-1}^{\mathrm{nisko}} = -0{,}000$, $\mathrm{cf}_{t-1}^{\mathrm{srednje}} = 0{,}043$ i $\mathrm{cf}_{t-1}^{\mathrm{srednje}} = 0{,}015$, pri čemu je prvi koeficijent nesignifikantan uz razinu značajnosti 1 %, a posljednji uz razinu značajnosti 5 %. Procijenjeni koeficijenti uz novčane tokove pokazuju nelinearnu vezu, što potvrđuje drugu hipotezu ovog rada. Valja primijetiti da je granica koja razgraničava nisko i srednje likvidne tvrtke relativno visoka. Ako se primjerice kao granica upotrijebi vrijednost od $\mathrm{wc}_{t-1} < -0{,}5$, vrijednost koeficijenta uz novčane tokove u prvoj koloni iznosi $\mathrm{cf}_{t-1}^{\mathrm{nisko}} = -0{,}016$. Očito je dakle da sa smanjenjem stupnja likvidnosti opada i osjetljivost investicija na novčane tokove. Ako se u investicijsku jednadžbu dodaju tekući novčani tokovi, još postoji nelinearnost u vrijednosti koeficijenta, ali je ona u prvom režimu

(nelikvidna poduzeća) pozitivna (0,06). Rezultati su slični po smjeru, a različiti po intenzitetu ako se upotrebljava GMM procjenitelj (tablica 5-24) s uključenom vremenski pomaknutom zavisnom varijablom. Vrijednost je koeficijenta uz novčane tokove negativna, upravo u skladu s hipotezom o likvidnom ograničenu.

Tablica 5-21: Rezultati procjene modela fiksnih efekata s intenzitetom zaduženosti kao varijablom razgraničavanja uzorka

Varijable	$ten_{t-1} < 0.5$	$0.5 \geq ten_{t-1} < 1$	$ten_{t-1} \geq 1$	$ten_{t-1} < 0.5$	$0.5 \geq ten_{t-1} < 1$	$ten_{t-1} \geq 1$
$\boldsymbol{cf_{t-1}}$	**-0.0413*** **	**-0.0274*** **	**-0.0212*** **	**-0.0483*** **	**-0.0241*** **	**-0.00344**
	(0.00532)	**(0.00443)**	**(0.00689)**	**(0.00593)**	**(0.00440)**	**(0.00716)**
$sales_{t-1}$	0.0173***	0.0130***	0.00793***	0.00231**	-0.000977*	-0.00493***
	(0.00104)	(0.000461)	(0.00145)	(0.00108)	(0.000515)	(0.00154)
emp_{t-1}	-8.87e-05***	-0.000131**	-0.00149***	-0.000141***	-0.000336***	-0.00157***
	(2.85e-05)	(6.27e-05)	(0.000346)	(4.54e-05)	(9.72e-05)	(0.000412)
ten_{t-1}	-0.114***	-0.135***	-6.68e-06	-0.227***	-0.148***	-1.25e-05
	(0.00842)	(0.00786)	(2.75e-05)	(0.0309)	(0.00768)	(2.38e-05)
nva_{t-1}	0.0636***	0.0658***	0.0542***	0.0581***	0.0484***	0.0374***
	(0.00380)	(0.00286)	(0.00692)	(0.00415)	(0.00308)	(0.00723)
$\boldsymbol{cf_t}$				**0.218*** **	**0.194*** **	**0.0228** **
				(0.0128)	**(0.00578)**	**(0.00919)**
$sales_t$				0.0237***	0.0237***	0.0278***
				(0.00204)	(0.000634)	(0.00202)
emp_t				8.66e-05**	0.000241***	0.000571
				(3.81e-05)	(6.57e-05)	(0.000395)
ten_t				0.222***	-9.98e-07***	4.99e-06***
				(0.0736)	(4.04e-08)	(4.04e-07)
nva_t				-0.0211***	0.0192***	0.0382***
				(0.00476)	(0.00373)	(0.00877)
$cons$	0.0976***	0.228***	0.0871***	-0.0188	0.113***	0.00190
	(0.00524)	(0.00752)	(0.0106)	(0.0147)	(0.00749)	(0.0116)
N	118,626	218,942	43,018	118,622	218,938	43,017
R^2	0.083	0.103	0.041	0.182	0.178	0.100
P	24,700	42,945	13,614	24,698	42,945	13,613

BILJEŠKA: U tablici su prikazane vrijednosti procijenjenih parametara osnovnog modela fiksnih efekata za različite, apriorno određene poduzorke nefinancijskih firmi. Zavisna je varijabla stopa investicija, $\frac{I_{it}}{K_{it-1}}$. Nezavisne varijable su objašnjene u poglavljima 4.1. i 5.7.1. Oznake $*$, $**$, $***$ skraćene su oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$. U zagradi su dane robusne standardne pogreške. *N* označuje broj opservacija. *P* označuje broj poduzeća

Tablica 5-22: Arellano-Bond GMM procjenitelji sa intenzitetom zaduženosti kao varijablom razgraničavanja uzorka

Varijable	$\boldsymbol{ten_{t-1} < 0.5}$	$\boldsymbol{0.5 \geq ten_{t-1} < 1}$	$\boldsymbol{ten_{t-1} \geq 1}$	$\boldsymbol{ten_{t-1} < 0.5}$	$\boldsymbol{0.5 \geq ten_{t-1} < 1}$	$\boldsymbol{ten_{t-1} \geq 1}$
inv_{t-1}	0.0408***	0.0693***	0.0434***	-0.0216***	0.0364***	0.0359***
	(0.00675)	(0.00491)	(0.00808)	(0.00653)	(0.00441)	(0.00773)
$\boldsymbol{cf_{t-1}}$	-0.104***	-0.144***	-0.000698	-0.0111	-0.0551***	0.00878
	(0.00758)	(0.0117)	(0.00811)	(0.00756)	(0.0100)	(0.00724)
$sales_{t-1}$	-0.00272**	-0.00384***	-0.00605***	0.000856	1.53e-05	-0.00595***
	(0.00126)	(0.000914)	(0.00156)	(0.00120)	(0.000854)	(0.00147)
emp_{t-1}	-0.000114**	-0.000296***	-0.00131***	-0.000101**	-0.000310***	-0.00147***
	(4.48e-05)	(8.65e-05)	(0.000255)	(4.52e-05)	(8.41e-05)	(0.000261)
ten_{t-1}	-0.0714**	-0.209***	-1.58e-05	-0.0706**	-0.204***	-1.79e-05
	(0.0306)	(0.0718)	(2.82e-05)	(0.0310)	(0.0701)	(2.41e-05)
nva_{t-1}	0.0419***	0.0327***	0.0232***	0.0402***	0.0366***	0.0301***
	(0.00511)	(0.00515)	(0.00807)	(0.00452)	(0.00468)	(0.00733)
$\boldsymbol{cf_t}$				0.124***	0.0629***	-0.0424***
				(0.0125)	(0.00789)	(0.00993)
$sales_t$				0.0404***	0.0497***	0.0462***
				(0.00209)	(0.000952)	(0.00258)
emp_t				1.57e-05	-5.16e-05	-0.000469**
				(3.31e-05)	(5.38e-05)	(0.000227)
ten_t				0.188***	-4.01e-07***	1.08e-06
				(0.0621)	(9.18e-08)	(1.31e-06)
nva_t				0.0575***	0.155***	0.0838***
				(0.00617)	(0.00510)	(0.00995)
$cons$	0.135***	0.0994*	0.184***	-0.281***	-0.0458	-0.0307**
	(0.0174)	(0.0578)	(0.0140)	(0.0218)	(0.0566)	(0.0147)
N	103,748	183,001	35,412	103,744	182,997	35,411
P	23,367	40,660	12,567	23,365	40,659	12,566

BILJEŠKA: U tablici su prikazane vrijednosti procijenjenih parametara Arellano-Bond GMM modela za različite, apriorno određene poduzorke nefinancijskih tvrtki. Zavisna je varijabla stopa investicija, $\frac{I_{it}}{K_{it-1}}$. Nezavisne su varijable objašnjene u poglavljima 4.1. i 5.7.1. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10, p < 0.05, p < 0.01$. U zagradi su dane robusne standardne pogreške. N označuje broj opservacija. P označuje broj poduzeća

Tablica 5-23: Rezultati procjene modela fiksnih efekata sa stopom neto radnoga kapitala kao varijablom razgraničavanja uzorka

Varijable	$wc_{t-1} < -0.1$	$-0.1 \geq wc_{t-1} < 1.5$	$wc_{t-1} \geq 1.5$	$wc_{t-1} < -0.1$	$-0.1 \geq wc_{t-1} < 1.5$	$wc_{t-1} \geq 1.5$
$\boldsymbol{cf_{t-1}}$	**-0.0401*** **	**-0.00388**	**-0.0251** **	**-0.0152** **	**-0.0340*** **	**-0.0757*** **
	(0.00648)	**(0.00476)**	**(0.0111)**	**(0.00670)**	**(0.00491)**	**(0.00792)**
$sales_{t-1}$	0.0131***	0.0134***	0.00628*	-0.00178*	-0.00198***	-0.000719
	(0.000982)	(0.000521)	(0.00365)	(0.00108)	(0.000588)	(0.000982)
emp_{t-1}	-7.65e-05**	-0.000165***	-0.000848*	-0.000166**	-0.000289***	-0.000605*
	(3.74e-05)	(4.30e-05)	(0.000496)	(7.17e-05)	(6.74e-05)	(0.000346)
ten_{t-1}	-7.57e-07	-0.0175***	-1.87e-05	-1.05e-05	-0.0241***	-0.240***
	(2.72e-05)	(0.00650)	(2.44e-05)	(2.33e-05)	(0.00929)	(0.0229)
nva_{t-1}	0.0607***	0.0711***	0.0617***	0.0414***	0.0612***	0.0367***
	(0.00526)	(0.00273)	(0.0112)	(0.00564)	(0.00308)	(0.00525)
$\boldsymbol{cf_t}$				**0.0611*** **	**0.226*** **	**0.153*** **
				(0.00800)	**(0.00575)**	**(0.0103)**
$sales_t$				0.0311***	0.0241***	0.0209***
				(0.00145)	(0.000704)	(0.00126)
emp_t				0.000105*	0.000185***	0.000268*
				(5.65e-05)	(4.85e-05)	(0.000154)
ten_t				6.55e-06***	-1.21e-06***	0.297***
				(3.42e-07)	(6.75e-08)	(0.0416)
nva_t				0.0467***	0.000659	0.00101
				(0.00696)	(0.00363)	(0.00647)
$cons$	0.109***	0.104***	0.0464**	0.0132**	0.0112*	-0.0978***
	(0.00599)	(0.00529)	(0.0196)	(0.00657)	(0.00668)	(0.0191)
N	86,256	249,136	14,125	86,255	249,131	45,191
R^2	0.072	0.095	0.034	0.135	0.168	0.130
P	27,596	44,980	5,211	27,596	44,979	16,289

BILJEŠKA: U tablici su prikazane vrijednosti procijenjenih parametara osnovnog modela fiksnih efekata za različite, apriorno određene poduzorke nefinancijskih tvrtki. Zavisna je varijabla stopa investicija, $\frac{I_{it}}{K_{it-1}}$. Nezavisne su varijable objašnjene u poglavljima 4.1. i 5.7.1. Oznake $*$, $**$, $***$ su skraćene oznake za $p < 0.10$, $p < 0.05$, $p < 0.01$. U zagradi su dane robusne standardne pogreške. N označuje broj opservacija. P označuje broj poduzeća

Tablica 5-24: Arellano-Bond GMM procjenitelji sa stopom neto radnoga kapitala kao varijablom razgraničavanja uzorka

Varijable	$\boldsymbol{wc_{t-1} < -0.1}$	$\boldsymbol{-0.1 \geq wc_{t-1} < 1.5}$	$\boldsymbol{wc_{t-1} \geq 1.5}$	$\boldsymbol{wc_{t-1} < -0.1}$	$\boldsymbol{-0.1 \geq wc_{t-1} < 1.5}$	$\boldsymbol{wc_{t-1} \geq 1.5}$
inv_{t-1}	0.0846***	0.0584***	0.0931***	0.0545***	0.0206***	-0.0323**
	(0.00648)	(0.00371)	(0.0166)	(0.00589)	(0.00336)	(0.0134)
$\boldsymbol{cf_{t-1}}$	**-0.0172****	**-0.0854*****	**-0.205*****	**0.00728**	**-0.0167*****	**-0.0754*****
	(0.00750)	**(0.00553)**	**(0.0111)**	**(0.00688)**	**(0.00484)**	**(0.00882)**
$sales_{t-1}$	-0.00739***	-0.00452***	-0.00612***	-0.00592***	-0.00166**	0.00486***
	(0.00149)	(0.000722)	(0.00140)	(0.00139)	(0.000687)	(0.00120)
emp_{t-1}	-0.000275*	-0.000266***	-0.000760	-0.000236*	-0.000257***	-0.000647*
	(0.000160)	(5.68e-05)	(0.000493)	(0.000139)	(5.78e-05)	(0.000370)
ten_{t-1}	-7.51e-06	-0.0245**	-0.0987**	-2.34e-05	-0.0258**	-0.104***
	(2.95e-05)	(0.0101)	(0.0498)	(2.66e-05)	(0.0106)	(0.0357)
nva_{t-1}	0.00398	0.0282***	0.0900***	0.0178***	0.0287***	0.0703***
	(0.00719)	(0.00394)	(0.00749)	(0.00645)	(0.00346)	(0.00624)
$\boldsymbol{cf_t}$				**-0.0524*****	**0.114*****	**0.121*****
				(0.00912)	**(0.00652)**	**(0.0112)**
$sales_t$				0.0646***	0.0489***	0.0393***
				(0.00207)	(0.00103)	(0.00150)
emp_t				-5.84e-05	-4.84e-05	-0.000491*
				(6.61e-05)	(3.88e-05)	(0.000274)
ten_t				2.09e-06	-5.45e-07***	0.317***
				(2.33e-06)	(1.22e-07)	(0.0374)
nva_t				0.175***	0.111***	0.0576***
				(0.00866)	(0.00478)	(0.00783)
$cons$	0.677***	0.182***	0.398***	0.183***	-0.215***	-0.0624**
	(0.0145)	(0.00962)	(0.0417)	(0.0120)	(0.0100)	(0.0242)
N	69,405	217,258	35,498	69,404	217,253	35,495
P	24,521	42,860	13,834	24,521	42,859	13,832

BILJEŠKA: U tablici su prikazane vrijednosti procijenjenih parametara Arellano-Bond GMM modela za različite, apriorno određene poduzorke nefinancijskih tvrtki. Zavisna je varijabla stopa investicija, $\frac{I_{it}}{K_{it-1}}$. Nezavisne su varijable objašnjene u poglavljima 4.1. i 5.7.1. Oznake $*$, $**$, $***$ skraćene su oznake za $p < 0.10, p < 0.05, p < 0.01$. U zagradi su dane robusne standardne pogreške. N označuje broj opservacija. P označuje broj poduzeća

6 UČINAK ZAKONA O FINANCIJSKOM POSLOVANJU I PREDSTEČAJNOJ NAGODBI NA INVESTICIJE PODUZEĆA

6.1 Efekti tretmana i *difference-in-differences* procjenitelj uparivanja

Savršena tržišta kapitala impliciraju nezavisnost financijskog položaja tvrtke (struktura kapitala, dospijeće dugova, valutna struktura dugova i drugo) prema odlukama o investicijama. U takvim uvjetima stupanj financijskog ograničenja, odnosno postojanje financijskih frikcija, najčešće se procjenjuje osjetljivošću investicija na novčane tokove kao funkcije zaduženosti poduzeća. Kako je opisano u poglavlju 3.2.2., nekoliko je kritika takva pristupa, a osnovna je problem endogenosti. On se može eksplicirati kao pogreška u mjerenju q-a ili nedostajuće varijable u regresiji (investicijske prilike). Drugim riječima, javlja se problem identifikacije faktora ponude i potražnje za kreditima. Čak i nelinearne regresijske metode primijenjene u prošlom poglavlju ne mogu dovoljno pouzdano utvrditi je li visoki koeficijent uz novčani tok rezultat manjega financijskog ograničenja (faktora ponude kapitala) ili rasta profitabilnosti (faktora rasta potražnje). Prevladavanje ovog problema zahtijeva primjenu metode (kvazi)prirodnih eksperimenta, koji impliciraju procjenu učinka primjene egzogenog tretmana na varijablu ishoda. Radovi s potonjim pristupom opisani su poglavlju 3.3. U ovom se radu kao tretman upotrebljava Zakon o financijskom poslovanju i predstečajnoj nagodbi, a kao metoda *difference-in-differences matching* procjenitelj. U nastavku se stoga detaljnije opisuje metoda efekta tretmana i difference-in-differences matching procjenitelja (RR procjenitelj) prema Roberts i Whited (2013) i Angrist te Pischke (2009).

U studijama efekta tretmana cilj je procijeniti kauzalni efekt binarne varijable na varijable ishoda (Roberts, Whited, 2013). Binarna varijabla, d, ima vrijednost 1 ako je primijenjen tretman, i 0 ako nije primijenjen. Poduzeća na koja je primijenjen tretman tretmanska su skupina, a ona koja nisu primila tretman kontrolna su skupina. Varijabla ishoda može se označiti s γ. Moguća su dva ishoda, $\gamma(1)$ i $\gamma(0)$, ovisno o tome je li tvrtka primila tretman ili nije. Efekt tretmana razlika je između dvaju ishoda, $\gamma(1) - \gamma(0)$. Ako se primijeni operator očekivanja, moguće je izračunati tri različita efekta tretmana (Roberts, Whited, 2013):

$$Prosječni\ efekt\ tretmana\ (PTE) = E[\gamma(1) - \gamma(0)] \tag{132}$$

$$Prosječni\ efekt\ tretmana\ tretiranih\ (PTET) = E[\gamma(1) - \gamma(0)|d = 1] \tag{133}$$

$$Prosječni\ efekt\ tretmana\ netretiranih\ (PTEN) = E[\gamma(1) - \gamma(0)|d = 0] \quad (134)$$

Iz jednadžbi je odmah jasno koji je glavni problem u procjeni efekta tretmana. U stvarnosti se može opaziti samo jedan mogući ishod. Primjerice, ako se slučajno izabere poduzeće iz podskupine tretiranih poduzeća ($d = 1$), mogu se opaziti samo $\gamma(1)$, ali ne i $\gamma(0)$. U literaturi se ishod koji se ne može opaziti naziva protučinjenični ishod ili protučinjenični učinak (engl. *counterfactual*). Formalno, opaženi ishod može se zapisati na sljedeći način (Roberts, Whited, 2013):

$$\gamma = \begin{cases} \gamma(0)\ ako\ d = 0 \\ \gamma(1)\ ako\ d = 1 \end{cases} \quad (135)$$

$$\gamma = \gamma(0) + d[\gamma(1) - \gamma(0)]$$

Potonja je formulacija korisna jer izraz $\gamma(1) - \gamma(0)$ označuje kauzalni efekt određenog tretmana za određenog agenta (poduzeće). U realnosti će postojati distribucija ishoda za različite agente među poduzećima, pa tretman može dati različite ishode za različite agente. Budući da postoji problem nedostajuće varijable (jedan se ishod ne može opaziti), efekt tretmana moguće je procijeniti na sljedeći način (Roberts, Whited, 2013):

$$E[\gamma(1)|d = 1, X] - E[\gamma(0)|d = 0, X] \quad (136)$$

gdje je X skup eksplanatornih varijabli $(x_1, \dots, x_k)$, koje su relevantne za γ i korelirane s d. Ako se zanemare eksplanatorne varijable, jednadžba (143) označuje razliku u prosječnim ishodima za tretmansku i kontrolnu skupinu. Upotrebljavajući (135), (136) se može zapisati na sljedeći način (Roberts, Whited, 2013):

$$E[\gamma(1)|d = 1] - E[\gamma(0)|d = 0] = \{E[\gamma(1)|d = 1] - E[\gamma(0)|d = 1]\} \quad (137)$$

$$+\{E[\gamma(0)|d = 1] - E[\gamma(0)|d = 0]\}$$

Jednadžba pokazuje da jednostavna usporedba prosjeka tretmanske i kontrolne skupine ne odgovara efektu tretmana. Prva razlika u jednadžbi koja se može označiti i izrazom $E[\gamma(1) - \gamma(0)|d = 1]$ odgovara PTET-u, a druga je razlika pristranost izbora (engl. *selection bias*). Pristranost izbora odražava mogućnost povezanosti tretmana i ishoda. Upravo je mogućnost povezanosti tretmana i mogućih ishoda glavni problem u procjeni kauzalnog efekta tretmana na varijablu ishoda.

Kako se može riješiti navedeni problem? Najjednostavnije rješenje slučajna je primjena tretmana na pojedina poduzeća. Pritom je primjena tretmana, d, nezavisna od potencijalnih ishoda $(\gamma(0), \gamma(1))$, pa je pristranost izbora jednaka nuli. Tada je PTE jednak $PTET$ (jer je $E[\gamma(1)|d = 1] = E[\gamma(1)]$, i $E[\gamma(0)|d = 1] = E[\gamma(0)]$, to jest $E[\gamma(0)|d = 1] = E[\gamma(0)|d = 0]$). Jednostavnije rečeno, slučajna primjena tretmana osigurava da je opažena razlika između poduzeća u prosjeku mala. Međutim, u praksi, posebice u primjeni ekonomskih politika, takvo je rješenje neprimjenjivo. Istraživači nemaju kontrolu nad primjenom tretmana, već se analiza provodi nad opaženim (retrospektivnim, neeksperimantalnim) podacima.

Jednadžba (139) se može proučavati i unutar regresijske analize, s dodatnim eksplanatornim varijablama. Primjenom vektora X može se kontrolirati za određene razlike između tretmanske i kontrolne skupine. Ako su kontrolna i tretmanska skupina balansirane (kontrolne su varijable nekorelirane s tretmanom), onda će procjena efekta tretmana biti vrlo blizu procjene iz skraćene jednadžbe. Problem nastaje kada postoje neopažene razlike između poduzeća. Ukratko, postavlja se pitanje primjene odgovarajuće metode za procjenu kauzalne veze između tretmana i varijable ishoda.

U doktorskom se radu za procjenu efekta tretmana upotrebljava *difference-in-differences* procjenitelj (RR procjenitelj). On je sličan metodi prirodnih i kvazieksperimenata.[48] Metoda omogućuje tri različita pristupa procjeni efekta tretmana. Prvo, moguće je procjenjivati razliku u ishodima nakon primjene tretmana. Ova metoda implicira raspolaganje prostornim podacima o ishodima za kontrolnu i tretmansku skupinu. Druga metoda uzima u obzir i informacije prije tretmana, pa se podrazumijeva raspolaganje vremenskim odsječcima za poduzeća koja su primila tretman, a kontrolna i tretmanska skupina uključuju opservacije prije i nakon tretmana. Treći pristup kombinira prethodna dva pristupa, a naziva se *difference-in-differences* procjenitelj. Uzimaju se dvije skupine poduzeća sličnih karakteristika. Ako u poduzećima koja su primila tretman postoji signifikantan učinak na varijablu ishoda, a u kontrolnoj skupini primjena tretmana ne stvara signifikantan utjecaj, može se zaključiti da postoji uzročno-posljedična veza između tretmana i varijable ishoda.

Regresijski model RR procjenitelja ima sljedeći oblik (Roberts, Whited, 2013):

$$\gamma = \beta_0 + \beta_1 d \times p + \beta_2 d + \beta_3 p + u \tag{138}$$

[48] Razlika je između termina u tome što se u potonjem prostorne jedinice pojavljuju u svim promatranim razdobljima.

gdje je d tretmanksa varijabla, p indikator jednak 1 za razdoblje prije tretmana i 0 nakon tretmana. Tretmanska bi varijabla trebala kontrolirati za permanentne (vremenski invarijantne) razlike između kontrolne i tretmanske skupine. Varijabla p trebala bi kontrolirati za trendove zajedničke tretmanskoj i kontrolnoj skupini. Preostala je varijacija dana s β_1, a trebala bi pokrivati varijacije koje su rezultat tretmana (RR procjenitelj). Formalno, moguće je izračunati uvjetne vjerojatnosti četiriju kombinacija indikatorskih varijabli (Roberts, Whited, 2013):

$$E(\gamma|d = 1, p = 1) = \beta_0 + \beta_1 + \beta_2 + \beta_3 \tag{139}$$

$$E(\gamma|d = 1, p = 0) = \beta_0 + \beta_2$$

$$E(\gamma|d = 0, p = 1) = \beta_0 + \beta_3$$

$$E(\gamma|d = 0, p = 0) = \beta_0$$

pretpostavljajući $E(u|d, p) = 0$. Ako se uvjetna očekivanja poredaju u tablicu i izračunaju razlike, dobije se tablica 6-1 (Roberts, Whited, 2013.)

Tablica 6-1: Procijenjena uvjetna očekivanja (Roberts, Whited, 2013)

	Poslije tretmana	Prije tretmana	Razlika
Tretman	$\beta_0 + \beta_1 + \beta_2 + \beta_3$	$\beta_0 + \beta_2$	$\beta_1 + \beta_3$
Kontrola	$\beta_0 + \beta_3$	β_0	β_3
Razlika	$\beta_1 + \beta_2$	β_2	$\boldsymbol{\beta_1}$

Procjenitelj β_1 može biti izračunan na dva načina; kao razlika prvih dvaju redaka posljednje kolone i kao razlika prvih dviju kolona posljednjeg retka. U prvom slučaju razlika odražava promjenu u tretmanskoj varijabli prije i poslije tretmana i promjenu u kontrolnoj varijabli prije i poslije tretmana. U drugom slučaju razlika odražava promjenu tretmanske i kontrolne skupine prije tretmana i tretmanske i kontrolne skupine nakon tretmana.

Jednadžba (138) se može proširiti za skup kontrolnih varijabli. Tri su razloga za to: 1) OLS procjenitelji su efikasniji jer kontrolne varijable smanjuju varijancu pogrešaka relacije, 2) kontrola nasumična odabira tretmana; uključivanje nezavisnih varijabli ne bi trebalo stvarati velike razlike u efektu tretmana i 3) prilagođavanje na uvjetni nasumičan odabir (engl. *conditional randomization*). Ako primjena tretmana nije slučajna nego ovisi o nekom pravilu, potrebno je kontrolirati pravilo za to..

Očito je da RR procjenitelj kontrolira za permanentne razlike među tvrtkama i opće trendove koji utječu na obje skupine. Koji je onda problem pri identifikaciji RR procjenitelja? Kao i u

svakoj regresiji, ključna je pretpostavka o nultom uvjetnom očekivanju (engl. *zero conditional mean*). Ova je pretpostavka poznata i pod nazivom „pretpostavka paralelnih trendova“. Pojam je najlakše objasniti pomoću slike:

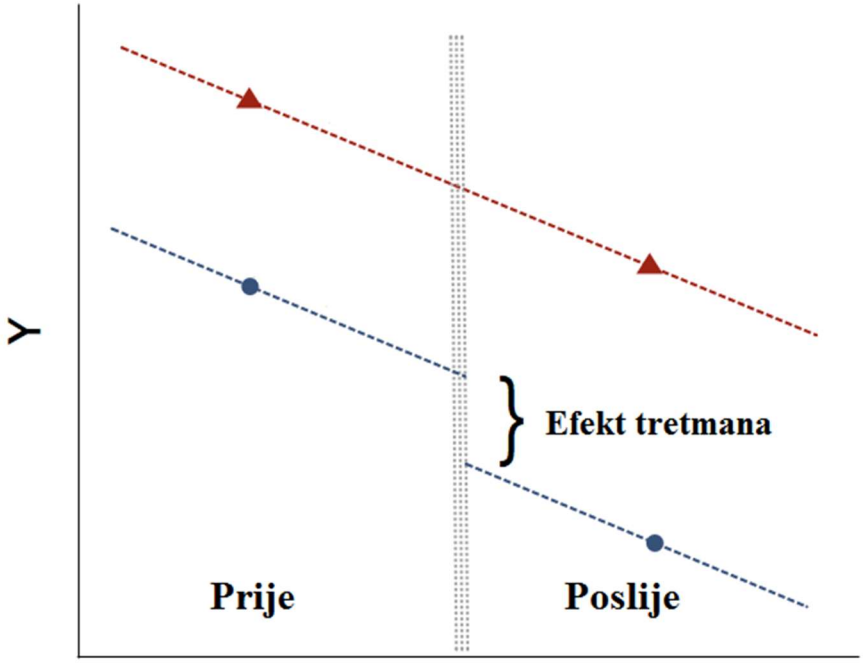

Slika 6-1: Grafička analiza efekta tretmana

Trendovi na grafikonu prikazuju vrijednosti varijabli ishoda u razdobljima prije i poslije tretmana. Kao što sam naziv govori, pretpostavka „paralelnih trendova“ pretpostavlja slične trendove za tretmansku i kontrolnu skupinu prije primjene tretmana. Jednostavno rečeno, bez primjene tretmana vrijednost DD procjenitelja iznosila bi 0, što se formalno može zapisati kao $E[\Delta\gamma(0)|d = 1, X] - E[\Delta\gamma(0)|d = 0, X] = 0$ (Mora i Reggio, 2012). Nisu važni iznosi varijable ishoda, već njihove promjene kroz vrijeme. Efekt tretmana tada je jednostavna razlika u promjeni varijable ishoda između kontrolne i tretmanske skupine, prije i poslije tretmana. Ako trendovi nisu paralelni, RR procjenitelj je pristran jer ne odražava efekt tretmana, već druge, neopažene razlike između tretmanske i kontrolne skupine. Problem paralelnosti trendova često se pokušava riješiti dodavanjem odgovarajućih kontrolnih varijabli. Međutim, uključivanje kontrolnih varijabli u regresiju ne mijenja činjenicu da skupine u uzorku mogu imati vrlo različite karakteristike. U ovom se radu stoga primjenjuje drukčiji pristup. Kontrolnu skupinu neće činiti svi subjekti koji nisu primili tretman, već će se iz skupine netretiranih subjekata izabrati oni koji su najsličniji subjektima iz tretmanske skupine. Za uparivanje subjekata tretmanske i kontrolne skupine primijenit će se metoda uparivanja (engl. *matching method*).

Metoda uparivanja svodi se na identificiranje subjekta u kontrolnoj skupini, sličnih subjektima u tretmanskoj skupini. Ishodi sličnih subjekata u razdoblju nakon tretmana aproksimiraju protučinjenične ishode subjekata iz tretmanske skupine. Primjerice, ako se želi procijeniti utjecaj tretmana na investicije, prvo se među poduzećima koja nisu primila tretman pronalaze ona koja su po određenim karakteristikama (kovarijablama) slična poduzećima koja su primila tretman. Razlika između investicija ovih dviju skupina, u razdoblju nakon tretmana, jest efekt tretmana. Procjeniteljem uparivanja može se koristiti za prostorne i panel-podatke. U drugom je slučaju riječ o RR procjenitelju uparivanja (engl. *difference-in- differences matching estimator*).

Dvije su pretpostavke nužne da bi procjenitelj uparivanja bio konzistentan (Imbens, 2004). Prvo, uvjetovano na opažene kovarijable X, potencijalni ishodi $\gamma(0)$ i $\gamma(1)$ nezavisni su od promjene tretmana d. Drugim riječima, kontrolirajući za opažene kovarijable, primjena tretmana na tretmansku i kontrolnu skupinu ima značajke slučajnosti. Prva je pretpostavka poznata kao pretpostavka uvjetne nezavisnosti (engl. *conditional indenpedence assumption*) ili „unconfoundedness“, a formalno se zapisuje na sljedeći način (Imbens, 2004):

$$\big(\gamma(0), \gamma(1)\big) \perp d|X \tag{140}$$

Druga pretpostavka kaže da za svaku vrijednost kovarijable postoji pozitivna vjerojatnost pripadanja kontrolnoj ili tretmanskoj skupini (Imbens, 2004):

$$0 < Pr(d = 1|X) < 1 \tag{141}$$

Ako bi za dani vektor kovarijabli svi subjekti izabrali tretman ($Pr(d = 1|X)$=1), tada ne bi postojali subjekti koji bi pripadali kontrolnoj skupini. U praksi, pretpostavka ($Pr(d = 1|X)$=1) podrazumijeva da za dani vektor kovarijabli ne postoji subjekt u kontrolnoj skupini sličan danom subjektu u tretmanskoj skupini. Druga je pretpostavka poznata kao pretpostavka identifikacije ili preklapanja (engl. *overlap assumption*).

Iako je metoda uparivanja poduzeća intuitivno jednostavna, primjena zahtijeva izbor između nekoliko mogućnosti. Prvo, moguće je procjenjivati PTE, $PTET$ i $PTEN$. Za procjenu PTE potrebno je pronaći parove za poduzeća iz tretmanske i kontrolne skupine, za $PTET$ iz kontrolne skupine, a za $PTEN$ samo iz tretmanske skupine. U radu se procjenjuje $PTET$. Drugo, potrebno je izabrati mjeru udaljenosti između vektora kovarijabli. Moguće je koristiti se Euclideanovom metrikom, Mahalanobisovom metrikom i inverz varijancama kovarijabli. U radu se koristi

posljednjom metrikom. Treće, potrebno je izabrati metodu uparivanja. Metoda najbližeg susjeda za svaku opservaciju i iz tretmanske skupine izabire j najbližih opservaciju iz kontrolne skupine. Uparivanje radijusom za svaku opservaciju i iz tretmnske skupine izabire j opservacija iz kontrolne skupine, koje su unutar određenog radijusa. Kernel-uparivanje spaja opservaciju i iz tretmasnske skupine s nekoliko opservacija iz kontrolne skupine, pri čemu su udjeli inverzno proporcionalni udaljenosti između kontrolnih i tretmanskih opservacija. Konačno, stratifikacija ili intervalno uparivanje uspoređuje ishode iz više blokova prema rezultatu sklonosti (engl. *propensity score*). U ovom radu primjenjuje se metoda najbližeg susjeda.

Metoda najbližeg susjeda nužno implicira dva dodatna izbora. Prvo, moguće je primijeniti uparivanje sa zamjenom ili bez zamjene. U prvom slučaju svaka opservacija iz kontrolne skupine može biti više puta korištena kao par poduzeću iz tretmanske skupine. U drugom se slučaju opservacija iz kontrolne skupine upotrebljava samo jednom. Uparivanje sa zamjenom omogućuje bolje uparivanje i manju pristranost (Roberts, Whited, 2013). Također, zahtijeva se manji uzorak kontrolnih varijabli jer opservacije mogu biti izabrane više puta. Drugo, za svaku opservaciju u tretmanskoj skupini moguće je upotrijebiti jednu ili više opservacija u kontrolnoj skupini. Korištenje jednim parom smanjuje pristranost, ali uvećava varijancu. U radu se upotrebljava uparivanje sa zamjenom, s jednim parom iz kontrolne skupine za svaku opservaciju iz tretmanske skupine. Na kraju, potrebno je izabrati kovarijable, i to prije tretmana.

Ukratko, u radu se primjenjuje procjenitelj najbližeg susjeda (engl. *nearest neighborhood estimator*) prema (Abadie, Imbens, 2002). Budući da se upotrebljava jedan par za svaku opservaciju iz kontrolne skupine, $PTET$ je jednak (Abadie, Imbens, 2002):

$$\frac{1}{N}\sum_{i:d_i=1}[\gamma_i - \hat{\gamma}_i(0)] \tag{142}$$

gdje je N broj opservacija u tretmanskoj skupini, a $\hat{\gamma}_i(0)$ je procijenjena prosječna vrijednost varijable ishoda za opservaciju i.

Zaključno, za svaku varijablu treba pronaći najbolji par i usporediti opažene vrijednosti sa procijenjenom prosječnom vrijednostima para.

6.2 Predstečajne nagodbe kao egzogeni tretman na financijsku situaciju

U ovom se poglavlju opisuju ključne karakteristike Zakona o financijskom poslovanju i predstečajnoj nagodbi. Ističu se odredbe Zakona koje utječu na financijsku i likvidnu poziciju poduzeća. U drugom se dijelu opisuje način uparivanja poduzeća u uzroku te se opisuje empirijski dizajn za analizu učinka Zakona na investicije poduzeća.

6.2.1 Opis Zakona o financijskom poslovanju i predstečajnoj nagodbi

Zakon o financijskom poslovanju i predstečajnoj nagodbi (NN, 2015) stupio je na snagu 1. listopada 2012. Zakon je imao više izmjena (NN 108/12, 144/12, 81/13, 112/13, 71/15, 78/15), ali su glavne odredbe ostale nepromijenjene.[49] Važnija promjena Zakona dogodila se 1. rujna 2015, kada je na snagu stupio novi Stečajni zakon, kojeg je sastavni dio i postupak predstečajne nagodbe.

Zakon propisuje obvezu pokretanja postupka predstečajne nagodbe za dužnike koji su nelikvidni ili insolventni. Postupak se predstečajne nagodbe „provodi s ciljem uspostavljanja likvidnosti i solventnosti dužnika“ (NN, 2015). Postupak se pokreće isključivo na temelju prijedloga dužnika. Dužnik je dužan podnijeti prijedlog za pokretanje postupka kada se ispuni jedan od dvaju uvjeta:

- „dužnik u roku od 60 dana poduzetim mjerama financijskog restrukturiranja izvan postupka predstečajne nagodbe ne može uspostaviti stanje likvidnosti,
- najkasnije 21 dan od nastanka insolventnosti“ (NN, 2015).

Zakon detaljno definira pojam nelikvidnosti. Poduzetnik je nelikvidan ako: „1) više od 60 dana kasni u ispunjenju jedne ili više novčanih obveza, čiji iznos prelazi 20% od iznosa svojih kratkoročnih obveza objavljenih u godišnjim financijskim izvještajima za proteklu financijsku godinu, ili 2) više od 30 dana kasni s isplatom plaće u visini ugovorene plaće“ (NN, 2015). Pojam insolventnosti Zakon definira kao 1) nesposobnost za plaćanje, tj. trajna nemogućnost u

[49] Dana 21. prosinca 2012. godine stupila je na snagu Uredba o izmjenama i dopunama Zakona o financijskom poslovanju i predstečajnoj nagodbi (NN 144/2012). „Danom stupanja na snagu Zakona o izmjenama i dopunama Zakona o financijskom poslovanju i predstečajnoj nagodbi koji je stupio na snagu 30. lipnja 2013. godine (NN 81/2013) prestala je važiti Uredba o izmjenama i dopunama Zakona o financijskom poslovanju i predstečajnoj nagodbi. Dana 7. rujna 2013. godine stupila je na snagu Uredba o izmjenama i dopunama Zakona o financijskom poslovanju i predstečajnoj nagodbi (NN 112/13)“ (NN, 2015).

ispunjavanju dospjelih novčanih obveza,[50] ili 2) prezaduženost, tj. stanje u kojem je vrijednost imovine veća od vrijednosti postojećih obveza.

Vjerovnici se, radi odlučivanja o planu financijskog restrukturiranja, dijele na tri skupine. U prvoj su tijela javne uprave i trgovačka društva u većinskom državnom vlasništvu, u drugoj financijske institucije, a u trećoj ostali vjerovnici (uglavnom dobavljači). Plan financijskog restrukturiranja smatra se prihvaćenim ako „za njega glasuju vjerovnici čije tražbine prelaze polovinu vrijednosti prijavljenih tražbina za svaku grupu vjerovnika, ili ako za njega glasuju vjerovnici čije tražbine prelaze 2/3 vrijednosti svih prijavljenih tražbina“ (NN, 2015).

Tvrtke koje su uspješno sklopile predstečajnu nagodbu sa svojim vjerovnicima iskusile su znatno olakšanje proračunskog ograničenja. U pravilu su otpisane sve zatezne kamate na dugove i određeni postotak redovitih kamata i/ili glavnice. Zakon je u početku omogućivao otpis i do 70% glavnice za određene obveze, a poslije se postotak smanjivao sve do 10%, koliko iznosi u posljednjoj izmjeni Zakona. Dodatan učinak na poboljšanje financijske situacije imala je odgoda plaćanja svih dospjelih obveza. Najčešće su se dogovarala plaćanja dospjelih obveza u jednakim mjesečnim ratama s počekom od nekoliko mjeseci do godine dana. Uspješno sklopljena predstečajna nagodba urodila je velikim jednokratnim poboljšanjem financijske situacije poduzeća.

Usvajanje i primjena Zakona o financijskom poslovanju i predstečajnoj nagodbi u ovom se radu upotrebljavaju kao prirodan eksperiment za testiranje relevantnosti financijskih varijabli na investicije poduzeća. Predstečajna nagodba, u smislu efekta tretmana, označava tretman, a procjena se svodi na uspoređivanje ishoda (investicija) skupine subjekata koji su je uspješno sklopili (tretmanska skupina) i sličnih poduzeća koja nisu pokrenula postupak za to (kontrolna skupina).

U predstečajnu nagodbu ulaze tvrtke koje imaju velikih financijskih poteškoća. Brojne tvrtke imaju negativnu neto vrijednost, pa se može pretpostaviti da su sva poduzeća koja predlažu pokretanje postupka predstečajne nagodbe likvidno i financijski ograničena (ograničena apriorno). Svrha je pokazati postoji li i financijska ograničenost aposteriori. Drugim riječima, cilj je procijeniti utjecaj smanjenja stupnja likvidnog i financijskog ograničenja na stopu investicija.

[50] Poduzetnik je nesposoban za plaćanjeako „u Očevidniku redoslijeda osnova za plaćanje koji vodi Financijska agencija ima evidentirane neizvršene osnove za plaćanje u razdoblju duljem od 60 dana“ (NN, 2015).

Početni empirijski radovi o osjetljivosti investicija na novčane tokove impliciraju monotono rastuću osjetljivost investicija na novčane tokove. Očekuje se da smanjenje financijskog ograničenja pozitivno utječe na investicije jer su one pozitivna funkcija neto vrijednosti, a neto vrijednost raste zbog oprosta dugova. Tvrtke koje su prošle predstečajnu nagodbu uživaju znatno bolji financijski položaj te bi trebale povećavati svoje investicije nakon predstečajne nagodbe u odnosu prema sličnim tvrtkama koje nisu prošle predstečajnu nagodbu. Suprotno tom gledištu, istraživačka hipoteza u ovom radu pretpostavlja neosjetljivost investicija na smanjenje financijskog i likvidnog ograničenja za nelikvidne, to jest financijski ugrožene tvrtke. Važno je primijetiti da potonja neosjetljivost ne implicira odsutnost financijskog ograničenja. Dapače, ona je upravo potvrda postojanja likvidnog ograničenja, prema kojem stupanj likvidnosti pokazuje nelinearan odnos s investicijama. Kao što je pokazano u 5. poglavlju, za danu razinu investicijskih prilika uspostavljanje granične likvidnosti (oko 1) ne povećava investicije ako su subjekti prije toga rasta bila među nelikvidnim poduzećima. Ukratko, očekuje se da RR procjenitelj ne bude signifikantno različit od 0.

Ispitivanjem međuovisnosti financijske situacije i investicija posredno se analizira ispunjenje primjenjivih ciljeva Zakona. Osim uspostavljanja likvidnosti i solventnosti dužnika, konačan bi se učinak Zakona trebao očitovati u „ponovnom pokretanju održive poslovne aktivnosti i čuvanja zaposlenosti“ (Hrvatski sabor, 2013). Budući da je jedan od ciljeva ovog rada analiziranje uspješnosti Zakona (u smislu ostvarivanja ciljeva), prikazat će se i rezultati istraživanja u kojem se kao varijabla ishoda upotrebljava broj zaposlenih. Kako je rast potencijala poduzeća putem novih investicija preduvjet novog zapošljavanja, očekuje se da sklopljena predstečajna nagodba neće imati signifikantan utjecaj na promjenu zaposlenosti u odnosu prema kontrolnim subjektima.

6.2.2 Uparivanje poduzeća iz kontrolne skupine

Efekt tretmana procjenjuje se primjenom različitih metoda. Najprimjerenije bi bilo slučajno dodijeliti tretman poduzećima iz uzorka tako da se određenom broju njih oproste i reprogramiraju dugovi, a ostalima ne. Međutim, po prirodi eksperimenta, slučajna primjena tretmana nije primjenjiva jer Zakon definira pod kojim se uvjetima primjenjuje tretman. Samo

nelikvidne i insolventne tvrtke mogu pokrenuti postupak predstečajne nagodbe.[51] Dakle, primjena tretmana nije slučajna, već je namijenjena samo određenoj skupini subjekata koja ispunjavaju unaprijed definirane uvjete.

Kada slučajna primjena tretmana nije moguća, osnovni izazov u procjeni efekta tretmana jest procjenjivanje protučinjeničnih ishoda (engl. *counterfactuals*). Budući da je naglasak na procjeni $PTET$, potrebno je procijeniti koliko bi iznosila stopa rasta investicija tretiranih poduzeća bez tretmana.

Skupinu tretmana lako je identificirati. U njoj su subjekti koji su sklopili predstečajnu nagodbu u 2013. godini. Riječ je o subjektima koji su iskusili poboljšanje financijskog položaja zbog oprosta i reprogramiranja dugova. Izbor kontrolne skupine mnogo je složeniji i zahtjeva posebnu pozornost. Prvo rješenje koje se nameće uključivanje je u kontrolnu skupinu svih poduzeća koja nisu sklopila nagodbu u 2013. godini. Međutim, to nije najbolji izbor jer se unutar uzorka nalaze poduzeća različitih karakteristika, pa se i trendovi stope rasta investicija vjerojatno razlikuju. Naime, osnovna je pretpostavka RR metode paralelnost trendova očekivanih vrijednosti varijable ishoda. Ako se poduzeća razlikuju po opaženim ili neopaženim karakteristikama, veća je vjerojatnost da se varijable ishoda mijenjaju neovisno o tretmanu. Primjerenije je kontrolnu grupu identificirati korištenjem metodom uparivanja, koja je opisana u poglavlju 6.1. U radu se primjenjuje upravo navedena metoda. Točnije, osnovni model kao kontrolnu skupinu upotrebljava opservacije dobivene metodom uparivanja, a drugi će pristup uključivati sva poduzeća koja ne pripadaju tretmanskoj skupini.

Osnovni je istraživački cilj procijeniti prosječan efekt tretmana tretiranih (PETT) poslovnih subjekata, odnosno utjecaj tretmana na investicije poduzeća koja su sklopila predstečajnu nagodbu. Apstrahiranje efekta netretiranih poduzeća znači obraćanje pozornosti opservacijama iz tretmanske skupine. Postupak je sljedeći. prvo se izoliraju poduzeća koja su primila tretman (sklopila predstečajnu nagodbu), a onda se od preostalih subjekata, koji nisu primili tretman, izabiru kontrolne opservacije koje se, prema određenim dimenzijama (kovarijablama) najviše podudaraju s opservacijama iz tretmanske skupine. Skup protučinjeničnih opservacija aproksimira se uparenim kontrolnim opservacijama Drugim riječima, bez tretmana, kontrolna

[51] Zakon propisuje obvezu pokretanja postupka, ako se ispune već opisani uvjeti, ali u stvarnosti su poduzeća mogla odabrati hoće li pokrenuti nagodbu ili ne. Nekoliko je razloga zašto nisu sva poduzeća pokrenula nagodbu: 1) postojao je vrlo velik broj poduzeća koja su ispunjavala uvjete za pokretanje postupka, 2) nadzor zahtijeva angažiranje brojnih resursa i 3) teško je ustanoviti kada je točno poduzeće postalo nelikvidno i ima li mogućnosti samo se izvući iz nelikvidnosti bez pokretanja postupka.

bi se skupina trebala ponašati vrlo slično tretmanskoj skupini. Procjena RR procjenitelja na kraju se svodi na razliku u stopama rasta varijabli ishoda za kontrolnu i tretmansku skupinu.

Više je metoda uparivanja tretmanske i kontrolne skupine. U radu se primjenjuje pristup uparivanja najbližeg susjeda (engl. *nearest-neighborhood matching*), prema Abadie et al. (2004). Abadie-Imbensov procjenitelj uparivanja (engl. *Abadie-Imbens matching estimator*) minimizira udaljenost između vektora opaženih kovarijabli tretmanske i kontrolne skupine. Procjenitelj automatski testira za moguće interakcije između nezavisnih varijabli. Ovakav pristup omogućuje usporedbu vrlo sličnih poduzeća, s jedinom razlikom što je jedna skupina sklopila predstečajnu nagodbu, a druga nije. Iako metoda omogućuje više uparivanja po jednoj opservaciji iz tretmanske skupine, u radu se izabire uparivanje 1:1, to jest, za svaku opservaciju iz tretmanske skupine postoji jedan subjekt iz kontrolne skupine.

Procedura omogućuje da se poduzeća iz kontrolne skupine više puta povežu s onima iz tretmanske skupine (uparivanje sa zamjenom). U odnosu prema uparivanju bez zamjene, ova metoda omogućuje manju pristranost, ali veću varijancu. Za kovarijable se mogu birati kategorijalne i kontinuirane varijable. Za kategorijalne varijable Abadie-Imbensov procjenitelj stvara egzaktno uparivanje. Za kontinuirane varijable uparivanje nije egzaktno, ali su vrijednosti za veći broj varijabli vrlo bliske. Procjenitelj stvara standardne pogreške robusne na heteroskedastičnost.

U metodi uparivanja naglasak je na izboru sličnih poduzeća prije primjene regresijske jednadžbe, umjesto korištenja kontrolnim varijablama u samoj regresijskoj jednadžbi. Izbor kontrolnih varijabli u regresijskoj jednadžbi nema istu logiku kao izbor kovarijabli u svrhu uparivanja.

Kontinuirane varijable, koje će se upotrijebiti za uparivanje subjekata, uključuju stopu novčanog toka, stopu dodane nove vrijednosti i stopu gotovine. U pregledu empirijske literature naveden je niz primjera u kojima autori pronalaze ekonomski i statistički signifikantnu vezu novčanih tokova i investicija. U deskriptivnoj analizi također je pokazano da su interni izvori vrlo važan izvor financiranja investicija, stoga je uparivanje poduzeća po stopi novčanog toka logičan izbor. Stopa dodane nove vrijednosti indicira konkurentnu sposobnost poduzeća, a u 5. poglavlju potvrđen je važan utjecaj na investicije. Stopa novčanog toka i nove dodane vrijednosti, kao varijable toka, odražavaju potražne faktore. Stopa gotovine, kao varijabla stoka, omogućuje uspoređivanje subjekata slične strukturalne likvidnosti, što je vrlo važno pri analizi financijske i likvidne ograničenosti.

Kategorijalne varijable, koje služe za uparivanje poduzeća, uključuju djelatnost poduzeća i veličinu poduzeća. Djelatnost se odnosi na prvi razred Nacionalne klasifikacije djelatnosti (NKD 2007). Veličina subjekta podijeljena je na četiri kategorije: mikro, mali, srednji i veliki subjekti.[52] Za kategorijalne varijable vrijedi egzaktno uparivanje. Drugim riječima, zadovoljeni su fiksni efekti po kriteriju djelatnosti i veličine subjekta. Izbor je navedenih kategorija očit. Rezultati i financijska struktura poduzeća uvelike ovise o djelatnosti u kojoj posluju i njihovoj veličini.

Važno je napomenuti da su subjekti upareni na temelju vrijednosti kovarijabli iz 2012. godine. Uparivanje prije primjene tretmana omogućuje korištenje varijablama ishoda kao kovarijablama za uparivanje poduzeća. Nakon uparivanja odgovarajućih opservacija procjenjuje se prosječan efekt tretmana kao promjena stope rasta investicija (ne promjene razina) tretmanske i kontrolne skupine od 2012. do2013. godine.[53] Sličan je pristup primijenjen u Almeida i dr. (2012).

Valja podsjetiti da je ključan element ispravne identifikacije modela egzogenost tretmana. Moguće je da su promjene u investicijama nakon tretmana rezultat potražnih faktora, a ne promjena u stupnju financijskog ili likvidnog ograničenja. Drugim riječima, važno je pratiti promjenu financijskog položaja uz konstantne investicijske prilike. Ovaj se zahtjev može formalno izraziti kao $E[\gamma(0)|d = 1] = E[\gamma(0)|d] = 0$. Ako bi lijeva strana jednadžbe bila manja od desne strane, RR procjenitelj bio bi pristran prema dolje. Drugim riječima, usprkos provođenju postupka uparivanja, neopažene razlike između tretmanske i kontrolne skupine pridonose različitu ponašanju investicija nakon tretmana. Nekoliko je razloga zašto se u opisanu istraživačkom dizajnu predstečajne nagodbe mogu smatrati egzogenim tretmanom. Prvo, u postupku restrukturiranja, u vrijeme trajanja postupka predstečajne nagodbe, promijenjeno je samo 2% menadžmenta (Košćak i Vlajo, 2014). To znači da se u procesu restrukturiranja poduzeća nisu dogodile važne promjene u strukturama upravljanja, pa se rast investicija nakon tretmana ne može pripisati snazi novog menadžmenta nakon restrukturiranja. Održavanje istog menadžmenta implicira i održavanje istih planova o realnim investicijama. Drugo, nagodbe su

[52] Kriteriji su razlikovanja mikro, malih, srednjih i velikih subjekata sljedeći: mikrosubjekti su oni koji ne prelaze dva od sljedeća tri uvjeta: 1) maksimalno 10 zaposlenih, 2) maksimalna vrijednost prihoda 5,2 milijuna kn, 3) maksimalna vrijednost ukupne aktive 2,6 milijuna kuna. Mali subjekti ispunjavaju najmanje dva kriterija od sljedeća tri: 1) maksimalno 50 zaposlenih, 2) maksimalna vrijednost prihoda 60 milijuna kn, 3) maksimalna vrijednost ukupne aktive 30 milijuna kuna. Srednje veliki subjekti ispunjavaju najmanje dva kriterija od sljedeća tri: 1) maksimalno 250 zaposlenih, 2) maksimalna vrijednost prihoda 300 milijuna kn, 3) maksimalna vrijednost ukupne aktive 150 milijuna kuna. Ostali su subjekti klasificirani kao veliki subjekti.

[53] Točnije, 2012. godina predstavlja prosjek od 2011. do 2012. (razdoblje prije tretmana), a 2013. godina predstavlja prosjek za 2013-2014. (razdoblje poslije tretmana).

bile sklapane u 2013. godini, koja nije bila praćena velikim šokovima realnih stopa rasta. Dio je problema riješen dizajnom ekonometrijskog modela. Uparivanje poduzeća omogućuje usporedbu sličnih poduzeća s jedne strane, a RR procjenitelj omogućuje uvažavanje promjena u trendu i razlike između kontrolne i tretmanske grupe, s druge strane. Pristranost procjenitelja dodatno se smanjuje upotrebom kontrolnih varijabli u regresijskoj jednadžbi.

6.3 Opis podataka upotrijebljenih u analizi

Poglavlje započinje opisom podataka korištenih u analizi. To uključuje opis izvora podataka te prikaz osnovnih statističkih veličina. Potom se prilagođavaju podaci za primjenu metode efekta tretmana: definiraju se tretmanska i kontrolna skupina te se provodi prilagodba podataka uobičajena za ovakav tip analize. Na kraju se deskriptivnom analizom pruža prvi uvid o učinku Zakona na investicije poduzeća.

6.3.1 Podaci o predstečajnim nagodbama

Podaci o predstečajnim nagodbama Financijske agencije strukturirani su u dvije odvojene baze podataka. Obje baze podataka uključuju 1319 poslovnih subjekata koji su uspješno sklopili predstečajnu nagodbu sa svojim vjerovnicima od 23. travnja 2013. do 1. rujna 2014. Prva baza podataka sadržava popis vjerovnika koji su uspješno sklopili predstečajnu nagodbu i, za svakog pojedinog dužnika, popis svih njegovih vjerovnika. Za svakog vjerovnika postoje detaljni podaci o obilježju duga.[54] Druga baza podataka sadržava podatke o datumu početka i završetka predstečajne nagodbe, datumu osnivanja i gašenja poduzeća (ako je subjekt ugašen) te podatke o djelatnosti, legalnu obliku i ukupnu dugu subjekata koji su uspješno sklopili nagodbu. Za potrebe deskriptivne statistike poslužit će obje baze podataka, a u provođenju formalne procjene efekta tretmana koristit će se podacima iz druge baze podataka. Objema bazama podataka mogu se pridružiti statistički podaci i podaci iz računovodstveno-financijskih izvještaja opisani u poglavlju 5.1.[55] Na raspolaganju su i podaci iz pregleda zbirnih podataka o predstečajnim

[54] Baza podataka sadržava: 1) iznos obveze prema izvješću dužnika, 2) iznos tražbine prema prijavi vjerovnika, 3) postojanje ovršne isprave, 4) utvrđeni iznos tražbine, 5) osporeni iznos tražbine, 5) iznos protutražbine, 6) iznos koji je prestao prijebojem, 7) iznos tražbine nakon prijeboja, 8) postojanje razlučnog prava, 9) postojanje izlučnog prava

[55] Računonovodstveno-financijski izvještaji ne mogu se pridružiti za obrte, koji su obveznici poreza na dohodak.

nagodbama koje izdaje Financijska agencija, institucija zadužena za pružanje administrativne podrške provedbi predstečajnih nagodbi.

Za početak, u tablici 6-2 daju se osnovni podaci o predstečajnim nagodbama prema posljednjem „Pregledu zbirnih podataka iz sustava predstečajnih nagodbi za razdoblje 1.10.2012. – 18.12.2015.“, koje je objavila Financijska agencija (FINA, 2015). Pregled pokazuje da je prijedlog za otvaranje postupka predstečajne nagodbe predalo 8959 poduzeća, od čega je riješeno 92,59% predmeta. Od ukupno prijavljenih predmeta, 12,47% odnosi se na prijavljene obveze veće od 10 milijuna kn. Međutim, ako se kao kriterij uzme broj zaposlenih, onda je udio obveza koje premašuju 10 milijuna kuna znatno veći, 70,41%. Nagodba je sklopljena u 2469 predmeta. Drugim riječima, od ukupnog broja riješenih predmeta samo je u 29,76% njih sklopljena predstečajna nagodba. Ako je predstečajna nagodba obustavljena, nad poduzećem je pokrenut stečajni postupak. Od donošenja Zakona, samo na temelju obustave predstečajnog postupka pokrenut je 6091 stečajni postupak.

Tablica 6-3 pruža zbirni pregled broja predmeta i vrijednosti obveza prema djelatnosti subjekata. Podaci o predstečajnim nagodbama, koje objavljuje Financijska agencija, stavljeni su u odnos s agregiranim podacima po djelatnosti u 2013. godini. Cilj je dobiti spoznaju o učinku predstečajnih nagodbi na cjelokupnu poslovnu aktivnost i pojedinu industriju. Treba upozoriti na to da podaci o predstečajnim nagodbama uključuju sva poduzeća, a agregirani podaci iz 2013. uključuju trgovačka društva i obrte koji su obveznici poreza na dobit. Međutim, obrti u prosjeku imaju manji broj zaposlenih, pa se može očekivati da podaci iz 2013. godine odgovaraju stanju za sva poduzeća.

U apsolutnim iznosima, najviše obveza prijavile su tvrtke iz građevinskog sektora, a slijede prerađivački sektor i trgovina. Prema broju zaposlenih, u predstečajnim nagodbama najviše je sudjelovala prerađivačka industrija, a slijedi građevinski sektor i trgovina. Ove tri djelatnosti čine 68% svih zaposlenih u poslovnim subjektima koji su podnijeli prijedlog za predstečajnu nagodbu.

Tablica 6-2: Pregled zbirnih podataka iz sustava predstečajnih nagodbi od 1.listopada 2012. do 18. listopada2015. godine

Opis	Iznos prijavljenih obveza	Broj zaposlenih	Broj predmeta	% od ukupnih obveza	% od ukupnog broja predmeta
Iznos prijavljenih obveza	**81.985.314.011,27**	**66.820**	**8.959**	**100,00%**	**100,00%**
- Prijavljene obveze < 10.000.000 kn	8.414.342.988,93	19.771	7.842	10,26%	87,53%
- Prijavljene obveze > 10.000.000 kn	73.570.971.022,34	47.049	1.117	89,74%	12,47%
Broj riješenih predmeta	**81.985.314.011,27**	**66.820**	**8.959**	**100,00%**	**100,00%**
- Riješeno	71.582.288.414,28	60.284	8.295	87,31%	92,59%
- U radu	10.403.025.596,99	6.536	664	12,69%	7,41%
Broj sklopljenih nagodbi	**45.178.362.946,31**	**40.344**	**2.868**	**55,10%**	**32,01%**
- Prihvaćen plan	9.798.986.932,57	6.336	399	11,95%	4,45%
- Sklopljena nagodba	35.379.376.013,74	34.008	2.469	43,15%	27,56%

Izvor: FINA (2015)

BILJEŠKA: „Iznos prijavljenih obveza je iznos duga koji su dužnici prijavili kod podnošenja prijedloga za pokretanje postupka predstečajne nagodbe. Prihvaćen plan se odnosi na sve predmete u kojima su vjerovnici prihvatili plan financijskog restrukturiranja dužnika. Sklopljena nagodba se odnosi na sve predmete u kojima je doneseno rješenje o sklapanju nagodbe. Riješeno se odnosi na predmete koji uključuju odbačene prijedloge za otvaranje postupka predstečajne nagodbe, obustavljene postupke te postupke koji su završili prihvaćanjem plana financijskog restrukturiranja“ (FINA, 2015). Ostali su predmeti u radu. (FINA, 2015)

Tablica 6-3: Zbirni pregled broja predmeta i iznosa obveza prema području djelatnosti i usporedba s agregatnim vrijednostima u 2013. godini

Djelatnost	**Iznos obveza (mil. kn)**	**Broj zaposlenih**	**Broj predmeta**	**Iznos obveza 2013.**	**%**	**Broj zaposlenih 2013.**	**%**
Građevinarstvo	20.406	13.186	1.483	120.455	17%	79090	17%
Prerađivačka industrija	16.521	22.807	1.274	105.167	16%	228087	10%
Trgovina na veliko i malo	13.533	9.553	2.049	128.497	11%	187894	5%
Usluge smještaja i hrane	7.598	4.519	874	37.112	20%	47239	10%
Stručne, znanstvene i tehničke djelat.	7.362	2.250	644	42.682	17%	49638	5%
Poslovanje nekretninama	4.940	190	208	55.079	9%	17774	1%
Informacija i komunikacije	3.311	1.993	216	17.595	19%	33508	6%
Poljoprivreda, šumarstvo ribarstvo	2.459	1.923	301	20.962	12%	28655	7%
Prijevoz i skladištenje	1.394	3.433	427	30.518	5%	63970	5%
Umjetnost, zabava i rekreacija	941	371	88	5.482	17%	9849	4%
Administrativne i pomoćne uslužne djelat.	860	2.664	210	8.974	10%	35482	8%
Rudarstvo	560	379	45	4.288	13%	5008	8%
Gospodarenjem vodom i otpadom	514	767	42	24.513	2%	21700	4%
Zdravstvena zaštita i socijalna skrb	275	385	33	1.630	17%	9124	4%
Ostale uslužne djelatnosti	189	500	267	1.932	10%	8211	6%
Ostalo	1.104	1.900	798	80.432	1%	1.900	7%
Ukupno	**81.967**	**66.820**	**8.959**	**685.316**	**12%**	**66.820**	**8%**

Relativni pokazatelji pružaju jasniju predodžbu o pogođenosti pojedinih sektora financijskom krizom. Posljednja kolona pokazuje odnos iznosa obveza prema prijavi dužnika u predstečajnoj nagodbi i ukupnih obveza u određenoj djelatnosti u 2013. godini. Peta je kolona sastavljena na isti način, ali je u odnos umjesto ukupnih obveza stavljen ukupan broj zaposlenih. Prema zaposlenosti, krizom je najviše pogođen građevinski sektor. Udio prijavljenog broja zaposlenih u ukupnom iznosu za industriju čini čak 17%. To je u skladu sa stiliziranom činjenicom o cikličnom obilježju građevinske industrije (npr. u CAPM modelima građevinski sektor pokazuje najveću osjetljivost prinosa u odnosu prema tržištu). Drugim riječima, u kriznim vremenima u građevinskom sektoru ima najviše insolventnih i nelikvidnih društava. Slijede prerađivački sektor te usluge smještaja i hrane. Prema iznosu prijavljenih obveza, najviše su pogođeni sektori pružanja usluga smještaja i hrane te sektor informacija i komunikacija. Najmanje je pogođen sektor komunalnih usluga, što je u skladu s očekivanjima jer je većinom riječ o subjektima koji su u vlasništvu države ili lokalne samouprave, pa uživaju monopolistički položaj na lokalnim tržištima i meko proračunsko ograničenje. Također, u poglavlju 5.5.4. pokazano je da javna poduzeća ne pokazuju znakove financijskog ograničenja. Djelatnost prijevoza i skladištenja manje je pogođena krizom. Samo 5% ukupnih obveza prijavljeno je u postupku predstečajne nagodbe.

Baza podataka o predstečajnim nagodbama, opisana na početku ovog poglavlja, sadržava ukupno 1319 predmeta u kojima je sklopljena predstečajna nagodba, što je 53,42% ukupnog broja do sada sklopljenih nagodbi. Od toga, 617 nagodbi sklopljeno je u 2013, a 702 u 2014. godini. Ukupan iznos prijavljenih obveza u uzorku, nakon prijeboja, iznosi 44.980 milijuna kuna. Od toga se na prvih deset subjekata odnosi 21.722 milijuna ili 48,29% svih prijavljenih obveza, a na prvih 20 subjekata 28.588 milijuna ili 63,56% svih prijavljenih obveza. Najveći iznos prijavljenih obveza imaju tvrtke iz građevinskog sektora (Nexe grupa d.o.o., Dalekovod d.o.o., Našicecement tvornica cementa d.o.o.). Od svih poduzeća koja su sklopila nagodbu (1319), 23 su, nakon toga, ugašene (riječ o manjim tvrtkama koje čine svega 0.08% svih prijavljenih obveza). Prema legalnom obliku, 542 subjekta pripadaju obrtima, 692 društvima s ograničenom odgovornošću, 65 dioničkim društvima, 8 poljoprivrednim zadrugama, 1 jednostavnom društvu s ograničenom odgovornošću te 11 skupini ustanova i udruga.

Tablica 6-4: Popis najvećih vjerovnika prema iznosu utvrđenih tražbina od 23. travnja 2013. do 1. rujna 2014.

Naziv	Kategorija vjerovnika	Iznos tražbine (u tisućama kn)	% od ukupnih tražbina
Zagrebačka banka d.d.	Financijska institucija	4.682.985	10,41%
Porezna uprava	Država	3.133.700	6,97%
Hypo Alpe-Adria Bank d.d.	Financijska institucija	1.880.351	4,18%
PBZ d.d.	Financijska institucija	1.683.184	3,74%
Našisecement d.d.	Dobavljač	1.556.334	3,46%
Erste&Steimarkische bank d.d.	Financijska institucija	1.461.334	3,25%
HBOR	Financijska institucija	1.391.073	3,09%
Hypo leasing Croatien d.d.	Financijska institucija	860.286	1,91%
Splitska banka d.d.	Financijska institucija	826.019	1,84%
Raiffeisen banka d.d.	Financijska institucija	817.265	1,82%
UKUPNO		**44.974.917**	**100,00%**

Tablica 6-4 pokazuje deset najvećih vjerovnika prema iznosu utvrđenih tražbina. Od 24.554 ukupno utvrđena vjerovnika u postupcima predstečajne nagodbe, prikazanih deset vjerovnika ima 40,67% ukupnih tražbina. U skladu s očekivanjem, najveći se dio odnosi na financijske institucije. Zanimljivo je da najveći vjerovnik nije država nego Zagrebačka banka d.d., s čak 10,41% svih prijavljenih tražbina. Od dobavljača se pojavljuje tek građevinska tvrtka Našiscecement d.d.

Razina efekta tretmana ovisi o veličini varijable koja ga predstavlja. U ovom primjeru, efikasnost predstečajne nagodbe uvelike ovisi o iznosu oproštenih dugova ili vremenu odgode dospjelih obveza. Ako su iznosi otpisa mali prema ukupnim obvezama ili su odgode kratke, utjecaj predstečajne nagodbe na ukupno poslovanje ne bi trebao biti važan. Tablica 6-5 otkriva prosječnu promjenu financijskih varijabli za poduzeća koja su sklopila predstečajnu nagodbu u 2013. godini. Razdoblje prije tretmana (2012. godina) sadržava prosječne vrijednosti varijabli od 2011. do 2012, a razdoblje nakon tretmana (2013. godina) sadržava prosječne vrijednosti za razdoblje 2013–-2014.

Tablica 6-5: Medijani financijskih pokazatelja za tretmansku grupu i ostalih poduzeća

Opis	**2012.**	**2013.**	**Razlika**
A) Tretmanska grupa			
Tekuća likvidnost	0.6587	0.9672	0.31
Stopa neto radnoga kapitala	- 0.4387	- 0.0877	0.35
Stopa gotovine	0.0185	0.0252	0.01
Pokrivenost kamata	- 0.4877	1.0604	1.55
Koeficijent zaduženosti	0.9232	0.8566	-0.07
Financijska poluga	1.6013	1.1152	- 0.49
B) Sva poduzeća			
Tekuća likvidnost	1.1662	1.2642	0.10
Stopa neto radnog kapitala	0.1175	0.2265	0.11
Stopa gotovine	0.0705	0.0780	0.01
Pokrivenost kamata	2.2975	3.2873	0.99
Koeficijent zaduženosti	0.7505	0.7125	-0.04
Financijska poluga	1.0154	0.7052	-0.31

Prva tri pokazatelja odražavaju stanje likvidnosti, a ostala tri stupanj zaduženosti. Medijan tekućeg omjera pokazuje značajan rast likvidnosti u subjekata koji su sklopili predstečajnu nagodbu (tretmanska skupina). Ako se kao granica razgraničavanja nelikvidnih i likvidnih poduzeća upotrijebi procjena iz poglavlja 5.5.2., može se zaključiti da su poduzeća iz stanja nelikvidnosti prešla u stanje granične likvidnosti. Stopa neto radnoga kapitala pokazuje isti rezultat: nakon provedene predstečajne nagodbe subjekti su na otprilike jednakoj razini kratkotrajne imovine i kratkotrajnih obveza. Ako se prva dva pokazatelja likvidnosti usporede s pokazateljima ostalih poduzeća, izvode se dva zaključka. Prvo, poduzeća u drugoj skupini imaju veće pokazatelje likvidnosti, što je očekivano jer su u prvoj skupini financijski ugrožena poduzeća. Drugo, poduzeća koja su uspješno prošla predstečajnu nagodbu iskusila su tri puta veći rast tekuće likvidnosti i stope neto radnoga kapitala. U skladu s očekivanjima, poduzeća su u tretmanskoj skupini nelikvidna i iskusila su snažan rast likvidnosti nakon sklopljene nagodbe.

Stopa gotovine znatno je veća u drugoj u skupini u kojoj su sva poduzeća. Međutim, promjene novca u relativnom smislu znatno su veće u tretmanskoj skupini. Može se pretpostaviti da subjekti u drugoj skupini održavaju optimalnu razinu novca, a poduzeća koja su prošla kroz predstečajnu nagodbu gomilaju likvidnost radi osiguranja održivosti poslovanja

Za subjekte iz prve skupine pokazatelj pokrivenosti kamata raste 1,55, što implicira snažan pad obveza prema kamatama i/ili snažan rast zarada prije kamata i poreza. Financijska poluga i koeficijent zaduženosti padaju nakon sklopljene nagodbe što je također u skladu s očekivanjima jer se u predstečajnoj nagodbi oprašta dio dugova. Oprost duga vjerojatno bi bio i veći jer poduzeća rijetko korigiraju bilance za rast zateznih kamata. Iako su poduzeća u drugoj skupini također iskusila pad zaduženosti, on je u relativnom smislu manji od smanjenja u tretmanskoj skupini.

Tablica pokazuje poboljšanje financijskog položaja subjekata koji su sklopili predstečajnu nagodbu, kako u apsolutnim iznosima, tako i u odnosu prema svim ostalim poduzećima koja posluju u RH. Analiza odražava i razlike u kretanju pokazatelja između dviju skupina, što je glavni predmet analize u narednom poglavlju.

6.3.2 Prilagodba podataka za primjenu metode efekta tretmana

U nastavku se opisuje kako je nastao uzorak poduzeća koji će poslužiti za procjenu efekta tretmana. Baza podataka sadržava sva mjesta iz računovodstveno-financijskih izvještaja (bilanca, račun dobiti i gubitka, procijenjeni izvještaj o novčanom toku) i dodatnih godišnjih izvještaja (dodatni podaci financijskog izvještaja poduzetnika – obrazac POD-DOP). Detaljan opis ove baze podataka dan je u poglavlju 4.1. Poduzećima koja su sklopila predstečajnu nagodbu pridruženi su dodatni podaci o predstečajnim nagodbama (datumi početka i završetka nagodbe te ukupan iznos duga). Kompletna baza dakle sadržava sva trgovačka društva u RH od kojih je dio sklopio predstečajnu nagodbu.

Uzorak se odnosi na razdoblje od 2011. do 2014. Primjena RR procjenitelja radi procjene efekta tretmana zahtijeva raspolaganje s najmanje dvama razdobljima, prije i poslije tretmana. Vrijednosti prije tretmana dobivene su kao prosjek vrijednosti iz razdoblja 2011–2012, a vrijednosti nakon tretmana kao prosjek iz razdoblja 2013–2014.[56] Iz uzorka su izbačena poduzeća koja nemaju opservacije za dvije uzastopne godine (2012. i 2013). Osnovni model dakle sadržava opservacije za razdoblje 2012–2013, a u analizi robusnosti promatrat će se i

[56] U nastavku, kada se govori o razdoblju prije tretmana ili o 2012. godini, misli se na prosjek 2011–2012. Slično vrijedi i za razdoblje nakon tretmana.

druga razdoblja. Budući da se zahtijeva balansiran panel, u svakoj godini postoji jednak broj opservacija.

Iz uzorka su izbačena poduzeća u većinskom državnom vlasništvu. Zadržana su poduzeća iz svih djelatnosti, osim djelatnosti koje su pod regulacijom države i nisu izložene tržišnom natjecanju te poduzeća koja pružaju financijske usluge, a to uključuje: 1) sektor obrazovanja (osnovnoškolsko, srednjoškolsko i ostalo obrazovanje), 2) sektor javne uprave i obrane; obvezno socijalno osiguranje i 3) sektor novčarskog posredovanja, holding društava i uzajamnih fondova. Nad uzorkom su provedene prilagodbe kako bi se izbacile opservacije u kojima se pojavljuju neuobičajeno visoke ili niske vrijednosti i pogreške pri bilježenju podataka. Točnije, iz uzorka su izbačene: 1) opservacije u kojih nedostaju vrijednosti, 2) poduzeća u kojih je vrijednost imovine, prihoda, novčanih sredstava ili zaposlenih manja od 0 kn, 3) opažanja u kojih je vrijednost koeficijenta zaduženosti veća od 99. percentila, 4) opažanja u kojih je vrijednost stope novčanog toka i investicija, u odnosu prema pomaknutoj sadašnjoj vrijednosti kapitala manja od 1 percentila i veća od 99 percentila, 5) neaktivne tvrtke – opservacije u kojih je vrijednost prihoda u poslovnoj godini jednaka 0 kn.

U temeljnome modelu varijablu ishoda čini promjena u investicijama. Kao i prije, investicije su definirane kao razlika sadašnje vrijednosti materijalne imovine u tekućem razdoblju uvećane za amortizaciju i sadašnje vrijednosti materijalne imovine u prethodnom razdoblju podijeljene s pomaknutom sadašnjom vrijednosti imovine. Osim investicija, kao zavisna varijabla upotrijebit će se i broj zaposlenih jer je jedan od ciljeva ovog poglavlja procijeniti efikasnost Zakona u očuvanju zaposlenosti.

Kako je već spomenuto, za uparivanje subjekata u uzorku služe sljedeće varijable: djelatnost poduzeća, veličina poduzeća, stopa novčanog toka, stopa nove dodane vrijednosti i stopa gotovine. Stopa novčanog toka jednaka je omjeru zbroja neto dobiti i amortizacije i pomaknute sadašnje vrijednosti imovine. Stopa dodane nove vrijednosti jednaka je omjeru dodane nove vrijednosti i pomaknute sadašnje vrijednosti imovine. Stopa gotovine jednaka je omjeru novčanih sredstava i ukupne imovine. U poglavlju 4.1. iscrpno su opisane kategorijalne kontinuirane varijable koje su poslužile u analizi.

U analizi robusnosti upotrijebit će se drugi skup kovarijabli. Kao i u osnovnome modelu, stopa novčanog toka i dodane nove vrijednosti kontrolirat će za potražne faktore. Njima će se dodati dva pokazatelja: tekuća likvidnosti i koeficijent zaduženosti. Tekuća likvidnost jednaka je omjeru kratkotrajne imovine i kratkotrajnih obveza. Pokazatelj tekuće likvidnosti iz

kontinuirane je varijable transformiran u kategorijalnu varijablu kako bi se postiglo lakše uparivanje subjekata. Koeficijent zaduženosti jednak je omjeru ukupnih obveza i ukupne imovine. Uvođenjem pokazatelja likvidnosti i zaduženosti nastoji se ispitati osjetljivost rezultata na izbor kovarijabli uparivanja s jedne strane te steći spoznaju o utjecaju zaduženosti i likvidnosti na investicije s druge strane.

U tretmanskoj su skupini poduzeća koja su sklopila predstečajnu nagodbu tijekom 2013. godine. Kontrolna je skupina identificirana metodom uparivanja. Za traženje sličnih poduzeća primijenjena je metoda najbližeg susjeda. Računalni je program je preuzet od Abadie i dr. (2004), a primijenjen je u statističkom softveru Stata. Nakon uparivanja subjekata u 2012. godini nad uzorkom je provedena još jedna prilagodba za ekstremne vrijednosti kako bi se izbjegao učinak jedne vrijednosti na ishod procjene. Iz uzorka su izbrisane opservacije u kojih je vrijednost investicija, novčanog toka i stope gotovine veća od 99 percentila i manja od 1. percentila. Ista je prilagodba provedena i za opservacije uparenih poduzeća u 2013. godini. U konačnici, uzorak osnovnog modela, za razdoblje 2012–2013, sadržava 740 opservacija. Kako se svakom poduzeću u tretmanskoj skupini pridružuju poduzeća iz skupine ostalih poduzeća, jednak je broj opservacija u tretmanskoj i kontrolnoj skupini (370). Metodom uparivanja četiri su poduzeća dva puta izabrana za par, pa je jedinstvenih poduzeća u kontrolnoj skupini 181, a u tretmanskoj skupini 185. Riječ je o broju poduzeća i opservacija u temeljnome modelu. U analizi robusnosti preispitivat će se utjecaj promjene u stvaranju uzorka na rezultate procjene efekta tretmana.

Poželjno je navesti nekoliko primjera uparivanja kako bi se dobila predodžba o kvaliteti relacija. Radi prepoznatljivosti, navodi se primjer dvaju većih poslovnih subjekata. IGMA industrija građevinskog materijala d.o.o., pripada građevinskom sektoru, a osnovna joj je djelatnost vađenje šljunka, pijeska i gline. Tvrtka pripada skupini srednje velikih poduzeća. Predstečajnu je nagodbu sklopila 16. listopada 2013. godine. Identificirani par za IGMA je TONDACH HRVATSKA d.d. Osnovna je djelatnost društva također vađenje šljunka, pijeska i gline. Tvrtke dakle pripadaju istoj industriji te su iste veličine (srednje velika poduzeća). Poduzeća su slična i po vrijednostima kovarijabli kojima se koristilo pri uparivanju. Primjerice, stopa nove dodane vrijednosti za IGMA iznosi 0,22, a za Tondach 0,21, dok su im stope novčanog toka i stopa gotovine identične (0,07 i 0,02). Podaci pokazuju i učinak tretmana na financijsku situaciju. Tekući omjer IGMA-e u 2012. godini iznosi 0,73, a u sljedećoj godini (nakon tretmana) 1,33. Tondach je iskusio pad tekućeg omjera s 1,49 na 1,12. IGMA je iskusila poboljšanje i prema ostalim pokazateljima likvidnosti. Stopa neto radnoga kapitala narasla je s - 0,25 na 0,15., a

stope gotovine narasle su s 0,12 na 0,25. Obje su tvrtke iskusile pad intenziteta dugoročna financiranja i rast pokazatelja pokrivenosti kamata. IGMA je pod utjecajem nagodbe smanjila udio ukupnih obveza s 0,60 na 0,44.

Primjer su drugog para Orljava d.o.o. (tretmanska skupina) i Prerada d.o.o. (kontrolna skupina). Oba poduzeća pripadaju prerađivačkoj industriji (prvo proizvodi odjeću, a drugo tjesteninu) te grupi srednje velikih poduzeća. Oba imaju negativnu stopu neto novčanog toka u 2012. godini (- 0,25 i - 0.22). Stope gotovine su im identične (0,01), a u stopi dodane nove vrijednosti postoji određena razlika (1,11 i 0,71). Orljava je zabilježila znatan rast pokazatelja likvidnosti nakon sklopljene nagodbe. Tekući je omjer narastao s 0,77 na 1,10, stopa neto radnoga kapitala s – 0,48 na 0,05. Intenzitet dugoročna financiranja ostao je nepromijenjen, ali se poboljšao pokazatelj pokrivenosti kamata. Drugo poduzeće iskusilo je jednaku likvidnost, ali i pad zaduženosti. Može se dakle zaključiti da poduzeća pokazuju sličnosti prema izabranim kovarijablama te da u tretmanskoj skupini pokazuju znatno poboljšanje stupnja likvidnosti te, u nekim slučajevima, i smanjenje stupnja zaduženosti.

6.3.2.1 Opis statističkih veličina i deskriptivna analiza podataka

Poželjno je da tretmanska i kontrolna skupina budu što sličnije jedna drugoj. Ako subjekti u dvjema skupinama pokazuju različito ponašanje prema različitim dimenzijama, procjena efekta tretmana bit će pristrana. Pri tome nisu važne razlike u razinama nego trend promjena varijabli ishoda. Prvi uvid o usklađenosti tretmanske i kontrolne grupe pruža tablica 6-6, u kojoj je dan pregled medijana izabranih pokazatelja za subjekte identificirane metodom uparivanja te sve subjekte koji ne pripadaju tretmanskoj skupini. Tablica sadržava medijane kovarijabli upotrijebljenih pri uparivanju kontrolne i tretmanske skupine te izabrane pokazatelje likvidnosti i pokazatelje financiranja. Za testiranje razlike u medijanima između skupina upotrijebljena je Pearsonova χ^2 statistička veličina.

Tablica 6-6: Medijani izabranih pokazatelja u 2012. godini

Opis	cf	nva	$cash$	dr	ten	cr	i
A) Metoda uparivanja							
Tretmanska skupina	-0.065	0.178	0.016	0.068	0.919	0.650	0.013
Kontrolna skupina	-0.024	0.243	0.017	0.069	0.795	0.851	0.018
Razlika	-0.041	- 0.65	- 0.001	- 0.001	0.124	- 0.201	- 0.005
p vrijednost	0.212	0.022	1.000	1.000	0.000	0.001	0.677
Veličina (fiksni efekti)				DA			
Djelatnost (fiksni efekti)				DA			
B) *Ad hoc* metoda							
Tretmanska skupina	-0.070	0.178	0.016	0.068	0.923	0.650	0.012
Kontrolna skupina	0.002	0.114	0.028	0.093	1.082	0.396	0.019
Razlika	- 0.072	0.064	- 0.012	- 0.025	- 0.159	0.254	0.007
p vrijednost	0.000	0.657	0.018	0.001	0.000	0.000	0.459
Veličina (fiksni efekti)				NE			
Djelatnost (fiksni efekti)				NE			

BILJEŠKA: Tablica pokazuje medijane izabranih pokazatelja za tretmansku i kontrolnu skupinu. U dijelu A) poduzeća u kontrolnoj skupini identificirana su Abadie-Imbensovom metodom uparivanja, a u dijelu B) kontrolna se skupina sastoji od svih poduzeća koja ne pripadaju treatmanskoj skupini U prvom dijelu uzorak se sastoji od 181 subjekta u objema skupinama, a u dijelu B) tretmanska skupina sadržava 185, a kontrolna 28.718 opservacija. Nad uzorkom su provedene prilagodbe opisane u poglavlju 6.3.2. Razlika u medijanima testira se Pearsonova χ^2 testom.

Dio A) tablice 6-6 uspoređuje poduzeća iz tretmanske i kontrolne skupine, gdje je kontrolna skupina dobivena Abadie-Imbensovom metodom uparivanja. Testovi pokazuju jednakost medijana za sve varijable, osim za varijable tekućeg omjera i koeficijenta zaduženosti. Koeficijent zaduženosti i tekući omjer dodani su namjerno. Željela se istaknuti razlika u financijskom položaju poduzeća u uzorku. Poduzeća iz kontrolne skupine likvidnija su i zaduženija od onih iz tretmanske skupine. Poduzeća iz tretmanske i kontrolne skupine posluju u istim djelatnostima te su iste veličine kao i ona iz kontrolne skupine.

Dio B) tablice 6-6 uspoređuje poduzeća iz tretmanske i kontrolne skupine, gdje su kontrolna skupina sva poduzeća koja nisu u tretmanskoj skupini. Poduzeća u kontrolnoj skupini pokazuju manju tekuću likvidnost, veću zaduženost, veću stopu amortizacije, veću stopu gotovine i veću stopu novčanih tokova. Razlike su u medijanima očekivane jer se eksperiment temelji na opaženim podacima.

Tablica 6-7: Test jednakosti distribucija za tretmansku kontrolnu skupinu za 2012. godinu

Opis	Skupina	25. perc	Medijan	75. perc	p vrijednost
A) Metoda uparivanja					
cf	Tretmanska	- 0.271	-0.065	0.073	0.194
	Kontrolna	- 0.223	-0.024	0.089	
nva	Tretmanska	0.010	0.178	0.907	0.368
	Kontrolna	0.016	0.243	0.796	
$cash$	Tretmanska	0.003	0.016	0.079	0.974
	Kontrolna	0.003	0.016	0.079	
dr	Tretmanska	0.034	0.068	0.159	0.529
	Kontrolna	0.257	0.069	0.151	
ten	Tretmanska	0.704	0.919	1.144	0.000
	Kontrolna	0.569	0.795	1.047	
cr	Tretmanska	0.315	0.650	1.070	0.001
	Kontrolna	0.489	0.851	1.625	
i	Tretmanska	- 0.007	0.013	0.556	0.243
	Kontrolna	-0.042	0.018	0.155	
A) Ad hoc metoda					
cf	Tretmanska	- 0.293	-0.070	0.073	0.000
	Kontrolna	- 0.137	0.002	0.144	
nva	Tretmanska	0.010	0.178	0.938	0.007
	Kontrolna	0.705	0.114	1.142	
$cash$	Tretmanska	0.003	0.016	0.084	0.000
	Kontrolna	0.006	0.028	0.090	
dr	Tretmanska	0.034	0.068	0.159	0.000
	Kontrolna	0.015	0.093	0.281	
ten	Tretmanska	0.700	0.923	1.146	0.000
	Kontrolna	0.923	1.082	1.418	
cr	Tretmanska	0.368	0.650	1.053	0.000
	Kontrolna	0.180	0.396	0.627	
i	Tretmanska	- 0.007	0.012	0.161	0.000
	Kontrolna	0.000	0.019	0.226	

BILJEŠKA: Tablica pokazuje distribuciju izabranih pokazatelja za tretmansku i kontrolnu skupinu. U dijelu A) poduzeća u kontrolnoj skupini identificirana su Abadie-Imbensovom metodom uparivanja, a u dijelu B) kontrolna se skupina sastoji od svih poduzeća koja ne pripadaju tretmanskoj skupini. U prvom dijelu uzorak se sastoji od 181 subjekta u objema skupinama, a u dijelu B) tretmanska skupina sadržava 185, a kontrolna 28.718 opservacija. Nad uzorkom su provedene prilagodbe opisane u poglavlju 8.3.2. Razlika u distribucijama testira se Kolmogorov-Smirnovljevim testom. Osim rezultata testa (p vrijednost), tablica sadržava medijane, 25. percentil te 75. percentil distribucije.

Tablica 6-7 umjesto medijana uspoređuje cijelu distribuciju izabranih kovarijabli za tri skupine poduzeća. Jednakost distribucija ispituje se upotrebom Kolmogorov-Smirnovljevim testom.

Tretmanska i kontrolna skupina definirane su kao i u prethodnom primjeru. Poduzeća u tretmanskoj i kontrolnoj skupini pokazuju značajnu razliku u distribucijama pokazatelja (p vrijednost iznosi 0) ako se kao kontrolna skupina upotrijebe sva poduzeća. U dijelu A), u kojem se kontrolna skupina dobiva metodom uparivanja, test pokazuje snažnu statističku signifikantnost u prilog alternativnoj hipotezi (jednakost distribucija). U svim pokazateljima, p vrijednost Kolmogorov-Smirnovljeva testa veća je od 0,10. Distribucije nisu podudarne jedino za pokazatelj tekuće likvidnosti i koeficijenta zaduženosti, što je očekivano jer se subjekti nisu uparivali prema tim dvama pokazateljima. Može se zaključiti da su prema vektoru upotrijebljenih kovarijabli poduzeća iz tretmanske skupine slična onima iz kontrolne skupine.

Zaključno, distribucije odabranih pokazatelja pokazuju da su razlike između kontrolne i tretmanske skupine vrlo male ako se za identificiranje kontrolne skupine primijeni metoda uparivanja. S druge strane, razlike između skupina važne su ako se za kontrolnu skupinu odabiru sva poduzeća koja nisu u tretmanskoj skupini. Drugim riječima, statistički testovi potvrđuju ispravnost namjere da se primjenom metode uparivanja smanji pristranost izbora.

Ključna identifikacijska pretpostavka RR modela paralelnost je trendova. Paralelnost trendova ovdje podrazumijeva slične stope promjena investicija između tretmanske i kontrolne skupine prije 2013. godine. To ne podrazumijeva slične razine investicija za tretmansku i kontrolnu skupinu. RR procjenitelj računa razliku u promjenama investicija između kontrolne i tretmanske skupine, prije i poslije tretmana. Nakon primjene tretmana očekivana vrijednost investicija između kontrolne i tretmanske skupine trebala bi se promijeniti. Drugim riječima, trendovi gube svojstvo paralelnosti.

Na slici 6-2 pružen je uvid u utjecaj tretmana (odgoda i djelomičan oprost zbog sklapanja predstečajne nagodbe) na varijablu ishoda (stopu investicija). Graf A) prikazuje ponašanje stope investicija od 2011. do 2014. Prvom vertikalom linijom označen je datum prve sklopljene predstečajne nagodbe, a druga linija označuje datum posljednje sklopljene nagodbe (31.prosinca 2013). Između dviju linija je period u kojem su poduzeća „primila tretman“. Graf pokazuje da je trend investicija prije primjene tretmana (2011–su -2012) paralelan. Valja podsjetiti da vrijednosti na grafikonu očekivane vrijednosti, a ne medijani kao u tablici 6-5. Na kraju 2013. nastale su određene promjene u trendovima. Kontrolna skupina pokazuje veće stope investicija od tretmanske skupine i, što je važnije, manju stopu pada investicija. U 2014. proces se preokrenuo. Investicije u kontrolnoj skupini padaju, a u tretmanskoj rastu. Treba podsjetiti da razdoblje nakon tretmana uključuje prosjek investicija u 2013. i 2014. godini. Ako se

usporedi prosjek 2013–2014. s prosjekom 2011–2012, može se zamijetiti da su poduzeća u kontrolnoj skupini iskusila malo veći rast investicija nakon primjene tretmana. Graf može implicirati nedjelotvornost politike oprosta dugova ili dugoročan (zakašnjeli) utjecaj tretmana na varijablu ishoda.

Ispraviti u kontrolna skupina, tretmanska skupina

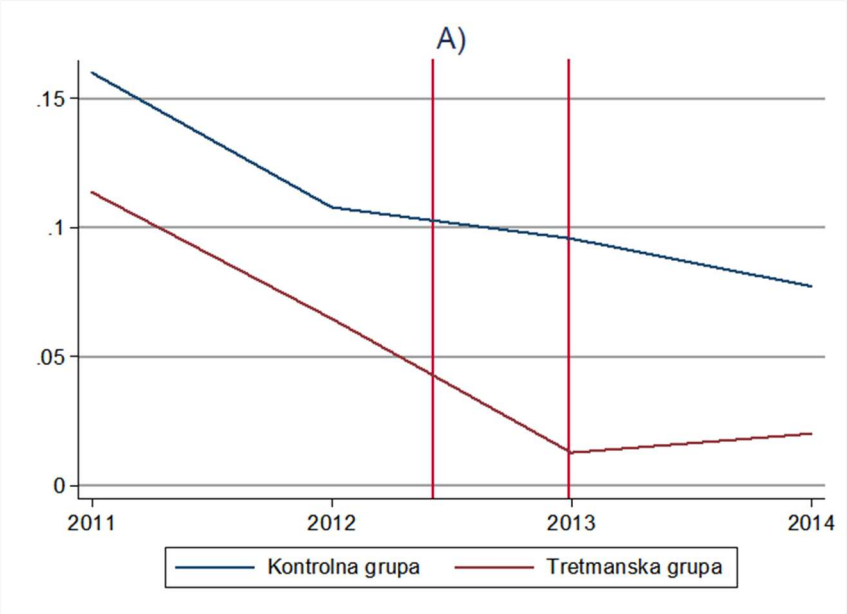

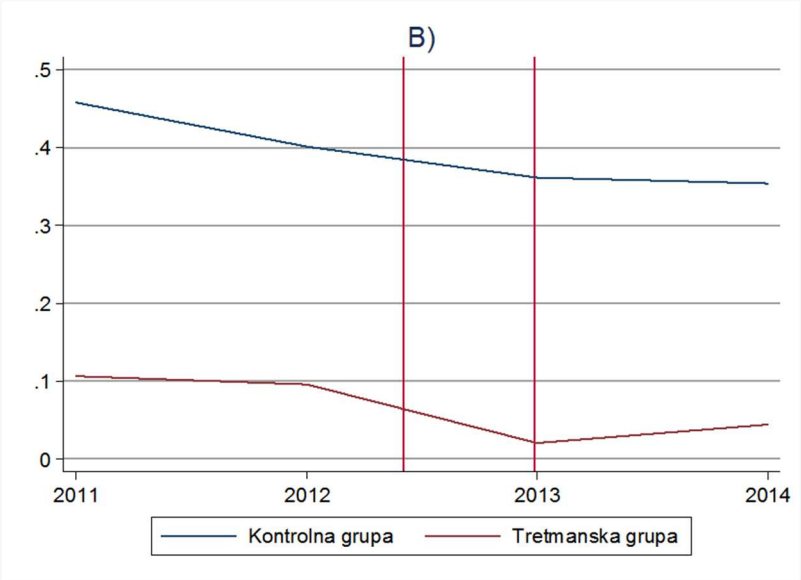

Bilješka: Grafovi prikazuju očekivane vrijednosti stope investicija za kontrolnu i tretmansku skupinu. Tretmansku skupinu čine poduzeća koja su sklopila predstečajnu nagodbu sa svojim vjerovnicima od 2013. do 2014. godine. Na grafu A) kontrolna je skupina identificirana metodom spajanja najbližeg susjeda. Radi brisanja utjecaja ekstremnih vrijednosti, iz uzorka su izbačene opservacije ispod 1. i iznad 99. percentila. Nakon prilagodbe, tretmanska skupina sadržava 740, a kontrolna 724 opservacije. Na grafu B) u kontrolnoj su skupini sva poduzeća koja ne pripadaju tretmanskoj skupini.

Slika 6-2: Očekivane vrijednosti investicija za tretmansku i kontrolnu skupinu od 2011. do 2014.

Na grafu B) u kontrolnoj su skupini sva poduzeća koja nisu sklopila predstečajnu nagodbu 2013. godine. Iako za identifikaciju kontrolne skupine nije primijenjena metoda uparivanja, trendovi pokazuju sličan obrazac prije primjene tretmana. Prosječne su investicije znatno veće u kontrolnoj skupini prije i poslije tretmana. Poslije tretmana investicije imaju manju stopu rasta u poduzećima u tretmanskoj skupini.

Grafikon pokazuje rezultate u skladu s hipotezom. Poduzeća koja su iskusila oprost i odgodu dugova, zbog sklapanje postupka predstečajne nagodbe, nisu iskusila rast investicija, kako u odnosu prema sličnim poduzećima, tako i u odnosu prema svim poduzećima.

6.4 Prikaz modela

Regresijska jednadžba koja se procjenjuje ima sljedeći oblik:

$$i_{it} = \beta_0 + \beta_1 d \times p + \beta_2 d + \beta_3 p + \delta' X + u_{it} \tag{143}$$

gdje zavisna varijabla označava stopu investicija, i označava poduzeće, t godinu, d binarnu varijablu jednaku 1 ako je poduzeće sklopilo predstečajnu nagodbe u 2013. godini i nula u ostalim slučajevima; p je binarna varijabla jednaka 1 za opservacije nakon tretmana (2013) i nula u ostalim slučajevima; X je vektor kontrolnih varijabli, a u su pogreške relacije. Osnovni je važan parametar β_1, koji odgovara prosječnoj promjeni investicija između razdoblja prije i poslije tretmana za tretmansku skupinu i stope investicija u istom razdoblju za kontrolnu skupinu. Jednadžba (143) je standardna OLS regresijska jednadžba u kojoj je važna varijabla (stopa investicija) regresirana na kvalitativnu varijablu za poduzeća iz tretmanske skupine.

Već je spomenuto da tretmanska varijabla, d, treba kontrolirati za permanentne razlike između kontrolne i tretmanske skupine. Na primjer, može se pretpostaviti da su poslovni subjekti iz kontrolne skupine profitabilniji od onih iz tretmanske skupine. Tretmanska bi varijabla trebala kontrolirati za te razlike. Varijabla p treba kontrolirati za trendove zajedničke kontrolnoj i tretmanskoj skupini. Primjerice, ako su investicije između godina prije i nakon tretmana rasle zbog pada kamatne stope, p bi trebao pokriti te varijacije. Preostale varijacije pokriva parametar β_1, tretmanski efekt, osnovna važna varijabla.

Kako bi se smanjila pristranost procjenitelja, unatoč primjeni metode uparivanja, u regresijsku su jednadžbu dodane sljedeće kontrolne varijable: stopa novčanog toka, stopa nove dodane vrijednosti i stopa gotovine. Dakle, kontrolne varijable sadržavaju kovarijable upotrijebljene pri uparivanju poduzeća i stopu prihoda. U poglavlju 5.5. pokazano je da stopa prihoda ima ekonomski i statistički signifikantan utjecaj na investicije, pa bi izostanak ove varijable mogao pridonijeti pristranim procjeniteljima.

U poglavlju 6.7. procjenjivat će se model panel-fiksnih efekata za razdoblje 2011–2014. Iako će se model detaljnije objasniti, valja napomenuti da primjena fiksnih efekata ne mijenja bit procjene. Umjesto jednog razdoblja, uvode se kvalitativne varijable za sva razdoblja (osim bazične godine) te se kontrolira za sve karakteristike poduzeća koje su konstantne tijekom vremena. Ali, kao i u osnovnome modelu, temeljni je cilj procjena efekta tretmana β_1.

Procjena DD procjenitelja zahtijeva raspolaganje s najmanje dva razdoblja: razdobljem prije i poslije tretmana. Očito je da se ova dva razdoblja ne mogu jednoznačno identificirati za cijeli uzorak jer je dio poduzeća sklopio nagodbu u 2013, a dio u 2014. godini. Zato se pretpostavlja da su sva poduzeća sklopila nagodbu u 2013. godini, tj. primila tretman 2013. godine. U analizi robusnosti proučavat će se utjecaj tretmana za različita razdoblja prije i poslije tretmana. Osnovni model uspoređuje 2012. i 2013. godinu, gdje 2012. godina uključuje prosjek vrijednosti varijabli za 2011. do 2012, a 2013. godina prosjek varijabli za razdoblje 2013–2014.

Na kraju, valja napomenuti da interpretacija rezultata uvelike ovisi o funkcionalnoj formi jednadžbe (148). Primjerice, ako investicije u tretmanskoj grupi rastu s 40% na 60%, a u kontrolnoj grupi s 10% na 20%, RR procjenitelj iznosi 10% (Roberts i Whited, 2013). Međutim, ako se varijabla ishoda napiše u formi prirodnog logaritma, RR procjenitelj iznosi -0,29. Dakle, velika je razlika između mjerenja apsolutnih i relativnih promjena. Temeljni će model sadržavati razlike u razinama, a u tekstu će se komentirati i relativne promjene.

6.5 Rezultati analize

U ovom poglavlju donose se rezultati empirijskog modela. Prvo se prikazuju rezultati osnovnog modela u kojem razdoblje prije tretmana uključuje prosjek 2011–2012, a razdoblje nakon tretmana prosjek za razdoblje 2013–2014. U tretmanskoj su skupini poduzeća koja su uspješno

sklopila predstečajnu nagodbu, a u kontrolnoj su skupini poduzeća identificirana metodom uparivanja. U drugom se dijelu prikazuju rezultati s brojem zaposlenih kao varijablom ishoda.

6.5.1 Rezultati osnovnog modela

Rezultati osnovnog modela procjenjuju utjecaj sklopljene predstečajne nagodbe na investicije poduzeća. Predstečajna nagodba pridonosi jednokratnu poboljšanju financijskog položaja (odgoda i djelomičan oprost dugova), što, zbog teorije o financijskom i likvidnom ograničenju može utjecati na investicije poduzeća. Kontrolna skupina sadržava poduzeća identificirana metodom uparivanja.

Rezultati se nalaze u tablici 6-8. Dio A) tablice pokazuje veću prosječnu stopu investicija za kontrolnu skupinu u 2012. godini. Razlika iznosi 0,169 i statistički je signifikantna uz razinu značajnosti 1% (p vrijednost iznosi 0,009). Duga kolona u dijelu A) pokazuje stope investicija u 2013. godini. Obje skupine pokazuju pozitivne stope investicija u razdoblju nakon tretmana, ali je rast investicija veći u kontrolnoj skupini. Točnije, investicije u tretmanskoj skupini pale su 0,184, a u kontrolnoj skupini 0,134. Prva je promjena signifikantna uz razinu značajnosti 5%, a druga uz razinu značajnosti 1%. Konačno, DD procjenitelj pokazuje da su investicije za tretmansku grupu u prosjeku niže 0,051. Međutim, procjenitelj je nesignifikantan uz razinu značajnosti 10% (p vrijednost iznosi 0,514). Korištenje logaritmom investicija, koji pokazuje relativne promjene, daje slične rezultate. Subjekti koji su uspješno sklopili predstečajnu nagodbu u prosjeku investiraju 55% manje od subjekata iz tretmanske grupe.

Drugi dio tablice prikazuje rezultate Abadie-Imbensova procjenitelja. Subjekti iz tretmanske skupine sada su uspoređeni s protučinjeničnim ishodima (ishodima uparenih poduzeća). Prema očekivanjima, u 2012. godini očekivane vrijednosti investicija vrlo su slične u dvjema promatranim skupinama. Razlika iznosi 0,005 i nije statistički signifikantna. Međutim, nakon primjene tretmana nastaje razlika u ponašanju investicija. Tvrtke koje su uspješno sklopile predstečajnu nagodbu (iskusile odgodu i djelomičan oprost dugova), u prosjeku su investirale manje od sličnih poduzeća koja nisu sklopila nagodbu. Promjena iznosi $-0{,}157$ i statistički je signifikantna uz razinu značajnosti 10% (p vrijednost iznosi 0,073)

Ako se umjesto razina promatra relativna promjena investicija, rezultati su slični. Subjekti koji su sklopili nagodbu u prosjeku investiraju 18,5% manje od sličnih poduzeća, koja nisu sklopila

predstečajnu nagodbu. Procjenitelj je statistički nesignifikantan uz razinu značajnosti 10% (p vrijednost iznosi 0,705).

Tablica 6-8: DD procjenitelj stope investicija između poduzeća koja su sklopila predstečajnu nagodbu i sličnih poduzeća od 2012. do 2013.

Prosječna godišnja promjena stope investicija između tretmanske i kontrolne skupine od 2012. do 2013.			
	A) *Ad hoc* model		
	2012.	2013.	2012–2013.
Tretmanska skupina	0.200	0.016	-0.184^{**} (0.078)
Kontrolna skupina	0.369	0.235	-0.134^{***} (0.006)
Razlika	-0.169^{***} (0.064)	-0.219^{***} (0.044)	$\mathbf{-0.051}$ ($\mathbf{0.079}$)
n	43.329	43.329	
	B) Model uparivanja		
	2012	2013	2012 - 2013
Tretmanska skupina	0.124	-0.023	-0.148^{***} (0.057)
Kontrolna skupina	0.119	0.129	0.005 (0.056)
Razlika	-0.005 (0.056)	-0.152^{**} (0.064)	$\mathbf{-0.157}^{*}$ ($\mathbf{0.087}$)
n	370	370	

***, **, * označavaju razinu značajnosti od 1%, 5% i 10%

Bilješka: Tablica prikazuje nalaze osnovnog modela. Graf A) procjenjuje razliku stope investicija za tretmansku i kontrolnu skupinu, pri čemu kontrolnu skupinu čine sva poduzeća koja nisu sklopila predstečajnu nagodbu. Uspoređuje se promjena stope investicija za kontrolnu i tretmansku skupinu od 2012. do 2013, gdje 2012. godina uključuje prosjek vrijednosti zavisnih i nezavisnih varijabli u razdoblju 2011–2012, a 2013. prosjek varijabli od 2013. do 2014. U oba razdoblja postoji 43.329 opservacija, od kojih se 188 odnosi na tretmansku skupinu, a ostatak na kontrolnu skupinu. Radi smanjivanja pristranosti procijenjenog parametra, u regresijsku su jednadžbu dodane kontrolne varijable: stopa novčanog toka, stopa neto radnoga kapitala i stopa gotovine (koeficijenti uz kontrolne varijable izostavljeni su radi preglednosti). Definicija varijabli dana je u poglavlju 6.3.2 Graf B) procjenjuje razliku stope investicija za tretmansku i kontrolnu grupu, pri čemu kontrolnu skupinu čine poslovni subjekti identificirani metodom uparivanja. Za uparivanje su upotrijebljene sljedeće kovarijable: djelatnost subjekta, veličina, stopa nove dodane vrijednosti, stopa novčanog toka, stopa gotovine. U oba razdoblja postoji 370 opservacija, od kojih se 185 odnosi na tretmansku skupinu, a ostatak na kontrolnu skupinu. Radi smanjivanja pristranosti procjenitelja, u regresijsku su jednadžbu dodane kontrolne varijable opisane ranije. Ispod procijenjenih razlika navedene su standardne pogreške robusne na heteroskedastičnost.

U tablici 6-9 prikazane su vrijednosti procijenjenih koeficijenata i standardne pogreške robusne na heteroskedastičnost. Stopa je gotovine signifikantna uz razinu značajnosti 10%. Vrijednost je koeficijenta vrlo visoka, 0,414. Ostali parametri nisu ekonomski i statistički signifikantni, pa se neće dodatno analizirati.

Tablica 6-9: Vrijednosti procijenjenih parametara, standardne pogreške i p vrijednosti za osnovni model

Varijabla	Koeficijent	Standardne pogreške	p vrijednost
cf	-0.002	0.024	0.934
nva	0.011	0.008	0.182
$cash$	0.414	0.212	0.052
$cons$	0.035	0.050	0.486

Prikazani rezultati u skladu su s postavljenom istraživačkom hipotezom. Pretpostavka o monotono rastućoj osjetljivosti stupnja likvidnosti i investicija implicirala bi veći rast investicija za poduzeća koja su uspješno sklopila predstečajnu nagodbu jer su uparivana prema varijablama koje odražavaju potražne faktore. Ako poduzeća imaju sličnu stopu novčanog toka, dodane nove vrijednosti, gotovine, iste su veličine te pripadaju istoj djelatnosti, monotono rastuća osjetljivost implicirala bi da oprost dugova i/ili povećanje neto radnoga kapitala povećava investicije u tretmanskoj skupini u odnosu prema kontrolnoj skupini. Međutim, nelinearan odnos između stanja likvidnosti i investicija implicira drukčiji rezultat. Potražni faktori postaju bitni tek nakon uspostavljanja primjerene likvidnosti i stvaranja dovoljno neto radnoga kapitala (novca) za novčane pričuve. Ovakvo stanje u sebi implicira i financijsko ograničenje jer poduzeće ne uživa povjerenje u izvršenje budućih mogućih obveza.

Valja se podsjetiti statističkih veličina u tablici 6-7. Medijan tekuće likvidnosti rastao je s 0,6 2012. godine na 0,9 u 2013. godini. Međutim, slijedeći rezultate analize iz poglavlja 5.5.2, poduzeća su još u polju nelikvidnih poduzeća ili u skupini poduzeća s graničnom likvidnošću, što implicira likvidno ograničenje. Nadalje, može se očekivati da poduzeća gomilaju likvidnost za plaćanje odgođenih, djelomično oproštenih obveza i novih operativnih troškova. S druge strane, poduzeća su u kontrolnoj skupini likvidnija i manje zadužena (tablica 6-7), pa mogu lakše financirati nove investicije.

Teorija o financijskom ograničenju implicirala bi veće investicije za tretmansku skupinu. Naime, ako su poduzeća u uzorku sličnih karakteristika te jedna skupina iskusi smanjenje stupnja financijske ograničenosti, očekivalo bi se da ima i veći rast investicija. Međutim, teorija o nelinearnu likvidnom ograničenju predviđa rezultat dobiven u tablici.

Rezultati stoga potvrđuju postavljenu istraživačku hipotezu. Poduzeća su prije sklapanja predstečajne nagodbe pripadala skupini financijski i likvidno ograničenih poduzeća. Nakon sklapanja nagodbe iskusila su poboljšanje financijske situacije, ali ne dovoljno da bi pokrenula veći investicijski ciklus u odnosu prema sličnim poduzećima.

Prikazani rezultati imaju učinak i na ekonomsku politiku. Djelomičan oprost i odgoda dugova neće pozitivno utjecati na investicije jer su poduzeća u skupini financijski ugroženih. Rast investicija zahtijevao bi veći oprost i još veću odgodu dugova i/ili povećanje agregatne potražnje. Poduzeća su prije sklapanja nagodbe bila kandidati za stečaj, a nakon nagodbe uspjela su uspostaviti tek graničnu likvidnost i smanjiti dugove za ipak male iznose. Ukratko, ne postoji uzročan odnos između oprosta i odgode dugova te veće investicijske aktivnosti poduzeća.

6.5.2 Utjecaj tretmana na zaposlenost poslovnih subjekata

Jedan od primjenjivih ciljeva ovog rada procjena je uspješnosti Zakona o financijskom poslovanju i predstečajnoj nagodbi. Izravan je cilj Zakona uspostavljanje likvidnosti i solventnosti dužnika. Međutim, krajnji je cilj održavanje radnih mjesta i rast poslovnih subjekata koji su sklopili nagodbu. Rezultat osnovnog modela pokazuje efekte investicija, ali ne govori kakav je utjecaj predstečajne nagodbe na broj zaposlenih. U ovom se poglavlju kao varijabla ishoda upotrebljava broj zaposlenih. Kontrolna se skupina određuje na isti način kao i prije. Čine je poslovni subjekti koji su slični poduzećima u tretmanskoj skupini prema sljedećim varijablama: djelatnost poduzeća, veličina poduzeća, stopa novčanog toka, stopa nove dodane vrijednosti, stopa gotovine.

Rezultati su dani u tablici 6-10. U 2012. godini postoji signifikantna razlika između logaritma broja zaposlenih u tretmanskoj i kontrolnoj skupini. Nakon primjene tretmana pada broj zaposlenih u objema skupinama poduzeća. Međutim, poduzeća iz tretmanske skupine otpustila su više radnika od onih u kontrolnoj skupini. Točnije, DD procjenitelj pokazuje da je broj zaposlenih nakon tretmana za 0,154 (15.0% ako se kao zavisna varijabla rabi logaritam broja zaposlenih) manji od broja zaposlenih u kontrolnoj skupini nakon tretmana. Razlika je signifikantna uz razinu značajnosti od 5% (p vrijednost iznosi 0.028).

Tablica 6-10: DD procjenitelj logaritma zaposlenih između poduzeća koja su sklopila predstečajnu nagodbu i sličnih poduzeća od 2012. do 2013.

Prosječna godišnja promjena logaritma broja zaposlenih između tretmanske i kontrolne skupine od 2012. do 2013.			
	Model uparivanja		
	2012.	2013.	2012–2013.
Tretmanska grupa	2.866	2.577	-0.289^{***} (0.054)
Kontrolna grupa	2.501	2.366	-0.134^{**} (0.045)
Razlika	0.365^{**} (0.176)	0.211 (0.176)	$\mathbf{-0.154}^{**}$ $(\mathbf{0.016})$
n	362	362	

***, **, * označavaju razinu značajnosti od 1%, 5% i 10%

Bilješka: Tablica pokazuje da su tvrtke koje su sklopile predstečajnu nagodbu smanjile broj zaposlenih u odnosu prema sličnim poduzećima. U kontrolnoj su skupini poslovni subjekti identificirani metodom uparivanja. Za uparivanje su upotrijebljene sljedeće kovarijable: djelatnost subjekta, veličina, stopa nove dodane vrijednosti, stopa novčanog toka, stopa gotovine. Definicija varijabli dana je u poglavlju 8.3.2. Uspoređuje se promjena stope investicija za kontrolnu i tretmansku skupinu od 2012. do 2013, gdje 2012. godina uključuje prosjek vrijednosti zavisnih i nezavisnih varijabli u razdoblju 2011–2012, a 2013. prosjek varijabli od 2013. do 2014. Za oba razdoblja postoje 362 opservacije, od kojih se 181 odnosi na tretmansku skupinu, a ostatak na kontrolnu skupinu. Radi smanjivanja pristranosti procijenjena parametra, u regresijsku su jednadžbu dodane kontrolne varijable: stopa novčanog toka, stopa neto radnoga kapitala, stopa gotovine (koeficijenti su uz kontrolne varijable izostavljeni radi preglednosti). Ispod procijenjenih razlika navedene su standardne pogreške robusne na heteroskedastičnost.

Može se zaključiti da predstečajne nagodbe nisu pridonijele relativnu rastu zaposlenosti. Drugim riječima, Zakon nije ispunio cilj koji je postavljen. Poduzeća nisu povećala investicije, a broj je zaposlenih manji usporedi li se s onim u sličnim poduzećima.

6.6 Analiza robusnosti osnovnog modela

U idućim dvama poglavljima analizira se robusnost osnovnog modela. Prvo se analizira osjetljivost rezultata na izbor različitog razdoblja promatranja. Moguće je da Zakon ima dugoročne efekte, koji nisu vidljivi u istoj godini kada je primljen tretman. U drugom se dijelu testira osjetljivost rezultata na izbor kovarijabli upotrijebljenih pri uparivanju. Moguće je da izbor različitih varijabli daje i različite rezultate.

6.6.1 Promjena investicija za različita razdoblja

Analiza robusnosti započinje ispitivanjem osjetljivosti rezultata na izbor različitih razdoblja prije i nakon tretmana. U osnovnome modelu, razdoblje prije tretmana uključuje prosjek varijabli za razdoblje 2011–2012. godine, a razdoblje nakon tretmana uključuje prosjek varijabli za razdoblje 2013–2014. Većina je subjekata primila tretman (sklopila predstečajnu nagodbu) u drugoj polovici 2013. godine. Moguće je da je subjektima koji su sklopili nagodbu potkraj 2013. bilo potrebno više vremena kako bi proveli restrukturiranje i pokrenuli investicije. Drugim riječima, moguće je da su u 2014. godini utjecaji predstečajne nagodbe bili izraženiji nego potkraj 2013. godine. Kako bi se ispitale potonje hipoteze, u nastavku se prikazuju rezultati procjene efekta tretmana za različita razdoblja. Više se ne promatraju srednje vrijednosti varijabli već se uspoređuju pojedine godine.

Procjenjuje se efekt tretmana za tri razdoblja: 2012–2013, 2012–2014. i 2013–2014. godine. Rezultati procijenjenih parametara prikazani su u tablici 6-11. Za sve su modele izračunani efekti tretmana u apsolutnim i relativnim terminima. Sva tri modela potvrđuju prijašnje rezultate. Uz razinu značajnosti 10%, ne može se odbiti nulta hipoteza prema kojoj je vrijednost efekta tretmana jednaka 0. Slijede interpretacije pojedinih modela.

Prvi model uključuje razdoblje 2012–2013. Kontrolna je skupina izabrana metodom uparivanja u 2012. godini. Ako se promatra apsolutna promjena investicija, subjekti iz tretmanske skupine imali su veći rast investicija (koeficijent iznosi $0{,}091$). Međutim, ako se kao zavisna varijabla upotrijebi logaritam investicija (relativne promjene), subjekti iz tretmanske skupine investiraju manje od sličnih poduzeća iz kontrolne skupine (koeficijent iznosi $-0{,}123$). Oba su procijenjena parametra nesignifikantna uz razinu značajnosti 10%. Za prvi model p vrijednost iznosi $0{,}359$, a za drugi $0{,}543$.

Drugi model pokazuje dugoročan utjecaj predstečajnih nagodbi na varijablu ishoda. Procijenjeni su koeficijenti nesignifikantni uz razinu značajnosti 10% (p vrijednost za prvi model iznosi $0{,}911$, a za drugi model $0{,}899$), odnosno poduzeća koja su sklopila predstečajnu nagodbu ne investiraju više od sličnih poduzeća koja je nisu sklopila. Konačno, treći model pokazuje promjene u investicijama nakon sklopljene predstečajne nagodbe. Rezultati su isti: koeficijenti su nesignifikantni uz razinu značajnosti 10% (p vrijednosti iznose $0{,}273$ za relativnu promjenu i $0{,}667$ za apsolutnu promjenu).

Tablica 6-11: DD procjenitelj investicija između poduzeća koja su sklopila predstečajnu nagodbu i sličnih poduzeća za razdoblja: 2012–2013, 2012–2014. i 2013–2014. godine.

Promatrano razdoblje	**DD procjenitelj**	
	Apsolutne promjene	Relativne promjene
2012–2013.	0.091	−0.214
	(0.099)	(0.543)
2012–2014.	0.001	0.073
	(0.099)	(0.571)
2013–.2014	−0.099	0.253
	(0.090)	(0.588)

***, **, * označavaju razinu značajnosti od 1%, 5% i 10%

Bilješka: Tablica pokazuje da ne postoji signifikantna razlika u promjenama stope investicija između kontrolne i tretmanske skupine za različito definirana razdoblja prije i nakon tretmana. Kontrolnu skupinu čine poslovni subjekti identificirani metodom uparivanja. Za uparivanje su upotrijebljene sljedeće kovarijable: djelatnost subjekta, veličina, stopa nove dodane vrijednosti, stopa novčanog toka, stopa gotovine. Definicija varijabli dana je u poglavlju 8.3.2. Uspoređuje se promjena stope investicija za kontrolnu i tretmansku skupinu za tri razdoblja: 2012–2013, 2012 – 2014. i 2013 – 2014. godinu. Radi smanjivanja pristranosti procijenjenog parametra, u regresijsku su jednadžbu dodane kontrolne varijable: stopa novčanog toka, stopa neto radnoga kapitala, stopa deprecijacije, stopa gotovine (koeficijenti su uz kontrolne varijable izostavljeni radi preglednosti). Ispod procijenjenih razlika navedene su standardne pogreške robusne na heteroskedastičnost.

Može se zaključiti da slabiji rezultati poduzeća koja su sklopila nagodbu nisu osjetljivi na promjene razdoblja promatranja. Poduzeća u tretmanskoj skupini konzistentno pokazuju nesignifikantne vrijednosti koeficijenata uz tretmanski efekt. Ako i postoji promjena između skupina, odražava se prije kao smanjenje stope investicija i zaposlenosti u odnosu prema sličnim poduzećima, poslije primjene tretmana.

6.6.2 Uparivanje prema pokazateljima likvidnosti i zaduženosti

U tablici 6-7 (poglavlje 6.3.3) proveden je statistički test jednakosti distribucije odabranih varijabli. Rezultati testa pokazuju jednakost distribucija u varijablama koje služe za uparivanje poduzeća, ali i različitost distribucija za pokazatelje tekuće likvidnosti i koeficijenta zaduženosti. Drugim riječima, iako su poduzeća slična po varijablama za uparivanje, znatna je razlika u njihovu financijskom položaju. U nastavku se analizira efekt tretmana istim metodološkim pristupom kao i u prethodnom poglavlju, ali se za uparivanje subjekata upotrebljava drukčiji skup varijabli. Slična će se poduzeća identificirati prema četirima pokazateljima, a to su: stopa novčanog toka, koeficijent zaduženosti, stopa nove dodane

vrijednosti i tekuća likvidnost koja je iz kontinuirane varijable pretvorena u kategorijalnu varijablu.

Stopa je novčanog toka, kao i prije, jednaka omjeru zbroja neto dobiti i amortizacije i pomaknute sadašnje vrijednosti imovine. Koeficijent zaduženosti jednak je omjeru ukupnih obveza i ukupne imovine. Stopa dodane nove vrijednosti jednaka je omjeru dodane nove vrijednosti i pomaknute sadašnje vrijednosti imovine. Tekuća je likvidnost a omjeru kratkotrajne imovine i kratkotrajnih obveza, pri čemu su upotrijebljene kategorije opisane u fusnoti.[57]

Cilj je analizirati osjetljivost rezultata na izbor kovarijabli za uparivanje poduzeća. Pri tome su pokazatelji tekuće likvidnosti i koeficijenta zaduženosti izabrani s jasnom svrhom. Željela se procijeniti razlika u investicijama između tretmanske i kontrolne skupine, pri čemu obje skupine imaju slične pokazatelje likvidnosti i zaduženosti, ali i konkurentnosti i profitabilnosti. U osnovnome modelu poduzeća su uparivana prema potražnim varijablama, ali se nije poštovala razlika u financijskoj situaciji između subjekata. U sadašnjem se modelu e vodi briga i o financijskoj situaciji. Stopa novčanog toka i nove dodane vrijednosti kontroliraju za potražne faktore, a ostala dva pokazatelja za financijsku situaciju.

Zašto su izabrani upravo ovi pokazatelji? Prema rezultatima procijenjene *threshold* regresije u 6. poglavlju, odnos je investicija i likvidnosti, za dane investicijske prilike, nelinearan. Nelikvidna poduzeća imaju ugrožen opstanak, pa se dodatnim novčanim tokom koriste za uspostavljanje normirane likvidnosti. Ovoj skupini pripada većina poduzeća u uzorku. Također, poduzeća pokazuju visoke iznose financijske poluge što implicira poteškoće u pribavljanju eksternih sredstava. Ako je financijsko i posebno likvidno ograničenje bitno za razumijevanje ponašanja investicija, rezultati procijenjena efekta tretmana u ovome modelu trebali bi biti drukčiji od efekta tretmana u osnovnome modelu jer poboljšanje likvidne i financijske situacije zbog sklopljene predstečajne nagodbe omogućuje apsolutno veći iznos investicija zato što su manje ograničenje ili je manji pad investicija ako su vrijednosti stope investicija u objema skupinama negativne.

Hipoteza iz prethodnog pasusa može se dodatno objasniti pomoću primjera. Pretpostavimo da postoje dva poduzeća koja imaju jednaku likvidnosti(u tablici 6-12 vidi se da je medijan tekuće

[57] Granice kategorijalne varijable likvidnosti (cr) su sljedeće: 1. grupa: $0 < cr \leq 0.5$, 2. grupa: $0.5 < cr \leq 1$, 3. grupa: $1 < cr \leq 1.5$, 4. grupa: $1.5 < cr \leq 2$, 5. grupa: $2 < cr \leq 2.5$, 6. grupa: $2.5 < cr \leq 3$, 7. grupa: $3 < cr \leq 4$, , 8. grupa: $4 < cr \leq 5$, i posljednja grupa $5 < cr$

likvidnosti oko 0, 6), zaduženosti (medijan koeficijenta zaduženosti oko 0,9) i konkurentnosti (medijan stope dodane nove vrijednosti oko 0,196 i stope novčanog toka oko - 0,05). Pretpostavimo da jedno poduzeće iskusi poboljšanje financijske situacije zbog reprogramiranja i djelomična oprosta duga. Ako je likvidna i financijska situacija poduzeća važna za ponašanje investicija, one bi trebale biti veće u tretmanskoj skupini. To ne znači da bi investicije u toj skupini trebale rasti, već bi trebale imati manji apsolutni pad nego u poduzećima iz kontrolne skupine, *za dane razine novčanih tokova*. U apsolutnim se iznosima za obje skupine može očekivati dezinvestiranje ili nulta osjetljivost investicija na novčane tokove. Treba napomenuti da se očekuje različit rezultat u odnosu prema osnovnome modelu jer su poduzeća u tome modelu likvidnija i manje zadužena od subjekata iz tretmanske skupine. Dakle, očekuje se da će, za razliku od osnovnog modela, poduzeća iz tretmanske skupine imati veći rast investicija od onih iz kontrolne skupine.

Tablica 6-12 prikazuje testove o jednakosti distribucija za izabrane pokazatelje. Jednakost distribucija ispituje se Kolmogorov-Smirnovljevim testom. U svim pokazateljima uparivanje poduzeća p vrijednost Kolmogorov-Smirnovljeva testa veća je 0, 10. Poduzeća pokazuju sličnosti u distribuciji i za pokazatelj stope neto radnoga kapitala iako on nije poslužio za uparivanje poduzeća. Distribucije nisu podudarne jedino za pokazatelje stope gotovine i stopu amortizacije, što je očekivano jer se subjekti nisu uparivali prema tim dvama pokazateljima. Može se zaključiti da su prema vektoru kovarijabli (likvidnosti, zaduženosti, konkurentnosti) poduzeća iz tretmanske skupine slična onima iz kontrolne skupine.

Kao i u osnovnome modelu, efekt tretmana procjenjuje se primjenom DD procjenitelja pri čemu su kontrolna i tretmanska skupina identificirane Abadie-Imbensovom metodom uparivanja. Pri stvaranju uzorka provedene su prilagodbe opisane u poglavlju 6.3.2.[58] Rezultati su prikazani u tablici 6-13.

[58] Jedina je razlika u tom što se izbacuju promatranja u kojima su, osim vrijednosti stope novčanog toka i investicija, i vrijednosti koeficijenta zaduženosti i likvidnosti iznad 99. percentila i ispod 1. percentila.

Tablica 6-12: Test jednakosti distribucija za tretmansku kontrolnu skupinu za 2012. godinu

Opis	Skupina	25. perc	Medijan	75. perc	p vrijednost
cf	Tretmanska	- 0.265	-0.063	0.076	0.795
	Kontrolna	- 0.242	-0.035	0.085	
nva	Tretmanska	0.017	0.196	1.028	0.707
	Kontrolna	-0.013	0.196	0.862	
$cash$	Tretmanska	0.003	0.018	0.089	0.052
	Kontrolna	0.006	0.028	0.081	
dr	Tretmanska	0.034	0.072	0.166	0.008
	Kontrolna	0.002	0.079	0.234	
ten	Tretmanska	0.711	0.921	1.137	1.000
	Kontrolna	0.704	0.919	1.142	
cr	Tretmanska	0.396	0.658	1.067	0.365
	Kontrolna	0.276	0.626	1.056	
wc	Tretmanska	-0.915	-0.435	0.038	0.151
	Kontrolna	-1.195	-0.431	0.016	
i	Tretmanska	- 0.007	0.013	0.158	0.240
	Kontrolna	-0.080	0.017	0.221	

BILJEŠKA: Tablica pokazuje distribuciju izabranih pokazatelja za tretmansku i kontrolnu skupinu. Poduzeća u kontrolnoj skupini identificirana su Abadie-Imbensovom metodom uparivanja. Uzorak se sastoji od 184 subjekta u objema skupinama (ukupno 736 promatranja). Nad uzorkom su provedene prilagodbe opisane u poglavlju 6.3.2. Razlika u distribucijama testira se Kolmogorov-Smirnovljevim testom. Osim rezultata testa (p vrijednost), tablica sadržava medijane, 25. percentil te 75. percentil distribucije.

Tablica pokazuje da poduzeća u kontrolnoj skupini u 2012. godini imaju 0,182 veću stopu investicija (signifikantno uz razinu značajnosti 5%). Druga kolona pokazuje stope investicija u 2013. godini. Obje skupine pokazuju smanjenje stope investicija poslije tretmana, ali je pad investicija veći u kontrolnoj nego u tretmanskoj skupini. Točnije, investicije su u tretmanskoj skupini pale 0,103, a u kontrolnoj skupini 0,269. Prva je promjena signifikantna uz razinu značajnosti 10%, a druga uz razinu značajnosti 1%. DD procjenitelj pokazuje da su investicije za tretmansku skupine u prosjeku više 0,166. Procjenitelj je signifikantan uz razinu značajnosti 10% (p vrijednost iznosi 0,093). Korištenje logaritmima investicija pokazuje veću stopu investicija za tretmansku skupinu (2,9%), ali je procijenjeni koeficijent statistički nesignifikantan (p vrijednost iznosi 0,956).

Tablica 6-13: DD procjenitelj stope investicija između poduzeća koja su sklopila predstečajnu nagodbu i sličnih poduzeća od 2012. do 2013.

Prosječna godišnja promjena investicija između tretmanske i kontrolne skupine od 2012. do 2013.			
	Model uparivanja		
	2012.	2013.	2012 –2013.
Tretmanska skupina	0.124	0.021	-0.103^{*} (0.062)
Kontrolna skupina	0.306	0.037	-0.269^{***} (0.076)
Razlika	-0.182^{**} (0.086)	-0.016 (0.049)	$\mathbf{0.166}^{*}$ $(\mathbf{0.098})$
n	368	368	

***, **, * označavaju razinu značajnosti od 1%, 5% i 10%

Bilješka: DD procjenitelj procjenjuje razliku stope investicija za tretmansku i kontrolnu skupinu, pri čemu su u kontrolnoj skupini poslovni subjekti identificirani metodom uparivanja. Uspoređuje se promjena stope investicija za kontrolnu i tretmansku skupinu od 2012. do 2013, gdje 2012. godina uključuje prosjek vrijednosti zavisnih i nezavisnih varijabli od 2011.do 2012, a 2013. prosjek varijabli od 2013. do 2014. Za uparivanje su poslužile sljedeće kovarijable: tekući omjer (transformiran u kategorijalnu varijablu), koeficijent zaduženosti, stopa nove dodane vrijednosti i stopa novčanog toka. Radi smanjivanja pristranosti procijenjenog parametra, u regresijsku su jednadžbu dodane kontrolne varijable: stopa novčanog toka, stopa neto radnoga kapitala, stopa deprecijacije, stopa gotovine (koeficijenti uz kontrolne varijable su izostavljeni radi preglednosti). U oba razdoblja postoji 370 opservacija, od kojih se 185 odnosi na tretmansku skupinu te isto toliko na kontrolnu skupinu. Ispod procijenjenih razlika navedene su standardne pogreške robusne na heteroskedastičnost.

Prikazani rezultati u skladu su s očekivanjima. Prvo, poduzeća iz obje skupine pokazuju pad investicija u 2013. godini jer su obje skupine likvidno i financijski ograničene. Drugo, poduzeća iz tretmanske skupine, za danu razinu novčanih tokova i investicija, pokazuju manji pad investicija jer su odgodom i oprostom duga poboljšala financijsku situaciju u odnosu prema poduzećima iz kontrolne skupine, pa su stoga iskusila manji pad investicija. Važno je primijetiti da ovakvi rezultati nisu u suprotnosti s postavljenom i potvrđenom hipotezom u osnovnome modelu.

6.7 Analiza efekta tretmana metodom panel-fiksnih efekata

DD procjenitelj podrazumijeva procjenu OLS jednadžbe (144), u kojoj je važna procjena koeficijenta uz interakciju binarne varijable tretmana i razdoblja nakon tretmana. Alternativni

način procjene efekta tretmana podrazumijeva primjenu metode panel-fiksnih efekata. Panel-fiksni efekti vrlo su česta ekonometrijska metoda i već je primijenjena u poglavlju 5.6. pa se u nastavku pruža lapidaran prikaz metode prema Hsiao (2014).

Pretpostavimo da raspolažemo podacima o karakteristikama N poduzeća tijekom razdoblja T: y_{it}, x_{kit}, $i = 1, \dots N, t = 1, \dots T, k = 1, \dots K$. Opservacija y je ishod slučajnog eksperimenta s distribucijom vjerojatnosti uvjetovanom vektorom x i fiksnim brojem parametara θ, $f(y|x, \theta)$. U ovom se poglavlju pretpostavlja da je veza između parametara linearna, a parametri konstantni tijekom vremena i po poduzećima. Drugim riječima, upotrebljava se panel-model promjenjivog odsječka (engl. *intercept*):

$$y_{it} = \boldsymbol{x}_{it}'\boldsymbol{\beta} + \alpha_i^* + \lambda_t + u_{it}, \qquad i = 1, \dots, N, \qquad t = 1, \dots, T \tag{144}$$

gdje je $\boldsymbol{x_{it}}$ $K \times 1$ vektor eksplanatornih varijabli, uključujući i konstantni član, $\boldsymbol{\beta}$ je $K \times 1$ vektor konstanti, α_i^* i λ_t su neopaženi (unobserved) individualni i vremenski specifični efekti (engl. *individual and time specific effects*), za koje se pretpostavlja da su konstantni za dani i i različite t te za dani t, a različite i; u_{it} odražava efekte neopaženih varijabli koje variraju kroz i i t.

Utjecaj predstečajne nagodbe na investicije može se testirati jednadžbom (144), gdje se kao nezavisne varijable pojavljuju kvalitativne varijable za četiri razdoblja (2011–2014) i kvalitativna varijabla jednaka 1 ako subjekt pripada tretmanskoj skupini i 0 ako pripada kontrolnoj skupini. Procjenitelj unutar tvrtke (engl. *Within-firm estimator*) omogućuje kontrolu za neopažene efekte. Zavisna varijabla u modelu ponovno su investicije podijeljene s ukupnom pomaknutom ukupnom imovinom. Glavna je važna nezavisna varijabla interakcija dviju kvalitativnih varijabli. Kontrolne su varijable preuzete iz prijašnjih poglavlja: pomaknute vrijednosti stope novčanog toka, stope nove dodane vrijednosti, stope prihoda.

Rezultati su prikazani u tablici 6-14. Ključan je parametar te, koji mjeri efekt tretmana. Rezultati upućuju na to da se ne može odbaciti nulta hipoteza, prema kojoj je vrijednost efekta tretmana jednaka 0. Drugim riječima, ne postoji razlika između stope investicija za tretmansku i kontrolnu skupinu.

Tablica 6-14: Procijenjeni koeficijenti primjenom metode panel-fiksnih efekata

Varijabla	Koeficijent	Standardne pogreške	p vrijednost
2012	-0.009	0.001	0.000
2013	0.003	0.001	0.001
d	-0.014	0.001	0.000
$\boldsymbol{te}$	$\mathbf{-0.003}$	$\mathbf{0.011}$	$\mathbf{0.771}$
cf_{t-1}	0.001	0.006	0.927
nva_{t-1}	0.048	0.004	0.000
dr_{t-1}	-0.320	0.018	0.000
dr_t	0.553	0.020	0.000
$cons_t$	0.026	0.002	0.000

BILJEŠKA: Tablica prikazuje vrijednosti procijenjenih parametara panel-fiksnih efekata. Balansirani panel sadržava 128.848 podataka ili 32.212 poduzeća. Standardne su pogreške s robusne na heteroskedastičnost.

Valja napomenuti da je uzorak izrazito velik (8053 poduzeća) pa su standardne pogreške vrlo male. Zanimljivo je primijetiti da novčani tok, nakon kontroliranja za stopu nove dodane vrijednosti, ne objašnjava ponašanje investicija (p vrijednost vrlo je visoka, 0,771).

Može se zaključiti da Zakon o predstečajnoj nagodbi nije ispunio cilj zbog kojeg je donesen. Tvrtke koje su uspješno sklopile predstečajnu nagodbu nisu investirale više od onih koje su slične po potražnim faktorima. Ako se rezultati usporede s onima u tvrtkama koje su slične po potražnim i bonitetnim faktorima, postoji naznaka manjeg pada investicija za tretmansku skupinu, ali je promjena signifikantna tek uz razinu značajnosti 10%. Slična je interpretacija kada se umjesto stope investicija kao varijabla ishoda upotrijebi broj zaposlenih.

7 . ZAKLJUČAK

Znanstveni doprinos ove doktorske disertacije može se sažeti u nekoliko točaka:

- Procijenjen je stupanj financijskog ograničenja poslovnih subjekata u RH procjenom osjetljivosti investicija na novčane tokove primjenom *threshold* regresije.
- Obavljena je distinkcija između financijskog i likvidnog ograničenja te je prvi put ispitana hipoteza o postojanju likvidnog ograničenja poslovnih subjekata u RH.
- Ispitano je postojanje heterogenosti u stupnju financijskog i likvidnog ograničenja s obzirom na podrijetlo kapitala i oblik vlasništva.
- Istražen je utjecaj Zakona o financijskom poslovanju i predstečajnoj nagodbi na investicije i zaposlenost poslovnih subjekata.
- Objašnjenja je heterogenost dinamike investicija na gotovo sva poduzeća u RH prije i poslije financijske krize.

U nastavku se donose nalazi provedenog istraživanja te se detaljnije obrazlaže znanstveni doprinos rada.

7.1 Investicijski tokovi u Republici Hrvatskoj i Europskoj uniji

Investicijske tokove, kao komponentu poslovnog ciklusa, obilježava snažna procikličnost i visoka volatilnost. Investicije su u prosjeku od dva do tri puta volatilnije od BDP-a, kako u razvijenim, tako i u nerazvijenim zemljama. Investicije također obilježava tipičan „boom-bust“ okvir ponašanja, kako u Europskoj uniji, tako i u ostalim razvijenim zemljama od 1995. do 2015. Investicije su snažno rasle u svim zemljama do Velike recesije. Nakon krize, ne samo da se nisu vratile na prijašnji *trend* rasta nego nisu imale ni pretkriznu *stopu* rasta. Izvještaj ECB-a (2013) navodi da je gubitak investicija u vrijeme kontrakcijske faze u EU iznosio 14%, pri čemu se gubitak investicija mjeri kao razlika stvarne razine investicija i razine investicija koja bi bila postignuta da je nastavljen pretkrizni trend. Slab oporavak investicija ključan je razlog manjih stopa rasta u razvijenim i nekim nerazvijenim zemljama. Važnost investicijske dinamike očituje se i u brojnim teorijskim razmatranjima o financijskoj krizi. Teorija sekularne stagnacije kao ključan problem identificira nedostatak investicijskih prilika, teorija nedostataka sigurne likvidne imovine ističe važnost rasta premije likvidnosti na investicije, a makroekonomske

teorije o financijskim frikcijama amplifikaciju i perzistentnost ekonomskih šokova objašnjavaju investicijskim kanalom financijskih frikcija. Neobjašnjivi šokovi investicija presudni su za objašnjenje poslovnih ciklusa, pa su one osnovni objekt utjecaja ekonomskih politika, kako fiskalnom politikom stimulansa, tako i kao dio transmisijskog mehanizma monetarne politike.

Snažna je heteregenost u stopama rasta investicija u Europskoj uniji. Komparativna analiza prostornih podataka o stopama rasta bruto kapitalne formacije za zemlje članice EU pokazuju da je Hrvatska, poslije Grčke, Cipra i Slovenije od 2008. do 2015. imala najveći pad bruto investicija. Najrazvijenije članice EU posve su se oporavile od investicijskog šoka, a neke poput Velike Britanije, Poljske i skandinavskih zemalja već ostvaruju pozitivne stope rasta bruto investicija u odnosu prema onima iz 2008 godine. Očigledno je da dinamika investicija nije samo rezultat međunarodnih šokova, već ponajprije posljedica karakteristika domaćih ekonomskih tokova.

Stilizirane činjenice investicijske dinamike kroz poslovni ciklus prepoznate su i u Hrvatskoj. Investicije nefinancijskih poduzeća u RH rasle su s 23 milijarde kuna 2001. godine na 69 milijardi kuna 2007. godine što je prosječan složeni godišnji rast od 20%. Nakon financijske krize, vrijednost investicija stalno opada te 2014. godine iznosi 25 milijardi kuna, što je, prema 2007. godinu, 62,88% manje. Dok su osobna i državna potrošnja, kao omjer BDP-a, relativno stabilne u cijelome razdoblju, investicije pokazuju veliku volatilnost. Od 2000. do 2008. godine rasle su s 18% na čak 30% BDP-a, a u samo jednoj godini pale su na 24% BDP-a. Pad je nastavljen i nakon Velike recesije, pa su se 2014. godine vratile na razine BDP-a na kojima su bile 2000. godine. Riječ je o velikim fluktuacijama investicija. Stoga je za ekonomsku (financijsku) krizu u Hrvatskoj najvažnije objašnjavanje šokova investicija.

Agregatna investicijska dinamika ne otkriva složenu heterogenost investicija poduzeća u RH prema različitim kriterijima. Investicijsku dinamiku obilježava visoka koncentriranost. Udio investicija pet najvećih investitora iznosi čak 20%, pri čemu se stupanj koncentriranosti stalno smanjuje nakon financijske krize. Najveću investicijsku aktivnosti (10% svih investicija) zabilježila su dva javna poduzeća koja su ulagala u prometnu infrastrukturu (poduzeća Hrvatske autoceste d.o.o. i Autocesta Zagreb–Rijeka d.o.o.). Prema strukturi industrije, najveća su ulaganja bila u trgovini, prerađivačkoj industriji i građevinarstvu, pri čemu građevinarstvo obilježava najveća cikličnost. Velika poduzeća ulažu najviše (50%), iako u udjelu tvrtki čine samo 0,3%. Gotovo cjelokupan rast investicija u pretkriznom razdoblju bio je usmjeren u građevinske objekte, nekretnine i zemljišta. Ulaganje u pogone i opremu, s druge strane, ima

manje-više stabilan apsolutni iznos u promatranu razdoblju. Tijekom cijelog razdoblja privatne su investicije bile veće od javnih. Međutim, udio je javnih u ukupnim investicijama u prosjeku veći od 15%, što potvrđuje velik utjecaj javnih poduzeća i fiskalne politike koja djeluje kroz kanal javnih poduzeća, na ukupne investicije. Iako većinu investicija čine poduzeća s domaćim kapitalom, postoji trend rasta udjela investicija poduzeća sa stranim kapitalom.

7.2 Odrednice investicija s naglaskom na investicijski kanal financijskih frikcija

Ponašanje investicija oduvijek je bilo predmet ekonomske teorije. U Keynseovoj teoriji, ulaganje u kapitalnu imovinu određeno je graničnom efikasnosti kapitala. Stopa investicija rast će do točke na kojoj je granična efikasnost kapitala jednaka tržišnoj kamatnoj stopi. Ovakvu formulaciju preuzela je neoklasična teorija investicija, prema kojoj tvrtke unajmljuju kapital i rad sve dok se granični proizvodi ne izjednače s relativnim cijenama. Zbog očitih nedostataka neoklasične teorije investicija (trenutačno prilagođavanje), u teorijske su se modele počeli uključivati razni oblici frikcija, od kojih su najzastupljenije dvije. Prva je uključivanje troškova prilagođavanja investicija (q teorija investicija): sve informacije nužne za donošenje odluke o investicijama dane su u varijabli q. Drugo je uključivanje neizvjesnosti, koje se najčešće analizira kao problem vrednovanja američkih „call“ opcija. Međutim, empirijska procjena investicijske jednadžbe na panel-podacima tvrtki pokazivala je vrlo malu osjetljivost investicija na Tobinov q, ali veliku osjetljivost na novčane tokove.

Teorija visokoj osjetljivosti investicija na novčane tokove pripisuje dva objašnjenja. Prema prvom objašnjenju, osjetljivost je posljedica ponašanja menadžmenta, koji preferira loše investicije u stanjima s viškom likvidnosti jer im omogućuju uživanje privatne koristi (oblik troškova agenata). Prema drugom objašnjenju, visoka je osjetljivost rezultat nesvršenosti na financijskim tržištima zbog postojanja asimetričnosti informacija između kreditora i dužnika (poduzeća). Drugi je razlog detaljno objašnjen u ovom radu unutar modela investicija koji pretpostavljaju nesavršena tržišta kapitala. Za razliku od q teorije investicija, koja pretpostavlja postojanje Modigliani-Millerova svijeta, u kojem ne postoje asimetričnosti na tržištu kapitala (između ostalih pretpostavki), unutar teorije ugovora i korporativnih financija od 70-ih godina prošlog stoljeća počele su se otpuštati pretpostavke o savršenim tržištima kapitala te se posebno razvila teorija financijskog ugovaranja. U ovom je radu prikazana jedna mogućnost teorijskog

objašnjenja financijskog ugovaranja, prema kojoj poduzetnik ne može založiti sav dohodak projekta, što može uzrokovati fenomen racioniranja kredita.

Jedan od doprinosa rada razgraničavanje je financijskog i likvidnog ograničenja. Likvidno ograničenje određeno je nedostatkom likvidnih sredstava za prevladavanje kratkoročnih likvidnih šokova. Pri likvidnim ograničenjima novi novčani tokovi ne pridonose rastu investicija. Novčani tok ne utječe na investicije ni pri prevelikoj likvidnosti poduzeća. Drugim riječima, odnos je investicija i novčanih tokova nelinearan. Financijsko ograničenje, s druge strane, obilježava stanje kreditne nesposobnosti poslovnog subjekta, odnosno nemogućnost prikupljanja eksternih sredstava. Empirijska je analiza pokazala da stanje likvidnosti bolje objašnjava heterogenost u osjetljivosti investicija na novčane tokove od pokazatelja koji se uobičajeno upotrebljavaju za aproksimiranje stupnja financijskog ograničenja.

Empirijski dio rada pokazao je visoku osjetljivost investicija nefinancijskih poduzeća u RH na tekuće novčane tokove u svim specifikacijama investicijske jednadžbe. Koeficijent uz pomaknute novčane tokove varira ovisno o potražnim varijablama. Pri tome se kao potražna varijabla, prema autorovim spoznajama, prvi put upotrijebila nova dodana vrijednost. Nova dodana vrijednost bolje objašnjava promjene investicija od stope rasta prihoda, a vremenski pomaknuta vrijednost investicija u dinamičkome modelu investicija manje je važna nego u drugim istraživanjima.

Utvrđena je heterogenost u osjetljivosti investicija na novčane tokove za različite skupine poduzeća. Prezadužena poduzeća pokazuju nultu povezanost novčanih tokova i investicija što je u suprotnosti s nekim postojećim istraživanjima. Mala poduzeća pokazuju veću osjetljivost od velikih. S obzirom na pokriće troškova kamata, raste osjetljivost investicija na novčane tokove. Heterogenost s obzirom na likvidnost pokazuje konzistentno nelinearnu vezu likvidnosti i investicija. U radu je dodatno istražena heterogenost financijskog i likvidnog ograničenja s obzirom na oblik vlasništva i podrijetlo kapitala te je zaključeno da javna poduzeća i poduzeća s inozemnim podrijetlom kapitala pokazuju značajke mekog budžetskog ograničenja.

7.3 Razmatranje utjecaja financijskog ograničenja na investicije tvrtki u Republici Hrvatskoj

Tablica 7-1 daje pregled postavljenih istraživačkih hipoteza ove disertacije i rezultate njihova testiranja. Prva hipoteza (H1) rada pretpostavljala je ekonomski signifikantan utjecaj financijskog ograničenja na investicijsku dinamiku tvrtki u Republici Hrvatskoj, što bi trebalo biti dokaz postojanja nesavršenosti na financijskim tržištima. Navedena hipoteza izravno proizlazi iz empirijskih radova koji su istaknuli važnost financijskih faktora na investicije i iz teorije o racioniranju kredita, koja opisuje i objašnjava važnost ponude kapitala na investicije poduzeća. Rezultati analize u 5. poglavlju opovrgnuli su ovu hipotezu.

Hipoteza o postojanju financijskog ograničenja testirala se osjetljivošću investicija na novčane tokove prema poznatom i u literaturi često upotrijebljenom empirijskom dizajnu Fazzarija i dr. (1988). Prema hipotezi o postojanu financijskog ograničenja, koeficijent uz novčane tokove u investicijskoj jednadžbi trebao bi biti monotono rastuća funkcija asimetričnosti informacija. Ekonometrijska je procjena pokazala nemonoton rast koeficijenta. Najzaduženija skupina poduzeća pokazuje najmanju osjetljivost investicija na novčane tokove, a prema hipotezi bi trebala imati najveću osjetljivost. Pri tome se koristilo gotovo svim poduzećima u Republici Hrvatskoj, nelinearnom ekonometrijskom metodom (panel-*threshold* regresija) i novom varijablom za kontroliranje agregatne potražnje – nova dodana vrijednost, što u kombinaciji daje doprinos s obzirom na druge radove. Posebno treba istaknuti dodavanje nove dodane vrijednosti u investicijsku jednadžbu jer se pokazalo da u brojnim specifikacijama, nakon njezina uvrštavanja, pomaknuti novčani tokovi imaju vrlo malen ili čak negativan utjecaj na investicije.

Dva su glavna prigovora upotrebi potonjeg empirijskog dizajna u mjerenju financijskog ograničenja: problem endogenosti (novčani tokovi kontroliraju za investicijske prilike) i problem apriorne klasifikacije tvrtki (razni kriteriji razgraničavanja poduzeća ne odražavaju financijsko ograničenje). Međutim, ovi prigovori ne utječu na rezultate istraživanja jer kritika pokušava objasniti visoku osjetljivost investicija na novčane tokove za zaduženu skupinu poduzeća; dakle, fenomen koji u analizi uopće nije identificiran. Novčani tokovi ne utječu na investicije visoko zaduženih tvrtki. Kada se kao *threshold* varijabla upotrijebi veličina poduzeća, osjetljivost je investicija na novčane tokove monotno rastuća, što je upravo suprotno postavljenoj hipotezi, koja pretpostavlja da velika poduzeća imaju manji stupanj ograničenja (manju osjetljivost investicija na novčane tokove).

Tablica 7-1: Pregled postavljenih istraživačkih hipoteza i rezultati njihova istraživanja.

Hipoteza	**Testiranje hipoteze**
H1: Dinamika investicijske aktivnosti poslovnih subjekata u Republici Hrvatskoj ukazuje na postojanje financijskog ograničenja što potvrđuje postojanje tržišnih nesavršenost (frikcija) na tržištima kapitala	Nije potvrđena
H2: Kretanje investicija poslovnih subjekata u Republici Hrvatskoj sadržajno je heterogeno u smislu tržišnih nesavršenosti (frikcija) proizašlih iz likvidnog i financijskog ograničenja kao čimbenika investicijske aktivnosti.	Potvrđena
H3. Postojanje heterogenosti u stupnju financijskog i likvidnog ograničenja poslovnih subjekata u Republici Hrvatskoj uvjetovano je i udjelom javnog vlasništva i inozemnog kapitala u poslovnim subjektima u RH.	Potvrđena
H4: Oprost i prolongacija dugova uslijed uspješno sklopljene predstečajne nagodbe nema utjecaj na ublažavanje posljedica tržišnih nesavršenosti (frikcija), odnosno na relativno povećanje investicijske aktivnosti poslovnih subjekata uključenih u predstečajne nagodbe.	Potvrđena

Buduća istraživanja o utjecaju financijskih frikcija na investicije najveći doprinos mogu pružiti u dijelu empirijskog dizajna. Najizravniji pristup mjerenja financijskog ograničenja uključivao bi korištenje podacima o odnosima tvrtki i banaka, što omogućuje izravnu procjenu stupnja financijskog ograničenja. S aspekta metodologije, nove bi se spoznaje dobile korištenjem panel-*threshold* regresijom na nebalansiranu panelu podataka ili korištenjem *threshold* regresijom s dvjema ili više *threshold* varijabli.

7.4 Utjecaj politike upravljanja novčanim sredstvima na investicije poduzeća

U uvjetima savršenih tržišta kapitala za tvrtku je optimalno držati nulte razine likvidnih sredstava jer ne postoji rizik konverzije kratkotrajne imovine u novac. Čak i kada bi postojala potreba za kratkotrajnom likvidnošću, tvrtka bi je mogla osigurati uz pretpostavku pozitivne neto sadašnje vrijednosti projekta. U uvjetima racioniranja kredita i likvidnih šokova poduzeća mogu stvarati potražnju za likvidnim sredstvima (novčanim sredstvima, bankovnim linijama ili

derivativima). Osiguranje likvidnosti *ex ante* može utjecati na razinu realnih investicija u budućnosti. Jedan od doprinosa ovog rada uvažavanje je stanja likvidnosti i politike upravljanja novčanim sredstvima na realne investicije poduzeća. Poduzeća mogu biti u stanju likvidnog ograničenja, odnosno nemogućnosti nastavka postojećih i poduzimanja novih projekata zbog nelikvidnosti.

Druga hipoteza doktorske disertacije pretpostavlja da se poduzeća s likvidnim ograničenjem ne koriste dodatnim novčanim tokom za investicije nego za uspostavljanje optimalne likvidnosti. Granična poduzeća osjetljiva su na novčani tok, posebno ako su financijski ograničena. Poduzeća s visokom likvidnosti najčešće imaju i visoku kreditnu sposobnost, pa im odluke o realnim investicijama ne ovise o novčanim tokovima. Drugim riječima, veza između investicija i likvidnosti nelinearna je. Druga je hipoteza potvrđena. Korištenje različitim mjerama likvidnosti, različitim ekonometrijskim metodama i uzorcima poduzeća potvrđuje nelinearnost u odnosima investicija i likvidnosti.

Ovakvi su rezultati važni implikacije za ekonomsku teoriju i za ekonomsku politiku. U teorijskom smislu potvrđuje se važnost heterogenosti poduzeća s obzirom na stanje likvidnosti. Razumijevanje financijskih frikcija i međuodnosa investicija i neto vrijednosti nije potpuno bez uvažavanja stanja likvidnosti. Modeli bi stoga trebali sadržavati i stanje likvidnosti kao varijablu stanja u dinamičkim modelima opće ravnoteže ili parcijalne ravnoteže u izučavanju tvrtki.

Treća hipoteza doktorskog rada pretpostavlja odsutnost financijskog i likvidnog ograničenja za javna poduzeća i poduzeća s većinskim inozemnim podrijetlom kapitala. Prema teoriji mekog proračunskog ograničenja, tvrtke u javnom vlasništvu mogu dobiti financiranje u slučajevima u kojima financiranje nije efikasno *ex ante*. Poduzeća sa stranim podrijetlom kapitala imaju lakši pristup financiranju zbog lakšeg pristupa inozemnom tržištu, boljeg imidža i mogućeg financiranja od društva majki. Za izrazito mali broj opservacija prepoznata je heterogenost s obzirom na stupanj likvidnost (kada se kao *threshold* varijable upotrebljavaju stopa likvidnosti i neto radni kapital), ali je broj poduzeća u jednom režimu bio zanemariv, a procijenjeni koeficijenti uz novčane tokove vrlo slični. Treća je hipoteza dakle potvrđena: javna poduzeća i poduzeća sa stranim podrijetlom kapitala ne pokazuju znakove financijskog/likvidnog ograničenja.

7.5 Učinak predstečajnih nagodbi kao egzogenog instrumenta na financijsku situaciju

Pozitivna veza novčanog toka i investicija može biti rezultat pogreške u mjerenju q-a, odnosno nedostatka investicijskih prilika u investicijskoj jednadžbi. Prevladavanje ovog problema zahtijeva primjenu metode (kvazi)prirodnih eksperimenta, koji impliciraju procjenu učinka primjene egzogenog tretmana na varijablu ishoda. U šestom se poglavlju kao tretman upotrijebio Zakon o financijskom poslovanju i predstečajnoj nagodbi, a metoda je bio *difference-in-differences matching* procjenitelj, kako bi se testirao utjecaj Zakona, koji je omogućio oprost i odgodu dugova dužnika, na investicije i zaposlenost.

Rezultati su u skladu s četvrtom istraživačkom hipotezom. Poduzeća koja su uspješno sklopila predstečajnu nagodbu nisu investirala više od sličnih poduzeća koja je nisu sklopila. Ako poduzeća imaju sličnu stopu novčanog toka, dodane nove vrijednosti, novčanih sredstava, iste su veličine te pripadaju istoj djelatnosti, monotono rastuća osjetljivost investicija na novčane tokove implicirala bi da oprost dugova i/ili povećanje neto radnoga kapitala povećavaju investicije u tretmanskoj skupini u odnosu prema kontrolnoj skupini. Međutim, nelinearan odnos između stanja likvidnosti i investicija implicira drukčiji rezultat. Potražni faktori i novčani tok postaju bitni tek nakon uspostavljanja primjerene likvidnosti i stvaranja dopuštene razine neto radnoga kapitala (novca) za novčane pričuve. Poduzeća su prije sklapanja predstečajne nagodbe pripadala skupini financijski i likvidno ograničenih. Poslije sklapanja nagodbe iskusila su poboljšanje financijske situacije, ali ne dovoljno da bi pokrenula veći investicijski ciklus u odnosu prema sličnim poduzećima. Ukratko, ne postoji uzročan odnos između oprosta i odgode dugova i veće investicijske aktivnosti poduzeća. Može se zaključiti da predstečajne nagodbe nisu pridonijele relativnu rastu zaposlenosti. Drugim riječima, Zakon nije ispunio cilj koji je bio postavljen. Poduzeća nisu povećala investicije, a zaposlenih je manje ako se njihov broj usporedi s onim u sličnim poduzećima.

Često se kao jedan od glavnih problema hrvatskoga gospodarstva ističe visoka nelikvidnost se te predlažu mjere nadilaženja ovog problema. Jedna od njih bio je upravo analizirani zakon o predstečajnoj nagodbi. Rezultati istraživanja pokazuju da oprost i odgoda dugova ne pridonose rastu investicija i zaposlenosti ako se učinci usporede s onima u sličnim poduzećima ili s prosjekom svih ostalih poduzeća. Može se pretpostaviti da bi ova skupina poduzeća povećala investicije pri još intenzivnijem stupnju oprosta i/ili rasta agregatne potražnje i novčanih tokova poduzeća. Također, ekonomska bi politika trebala voditi računa o nelikvidnosti i o pretjeranoj likvidnosti u vrijeme uzlaznih faza ekonomskog ciklusa. Posebno se to odnosi na snažan rast

izvanjske likvidnosti (engl. *outside liquidity*) potaknute stranim portfeljnim ulaganjima i inozemnim kreditiranjem.

POPIS LITERATURE

1. Abadie, A. & Imbens, G. (2002) *Simple and bias-corrected matching estimators for Average Treatment Effects*. NBER Technical Working Paper (283).
2. Abadie, A.,Drukker, D., Herr, J. & Imbens, G. (2004) Implementing Matching Estimators for for average treatment effects in Stata. *The Stata Journal*, 4(3), str. 290-311.
3. Abaoub, E. & Marouene, F. (2013) Investment cash-flow sensitivity under Financial Constraints Case of Tunisia. *International Journal of Business and Management*, 8(9), str. 14-23.
4. Abel, A. B. & Blanchard, O. J. (1986) The present valueof profits and cyclical movements in investment. *Econometrica*, 54, str. 249-273.
5. Abel, A. B. & Eberly, J. C. (1994) A unified model of investment under uncertaint. *American Economic Review*, 84, str. 1369–1384.
6. Adler, D (2014) *The new Economics of Liquidity and Financial Frictions*. CFA Institute Research Foundation Working Paper (3).
7. Adrian, T. & Colla, P., Shin, H. S. (2012) Which financial fricition? Paesing the evidence from the financial crisis of 2007-09, NBER Macroeconomics Annual 2012, 27.
8. Adrian, T. & Shin, H. S. (2013) *Procyclical leverage and value-at-risk*. NBER working paper 18943. Dostupno na: http://www.nber.org/papers/w18943.pdf
9. Almeida, H. et al. (2012) Corporate Debt Maturity and the Real Effects of the 2007 Credit Crisis. *Critical Finance Review*, 1, str. 3-58.
10. Alti, A. (2003) How sensitive is investment to cash flow when financing is frictionless. *Journal of Finance*, 58(2), str. 707-722.
11. Ameer, R. (2011) *Financial constraint and the Firm-level Investment in Asia: Dynamic Panel Smooth Thrteshold regression Approach*. Social Science Research Network Working Paper. Dostupno na: http://ssrn.com/abstract=2012071
12. Amleida et al. (2014) Corporate Liquidity Management: A Conteptual Framework and Survey. Annual Review of Financial Economics. 6, str. 135-62
13. Angirst, J. D. & Pischke, J.-S. (2009) *Mostly Harmless Econometrics:An Empiricist's Companion*. Princeton University Press
14. Arčabić, V., Tica, J., Lee., S., Sonora, R. J. (2018) Public debt and economic growth conundrum: nonlinearity and inter-temporal relationship. *Studies in nonlinear dynamics and econometrics*, 22(1), str. 1558-3708.
15. Bakke, T. E., Jens C. E. & Whited, T. M. (2012) The Real Effects of Delisting: Evidence from a Regression Discontinuity Design. *Finance Research Letters*, 9(4), str. 183-193.

16. Bank for international Settlements (2011) *The transmission channels between the financial and real sectors: a critical survey of the literature*, BCBS Working Papers (18). Dostupno na: http://www.bis.org/publ/bcbs_wp18.htm
17. Bates, T. W., Kahle K.M. & Stulz R. (2009) Why do U.S. firms hold so much more cash than they used to?. *Journal of Finance 64*, str. 1985-2021.
18. Baum, C. F. (2006) *An Introduction to Modern Econometrics Using Stata*. Texas: Stata Press.
19. Baum, C., Schäfer, D. & Talavera, O. (2009) The impact of the financial system's structure on firm's financial constraints. *Journal of International Money and Finance*, 30(4), str. 678–691.
20. Becker, S. O. & Ichino A. (2002) Estimation of average treatment effects based on propensitiy scores. *The Stata Journal*, Volume 2(4), str. 358-377.
21. Benmelech, E. et al. (2005) Do liquidation values affect financial contracts? Evidence from commercial loan contracts an,d zoning regulation. *The Quarterly Journal of Economics*, 120(3), str. 1121-1154.
22. Bernanke, B. S. & Gertler, M. (1989) Agency Costs, NetWorth, and Business Fluctuations. *American Economic Review*, 79(1), str. 14-31.
23. Bernanke, B. S., Gertler, M. & Gilchrist, S. (1999) The Financial Accelerator in a Quantitative Business Cycle Framework. *Handbook of Macroeconomics*, 1st edition, Taylor & Woodford (Ed.), Elsevier.
24. Bernanke, B., Gertler & M., Gilchrist, S. (1996) The Financial Accelerator and the Flight to Quality. *The Review of Economics and Statistics*, 78(1), str. 1-15.
25. Bernard, S. (2005) *The Economics of Contracts*, Cambridge: The MIT press.
26. Bhattacharya, S. & Faure-Grimaud, A. (2001) The debt hangover: renegotiation with noncontratible investment. *Economics Letters,* 70, str. 413‑419.
27. Blanchard, O. J., Lopez-de Silanes, F. & Shleifer, A. (1994.) What do firms do with cash windfalls?. *Journal of Financial Economics*, 36(3), str. 337-360.
28. Bolton, P., Chen, H. & Wang, N. (2011) A Unified Theory of Tobin's Q, Corporate Investment, Financing, and Risk Management. *Journal of Finance*, 66(5), str. 1545-1578.
29. Bond, S. & Meghir, C. (1994) Financial Constrints and Company Investment. *Fiscal Studies*, 15(2), str. 1-18.
30. Bond, S., Klemm, A., Newton-Smith, R., Syed, M., & G. Vlieghe (2004) *The Roles of Expected Profitability, Tobin's Q and Cash Flow in Econometric Models of Company Investment*. Institute for Fiscal Studies, Working Paper, No. 04/12.
31. Brainard, W. C. & Tobin, J. (1968) Pitfals in Financial Mode-Building. *American Economic Review*, 58, str. 99-122.
32. Brown, M. & P. R. Lane (2011.) *Debt Overhang in Emerging Europe?*. World Bank Policy Research Working Paper (5784).

33. Bruinshoofd, A. & Kool, C. (2006) Non-linear target adjustment in corporate liquidity management: an endogenous thresholds approach. Working paper No 87. Dostupno na: https://www.dnb.nl/binaries/Working%20Paper%20No%2087-2006_tcm46-146744.pdf
34. Brunnermeier, M. (2009) Deciphering the 2007-2008 Liquidity and Credit Crunch. *Journal of Economic Perspectives*, 23(1), str. 77-100.
35. Brunnermeier, M. K. & Oehmke, M. (2013) Bubbles, Financial Crises, and Systemic Risk. *Handbook of the Economics of Finance*, 2, Part B, str. 1221–1288.
36. Brunnermeier, M. K., Eisenbach, T. M. & Sannikov, Y. (2012) *Macroeconomics with financial frictions: A survey,* NBER Working paper(18102).
37. Brunnermeier, M. K., Sannikov, Y. (2014) A Macroeconomic Model with a Financial Sector. *American Economic Review,* 104(2), str. 379-421.
38. Bushman, R.-M., Smith, A. J. & Zhang, X. F. (2012) *Investment Cash Flow Sensitivities Really Reflect Related Investment Decisions*. Working paper. Dostupno na: http://public.kenan-flagler.unc.edu/faculty/bushmanr/bsz_may_2012.pdf
39. Buti, M. (2014) *Lacklustre investment in the Eurozone: The policy response* [online]. VOX, CEPR's Policy Portal. Dostupno na: http://www.voxeu.org/article/lacklustre-investment-eurozone-policy-response
40. Buttiglione, L. et al. (2014) *Deleveraging? What deleveraging?*. Geneva: Geneva Reports on World Economy, International Center for Monetary and Banking Studies.
41. Caggese, A. (2007) Testing Financing Constraints on Firm Investment Using Variable Capital. *Journal of Financial Economics,* 86, str. 683-723.
42. Calomiris, C. W. & Hubbard, R. G. (1995) Internal Finance and Investment: Evidence from the Undistributed Profits Tax of 1936–37. *Journal of Business,* 68, str. 443−482.
43. Cameron, A. C. & Trivedi, P. K. (2009) *Microeconometrics using Stata*. Texas: Stata Press.
44. Campello, M. E. et al. (2011) Liquidity Management and Corporate Investment During a Financial Crisis. *Review of Financial Studies*, 24, str. 1944–1979.
45. Carlstrom, C. T. & Fuerst, T. S. (1997) Agency Costs, Net Worth, and Business Fluctuations: A Computable General Equilibrium Analysis. *American Economic Review*, 87(5), str. 893-910.
46. Carpenter, R. & Guariglia, A. (2007) Investment behavior, observable expectations, and internal funds: a comment on Cummins et al. (AER, 2006). *Economics Bulletin*, 5(12), str. 1-12.
47. Carrascal, C. & Ferrando, A. (2008) *The Impact of financial position on investment: An analysis for non-financial corporations in Euro-area*, ECB Working Papers, ECB(943).
48. Carreira, C. & Silva, F. (2012) *Measuring firms financial constraints: A rough guide.* Notas Económicas, No 36, str. 23-46.

49. Chaney, T., Sraer, D. & Thesmar, D. (2010) *The collateral channel: How real estate shocks affect corporate investment*. NBER Working Papers(16060).
50. Chodorow-Reich, G. (2014) The Employment Effects of Credit Market Disruptions: Firm-level Evidence from the 2008–9 Financial Crisis. *The Quarterly Journal of Economics*, 129(1), str. 1-59.
51. Ciccarelli, M., Maddaloni, A. & Peydro, J. (2010) *Trusting to bankers. A New Look at the Credit Channel of Monetary Policy*. ECB Working Papers (1228).
52. Cleary, S. (1999) The Relationship between Firm Investment and Financial Status. *The Journal of Finance*, 54(2), str 673-692 .
53. Cleary, S., Povel, P.E. & Raith, M. (2007.) The U-shaped investment curve: Theory and evidence. *Journal of Financial and Quantitative Analysis*, 42(1), str. 1-39.
54. Cooley, T. R., Marimon & Quadrini, V. (2004) Aggregate Consequences of Limited Contract Enforceability. *Journal of Political Economy*, 112(4), str. 817-847.
55. Cummis, J., Hassett, K. & Oliner, S. (1999) *Investment Behavior, Observable Expectations, and Internal Funds*. Working paper. Dostupno na: https://www.federalreserve.gov/pubs/feds/1999/199927/199927pap.pdf
56. Čeh, A. M., Dumičić, M. & Krznar, I. (2011) *Model neravnoteže na tržištu kredita i razdoblje kreditnog loma*. Hrvatska nardona banka, Istraživanja I-30. Dostupno na: http://hnbnetra.hnb.hr/publikac/istrazivanja/i-030.pdf
57. Decamp, J.-P. & Villeneuve, S. (2013) Optimal Investment under liquidity constraints. *Real Options, Ambiguity, Risk and Insurance*, Bensoussan, Peng, & Sung (Ed.).
58. Ding, A., Guariglia, A. & Knight, J. (2010) *Negative investment in China: financing constraints and restructing versus growth*. University of Oxford, Economics Series Working Papers(519).
59. Ding, A., Guariglia, A. & Knight, J. (2011) *Investment and Financing Constraints in China: does working capital management make a difference*, University of Oxford, Department of Economics, Economics Series Working Papers(521).
60. Dixit, A. & R. Pindyck (1994) *Investment Under Uncertainty*. Princeton. NJ: Princeton University Press.
61. Drehmann, M. & Tsatsaronis, K. (2014) *The credit-to-GDP gap and countercyclical capital buffers: questions and answers*. Bank for international statement. Dostupno na: http://www.bis.org/publ/qtrpdf/r_qt1403g.htm
62. ECB (2013) Corporate Finance and Economic Activity in the Euro Area. *Structural issues Report*, Arthur et al. (Ed.).
63. ECB (2015) *Economic Bulletin, issue 7/2015*. Dostupno na: www.ecb.europa.eu
64. Edwards, J. & Fischer, L. (1994) *Banks, finance and investment in Germany*. University of Cambridge : Cambridge University Press.

65. Eklund, J. E. (2013) *Theories of investment: A theoretical Review with Empirical Applications*. Working paper from Swedish Entrepreneurship Forum, 22.
66. Erickson, T, Whited, T. M. (2000) Measurement Error and the Relationship between Investment and q. *Journal of Political Economy*, 108(5), str. 1027-1057.
67. Farrant, K. & Rutkowska, M. (2015) *Are firms ever going to empty their war chests?*.Bank Underground. Dostupno na: https://bankunderground.co.uk/2015/07/24/are-firms-ever-going-to-empty-their-war-chests/
68. Farre-Mensa, J. & Ljungqvist, A. (2013) *Do Measures of Financial Constraints Measure Financial Constraints?*. NBER Working Paper (19551). Dostupno na: http://www.nber.org/papers/w19551
69. Fazzari, S. et al. (2000) Investment- Cash Flow Sensitivities Are Useful: A Comment on Kaplan and Zingales. *Quarterly Journal of Economics*, 115, str. 695–705.
70. Fazzari, S. M. & Petersen, B. C. (1993) Working capital and fixed investment: New evidence on financing constraints. *RAND Journal of Economics*, 24(3), str. 328–342.
71. Fazzari, S., Hubbard, G. & Petersen, B. C. (1988) Financing Constraints and Corporate Investment. *Brookings Papers on Economic Activity*, 1, str. 141-206.
72. Financijska agencija (2015) *Pregled zbirnih podataka iz sustava predstečajnih nagodbi za razdoblje od 1.10.2012. do 18.12.2015. godine*. Dostupno na: http://www.fina.hr/Default.aspx
73. Fisher, I. (1933) The Debt-Deflation Theory of Great Depressions. *Econometrica*, 1(4), str. 337-357.
74. Gala, V. D. & Gomes, J. F. (2013) *Beyond Q: Investment without Asset Prices*. AFA, San Diego Meetings Paper.
75. Gale, D. & Hellwig, M. (1985*)* Incentive-Compatible Debt Contracts: The One-Period Problem. *Review of Economic Studies*, 52(4). Str. 647-663.
76. Geanakoplos, J. (1997) *Promises Promises*. Cowles Foundation Paper(1057).
77. George, R., Kabir, R. & Qian, J. (2011) Investment–cash flow sensitivity and financing constraints: New evidence from Indian business group firms. *Journal of Multinational Financial Management*, 21(2), str. 69-88.
78. Gertler, M. & Gilchrist, S. (1994) Monetary Policy, Business Cycles, and the Behavior of Small Manufacturing Firms. *Quarterly Journal of Economics*, 109, str. 309–340.
79. Gilchrist, S & Himmelberg, C. P. (1995) Evidence on the role of cash flow for investment. *Journal of Monetary Economics*, 36(3), str. 541-572.
80. Gilchrist, S & Sim, J.W. (2007) *Investment during the Korean Financial Crises: A Structural Econometric analysis*. NBER Working Paper(13315).
81. Giroud, X. & Mueller, H. M. (2015) *Firm leverage and unemployment during the great recession*. NBER Working Paper (21076). Dostupno na: http://www.nber.org/papers/w21076
82. Gomes, J. F. (2001) Financing Investment. *American Economic Review*, 91(5), str. 1263-1285.

83. Goretti, M. & Souto, M. (2015) *Macro-Financial Implications of Corporate (De)Leveraging in the Euro Area Periphery.* IMF Working Papers (13/154). Dostupno na: https://www.imf.org/external/pubs/ft/wp/2013/wp13154.pdf
84. Gould, J. P. (1968) Adjustment Costs in the Theory of Investment of the Firm. *Review of Economic Studies*, 35(1), str. 47-55.
85. Grullon, G., Hund, J. & Weston, J. P. (2017) *Concetrating on Q and Cash Flow*. Dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2910114
86. Guariglia, A. (2007) *Internal Financial Constraints, External Financial Constraints, and Investment Choice: Evidence from a Panel of UK Firms.* CFMC Workin Paper (07/03).
87. Guariglia, A. Tsoukalas, J. & Tsoukas, S (2012) Investment, irreversibility, and financing constraints: Evidence from a panel of transition economies. *Economics Letters*, 117, str. 582–584.
88. Guus, S. (2014) *The influence of financial constraints on the investment-cash flow sensitivity in Dutch SMEs.* Master thesis. University of Twente. Dostupno na: http://essay.utwente.nl/64723/1/Scheuten_MA_Management%26governance.pdf
89. Han, S., Qui, J. (2007) Corporate precautionary cash holdings. *Journal of Corporate Finance*, 13, str. 43-57.
90. Hansen, B. E. (1999) Sample splitting and threshold estimation. *Econometrica*, 68(3), str. 575-603.
91. Hansen, B. E. (1999) Threshold effects in non-dynamic panels:Estimation, testing and inference. *Journal of Econometrics*, 93, str. 345–368.
92. Hart, O. (2001) Financial Contacting. *Journal of Economics Literature*, 39, str. 1079-1100.
93. Hayashi, F. (1982) Tobin's Marginal q and Average q: A Neoclassical Interpretation. *Econometrica*, 50, str. 213–224.
94. Heathcote, J., Storesletten, K. & Violante G. L., (2009) Quantitative Macroeconomics with Heterogeneous Households. *Annual Review of Economics*, 1(1), str. 319-354.
95. Hennessy, C. A (2004) Tobins's Q. Debt Overhang, and Investment. *The Journal of Finance*. 59(4), str. 1717-1742.
96. Himmelberg, C. P. & Petersen, B. C. (1994) R&d and internal finance: A panel study of smallfirms in high-tech industries. *The Review of Economics and StatisticsI,* 76(1), str. 38–51.
97. HNB (2018) *Standardni prezentacijski format,* dostupno na: https://www.hnb.hr/-/spf
98. HNB. (2016) *Financijska stabilnost*. Broj 17. Zagreb: Hrvatska narodna banka.
99. Holmstrom, B. & Tirole, J. (1997) Financial Intermediation, Loanable Funds, and the Real Sector. *The Quarterly Journal of Economics*, 112(3), str. 663-691.
100. Holmstrom, B. & Tirole, J. (2011) *Inside and Outside Liquidity*. Paris: MIT Press.
101. Hoshi, T., Kashyap, A. K. & Scharfstein, D. (1991) Corporate structure, liquidity, and investment: Evidence from japanese panel data. *Quarterly Journal of Economics.* 106, str. 33–66.

102. Hovakimian, G. & Titman, S. (2006) Corporate Investment with Financial Constraints: Sensitivity of Investment to Funds from Voluntary Assets Sales. *Journal of Money, Credit and Banking,* 38(2), 357-374.

103. Hrvatski sabor (2013) *Prijedlog zakona o izmjenama i dopunama Zakona o financijskom poslovanju ipredstečajnoj nagodbi, s Konačnim prijedlogom zakona*, Zagreb.

104. Hsiao, C. & Tahmiscioglu, A. K. (2014) A Panel Analysis of Liquidity Constraints and Firm Investment. Journal of the American Statistical Association, 92(438).

105. Hsiao, C. (2014) *Analysis of panel data*. University of Cambridge: Cambridge University Press.

106. Hubbard, R. G. (1999) Capital Market Imperfections and Investment, *Journal of Economic Literature,* 36, str. 193-225.

107. Hubbard, R. G., Kashyap, A. K. & Whited, T. M. (1995) Internal Finance and Firm Investment. *Journal of Money, Credit and Banking*, 27(3), str. 683-701.

108. Imbens, G. (2004) Nonparametric estimation of average treatment effects under exogeneity. *Review of Ecnomics and Statistics*, 86, str. 4–29.

109. Jensen, M. C. (1976) Theory of the Firm: Managerial Behavior, Agency Costs and Ownership Structure. *Journal of Financial Economics*, 3(4), str. 305-360.

110. Jimenez, G., Ongena S., Peydro, J. & Saurina, J. (2010) *Credit Supply: Identifying Balance-sheet Channels with Loan Applications and Granted Loans*. European Central Bank Working paper, No 1779/2010. Dostupno na: https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp1179.pdf?32e821f5682335e585f20b85878144c8

111. Jorgenson, D. (1963) Capital Theory and invetment. *American Economic Review*, 53(2), str 247-259.

112. Jorgenson, D. (1967) The theory of investment behaviour. In: Determinants of Investment Behavior", Universities-National Bureau Conference Series, 18, Ed.: Ferber, R., Colombia University Press, New York.

113. Kahle, KM, Stulz, RM. 2013. Access to capital, investment, and the financial crisis. *J. Financ. Econ.* 110, str. 280–99.

114. Kaplan, S. N. & Luigi Zingales, L. (2000) *Investment cash-flow sensitivitiesare not valid measurees of fonancing constraints.* NBER Working Papers (7659).

115. Kaplan, S. N. & Zingales, L. (1997) Do investment-cash ow sensitivities provide useful measures of financing constraints. *The Quarterly Journal of Economics*, 112(1), str. 169-215.

116. Keen, S. (2012) *The Debtwatch Manifesto*. Steeve Keen Debtwatch website. Dostupno na: http://www.debtdeflation.com/blogs/manifesto/

117. Keynes, J.M. (1936) The General Theory of Employment, Interest and Money.

118. King, M. (1994) Debt Deflation: Theory and Evidence. *European Economic Review,* 38, str. 419–45.

119. Kiyotaki, N. & Moore, J. (1997) Credit Cycles. *Journal of Political Economy*, 105(2), str. 211-248.

120. Koo (2009) *The Holy Grail of Macroeconomics: Lessons from Japan s Great Recession*. Wiley: Revised edition.

121. Košćak, S., Vlajo M., B. (2014) *Predstečajne nagodbe: Promjenjeno samo 2 posto managementa* [online], banka.hr, dostupno na: http://www.banka.hr/komentari-i-analize/predstecajne-nagodbe-promijenjeno-samo-2-posto-managementa

122. Krugman, P. (2011) *Debt Is (Mostly) Money We Owe to Ourselves*, The New York Times Web site. Dostupno na: http://krugman.blogs.nytimes.com/2011/12/28/debt-is-mostly-money-we-owe-to-ourselves

123. Lahti, L., Huovari J., Kainu, M., Biecek, P. (2017) Retrieval and analysis of Eurostat open data with the eurostat package. R Journal, 9(1), str. 385-392. Version 3.3.1.3 Package URL: http://ropengov.github.io/eurostat Manuscript URL: https://journal.r-project.org/archive/2017/RJ-2017-019/index.html

124. Lamont, O. (1997) Cash Flow and Investment: Evidence from Internal Capital Markets. *Journal of Finance,* 52, str. 83–109.

125. Lemmon, M. & Roberts M. R. (2010) The Response of Corporate Financing and Investment to Changes in the Supply of Credit. *Journal of Financial and Quantitative Analysis*, 45, str. 555–587.

126. Lins, KV, Servaes, H & Tufano, P. 2010. What drives corporate liquidity? An international survey of cash holdings and lines of credit. *J. Financ. Econ.* 98, str. 160–76.

127. Lucas, R. E. (1967) Optimal Investment Policy and the Flexible Accelerator. *International Economic Journal*. 8(1), str 87-85.

128. Mayer, C. (1990) Financial systems, corporate finance, and economic development. *Asymmetric Information, CorporateFinance, and Investment*, Hubbard, G. (Ed.). NBER, University of Chicago Press.

129. McDonald, R. & Siegel, D. (1986) The Value of Waiting to Invest. *Quarterly Journal of Economics*, 101, str. 707 -728.

130. Mian, A. & Santos J. A. C. (2012) *Liquidity Risk Management Over The Credit Cycle*. Dostupno na: http://www.efa2012.org/papers/t2a3.pdf

131. Mian, A. & Sufi A. (2014) *House of debt: How They (and You) Caused the Great Recession, and How We Can Prevent It from Happening Again*. Chicago: The University of Chicago Press.

132. Mian, A. & Sufi, A. (2010) The great recession: Lessons from microeconomic dana. *American Economic Review: Papers & Proceedings*, 100, str. 1-10.

133. Mian, A., Sufi, A. & Verner, E. (2017*) How do credit supply shocks affect the real economy? Evidence from the United States in the 1980s*. Equitable Growth Working paper.

Dostupno na: http://equitablegrowth.org/working-papers/how-credit-supply-shocks-affect-the-economy/

134. Mizen, P. & Vermeulen, P. (2005) *Corporate Investment and Cash FlowSensitivity. What Drives the Relationship?*. European Central Bank Discussion Paper (485). Dostupno na: https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp485.pdf?f06f325373b62d0787bf392abdd70b9b
135. MMF (2015) *Private Investment: What's the hold up?*. Tecnical report, MMF.
136. Modigliani, F. & Miller, M. (1958) The Cost of Capital, Corporation Finance and the Theory of Investment. *American Economic Review*, 48(3), str. 261–297.
137. Moore, T. (2009) *Large Firms and Sodt Budget Constrints for Transition Economies*. Brunel University Working Paper No. 09-12. Dostupno na: https://www.brunel.ac.uk/__data/assets/pdf_file/0007/82096/0912.pdf
138. Mora, R. & Reggio, I. (2012) *dqd: A command for treatment effect estimation under alternative assumptions*. UC3M Working Papers (2340-5031).
139. Morkunaite K. & Huefner, F. (2014) *Business Investment in G7: Coming out of the Doldrums?*. IIF research note. Dostupno na: https://www.iif.com/publication/research-note/business-investment-g7-coming-out-doldrums
140. Moyen, N. (2002) *Investment-Cash Flow Sensitivities: Constrained Versus Unconstrained Firms*. AFA 2003 Washington, DC Meetings. Dostupno na:: http://ssrn.com/abstract=310599 or http://dx.doi.org/10.2139/ssrn.310599
141. Myers, S. (1977) Detemrinants of corporate borrowing. *Journal of Financial Economics*, 5(2), str. 147-175.
142. Myers, S. C. (2001) Capital Structure. *Journal of Economic Perspectives*, 15(2), str. 81-102.
143. Narodne novine (2015) *Zakon o financijskom poslovanju i predstečajnoj nagodbi*. Zagreb: Narodne novine d.d., 108/12, 144/12, 81/13, 112/13, 71/15, 78/15.
144. Nuno, G. & Thomas, C. (2013) *Bank leverage cyclese* [online]. VOX, CEPR's Policy Portal. Dostupno na: http://voxeu.org/article/bank-leverage-cycles
145. OECD (2001) *Measuring productivity: Measurement of aggregate and industry-level productivity growth*. OECD Manual.
146. Oliner, S. D. & Rudebusch, G. D. (1992) Sources of Financing Hierarchy for Business Investment. *The Review of Economics and Statistic*, 74(4) str. 643-654.
147. Orsag, S. (2002) *Budžetiranje kapitala*. Masmedia, Zagreb.
148. Pinkowitz, L.,Stulz, R. M. & Williamson, R. (2013) *Is there a U.S. high cash holdings puzzle after the financial crisis?*. Fisher College Fisher College of Business Working Paper

(2013-03-07), Dostupno na: http://ssrn.com/abstract=2253943 or http://dx.doi.org/10.2139/ssrn.2253943

149. Quadrini, V. (2011) *Financial frictions in macroeconomic fluctations*. Economic Quarterly 3Q, 3, str. 209-254.
150. Rajan, R, G. & Zingales, L. (1995) What Do We Know about Capital Structure? Some Evidence from International Dana. *The Journal of Finance*, 50(5), str. 1421-1460.
151. Rauh, J. D. (2006) Investment and _nancing constraints: Evidence from the funding of corporate pension plans. *The Journal of Finance*, 61(1), str. 33-71.
152. Reinhart, C. & Rogoff, K. (2008) Is the 2007 US Sub-Prime Financial Crisis So Different?: An International Historical Comparison. *American Economic Review*, 98(2), str. 339–44.
153. Reinhart, C. M. & Rogoff, K.S. (2011) *A Decade of Debt*. Cambridge: MIT Press.
154. Ricardo, B. et al. (2010): *A New Look into Credit Procyclicality: International Panel Evidence*. Central Bank of Argentina Working paper (2011/55).
155. Roberts, M. R & Whited, T. M. (2013) Endogeneity in Empirical Corporate Finance. U *Handbook of Economics of Finance*, 1st edition, Constantinides, Harris & Stulz (Ed.), Elsevier BV
156. Ross, S. A. (1977) The Determination of Financial Structure: The Incentive-Signalling Approach. *The Bell Journall of Economics*, 8(1), str. 23-40.
157. Salinger, M., Summers, L. H. (1983) Tax reform and corporate investment: A microeconometric simulation study. *Behavioral Simulation Methods in Tax Policy Analysis*, National Bureau of Economic Research Inc, str. 247-288.
158. Schularick, M., Taylor, A. M. (2011) Credit Booms Gone Bust: Monetary Policy, Leverage Cycles, and Financial Crises, 1870–2008. *American Economic Review*, 102(2), str. 1029–61.
159. Seo, M. H. & Shin, Y. (2014) *Dynamic Panels with Threshold Effect and Endogeneity*. Working papaer. Dostupno na: https://ideas.repec.org/p/cep/stiecm/577.html
160. Sharpe, A. & Suarez, G. A. (2013) *The Insensitivity of Investment to Interest Rates: Evidence from a Survey of CFO's*. FED Finance and Economics Discussion Series.
161. Shen, C.-H. & Wang, C.-A. (2007) The impact of cross-ownership on the reaction of corporate investment and financing constraints: A panel threshold model. *Applied Economics*, 37(20), str. 2315-2325.
162. Shin, H. & Park, Y.S. (1999) Financing constraints and internal capital markets: evidence from Korean 'chaebols'. *Journal of Corporate Finance*, 5, str. 169-191.

163. Solow, R. (1956) A Contribution to the Theory of Economic Growth. *The Quarterly Journal of Economics*, 70(1), str. 65-94.

164. StataCorp. (2013) *Stata 13 Base Reference Manual.* Texas: Stata Press.

165. StataCorp. (2015*) Stata Statistical Software: Release 13*, Texas: Stata Press.

166. Stein, J. C. (2003) Agency, information and corporate investment. Handbook of the Economics of Finance, Constantinides et al. (Ed.), Amsterdam: North Holand, str. 111-165.

167. Stiglitz, J. E. & Weiss, A. (1981) Credit Rationing in Markets with Imperfect Information. *American Economic Review*, 71(3), str. 393-410.

168. Stokey, N. (2009) *The Economic of Inaction*, Princeton University Press.

169. Strebulaev, I. A. & Whited T. M. (2012) Dynamic Models and Structural Estimation in Corporate Finance*. Foundations and Trends in Finance*, 6(1-2), str. 1-163.

170. Sufi, A. (2009) Bank lines of credit in corporate finance: an empirical analysis. *Rev. Financ. Stud*. 22, str. 1057–88.

171. Summers, L. (1981) Taxation and corporate Investment: A q theory approach. Brookings Papers on Economic Activity, 1, str. 67-127.

172. Šagovac, M. & Šikić, L. (2016) Estimation of the firm's balance sheet channel effects during the economic crisis: Case of Croatia. *Croatian Review of Economic, Business and Social Statistics*, 2(2).

173. Šonje, V. (2014) *Suočavaju li se dobra poduzeća u krizi s financijskim ograničenjima?*. HUB analize (50).

174. Tarassow, A. (2015) *Financial investment constraints. A Panel Threshold Application to German Firm Level Data*. DEP Discussion Papers.

175. Temouri, Y & Wagner J. (2013) Do outliers and unobserved heterogeneity explain the exporter productivity premium? Evidence from France, Germany and the United Kingdom. Working paper, No. 278. Dostupno na: https://ideas.repec.org/a/ebl/ecbull/eb-13-00437.html

176. Tintor, J. (2009) *Poslovna analiza*. Zagreb: Masmedia.

177. Tirole, J. (2006) *The Theory of Corporate Finance*. New Jersey: Princeton University Press.

178. Tirole, J. (2008) *Liquidity shortages: theoretical underpinnings*, Bance de France, Financial stability review – special issues on liquidity, 11. Dostupno na: https://www.banque-

france.fr/fileadmin/user_upload/banque_de_france/publications/Revue_de_la_stabilite_financiere/etud8_0208.pdf

179. Tirole, J. (2010) *Illiquidity and all its friends*. BIS working paper (303).

180. Townsend, R. (1979): Optimal contracts and competitive markets with costly state verification. *Journal of Economic Theory*, 21, str. 417–425.

181. Villa, J. M. (2012) *Simplifying the estimation of difference in differences treatment effects with Stata*. Munich Personal RePEc Archive. Dostupno na: https://mpra.ub.uni-muenchen.de/43943/

182. Villeneuve, S. & Warin, X. (2014) Optimal Liquidity management and Hedging in the presence of a Non-Predictable Investment Opportunity. *Mathematics and Financial Economics*, 8(2), str. 193–227.

183. Vollrath, D. (2016) *GDP, Productivity, and Financial Performance*. Growth Economic blog. Dostupno na: https://growthecon.com/blog/Accounting-Profits/.

184. Wagner, J. & Veradi, V. (2011) Robust Estimation of Linear Fixed Effects Panel Data Models with an Application to the Exporter Productivity Premium. *Journal of Economics and Statistics*, 231(4).

185. Wang, Q. (2015) Fixed-effect panel threshold model using Stata. *The Stata Journal,* 15(1), str. 121-134.

186. Wooldridge, J. M. (2010) *Econometric Analysis of Cross Section and Panel Dana*. Cambridge: The MIT Press.

187. Wooldridge, J. M. (2013) *Introductory Econometrics: A Modern Approach*. 5th Edition, Michigan State University.

188. Xavier Sala-i-Martin (2005) *Internal and external adjustment costsin the theoryof fixed investments*. Lecture notes for Investemnt theory. Columbia University and Universitat Pompeu Fabra.

POPIS TABLICA I SLIKA

Tablice:

Tablica 2-1: Stopa rasta bruto kapitalne formacije za izabrana razdoblja (razdvojiti postotak) 21
Tablica 3-1: Kriteriji razgraničavanja poduzeća 110
Tablica 4-1: Tablica varijabli 133
Tablica 4-2: Statističke veličine za različite mjere investicija, u tisućama kuna, od 2000.do 2014. .. 143
Tablica 4-3: Investicije i bruto kapitalna formacija (BKF) u milijardama kuna od 2000. do 2014. .. 147
Tablica 4-4: Kriteriji razlikovanja veličine poduzeća 151
Tablica 4-5: broj poduzeća u grupi mikro, malih, srednjih i velikih poduzeća za izabrane godine ... 151
Tablica 4-6: Struktura pasive, u postotku od ukupne imovine, od 2000. do 2014. 154
Tablica 4-7: Struktura pasive, u postotku od ukupne imovine, od 2000. do 2014. 164
Tablica 4-8: Neto i bruto financiranje investicija od 2000. do 2014. 165
Tablica 4-9: Broj tvrtki koje pripadaju pojedinim režimima pokazatelja tekućeg omjera, u postocima, za razdoblje od 2002. do 2014. 179
Tablica 5-1: Tablica varijabli 188
Tablica 5-2: Razlika u statističkim veličinama balansiranog i nebalansiranog panela 191
Tablica 5-3: Sažetak osnovnih statičkih veličina balansiranog modela 192
Tablica 5-4: Rezultati testova o postojanu granica za skup financijskih i likvidnih threshold varijabli uz 95 % interval pouzdanosti 201
Tablica 5-5: Procijenjeni parametri statičke threshold regresije na balansiranu uzorku poslovnih subjekata s trima režimima 203
Tablica 5-6: Procijenjeni parametri statičke threshold regresije na balansiranu uzorku poslovnih subjekata s dvama režimima 206
Tablica 5-7: Postotak tvrtki koje pripadaju pojedinim režimima od 2002. do 2014. 208
Tablica 5-8: Rezultati threshold regresije za javna poduzeća u Republici Hrvatskoj od 2001. do 2014. 220
Tablica 5-9: Rezultati threshold regresije za javna poduzeća u Republici Hrvatskoj od 2001. do 2014. 222
Tablica 5-10: Analiza osjetljivosti rezultata na promjene specifikacije modela 226
Tablica 5-11: Osjetljivost rezultata na eliminaciju n-tog percentila ekstremnih vrijednosti 231
Tablica 5-12: Analiza osjetljivosti rezultata na dodavanje nezavisnih varijabli 233
Tablica 5-13: Procjena threshold regresije s tekućim novčanim tokovima 236
Tablica 5-14: Procijenjeni parametri statičke threshold regresije na balansiranu uzorku poslovnih subjekata s trima režimima 239
Tablica 5-15: Procijenjeni parametri statičke threshold regresije na balansiranu uzorku poslovnih subjekata s dvama režimima 242
Tablica 5-16: Eliminirani percentili u početnom uzorku 246
Tablica 5-17: Sažetak statističkih veličina 247
Tablica 5-18: Popis varijabli koje dijele uzorak i vrijednosti granica za svaki režim 248
Tablica 5-19: Rezultati procjene modela fiksnih efekata na cjelokupnom uzorku hrvatskih nefinancijskih poduzeća od 2002. do 2014. 251
Tablica 5-20: Rezultati procjene Arellano-Bond GMM modela na cjelokupnu uzorku hrvatskih nefinancijskih poduzeća od 2002. do 2014. 252

Tablica 5-21: Rezultati procjene modela fiksnih efekata s intenzitetom zaduženosti kao varijablom razgraničavanja uzorka 255
Tablica 5-22: Arellano-Bond GMM procjenitelji sa intenzitetom zaduženosti kao varijablom razgraničavanja uzorka 256
Tablica 5-23: Rezultati procjene modela fiksnih efekata sa stopom neto radnoga kapitala kao varijablom razgraničavanja uzorka 257
Tablica 5-24: Arellano-Bond GMM procjenitelji sa stopom neto radnoga kapitala kao varijablom razgraničavanja uzorka 258
Tablica 6-1: Procijenjena uvjetna očekivanja (Roberts, Whited, 2013) 262
Tablica 6-2: Pregled zbirnih podataka iz sustava predstečajnih nagodbi od 1.listopada 2012. do 18. listopada2015. godine 274
Tablica 6-3: Zbirni pregled broja predmeta i iznosa obveza prema području djelatnosti i usporedba s agregatnim vrijednostima u 2013. godini 275
Tablica 6-4: Popis najvećih vjerovnika prema iznosu utvrđenih tražbina od 23. travnja 2013. do 1. rujna 2014. 277
Tablica 6-5: Medijani financijskih pokazatelja za tretmansku grupu i ostalih poduzeća 278
Tablica 6-6: Medijani izabranih pokazatelja u 2012. godini 283
Tablica 6-7: Test jednakosti distribucija za tretmansku kontrolnu skupinu za 2012. godinu 284
Tablica 6-8: DD procjenitelj stope investicija između poduzeća koja su sklopila predstečajnu nagodbu i sličnih poduzeća od 2012. do 2013. 290
Tablica 6-9: Vrijednosti procijenjenih parametara, standardne pogreške i p vrijednosti za osnovni model 291
Tablica 6-10: DD procjenitelj logaritma zaposlenih između poduzeća koja su sklopila predstečajnu nagodbu i sličnih poduzeća od 2012. do 2013. 292
Tablica 6-11: DD procjenitelj investicija između poduzeća koja su sklopila predstečajnu nagodbu i sličnih poduzeća za razdoblja: 2012–2013, 2012–2014. i 2013–2014. godine. 295
Tablica 6-12: Test jednakosti distribucija za tretmansku kontrolnu skupinu za 2012. godinu 298
Tablica 6-13: DD procjenitelj stope investicija između poduzeća koja su sklopila predstečajnu nagodbu i sličnih poduzeća od 2012. do 2013. 299
Tablica 6-14: Procijenjeni koeficijenti primjenom metode panel-fiksnih efekata 301
Tablica 7-1: Pregled postavljenih istraživačkih hipoteza i rezultati njihova istraživanja. 307

Slike:

Slika 2-1: Osobna potrošnja, državna potrošnja, investicije i neto izvoz od 2000. do 2017. u postotku od agregiranog BDP-a; cjenovni indeks 2010 =100. 19
Slika 2-2: Bruto kapitalna formacija na razini EU 28 od 1995. do 2017; cjenovni indeks 2010 = 100 20
Slika 2-3: Postotna promjena bruto investicija u fiksni kapital i ukupnih kredita nefinancijskim institucijama, u nominalnim iznosima 24
Slika 2-4: Promjene duga i kapitala poslovnih banaka prema promjeni imovine od 1995. do 2018. . 25
Slika 2-5: Višak likvidnosti bankarskog sektora u Republici Hrvatskoj 26
Slika 2-6: Dinamika bruto investicija u fiksni kapital i dugoročnih kamatnih stopa za trgovačka društva od 2000. do 2014. 27
Slika 2-7: Međuovisnost financijskog i likvidnog ograničenja 72

Slika 4-1: Struktura i dinamika novododane vrijednosti nefinancijskih poduzeća, u milijardama kuna, od 2000. do 2014. 137
Slika 4-2: Vremenski odsječci ključnih varijabli poslovanja 139
Slika 4-3: Dinamika parcijalne i višefaktorske produktivnosti nefinancijskih poduzeća od 2001. do 2014. 140
Slika 4-4: Investicije, bruto kapitalna formacija, investicijski tok i neto investicije nefinancijskih poduzeća od 2001. do 2014. u milijardama kuna 142
Slika 4-5: Dinamika investicija i investicija s novoosnovanim subjektima od 2001. do 2014. 145
Slika 4-6: Investicije po djelatnostima, u milijunima kuna, od 2001.do 2014. 150
Slika 4-7: Struktura investicija prema veličini poduzeća od 2001. do 2014. 151
Slika 4-8: Dinamika stope neto investicija za male, srednje i velike subjekte 152
Slika 4-9: Struktura investicija u Republici Hrvatskoj prema vrsti materijalne imovine od 2000. do 2014. u milijardama kuna. 156
Slika 4-10: Udio investicija poduzeća s inozemnim i domaćim podrijetlom kapitala te javnih i privatnih investicija u ukupnim investicijama od 2000. do2014. u postocima od ukupnih investicija. 158
Slika 4-11: Struktura kapitala nefinancijskih poduzeća, udio knjigovodstvene vrijednosti pojedine komponente pasive u ukupnoj pasivi od 2000. do 2014. 160
Slika 4-12: Struktura zajmova s obzirom na podrijetlo i ročnost u milijardama kuna od 2008. do 2014. 161
Slika 4-13: Medijani stope investicija za poslovne subjekte različita financijskog položaja od 2001. do2014. 168
Slika 4-14: Medijan intenziteta zaduženosti po djelatnostima od 2000. do 2014. 169
Slika 4-15: Histogram pokazatelja intenziteta zaduženosti za 2000., 2007. i 2014. godinu. 170
Slika 4-16: Dinamika neto investicija, neto radnoga kapitala, novčanog toka i novca u odnosu prema ukupnoj imovini od 2001. do 2014. 174
Slika 4-17: Dinamika investicija i novčanih tokova po županijama u Republici Hrvatskoj od 2001. do 2014. 175
Slika 4-18: Regresija investicija na novčane tokove za 21 županiju u Republici Hrvatskoj (izuzev Zagreba)od 2001. do 2014. 176
Slika 4-19: Histogram pokazatelja tekućeg omjera za 2000., 2007. i 2014. godinu. 178
Slika 4-20: Dinamika stope neto investicija za „nelikvidna“, „likvidna“ i „prelikvidna“ poduzeća 180
Slika 5-1: LR statistika za dvije granice s koeficijentom zaduženosti kao threshold varijablom 209
Slika 5-2: LR statistika za dvije granice s pokrićem troškova kamata kao threshold varijablom 211
Slika 5-3: LR statistika za dvije granice s veličinom poduzeća kao threshold varijablom. 212
Slika 5-4: LR statistika za dvije granice sa stopom likvidnosti poduzeća kao threshold varijablom. . 214
Slika 5-5: LR statistika za dvije granice s tekućom likvidnosti kao threshold varijablom 216
Slika 5-6: LR statistika za dvije granice sa stopom neto radnoga kapitala kao threshold varijablom 216
Slika 6-1: Grafička analiza efekta tretmana 263
Slika 6-2: Očekivane vrijednosti investicija za tretmansku i kontrolnu skupinu od 2011. do 2014. .. 287

ŽIVOTOPIS

Mislav Šagovac rođen je 2. srpnja 1986. godine u Zagrebu gdje je maturirao 2004. godine u I. gimnaziji. Iste godine upisao je Ekonomski fakultet Sveučilišta u Zagrebu te 2009. godine stekao status prvostupnika ekonomije. Status magistra ekonomije stekao je 2010. godine uspješnom obranom diplomskog rada *Procjena boniteta poduzeća Kraš d.d.* Potkraj 2011. godine upisao je Doktorski studij ekonomije na Ekonomskome fakultetu u Zagrebu, s izabranom temom doktorskog rada: *Procjena investicijskoga kanala financijskih frikcija u Republici Hrvatskoj.* Od siječnja 2012. zaposlen je kao podatkovni analitičar u tvrtki Contentio d.o.o. Dodatno se obrazovao i usavršavao u inozemstvu pohađajući dva semestra na doktorskome studiju u Beču (Vienna Graduate School of Economics), na kojem je uspješno položio dva kolegija: Makroekonomija s heterogenim agentima. Od stranih jezika aktivno se služi engleskim, a pasivno njemačkim jezikom. Od računalnih vještina aktivno se koristi programskim jezicima R, Stata i Python.

POPIS OBJAVLJENIH AUTOROVIH RADOVA

Znanstveni radovi u znanstvenim časopisima

Šagovac, M., Šikić, L. (2016). Estimation of the firm's balance sheet channel effects during the economic crisis: Case of Croatia. *Croatian Review of Economic, Business and Social Statistics, 2(2)*.

Šagovac, M., Šikić, L. (2017) An International Integration History of the Zagreb Stock Exchange. *Financial theory and Practice*, 41(2).

Znanstveni radovi izloženi na znanstvenim skupovima i objavljeni u zbornicima

Šagovac, M., Šikić, L. (2016) *The time desegregation of GDP series for chosen five South-East European countries*, International Statistical Conference in Croatia, Vol. 1, No. 1, Zagreb.

Jurlina Alibegović, D., Kordej-De Villa, Ž., Šagovac, M. (2018) *Smart City Indicators: Can They Improve Governance in Croatian Large Cities?*, Smart Specialization Strategies: Contemporary Challenges of its Design and Implementation Zagreb, Hrvatska, 2018.

Radovi u postpupku objavljivanja

Jurlina Alibegović, D., Kordej-De Villa, Ž., Šagovac, M. (2018) *Smart City Indicators: Can They Improve Governance in Croatian Large Cities?*, EIZ Working Papers, EIZ-WP-1805 , 1-48.