

Utjecaj upravljanja obrtnim kapitalom na profitabilnost malih i srednjih poduzeća u post-tranzicijskom gospodarstvu

Prša, Darija

Doctoral thesis / Disertacija

2019

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

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:192:847763>

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

Download date / Datum preuzimanja: **2024-04-26**



SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Repository / Repozitorij:

[Repository of the University of Rijeka, Faculty of Economics and Business - FECRI Repository](#)



SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Darija Prša

**UTJECAJ UPRAVLJANJA OBRTNIM
KAPITALOM NA PROFITABILNOST
MALIH I SREDNJIH PODUZEĆA U POST-
TRANZICIJSKOM GOSPODARSTVU**

DOKTORSKI RAD

Rijeka, 2019.

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Darija Prša

**UTJECAJ UPRAVLJANJA OBRTNIM
KAPITALOM NA PROFITABILNOST
MALIH I SREDNJIH PODUZEĆA U POST-
TRANZICIJSKOM GOSPODARSTVU**

DOKTORSKI RAD

Mentor: Prof. dr. sc. Silvije Orsag
Komentorica: Prof. dr. sc. Mira Dimitrić

Rijeka, 2019.

UNIVERSITY OF RIJEKA
FACULTY OF ECONOMICS

Darija Prša

**THE INFLUENCE OF WORKING
CAPITAL MANAGEMENT ON THE
PROFITABILITY OF SMALL AND
MEDIUM-SIZED ENTERPRISES IN A
POST-TRANSITIONAL ECONOMY**

DOCTORAL THESIS

Rijeka, 2019.

Mentor rada: Prof. dr. sc. Silvije Orsag
Komentorica rada: Prof. dr. sc. Mira Dimitrić

Doktorski rad obranjen je dana 16. travnja 2019. na Ekonomskom fakultetu Sveučilišta u Rijeci, pred Povjerenstvom u sastavu:

1. Prof. dr. sc. Lidija Dedi, predsjednica povjerenstva
2. Prof. dr. sc. Neda Vitezić, članica povjerenstva
3. Prof. dr. sc. Davor Vašićek, član povjerenstva

ZAHVALA

Ovaj doktorski rad posvećujem svojim roditeljima jer upravo zahvaljujući njihovoj ljubavi i vjeri u mene došla sam do uspješnog završetka doktorskog studija. Izuzev mojih roditelja vrlo važnu ulogu na tom putu činili su moja kći Irina i sestra Valentina koje su me svakodnevno poticale i potvrđivale mi svoju bezuvjetnu ljubav.

Neizmijerna hvala mojem mentoru prof. dr. sc. Silviju Orsagu koji mi je bio uzor cijeli moj akademski put i čija su stručnost, osobnost i ljudskost neprocjenjive. Ponosna sam što mi je bio mentor i velika mi je čast što sam imala priliku od njega učiti. Hvala mu na stalnoj podršci, ohrabrenju i vodstvu tijekom cijelog procesa izrade doktorskog rada te što je učinio mogućim završetak ovoga doktorskog rada. Velika hvala komentorici prof. dr. sc. Miri Dimitrić na kontinuiranoj podršci i dragocjenim savjetima. Njezina osobnost je veliko nadahnuće.

Hvala mojim dragim prijateljima koji su me pratili, hrabрили, savjetovali, dizali, nasmijavali na cijelom ovom znanstvenom putu, i kada je bilo najteže, njihova je podrška bila neprocjenjiva, uz posebnu zahvalu Gordanu, Jozi, Maji, Antoniji, Lidiji, Ana Mariji, Velimiru, Vicku, Toniju, Ivani, Ivani i Mariji.

Velika hvala svima!

SAŽETAK

Upravljanje obrtnim kapitalom važno je zbog njegova utjecaja na bogatstvo vlasnika, promatrano kao ekonomska vrijednost poduzeća koja je rezultat međuovisnosti profitabilnosti i rizika. Poduzeća koja ulažu velika sredstva u obrtni kapital mogu za posljedicu očekivati nižu razinu poslovnog rizika, ali i nepovoljniji utjecaj na visinu profitabilnosti. Obrnuto, manja ulaganja u obrtni kapital najvjerojatnije će rezultirati većom profitabilnošću, ali i većim rizikom njezina ostvarivanja. Efikasno upravljanje obrtnim kapitalom podrazumijeva održavanje optimalne razine obrtnog kapitala, odnosno ravnoteže između profitabilnosti i likvidnosti i profitabilnosti i rizika. Glavni je cilj ovoga doktorskog rada ispitati odnos između upravljanja obrtnim kapitalom i profitabilnosti malih i srednjih poduzeća u Republici Hrvatskoj te pružiti empirijske dokaze o učincima upravljanja obrtnim kapitalom na visinu profitabilnosti malih i srednjih poduzeća u Republici Hrvatskoj. Na temelju relevantne i dostupne domaće i strane literature, definirani su ključni čimbenici upravljanja obrtnim kapitalom na razini poduzeća koji utječu na visinu profitabilnosti malih i srednjih poduzeća a to su: zalihe, potraživanja od kupaca, obveze prema dobavljačima, rast prodaje, veličina poduzeća i sektor. Panel-analizom podataka ispitao se utjecaj, intenzitet i smjer ključnih čimbenika upravljanja obrtnim kapitalom na razini poduzeća na visinu profitabilnosti malih i srednjih poduzeća u Republici Hrvatskoj. Panel-analizom podataka ispitao se utjecaj, intenzitet i smjer ključnih čimbenika upravljanja obrtnim kapitalom na razini poduzeća na visinu profitabilnosti malih i srednjih poduzeća pojedinačno u četiri sektora koja čine najveći udio u strukturi malih i srednjih poduzeća a to su: građevinarstvo, prerađivački sektor, trgovina na malo i trgovina na veliko. Model je potvrdio utjecaj zaliha, obveza prema dobavljačima i rasta prodaje na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj, dok se utjecaj potraživanja od kupaca i veličine poduzeća na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj nije potvrdio čime je djelomično potvrđena prva temeljna radna hipoteza. Model je potvrdio utjecaj zaliha, obveza prema dobavljačima, veličine poduzeća, rasta prodaje i BDP-a na visinu profitabilnosti u pojedinim sektorima dok se utjecaj potraživanja od kupaca i inflacije na visinu profitabilnosti u svim sektorima nije pokazao statistički značajnim čime je djelomično potvrđena druga temeljna radna hipoteza.

KLJUČNE RIJEČI: Mala i srednja poduzeća, post-tranzicijsko gospodarstvo, čimbenici upravljanja obrtnim kapitalom, neto operativni obrtni kapital, profitabilnost.

SUMMARY

Working capital management is important because of its impact to the owner's wealth as an economic value of the enterprise resulting from the interdependence of profitability and risk. The companies which invest large amounts in the working capital can expect to face less business risks, but at the same time lower levels of profitability. Contrary to this, investing less in the working capital will probably result in more profit but also more risk in realizing it. Efficient management of working capital means maintaining an optimal level of working capital and a balance between profitability and liquidity and profitability and risk. The main aim of this PhD thesis is to examine the relationship between working capital management and profitability of the small and medium-sized enterprises in the Republic of Croatia and provide empirical evidence on the effects of working capital management on the level of profitability of these enterprises in Croatia. Based on the relevant and available domestic and foreign literature, the following common factors of working capital management which influence profitability levels of SMEs have been defined: goods in stock, accounts receivable, accounts payable, sales growth, company size and sector. A panel data analysis was conducted to study the influence, intensity and direction of key factors of working capital management of the enterprises to the levels of profitability of SMEs in Croatia, in four main sectors: civil engineering, processing industry, retail and wholesale. This model confirmed the impact of stocks, accounts payable and sales growth to the levels of profitability of SMEs in Croatia, while the impact of accounts receivable and company size to the levels of profitability was not confirmed, thus only partially validating the first working hypothesis. The model confirmed the impact of stocks, accounts payable, company size, sales growth and GDP to the levels of profitability in some sectors, while the impact of accounts receivable and inflation to the levels of profitability in all sectors was showed to be irrelevant, thus only partially validating the second working hypothesis.

KEY WORDS: small and medium-sized enterprises, post-transition economy, working capital management factors, net working capital, profitability.

SADRŽAJ

SAŽETAK.....	I
---------------------	----------

SUMMARY	II
----------------------	-----------

1. UVOD	1
----------------------	----------

1.1. Problem i predmet istraživanja	2
1.2. Ciljevi istraživanja i očekivani znanstveni doprinos	4
1.3. Hipoteze istraživanja	7
1.4. Kratak pregled dosadašnjih istraživanja	8
1.5. Znanstvene metode	12
1.6. Struktura rada	15

2. POJMOVNO ODREĐIVANJE MALIH I SREDNJIH PODUZEĆA.....	18
---	-----------

2.1. Definicija malih i srednjih poduzeća i njezina primjena	18
2.1.1. Kriteriji za definiranje malih i srednjih poduzeća u svijetu	20
2.1.2. Kriteriji za definiranje malih i srednjih poduzeća u Hrvatskoj	23
2.1.3. Trgovačka društva prema pravno ustrojbenim oblicima	24
2.2. Struktura, veličina i sastav malih i srednjih poduzeća u Republici Hrvatskoj i odabranim zemljama EU-a	26
2.2.1. Strukturno-poslovni pokazatelji poduzeća u Republici Hrvatskoj	26
2.2.1.1. Broj poduzeća prema gospodarskoj djelatnosti i veličini poduzeća	27
2.2.1.2. Zaposlenost prema gospodarskoj djelatnosti i veličini poduzeća	29
2.2.1.3. Dodana vrijednost prema gospodarskoj djelatnosti i veličini poduzeća	31
2.2.2. Strukturno poslovni pokazatelji poduzeća u zemljama Europske unije	33
2.3. Ključne razlike malih i srednjih poduzeća i velikih poduzeća	36

3. GOSPODARSTVO REPUBLIKE HRVATSKE.....	41
--	-----------

3.1. Tranzicija	41
3.1.1. Glavne sastavnice tranzicijskog procesa	41
3.1.2. Klasifikacijski sustav procesa tranzicije	43
3.2. Okruženje u kojem se nalazi malo gospodarstvo Republike Hrvatske	46
3.2.1. Međunarodna istraživanja u poslovnom okruženju	47
3.2.2. Poduzetnički problemi malih i srednjih poduzeća u Republici Hrvatskoj	52
3.2.3. Institucionalna potpora za mala i srednja poduzeća u Republici Hrvatskoj	56
3.3. Financiranje malih i srednjih poduzeća	57
3.3.1. Najvažniji oblici financiranja	59
3.3.2. Namjena korištenja vanjskih oblika financiranja	61

4. UPRAVLJANJE OBRTNIM KAPITALOM	64
---	-----------

4.1. Koncepti obrtnog kapitala	64
4.1.1. Bruto obrtni kapital	67
4.1.2. Permanentna i privremena tekuća imovina	67
4.1.3. Neto obrtni kapital	69
4.1.4. Neto operativni obrtni kapital	70
4.2. Određenje upravljanja obrtnim kapitalom	71
4.2.1. Učinkovito upravljanje obrtnim kapitalom	74
4.2.2. Optimalna veličina i struktura obrtnog kapitala	76
4.2.3. Odstupanja od optimalne veličine i strukture obrtnih sredstava	77

4.2.4.	Mjere i metode za optimalizaciju obrtnih sredstava	80
4.3.	Upravljanje tekućom imovinom.....	81
4.3.1.	Upravljanje potraživanjima od kupaca.....	82
4.3.2.	Upravljanje zalihama	85
4.4.	Upravljanje tekućim obvezama.....	87
4.4.1.	Spontano financiranje	90
4.4.1.1.	Trgovački kredit dobavljača.....	90
4.4.1.2.	Narastajuće stavke.....	93
4.4.2.	Ugovoreno financiranje	94
4.4.2.1.	Kratkoročni krediti banaka.....	94
4.4.2.2.	Factoring	97
4.4.3.	Komercijalni zapisi	98
5.	STRATEGIJE UPRAVLJANJA OBRTNIM KAPITALOM.....	100
5.1.	Strategije investiranja u obrtnom kapitalu.....	100
5.2.	Strategije financiranja obrtnog kapitala	101
5.3.	Umjerena politika.....	103
5.4.	Pokazatelji obrtnog kapitala.....	105
5.4.1.	Pokazatelji obrtaja imovine.....	105
5.4.2.	Pokazatelji likvidnosti	106
5.4.3.	Pokazatelji profitabilnosti.....	108
5.5.	Utjecaj sektora na upravljanje obrtnima kapitalom	109
6.	MODEL UTJECAJA UPRAVLJANJA OBRTNIM KAPITALOM NA PROFITABILNOST MALIH I SREDNJIH PODUZEĆA U REPUBLICI HRVATSKOJ.....	118
6.1.	Definiranje uzorka i podaci	118
6.2.	Varijable u modelu.....	119
6.2.1.	Zavisna varijabla	120
6.2.2.	Nezavisne varijable	121
6.2.3.	Kontrolne varijable	124
6.3.	Panel analiza.....	127
6.3.1.	Združeni model	128
6.3.2.	Model s fiksnim efektom.....	129
6.3.3.	Model sa slučajnim efektom	130
6.3.4.	Regresijska dijagnostika.....	132
6.4.	Empirijska analiza	133
6.4.1.	Svi sektori zajedno	133
6.4.1.1.	Deskriptivna statistika	134
6.4.1.2.	Spearmanov koeficijent korelacije.....	135
6.4.1.3.	Panel analiza svih sektora zajedno	137
6.4.1.4.	Regresijska dijagnostika svih sektora zajedno	139
6.4.2.	Sektor građevinarstvo	140
6.4.2.1.	Deskriptivna statistika sektora građevinarstvo	142
6.4.2.2.	Spearmanov koeficijent korelacije.....	144
6.4.2.3.	Panel analiza sektora građevinarstvo	144
6.4.2.4.	Regresijska dijagnostika sektora građevinarstvo	146
6.4.3.	Prerađivački sektor.....	147
6.4.3.1.	Deskriptivna statistika prerađivačkog sektora	148
6.4.3.2.	Spearmanov koeficijent korelacije.....	150
6.4.3.3.	Panel analiza prerađivačkog sektora	150
6.4.3.4.	Regresijska dijagnostika prerađivačkog sektora	152

6.4.4.	Sektor trgovina na malo	153
6.4.4.1.	Deskriptivna statistika sektora trgovina na malo	154
6.4.4.2.	Spearmanov koeficijent korelacije	156
6.4.4.3.	Panel analiza sektora trgovine na malo	156
6.4.4.4.	Regresijska dijagnostika sektora trgovine na malo	159
6.4.5.	Sektor trgovina na veliko	159
6.4.5.1.	Deskriptivna statistika sektora trgovina na veliko	160
6.4.5.2.	Spearmanov koeficijent korelacije	162
6.4.5.3.	Panel analiza sektora trgovina na veliko	162
6.4.5.4.	Regresijska dijagnostika sektora trgovina na veliko	164
6.4.6.	Kruskal-Wallis analiza	165
6.5.	Rezultati empirijskog istraživanja po hipotezama	170
6.5.1.	Prva temeljna radna hipoteza.....	170
6.5.2.	Druga temeljna radna hipoteza	173
6.5.2.1.	Dani naplate potraživanja i profitabilnost po sektorima	174
6.5.2.2.	Dani vezivanja zaliha i profitabilnost po sektorima	176
6.5.2.3.	Dani plaćanja dobavljačima i profitabilnost po sektorima	177
6.5.2.4.	Veličina poduzeća i profitabilnost po sektorima	178
6.5.2.5.	Rast prodaje i profitabilnost po sektorima	179
6.5.2.6.	Inflacija.....	180
6.5.2.7.	BDP.....	180
6.5.3.	Politike upravljanja obrtnim kapitalom po sektorima.....	181
7.	ZAKLJUČAK.....	185
	LITERATURA.....	198
	POPIS DRUGIH KORIŠTENIH IZVORA	206
	POPIS TABLICA	210
	POPIS SLIKA	212
	LONG ABSTRACT.....	213
	ŽIVOTOPIS AUTORICE I POPIS OBJAVLJENIH RADOVA	227

1. UVOD

Poduzeća koja djeluju u suvremenom poslovnom okruženju, pored tržišnog rizika, izložena su i nizu rizika vezanih za donošenje odluka o upravljanju poduzećem koje mogu negativno utjecati na rezultat poslovanja poduzeća. Dobro upravljanje poduzećem, koje podrazumijeva donošenje ispravnih odluka o upravljanju poslovanjem radi maksimiziranja zarada vlasnika poduzeća i pritom uvažavajući čitavu lepezu rizika, omogućuje svakom poduzeću maksimiziranje njegovih zarada iz osnovne djelatnosti.

Ovaj doktorski rad usmjerio je svoje istraživanje na upravljanje kratkoročnim odlukama, odnosno odlukama koje se donose u svakodnevnom poslovanju i koje moraju biti pod stalnom kontrolom menadžmenta jer su podložne promjenama na dnevnoj razini. To su odluke vezane za upravljanje tekućom imovinom i tekućim obvezama, odnosno odluke o upravljanju obrtnim kapitalom.

Učinkovito upravljanje obrtnim kapitalom podrazumijeva postizanje ravnoteže između profitabilnosti i likvidnosti i profitabilnosti i rizika poslovanja. Važnost učinkovitog upravljanja obrtnim kapitalom od posebnog je značaja za poduzeća čiji se veći dio imovine sastoji od tekuće imovine i koja se najvećim djelom financira iz kratkoročnih izvora. Predmet istraživanja ovog rada je utvrđivanje i sistematizacija ključnih čimbenika upravljanja obrtnim kapitalom na razini poduzeća koji značajno utječu na profitabilnost malih i srednjih poduzeća, čija se imovina sastoji najvećim dijelom od tekuće imovine i koja se najviše financira iz kratkoročnih izvora, te analiza utjecaja ključnih čimbenika upravljanja obrtnim kapitalom na razini poduzeća na visinu profitabilnosti malih i srednjih poduzeća u Republici Hrvatskoj.

Znanstveni rezultati i saznanja ovoga istraživanja imat će vrijednost za menadžment malih i srednjih poduzeća koja posluju u Republici Hrvatskoj, ali i u zemljama regije, jer će im pomoći bolje razumijevanje i unaprjeđenje upravljanja obrtnim kapitalom te se očekuje da će im spoznaje ovoga doktorskog rada probuditi svijest o postojećim problemima o upravljanju obrtnim kapitalom. Fokus ovoga rada je na malim i srednjim poduzećima iz četiri sektora koja čine najveći udio u strukturi malih i srednjih poduzeća i istovremeno imaju veliku razinu obrtnog kapitala u strukturi svoje imovine.

1.1. Problem i predmet istraživanja

Većina izvora iz područja financijskog menadžmenta usmjerena je na proučavanje dugoročnih financijskih i investicijskih odluka, odnosno ocjene isplativosti ulaganja, strukturu kapitala, politiku dividendi i slično dok su kratkoročne odluke, odnosno odluke o upravljanju obrtnim kapitalom, manje zastupljene u literaturi i znanstvenim studijama. Zbog činjenice da je najveći udio sredstava malih i srednjih poduzeća u obliku tekuće imovine, dok su tekuće obveze jedan od glavnih izvora vanjskog financiranja malih i srednjih poduzeća, ovaj doktorski rad usmjerio je svoje istraživanje na kratkoročne odluke, odnosno odluke o upravljanju obrtnim kapitalom.

Upravljanje obrtnim kapitalom važno je zbog njegova utjecaja na bogatstvo vlasnika, promatrano kao ekonomska vrijednost poduzeća koja je rezultat međuovisnosti profitabilnosti i rizika. Poduzeća koja ulažu velika sredstva u obrtni kapital mogu kao posljedicu očekivati manju profitabilnost, čime se smanjuje vrijednost, ali i manji rizik, što će povećati vrijednost poduzeća. Obrnuto, manja ulaganja u obrtni kapital najvjerojatnije će rezultirati većom profitabilnošću, ali i većim rizikom njezina ostvarivanja. U skladu s tim, za mnoga je poduzeća upravljanje obrtnim kapitalom vrlo važna komponenta njihova financijskog i investicijskog upravljanja. Dobro upravljanje obrtnim kapitalom podrazumijeva održavanje optimalne razine obrtnog kapitala, odnosno ravnoteže između profitabilnosti i likvidnosti i profitabilnosti i rizika. Ako poduzeće ne upravlja dobro obrtnim kapitalom, s jedne strane, može doći do prevelikog rizika poslovanja i nesigurnosti u poslovanju. S druge strane, zbog prekomjernog ulaganja u obrtni kapital može doći do nedovoljnog rasta stope prinosa.

Mala i srednja poduzeća su pokretač gospodarskog rasta jer sudjeluju s oko 99 % u ukupnom broju poduzeća, 69 % u ukupnom broju zaposlenih, 54 % u ukupnim prihodima, 56 % u dobiti razdoblja te 50 % u ukupnom izvozu. Unatoč velikoj važnosti malih i srednjih poduzeća u gospodarskom napretku svake države većina su istraživača svoje analize usmjerili na velika poduzeća. S jedne strane, to se može pripisati većoj dostupnosti financijskih izvještaja koji su javno objavljeni, odnosno informacija potrebnih za analizu upravljanja obrtnim kapitalom. Velika poduzeća su aktivni sudionici tržišta kapitala pa samim time i informacije o njihovom poslovanju su u većim razmjerima dostupne široj javnosti. S druge strane, prisutna je veća zainteresiranost i briga države za velika poduzeća jer u slučaju nestabilnosti poslovanja može doći do velikih financijskih šteta, nezaposlenosti, nepodmirenih

obveza koje potresaju države. Financiranje velikih poduzeća znatno je složenije, jer postoji puno više alternativa financiranja nego kod malih i srednjih poduzeća, a i radi se o znatno većim iznosima financijskih sredstava. Upravo zbog nedovoljne zastupljenosti malih i srednjih poduzeća u literaturi i znanstvenim studijama kao i manjeg interesa države, a istovremeno velike uloge malih i srednjih poduzeća u gospodarskom napretku svake države, ovaj rad usmjerio je svoje istraživanje na analizu upravljanja obrtnim kapitalom malih i srednjih poduzeća.

Razne su studije analizirale odnos upravljanja obrtnim kapitalom i profitabilnosti poduzeća na različitim tržištima, ali je najveći dio istraživanja proveden u najrazvijenijim zemljama za koje su karakteristična razvijena financijska tržišta. Interes za proučavanjem hrvatskih poduzeća proizlazi iz činjenice da ona djeluju u bankocentričnom financijskom sustavu gdje su tržišta kapitala manje razvijena pa samim time poduzeća imaju manje alternativa za dobivanje financijskih sredstava iz vanjskih izvora. Istraživanja koja su provedena u više zemalja ukazuju na postojanje određenog broja ključnih čimbenika upravljanja obrtnim kapitalom na razini poduzeća koja utječu na profitabilnost poduzeća i u zemljama u razvoju i u razvijenim zemljama. Stoga se kao jedno od istraživačkih pitanja pojavljuje pitanje utvrđivanja zajedničkih čimbenika upravljanja obrtnim kapitalom na razini poduzeća koji utječu na visinu profitabilnosti hrvatskih malih i srednjih poduzeća u sektorima koje čine najveći udio u strukturi malih i srednjih poduzeća.

Nakon utvrđivanja zajedničkih čimbenika upravljanja obrtnim kapitalom na razini poduzeća koji značajno utječu na visinu profitabilnost malih i srednjih poduzeća u različitim sektorima, nužno je izraditi jedinstven model koji će biti primjenjiv za sva mala i srednja poduzeća, bez obzira kojem sektoru poduzeće pripada. Iz toga izravno proizlazi pitanje mogućnosti korištenja jedinstvenog modela s čimbenicima upravljanja obrtnim kapitalom na razini poduzeća za sva poduzeća, bez obzira kojem sektoru pripadaju.

Teorijskim razmatranjima i empirijskim potvrdama može se zaključiti kako će isti čimbenici upravljanja obrtnim kapitalom, na razini poduzeća, većinom značajno utjecati na visinu profitabilnosti malih i srednjih poduzeća u svim sektorima, ali utjecaj svakog pojedinog čimbenika neće biti istog smjera i intenziteta u poduzećima različitih sektora. Stoga se kao dodatni istraživački problem pojavljuje pitanje utvrđivanja značaja i smjera utjecaja zajedničkih čimbenika upravljanja obrtnim kapitalom na razini

poduzeća na visinu profitabilnosti malih i srednjih poduzeća u različitim sektorima. Zato je nužno proučavanje utjecaja čimbenika upravljanja obrtnim kapitalom na razini poduzeća na visinu profitabilnosti malih i srednjih poduzeća u svakom sektoru posebno, uzimajući u obzir karakteristike sektora u kojem poduzeće posluje. Nastavno na potonje sljedeći problem istraživanja ovoga doktorskog rada jest utvrđivanje čimbenika upravljanja obrtnim kapitalom na razini poduzeća koji značajno utječu na visinu profitabilnosti malih i srednjih poduzeća za svaki sektor zasebno. Nakon utvrđivanja čimbenika upravljanja obrtnim kapitalom na razini poduzeća koji značajno utječu na visinu profitabilnosti malih i srednjih poduzeća na razini svakog sektora zasebno, nužno je izraditi modele koji će biti primjenjivi za mala i srednja poduzeća za svaki promatrani sektor posebno, i to za sektor građevinarstvo, prerađivački sektor, trgovinu na veliko i trgovinu na malo.

Prethodno navedeni problemi istraživanja određuju predmet istraživanja:

- na temelju relevantne i dostupne domaće i strane literature, utvrdit će se i sistematizirati zajednički čimbenici upravljanja obrtnim kapitalom na razini poduzeća koji utječu na visinu profitabilnosti malih i srednjih poduzeća u većini sektora;
- analizirat će se utjecaj zajedničkih čimbenika upravljanja obrtnim kapitalom na razini poduzeća na visinu profitabilnosti malih i srednjih poduzeća u većini sektora u Republici Hrvatskoj;
- analizirat će se utjecaj zajedničkih čimbenika upravljanja obrtnim kapitalom na razini poduzeća na visinu profitabilnosti malih i srednjih poduzeća u Republici Hrvatskoj za četiri sektora zasebno, i to: građevinarstvo, prerađivački sektor, trgovinu na veliko i trgovinu na malo.

1.2. Ciljevi istraživanja i očekivani znanstveni doprinos

Glavni je cilj ovoga doktorskog rada ispitati odnos između upravljanja obrtnim kapitalom i profitabilnosti malih i srednjih poduzeća u Republici Hrvatskoj te pružiti empirijske dokaze o učincima upravljanja obrtnim kapitalom na visinu profitabilnosti malih i srednjih poduzeća u Republici Hrvatskoj.

Da bi se postigao glavni cilj, definirani su posebni ciljevi ovoga rada:

- utvrditi i sistematizirati ključne čimbenike upravljanja obrtnim kapitalom na razini poduzeća koji značajno utječu na visinu profitabilnosti malih i srednjih poduzeća;
- izraditi model analize utjecaja upravljanja obrtnim kapitalom na visinu profitabilnosti malih i srednjih poduzeća u specifičnom okruženju, karakterističnih post-tranzicijskih zemalja;
- uključiti u model analize pripadnost različitim sektorima;
- utvrditi različitost utjecaja čimbenika upravljanja obrtnim kapitalom na razini poduzeća u različitim sektorima;
- analizirati i ocijeniti ključne čimbenike upravljanja obrtnim kapitalom koji utječu na visinu profitabilnosti u hrvatskim malim i srednjim poduzećima te ih usporediti u različitim sektorima;
- izolirati specifične okolnosti Hrvatske kao post-tranzicijskog gospodarstva;
- analizirati utjecaj upravljanja potraživanja od kupaca na visinu profitabilnosti malih i srednjih poduzeća za sve sektore zajedno;
- analizirati utjecaj upravljanja zalihami na visinu profitabilnosti malih i srednjih poduzeća za sve sektore zajedno;
- analizirati utjecaj upravljanja obveza prema dobavljačima na visinu profitabilnosti malih i srednjih poduzeća za sve sektore zajedno;
- analizirati utjecaj veličine poduzeća na visinu profitabilnosti malih i srednjih poduzeća za sve sektore zajedno;
- analizirati utjecaj rasta prodaje poduzeća na visinu profitabilnosti malih i srednjih poduzeća za sve sektore zajedno;
- analizirati utjecaj inflacije na visinu profitabilnosti malih i srednjih poduzeća za sve sektore zajedno;
- analizirati utjecaj BDP-a na visinu profitabilnosti malih i srednjih poduzeća za sve sektore zajedno;
- analizirati utjecaj sektora na visinu profitabilnosti malih i srednjih poduzeća;

- analizirati utjecaj upravljanja potraživanja od kupaca na visinu profitabilnosti malih i srednjih poduzeća za svaki sektor posebno;
- analizirati utjecaj upravljanja zalihama na visinu profitabilnosti malih i srednjih poduzeća za svaki sektor posebno;
- analizirati utjecaj upravljanja obveza prema dobavljačima na visinu profitabilnosti malih i srednjih poduzeća za svaki sektor posebno;
- analizirati utjecaj veličine poduzeća na visinu profitabilnosti malih i srednjih poduzeća za svaki sektor posebno;
- analizirati utjecaj rasta prodaje poduzeća na visinu profitabilnosti malih i srednjih poduzeća za svaki sektor posebno;
- analizirati utjecaj inflacije na visinu profitabilnosti malih i srednjih poduzeća za svaki sektor posebno;
- analizirati utjecaj BDP-a na visinu profitabilnosti malih i srednjih poduzeća za svaki sektor posebno.

Od ovog doktorskog rada očekuju se sljedeći znanstveni doprinosi:

1. Utvrđivanje i sistematizacija ključnih čimbenika upravljanja obrtnog kapitala na razini poduzeća koji značajno djeluju na visinu profitabilnosti malih i srednjih poduzeća.
2. Izrada modela analize utjecaja upravljanja obrtnim kapitalom na profitabilnost malih i srednjih poduzeća u specifičnom okruženju, karakterističnih post-tranzicijskih zemalja.
3. Uključivanje u model analize pripadnost različitim sektorima.
4. Utvrđivanje različitosti utjecaja čimbenika upravljanja obrtnog kapitala na razini poduzeća u različitim sektorima.
5. Analiza i ocjena ključnih čimbenika upravljanja obrtnog kapitala koji utječu na visinu profitabilnosti u hrvatskim poduzećima te njihova usporedba u različitim sektorima.
6. Dobiveni rezultati poslužiti će i za proširenje analize na ključne zemlje u regiji, jer će se izolirati specifične okolnosti Hrvatske kao post-tranzicijskog gospodarstva.

7. Znanstveni rezultati i saznanja imat će svoju aplikativnu stranu, jer će pomoći za unaprjeđenje upravljanja obrtnim kapitalom u malim i srednjim poduzećima.

1.3. Hipoteze istraživanja

Nastavno na potonje postavljena je **prva temeljna radna hipoteza** koja glasi:

H1. Potraživanja od kupaca, zalihe, obveze prema dobavljačima, veličina poduzeća i rast prodaje na razini poduzeća utječu na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj.

Tako postavljena temeljna hipoteza implicira više **pomoćnih hipoteza**:

H1.1. Postoji značajan i negativan utjecaj potraživanja od kupaca na visinu profitabilnosti poduzeća.

H1.2. Postoji značajan i negativan utjecaj zaliha na visinu profitabilnosti poduzeća.

H1.3. Postoji značajan i pozitivan utjecaj obveza prema dobavljačima na visinu profitabilnosti poduzeća.

H1.4. Postoji značajan i pozitivan utjecaj veličine poduzeća na visinu profitabilnosti poduzeća.

H1.5. Postoji značajan i pozitivan utjecaj rasta prodaje poduzeća na visinu profitabilnosti poduzeća.

H1.6. Postoji značajan utjecaj sektora na visinu profitabilnosti poduzeća.

H1.7. Postoji značajan utjecaj inflacije na visinu profitabilnosti poduzeća.

H1.8. Postoji značajan utjecaj BDP-a na visinu profitabilnosti poduzeća.

Nastavno na potonje postavljena je **druga temeljna radna hipoteza** koja glasi:

H2. Utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća i rasta prodaje poduzeća na visinu profitabilnosti malih i srednjih poduzeća različit je u različitim sektorima.

Tako postavljena temeljna hipoteza implicira više **pomoćnih hipoteza**:

H2.1. Utjecaj potraživanja od kupaca na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

H2.2. Utjecaj zaliha na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

H2.3. Utjecaj obveza prema dobavljačima na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

H2.4. Utjecaj veličine poduzeća na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

H2.5. Utjecaj rasta prodaje na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

H2.6. Utjecaj inflacije na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

H2.7. Utjecaj BDP-a na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

Radi dokazivanja glavnih i pomoćnih hipoteza rada:

Panel analizom podataka ispitao se utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća, rasta prodaje, rasta BDP-a, stope inflacije i sektora na visinu profitabilnosti malih i srednjih poduzeća u četiri sektora: građevinarstvu, prerađivačkom sektoru, trgovini na malo i trgovini na veliko.

Panel analizom podataka ispitao se utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća, rasta prodaje, rasta BDP-a i stope inflacije na visinu profitabilnosti malih i srednjih poduzeća pojedinačno u četiri sektora: građevinarstvu (24 % u ukupnom uzorku), prerađivačkom sektoru (24 % u ukupnom uzorku), trgovini na malo (23 % u ukupnom uzorku) i trgovini na veliko (29 % u ukupnom uzorku).

1.4. Kratak pregled dosadašnjih istraživanja

Razne su studije analizirale odnos upravljanja obrtnim kapitalom i profitabilnosti poduzeća različitih veličina na različitim tržištima. Rezultati su prilično mješoviti i pod utjecajem su tržišta na kojem poduzeće posluje kao i veličine poduzeća. Iako većina studija zaključuje da povećanje razine ulaganja u obrtni kapital rezultira manjom profitabilnosti poduzeća, postoje studije koje dobivaju suprotne nalaze, kao i studije koje nisu pronašle utjecaj razine obrtnog kapitala na visinu profitabilnosti poduzeća. Zato se prilikom donošenja zaključaka o utjecaju obrtnog kapitala na visinu profitabilnost poduzeća mora uzeti u obzir u kojoj državi poduzeća posluje, kao i radi li se o malom i srednjem ili velikom poduzeću.

Od 80-ih godina prošlog stoljeća empirijski se ispituje utjecaj razine obrtnog kapitala na profitabilnost poduzeća. Smith (1980) ukazuje na važnost upravljanja obrtnim kapitalom zbog njegovih učinaka na profitabilnost i rizik poduzeća, a shodno tomu i na njegovu vrijednost. Najveći dio istraživanja upravljanja obrtnim kapitalom, na temelju kojih se utvrđuju čimbenici upravljanja obrtnim kapitalom na razini poduzeća koji značajno utječu na visinu profitabilnosti poduzeća, proveden je u najrazvijenijim zemljama za koje su karakteristična razvijena financijska tržišta. Hrvatska pripada skupini post-tranzicijskih zemalja za koje su karakteristična manje razvijena tržišta kapitala i bankocentričan financijski sustav, što znači da se poduzeća najviše financiraju putem bankarskih kredita te su ovisna o kratkoročnom financiranju općenito (Garcia-Teruel i Martinez-Solano, 2007), a posebno o trgovačkom kreditu. Stoga je iznimno važno i treba uzeti u obzir u kojoj zemlji poduzeće posluje. U manje razvijenim kontinentalnim europskim zemljama razdoblja plaćanja su poprilično duga u usporedbi s primjerice SAD-om (Deloof, 2003). La Porta et al. (1997) tumače da zemlje sa slabijom zaštitom ulagača imaju manja i ograničenije tržišta kapitala, što financiranje bankarskim i trgovačkim kreditima čini atraktivnijima.

Istraživanja o upravljanju obrtnim kapitalom i njegovom utjecaju na profitabilnost poduzeća prema zemljama:

- Europa: London (Chatterjee, 2010), Ujedinjeno Kraljevstvo (Tauringana i Afrifa, 2013), Nizozemska (Baveld, 2012), Belgija (Deloof, 2003), Finska (Enqvist et al., 2014), Španjolska (Garcia-Teruel i Martinez-Solano, 2007), Grčka (Lyroudi i Lazaridis, 2000; Lazaridis i Tryfonidis, 2006);
- Euroazijske države: Turska (Samiloglu i Demirgunes, 2008; Sen i Oruc, 2009);
- Amerika: SAD (Gill et al., 2010) i Brazil (Ching et al., 2011);
- Azija: Indija (Vishnani i Shah, 2007; Ramachandran i Janakiraman, 2009; Sharma i Kumar 2011), Malezija (Zariyawati et al., 2009), Pakistan (Raheman i Nasr, 2007; Raheman et al., 2010; Gul et al., 2013), Saudijska Arabija (Almazari, 2014);
- Afrika: Adis Ababa (Nigatu, 2015; Seyoum et al., 2016), Gana (Akoto et al., 2013), Kenija (Mathuva, 2010; Gakure, 2012; ; Makori i Jagongo, 2013; Wesley et al., 2013).

Upravljanje obrtnim kapitalom je nedovoljno istraženo u tranzicijskim i post-tranzicijskim zemljama. Najveći broj istraživanja proveden je u SAD-u, Velikoj Britaniji, državama zapadne Europe i drugim razvijenim zemljama, dok je puno manje istraživanja provedeno u zemljama u razvoju. Istraživanja vezana za zemlje u razvoju više su usmjerena na Indiju, Maleziju i druge Azijske zemlje. Od tranzicijskih zemalja istraživanja su prisutna uglavnom za Baltičke zemlje, koje posluju u specifičnom skandinavskom okruženju, pa samim time istraživanja nisu dovoljno transparentna da bi se mogla generalizirati na područje ostalih tranzicijskih i post-tranzicijskih zemalja, a posebno ne na područje regije, a samim time i na Hrvatsku. Između ostalog, očekuje se posebno doprinos istraživanja upravljanja obrtnim kapitalom u specifičnim okolnostima jedne regije tranzicijskih i post-tranzicijskih zemalja.

U Republici Hrvatskoj, kao i u zemljama regije, nema javno objavljenih radova i istraživanja o utjecaju upravljanja obrtnim kapitalom na visinu profitabilnosti malih i srednjih poduzeća. Pregledom znanstvene literature pronađen je jedan rad od Lukića (2013) o utjecaja upravljanja obrtnim kapitalom na visinu profitabilnosti poduzeća sektora trgovine u Srbiji. Autor je koristio korelacijsku analizu kako bi utvrdio utjecaj zaliha, potraživanja od kupaca, tekućih obveza, ciklusa pretvorbe novca (krat. CCC), trenutnog omjera i financijske zaduženosti na visinu profitabilnosti poduzeća, a u ovom doktorskom radu koristit će se višestruka regresija nad panel podacima. Dobio je negativnu korelaciju između profitabilnosti i zaliha, potraživanja od kupaca, tekućih obveza i financijske zaduženosti. Dobiveni rezultati ne mogu se generalizirati na područje regije jer su za uzorak korištena samo poduzeća iz sektora trgovine. Osim navedenog istraživanja nema relevantnih istraživanja za područje post-tranzicijskih zemalja.

Bez obzira radi li se o razvijenim zemljama ili zemljama u razvoju, uočeni su zajednički čimbenici upravljanja obrtnim kapitalom na razini poduzeća koji utječu na visinu profitabilnost poduzeća:

- potraživanja od kupaca (prema Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Sen i Oruc, 2009; Gill et al., 2010; Mathuva, 2010; Raheman et al., 2010; Sharma i Kumar 2011; Baveld, 2012; Akoto et al., 2013; Gul et al., 2013; Makori i Jagongo, 2013; Tauringana i Afrifa, 2013; Wesley et al., 2013; Almazari, 2014; Engvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi);

- zalihe (prema Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Sen i Oruc, 2009; Gill et al., 2010; Mathuva, 2010; Raheman et al., 2010; Sharma i Kumar 2011; Baveld, 2012; Gul et al., 2013; Makori i Jagongo, 2013; Tauringana i Afrifa, 2013; Wesley et al., 2013; Almazari, 2014; Enqvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi);
- obveze prema dobavljačima (prema Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Sen i Oruc, 2009; Gill et al., 2010; Mathuva, 2010; Raheman et al., 2010; Sharma i Kumar 2011; Baveld, 2012; Akoto et al., 2013; Gul et al., 2013; Makori i Jagongo, 2013; Tauringana i Afrifa, 2013; Wesley et al., 2013; Almazari, 2014; Enqvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi);
- veličina poduzeća (prema Deelof, 2003; Raheman i Nasr, 2007; Gill et al., 2010; Mathuva, 2010; Raheman et al., 2010; Baveld, 2012; Gul et al., 2013; Wesley et al., 2013; Almazari, 2014; Enqvist et al., 2014; Seyoum et al., 2016 i drugi);
- rast prodaje (prema Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman et al., 2010; Sharma i Kumar 2011; Baveld, 2012; Gul et al., 2013; Makori i Jagongo, 2013; Wesley et al., 2013; Seyoum et al. 2016 i drugi);
- sektor (pripadnost industriji) (prema Deelof, 2003; Filbeck i Krueger, 2005; Garcia-Teruel i Martinez-Solano, 2007; Banos-Caballero et al., 2010; Baveld, 2012).

Većina prethodnih studija usmjerila je svoju analizu na velika poduzeća dok su mala poduzeća neopravdano izostavljena iz analiza s obzirom na njihovu veliku ulogu u gospodarskom razvoju svake države. Najveći problem predstavlja prikupljanje podataka s obzirom na to da mala i srednja poduzeća u većini slučajeva nisu obveznici javne objave financijskih izvještaja. Pregledom znanstvene literature pronađena su tri rada koja analiziraju upravljanje obrtnim kapitalom malih i srednjih poduzeća, i to za poduzeća iz Španjolske (Garcia-Teruel i Martinez-Solano, 2007), Velike Britanije (Tauringana i Afrifa, 2013) i Pakistana (Gul et al., 2013). U sva tri istraživanja dobiven je značajan i negativan odnos između potraživanja od kupaca i visine profitabilnosti poduzeća. Garcia-Teruel i Martinez-Solano (2007) i Gul et al. (2013) dobivaju značajan i negativan odnos između zaliha i visine profitabilnosti poduzeća dok Tauringana i Afrifa (2013) ne pronalaze značajan odnos između zaliha i visine profitabilnosti. Odnos

između obveza prema dobavljačima i visine profitabilnosti poduzeća je najinteresantniji jer sva tri istraživanja imaju drugačije nalaze. Dok Gul et al. (2013) dobivaju značajan i pozitivan odnos između obveza prema dobavljačima i visine profitabilnosti poduzeća, Tauringana i Afrifa (2013) dobivaju negativan odnos, a Garcia-Teruel i Martinez-Solano (2007) nisu uspjeli pronaći značajnost utjecaja obveza prema dobavljačima na visinu profitabilnosti poduzeća.

Iz dosadašnjih istraživanja, uvažavajući samo aspekt veličine poduzeća, vidi se da ne postoji univerzalni postupak za uspješno upravljanje obrtnim kapitalom, jer se između različitih čimbenika upravljanja obrtnim kapitalom na razini poduzeća i visine profitabilnosti poduzeća dobivaju odnosi različitog smjera i intenziteta.

1.5. Znanstvene metode

U radu se koriste različite znanstvene metode. Polazeći od deduktivnog pristupa provela se analiza relevantne znanstvene i stručne literature gdje se korištenjem metoda analize i sinteze, apstrakcije i konkretizacije, generalizacije i specifikacije i drugih potrebnih znanstvenoistraživačkih metoda deduciraju zaključci o značaju ključnih čimbenika upravljanja obrtnim kapitalom na razini poduzeća koji utječu na visinu profitabilnosti poduzeća općenito te specifičnosti utjecaja tih čimbenika na mala i srednja poduzeća u različitim gospodarstvima. Nakon toga sistematizirali su se ključni čimbenici upravljanja obrtnim kapitalom koji su ušli u istraživački model.

Polazeći od induktivnog pristupa, provelo se je empirijsko istraživanje na odabranom uzorku. Varijable su se analizirale deskriptivnom statistikom nad prikupljenim podacima o izabranim varijablama u razdoblju od 2011. do 2015. godine. Ti se isti podaci mogu organizirati u obliku panela, pa se je provela i njihova odgovarajuća analiza u ovisnosti o rezultatima Hausman testa. Napravljena je i regresijska dijagnostika kojom su se provjerila eventualna narušavanja polaznih pretpostavki, poput heteroskedastičnosti i autokorelacije pogrešaka relacije. Predmetom istraživanja su mala i srednja poduzeća u Republici Hrvatskoj. Koriste se sekundarni podaci prikupljeni iz financijskih izvještaja pojedinačnog poduzeća. Podaci su se prikupili s internetskih stranica FINA-e iz Registra godišnjih financijskih izvještaja i Sudskog registra, osim rasta BDP-a i stope inflacije koji su se dobili s internetske stranice Državnog zavoda za statistiku. Strategija određivanja uzorka bila je odabir malih i srednjih poduzeća u četiri različita sektora koji čine najviši udio u ukupnom broju malih i srednjih poduzeća.

Uzorak je napravljen sa stajališta raspoloživosti podataka tako da su se uzela samo ona poduzeća kod kojih se je moglo doći do svih stavki potrebnih za analizu. Veličina uzorka je oko 80 poduzeća po sektoru ili 25 % po sektoru u ukupnom uzorku, što znači oko 1.600 promatranja:

- Sektor trgovine na veliko i malo (24,38 % MSP-a) gdje će se zasebno razmatrati:
 - o trgovinu na veliko i
 - o trgovinu na malo;
- prerađivački sektor (11,55 % MSP-a);
- građevinarstvo (11,26 % MSP-a).

Sektor stručne, znanstvene i tehničke djelatnosti nije bio predmetom analize, iako prema broju poduzeća čini 15,77 % u ukupnom broju malih i srednjih poduzeća. Izostavljen je iz analize zbog raznolikosti djelokruga poslovanja pa su u skladu s time nelogičnosti i nedosljednosti u interpretaciji rezultata. Djelatnosti pružanja smještaja te pripreme i usluživanja hrane čine 7,76 % u ukupnom broju malih i srednjih poduzeća te su također izostavljene iz analize. Činjenica da čine ispod 10 % ukupnih malih i srednjih poduzeća, nije utjecala na njihovo izostavljanje u analizi. Razlog tomu je njihova tekuća imovina koja čini manje od 20 % ukupne imovine, i u isto vrijeme njihove tekuće obveze čine manje od 30 % ukupne pasive pa zbog neprisutnosti visoke razine obrtnog kapitala, iste nisu bile predmetom analize. Sve ostale djelatnosti čine ispod 5 % u ukupnom broju malih i srednjih poduzeća pa zbog njihova mala udjela u ukupnim malim i srednjim poduzećima nisu bile predmetom analize. Prema podacima FINA-e iz 2015. godine trgovina na veliko, trgovina na malo, prerađivački sektor i građevinarstvo sudjeluju s gotovo 50 % udjela u ukupnim rezultatima poslovanja, 47,19 % udjela u ukupnom broju poduzeća, 55,93 % u ukupnom broju zaposlenih, 64,74 % u ukupnom prihodu.

U odgovarajućem panel-modelu zavisna varijabla je profitabilnost, a nezavisne varijable potraživanja od kupaca, zalihe i obveze prema dobavljačima, dok su kontrolne varijable veličina poduzeća, rast prodaje, BDP, inflacija i sektor (pripadnost industriji). Za mjeru zavisne varijable profitabilnost koristi se prinos na imovinu (ROA). Za mjeru nezavisne varijable potraživanja od kupaca koriste se dani naplate potraživanja, za zalihe dani vezivanja zaliha, za dobavljače dani plaćanja

dobavljačima. Za mjeru kontrolne varijable veličina poduzeća koristi se logaritam prodaje dok je mjera za rast prodaje postotna promjena prodaje u odnosu na prethodnu godinu izražena u decimalnom broju. Stopa inflacije je izražena kao postotak inflacije u tekućoj godini u odnosu na prethodnu godinu izražena u decimalnom broju. Rast BDP-a izražen je kao postotak rasta BDP-a u tekućoj godini u odnosu na prethodnu godinu izražen u decimalnom broju. Podaci su analizirani u programskom paketu STATA 14.

Metodologija rada prikazana po hipotezama:

H1: Potraživanja od kupaca, zalihe, obveze prema dobavljačima, veličina poduzeća i rast prodaje na razini poduzeća utječu na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj.

1. na temelju dosadašnjih istraživanja metodom dedukcije određeni su čimbenici upravljanja obrtnim kapitalom na razini poduzeća koji utječu na visinu profitabilnosti malih i srednjih poduzeća;
2. usporedio se utjecaj istih na profitabilnost malih i srednjih poduzeća te su se metodom indukcije izolirali čimbenici upravljanja obrtnim kapitalom koji značajnije utječu na visinu profitabilnost malih i srednjih poduzeća;
3. provela se statistička obrada prikupljenih podataka koja uključuje deskriptivnu statistiku;
4. odredio se regresijski model panel-podataka koji je pokazao utjecaj izoliranih čimbenika na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj;
5. očekivalo se postojanje značajnog negativnog utjecaja potraživanja od kupaca i zaliha na visinu profitabilnosti malih i srednjih poduzeća;
6. očekivalo se postojanje značajnog pozitivnog utjecaja obveza prema dobavljačima, veličine poduzeća i rasta prodaje na visinu profitabilnosti malih i srednjih poduzeća;
7. očekivalo se postojanje utjecaja inflacije i BDP-a na visinu profitabilnosti malih i srednjih poduzeća;
8. dedukcijom su se izvukli zaključci o smjernicama koje su vezane uz dobivene nalaze i njihovom utjecaju na rizik.

H2: Utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća i rasta prodaje poduzeća na visinu profitabilnosti malih i srednjih poduzeća je različit u različitim sektorima.

1. postavilo se pitanje utječu li izolirani čimbenici uistinu u istoj mjeri na profitabilnost poduzeća unutar različitih sektora?;
2. očekivalo se da će utjecaj među različitim sektorima biti različit i različitog intenziteta;
3. očekivalo se da će razlike biti drugačije između istraživanja za razvijene zemlje, zemlje u razvoju i zemlje u tranziciji;
4. provela se statistička obrada podataka nad prikupljenim podacima, posebno za svaki sektor;
5. izradio se posebni regresijski modeli nad panel-podacima za svaki pojedini sektor.

1.6. Struktura rada

Polazeći od osnovnog problema, predmeta, zadanih ciljeva, očekivanih znanstvenih doprinosa i pregleda dosadašnjih istraživanja, prezentirani su rezultati istraživanja radi dokazivanja temeljnih radnih i pomoćnih hipoteza primjenom različitih znanstvenih metoda u ovom doktorskom radu u sedam međusobno povezanih poglavlja.

U prvom poglavlju **Uvodu**, definirani su problem i predmet istraživanja, ciljevi istraživanja i očekivani znanstveni doprinosi, dvije temeljne radne hipoteze i pomoćne hipoteze koje potkrepljuju temeljne znanstvene hipoteze. Izložen je kratak pregled dosadašnjih istraživanja drugih istraživača te su navedene znanstvene metode koje su se koristile u svrhu dokazivanja postavljenih hipoteza i prezentiranja rezultata istraživanja. Dan je kratak pregled strukture rada.

U drugom poglavlju s naslovom **Pojmovno određivanje malih i srednjih poduzeća** definirani su kriteriji određenja malih i srednjih poduzeća te upotrebe različitih definicija malih i srednjih poduzeća u Hrvatskoj i svijetu. Prikazana je struktura, veličina i sastav malih i srednjih poduzeća u Republici Hrvatskoj i odabranim zemljama Europske unije. Na kraju poglavlja definirane su ključne razlike između malih i srednjih poduzeća i velikih poduzeća.

U trećem poglavlju **Gospodarstvo Republike Hrvatske** definiran je pojam tranzicije kojim se označavaju zemlje u tranziciji te glavne sastavnice tranzicijskog procesa. Prema tranzicijskim pokazateljima, koje je razvila Europska banka za obnovu i razvoj, analiziran je napredak Republike Hrvatske i odabranih zemalja u procesu tranzicije. Poseban osvrt dan je na poduzetničke probleme malih i srednjih poduzeća u Republici Hrvatskoj te na institucionalnu potporu za mala i srednja poduzeća u Republici Hrvatskoj. Na kraju trećeg poglavlja analizirao se pristup financiranju i ispitivali su se različiti kriteriji koji određuju financiranje u pojedinoj zemlji.

Upravljanje obrtnim kapitalom naslov je četvrtog poglavlja doktorskog rada. U ovom poglavlju pojmovno su određeni bruto obrtni kapital, neto obrtni kapital i neto operativni obrtni kapital ili nenovčani obrtni kapital koji je u fokusu ovog doktorskog rada. Ilustriran je ciklus konverzije novca kao najčešća mjera učinkovitosti upravljanja obrtnim kapitalom. Nakon toga, definirano je utvrđivanje optimalne veličine i strukture obrtnog kapitala te problem njezina postizanja u praksi. Na kraju poglavlja kvalitativno je analizirano upravljanje tekućom imovinom kao i upravljanje tekućim obvezama.

U petom poglavlju pod naslovom **Strategije upravljanja obrtnim kapitalom** dan je pregled strategija upravljanja obrtnim kapitalom. Analiziran je utjecaj različitih strategija investiranja i financiranja obrtnog kapitala na profitabilnost, rizik, likvidnost i sigurnost poslovanja. Sistematizirani su pokazatelji obrtnog kapitala te je prikazan utjecaj sektora na upravljanje obrtnim kapitalom.

U šestom poglavlju rada s naslovom **Model utjecaja upravljanja obrtnim kapitalom na profitabilnost malih i srednjih poduzeća u Republici Hrvatskoj** prezentiran je empirijski dio istraživanja fokusiran na testiranje hipoteza i ostvarivanje ciljeva istraživanja. Teorijskim razmatranjima i empirijskim potvrdama utvrdili su se i sistematizirali ključni čimbenici upravljanja obrtnim kapitalom na razini poduzeća koji značajno utječu na profitabilnost malih i srednjih poduzeća u svim sektorima. Panel analizom ispitao se utjecaj utvrđenih čimbenika upravljanja obrtnim kapitalom na razini poduzeća na profitabilnost malih i srednjih poduzeća. Panel-analizom podataka ispitao se utjecaj utvrđenih čimbenika upravljanja obrtnim kapitalom na razini poduzeća na profitabilnost malih i srednjih poduzeća pojedinačno u četiri sektora, i to u: građevinarstvu, prerađivačkom sektoru, trgovini na malo i trgovini na veliko. Prikazani su rezultati empirijskog istraživanja po glavnim i pomoćnim hipotezama. Na kraju su deskriptivnom statistikom utvrđene politike upravljanja obrtnim kapitalom po sektorima.

U posljednjem dijelu, **Zaključku**, sustavno, koncizno i na jezgrovit način izložene su sve relevantne spoznaje, informacije, stavovi, znanstvene činjenice, teorije, zakoni te su formulirani i prezentirani najvažniji rezultati znanstvenih istraživanja, koji su prethodno detaljno predstavljani i elaborirani u analitičkom dijelu doktorskog rada, a kojima se dokazuju postavljene temeljne radne hipoteze i pomoćne hipoteze.

2. POJMOVNO ODREĐIVANJE MALIH I SREDNJIH PODUZEĆA

Mala i srednja poduzeća (MSP) ključni su izvor gospodarskog rasta. Oni sudjeluju s oko 99 % u ukupnom broju poduzeća¹, 69 % u ukupnom broju zaposlenih, 54 % u ukupnim prihodima, 56 % u dobiti razdoblja te 50 % u ukupnom izvozu u Republici Hrvatskoj. U Europskoj uniji devet od svakih deset poduzeća su mala i srednja poduzeća, a dva od svaka tri radna mjesta su u malim i srednjim poduzećima (Europska komisija, 2016). „U Europskom gospodarskom prostoru posluje oko 20 milijuna mikropoduzeća, malih i srednjih poduzeća. Ona su veliki izvor radnih mjesta i izazov za konkurentnost“ (Europska komisija, 2003a).

2.1. Definicija malih i srednjih poduzeća i njezina primjena

Zbog velike važnosti malih i srednjih poduzeća u gospodarskom rastu i stabilnosti zemlje, malim i srednjim poduzećima u državama Europske unije na raspolaganju su sredstva iz EU fondova u obliku bespovratnih potpora, zajmova i jamstva te sredstva iz različitih programa na nacionalnoj razini. Malim i srednjim poduzećima izuzetno je važno imati status malog i srednjeg poduzeća kako bi udovoljili definiranim kriterijima za primanje različitih namjenskih potpora i subvencija. Kriteriji za utvrđivanje veličine malih i srednjih poduzeća su različiti između država. Iz toga razloga je potrebna jasna definicija koja će mala i srednja poduzeća razlikovati od velikih poduzeća kako bi se izbjegli problemi nepravedne i neravnomjerne raspodjele sredstava.

„Zajedničkom definicijom pridonosi se poboljšanju dosljednosti i učinkovitosti politike za mala i srednja poduzeća diljem Europske unije. Štoviše, to je još potrebnije s obzirom na intenzivno međudjelovanje između nacionalnih mjera i mjera Europske unije čija je svrha pomoći malim i srednjim poduzećima u područjima kao što se regionalni razvoj i financiranje istraživanja“ (Europska komisija, 2016: 5). Prva definicija malih i srednjih poduzeća na razini Europske unije nastala je 1996. godine (Preporuka Komisije, 96/280/EZ), a 2003. godine je revidirana kako bi se njome riješile prepreke s kojima se suočavaju mala i srednja poduzeća. Revizije definicije iz 2003. godine uglavnom su se odnosile na ažuriranje pragova, utvrđivanje financijskih pragova za rastući broj mikropoduzeća, olakšavanje financiranja vlasničkog kapitala,

¹ U 2015. godini u Republici Hrvatskoj posluje 106.221 mikro, malih i srednjih poduzeća

promicanje inovacija i uzimanje u obzir različitih odnosa među poduzećima (Europska komisija, 2016).

Dva su glavna kriterija koja razlikuju mala i srednja poduzeća u odnosu na velika poduzeća (Europska komisija, 2016):

- veličina (broj zaposlenika, godišnji promet i ukupna bilanca) i
- resursi (vlasništvo, partnerstva i veze).

Poduzeće može imati zadovoljen kriterij veličine, ali ako ima pristup znatnim dodatnim resursima, možda nema pravo na status malog i srednjeg poduzeća pa će nekada biti potrebna i detaljnija analiza ciljanog poduzeća kako bi se utvrdio status poduzeća (Europska komisija, 2016). Prema preporuci Europske komisije (2003b) „kriterij broja zaposlenih („kriterij broja osoblja“) nesumnjivo ostaje jedan od najvažnijih kriterija i mora ga se poštovati kao glavni kriterij“. Europska komisija smatra da samo kriterij broja zaposlenih nije dovoljan, pa uvodi i financijski kriterij, i to kriterij godišnjeg prometa i kriterij ukupne imovine.

Europska komisija (2003b) donosi definiciju mikropoduzeća, malih i srednjih poduzeća unutar koje definira broj zaposlenika i financijske pragove koji određuju kategorije poduzeća:

1. Kategorija mikropoduzeća, malih i srednjih poduzeća (MSP-ova) sastoji se od poduzeća koja imaju manje od 250 zaposlenih i koja imaju godišnji promet koji ne prelazi 50 milijuna eura i/ili godišnju bilancu koja ne prelazi 43 milijuna eura.
2. Unutar kategorije MSP-ova, malo poduzeće definira se kao poduzeće koje ima manje od 50 zaposlenih, a čiji godišnji promet i/ili godišnja bilanca ne prelazi 10 milijuna eura.
3. Unutar kategorije MSP-ova, mikropoduzeće definira se kao poduzeće koje ima manje od 10 zaposlenih, a čiji godišnji promet i/ili godišnja bilanca ne prelazi 2 milijuna eura.

„Broj zaposlenika obvezni je kriterij kada se utvrđuje može li se poduzeće smatrati malim i srednjim poduzećem i, ako može, kojoj kategoriji malog i srednjeg poduzeća pripada. Ako poduzeće ne zadovoljava taj kriterij, ne može se smatrati malim i srednjim poduzećem. S druge strane, poduzeće može izabrati hoće li zadovoljiti kriterij gornje granice prometa ili ukupne bilance. Ono ne mora zadovoljiti oba uvjeta i može

premašiti jedan od njih bez utjecaja na njegov status MSP-a“ (Europska komisija, 2016: 11-12).

Osim navedenih pragova vezanih za veličinu, poduzeće mora, prije svega, utvrditi je li (Europska komisija, 2016: 7):

- neovisno poduzeće: ako je poduzeće potpuno neovisno ili je stranka u jednom ili više manjinskih partnerstva (svako manje od 25 %) s drugim poduzećima;
- partnersko poduzeće: poduzeće ima udjel od najmanje 25 %, ali ne više od 50 % kapitala ili glasačkih prava u drugom poduzeću i/ili drugo poduzeće ima udjel od najmanje 25 %, ali ne više od 50 % u predmetnom poduzeću;
- povezano poduzeće: ako udjeli u drugim poduzećima premašuju prag od 50 %, ta se poduzeća smatraju povezanim poduzećima (više u Europska komisija, 2016) .

Nakon što je poduzeće razvrstano u jednu od kategorija, pomoću izračuna će utvrditi pripada li malom i srednjem poduzeću ili ne. U slučaju ako npr. premašuje broj zaposlenih, neće se smatrati malim i srednjim poduzećem. U određenim se slučajevima zbog navedenih odnosa poduzeće ne može smatrati malim i srednjim poduzećem, posebno ako se njima stvaraju znatne vlasničke veze ili se osigurava pristup dodatnim financijskim ili drugim resursima (Europska komisija, 2016).

2.1.1. Kriteriji za definiranje malih i srednjih poduzeća u svijetu

Definicije malih i srednjih poduzeća razlikuju se među državama, različitim agencijama i institucijama, ali i među brojnim znanstvenicima i istraživačima koji se njima bave. Ipak, najviše literature oslanja se na kriterij zaposlenika pri definiranju i razvrstavanju poduzeća prema veličini. Berisha i Shiroka Pula (2015) u svom radu bave se kritičkim pristupom definiranja malih i srednjih poduzeća s posebnim naglaskom na nedosljednosti kriterija i različitim prijedlozima pristupa definiciji. Naglašavaju da je najveći problem u literaturi terminologija koja se koristi za kategorizaciju malih i srednjih poduzeća. Jedan dio literature odnosi se na njih kao mala poduzeća, drugi koriste koncept malog i srednjeg poduzeća, dok ih neki nazivaju mikro, malim i srednjim poduzećima. Iako se odnose na istu vrstu poslovanja, definicije se razlikuju po stupnju uključivanja tih poduzeća u opći naziv. Međutim Berisha i Shiroka Pula (2015) naglašavaju da se autor ili institucija mogu opredijeliti za korištenje bilo kojeg termina ako navedu prednosti usvojenog termina.

Razlike definicije malih i srednjih poduzeća protežu se na tri strane (Berisha i Shiroka Pula, 2015):

- definicije međunarodnih ustanova
- definicije nacionalnih zakona i
- definicije po sektorima.

Svaki projekt u sklopu kojeg se dodjeljuju različita bespovratna sredstva ima jasno definirane krajnje korisnike kako bi se sredstva pravedno i ravnomjerno raspodijelila. Zbog toga je izuzetno važno imati jasno definirane kriterije razvrstavanja poduzeća na mikro, mala i srednja poduzeća. Često međunarodne organizacije i vlade pojedinih država surađuju prilikom dodjele sredstava u sklopu različitih programa. No, nerijetko se događa da se njihovi kriteriji razlikuju, ako ne po razinama kriterija, onda po valuti. To zna izazvati dodatni problem i poduzećima otežati proceduru dobivanja sredstava.

Unutar grupe Svjetske banke, IFC (*International Finance Corporation*) i MIGA (*Multilateral Investment Guarantee Agency*) imaju službene definicije, ali također definiraju mala i srednja poduzeća na različite načine. Prema IFC i MIGA, mala i srednja poduzeća su poduzeća koja ispunjavaju dva od tri kriterija (IEG: 2014, 16):

- imaju više od 10 i manje od 300 zaposlenika;
- imaju prodaju između \$100 000 i \$15 milijuna;
- imaju imovinu između \$100 000 i \$15 milijuna.

IFC i MIGA ne prilagođavaju svoju definiciju prema razini dohotka zemlje, veličini gospodarstva, sektoru ili drugim kriterijima. Oni usvajaju jedan standard što izaziva snažnu proturječnost za primjenjivost sadašnje definicije u mnogim zemljama. Smatra se da je granica previsoka i da mala i srednja poduzeća uključuju neka od najboljih poduzeća (IEG: 2014).

Svjetska banka ima mnogo definicija – za pregled svojih poduzeća (poduzeća s 5-99 zaposlenika), za svoja istraživanja (u nekim slučajevima sve do 99 zaposlenika, u drugima do 250 zaposlenika) i za pojedinačne projekte (najčešće prema nacionalnim standardima). Svjetska banka nema dosljednu osnovu za klasifikaciju poduzeća. Odgovarajuća razlika u veličini bi, u najmanju ruku, trebala uzeti u obzir razinu dohotka u zemlji te bi se u teoriji mogla informirati o drugim čimbenicima (primjerice, veličini domaćeg gospodarstva i slično) (IEG: 2014).

Kao što je prije istaknuto, Europska komisija kriterij zaposlenika definira kao najvažniji kriterij. Istraživanje koje je napravila Svjetska banka na uzorku od 132 standarda zemlje o tome što predstavlja malu i srednju tvrtku, 250 zaposlenika je najčešća gornja granica definiranja malih i srednjih poduzeća (IEG: 2014).

Svjetska banka (WBG) definira mikro, mala i srednja poduzeća (IEG: 2008):

- mikropoduzeća imaju: ≤ 10 zaposlenika i $\leq \$100\ 000$ ukupne imovine ili $\leq \$100\ 000$ ukupne godišnje prodaje;
- mala poduzeća imaju: > 10 ; ≤ 50 zaposlenika i $> \$100\ 000$; $\leq \$3\ 000\ 000$ ukupne imovine ili $> \$100\ 000$; $\leq \$3\ 000\ 000$ ukupne godišnje prodaje i
- srednja poduzeća imaju > 50 ; ≤ 300 zaposlenika i $> \$3\ 000\ 000$; $\leq \$15\ 000\ 000$ ukupne imovine ili $> \$3\ 000\ 000$; $\leq \$15\ 000\ 000$ ukupne godišnje prodaje.

Zemlje Europske unije najčešće primjenjuju definiciju Europske komisije pri čemu Europska komisija potiče članice na primjenu, ali ih ne obvezuje. „Iako broj zaposlenih predstavlja objektivan i lako primjenjiv kriterij, on ima važna ograničenja, prvenstveno zato što broj zaposlenih ovisi o sektoru u kojem poduzeće posluje što otežava generaliziranje usporedbe između sektora“ (Stokes et al., 2010 u Berisha i Široka Pula, 2015).

Kao primjer dobre prakse, koja uvažava posebnosti sektora u kojem poduzeće posluje, mogu se navesti Sjedinjene Američke Države gdje definicija malih i srednjih poduzeća varira ovisno o sektoru. U SAD-u Američka administracija malih poduzeća (SBA) razvija standarde veličina za svaku NAICS² kategoriju. Na primjer, standard broj zaposlenih u proizvodnji i drugim sektorima (osim sektora trgovine na veliko i trgovine na malo), SBA usvaja šest razina, i to: 250 zaposlenika, 500 zaposlenika, 750 zaposlenika, 1 000 zaposlenika, 1 250 zaposlenika i 1 500 zaposlenika. Za sektor trgovine na veliko i trgovine na malo SBA koristi četiri razine: 100 zaposlenika, 150 zaposlenika, 200 zaposlenika i 250 zaposlenika (U.S. Small Business Administration,

² NAICS je sustav koji su razvili SAD, Kanada i Meksiko. NAICS je prvi sektorski sustav klasifikacije koji je razvijen u skladu s jednim principom agregacije. Principom da se proizvodne jedinice koje koriste slične proizvodne procese trebaju grupirati zajedno. NAICS je izvorno razvijen kako bi osigurao dosljedan okvir za prikupljanje, analizu i distribuciju sektorske statistike koju koriste analitičari vladinih politika, akademici i istraživači, poslovne zajednice i javnost (Executive office of the president of the United States, 2017).

2018). Kina, također, ima kriterije veličine poduzeća u ovisnosti o sektoru u kojem poduzeće posluje.

2.1.2. Kriteriji za definiranje malih i srednjih poduzeća u Hrvatskoj

Kriteriji za razvrstavanje poduzeća na mikro, mala i srednja u Hrvatskoj definirani su Zakonom o računovodstvu (NN 120/16) i Zakonom o poticanju razvoja malog gospodarstva (NN 121/16).

Prema Zakonu o računovodstvu (NN 120/16, čl.5) poduzeća se razvrstavaju na mikro, mala, srednja i velika ovisno o pokazateljima utvrđenim na zadnji dan poslovne godine koja prethodi poslovnoj godini za koju se sastavljaju financijski izvještaji. Pokazatelji na temelju kojih se razvrstavaju poduzeća su: iznos ukupne aktive, iznos prihoda i prosječan broj radnika tijekom poslovne godine.

Prema Zakonu o računovodstvu (NN 120/16, čl.5) mikropoduzeća su ona koje ne prelaze granične pokazatelje u dva od sljedeća tri uvjeta:

- ukupna aktiva 2 600 000,00 kuna
- prihod 5 200 000,00 kuna
- prosječan broj radnika tijekom poslovne godine – 10 radnika.

Mala poduzeća su ona koji nisu mikropoduzeća i ne prelaze granične pokazatelje u dva od sljedeća tri uvjeta:

- ukupna aktiva 30 000 000,00 kuna
- prihod 60 000 000,00 kuna
- prosječan broj radnika tijekom poslovne godine – 50 radnika.

Srednja poduzeća su ona koji nisu ni mikro ni mala poduzeća i ne prelaze granične pokazatelje u dva od sljedeća tri uvjeta:

- ukupna aktiva 150 000 000,00 kuna
- prihod 300 000 000,00 kuna
- prosječan broj radnika tijekom poslovne godine – 250 radnika.

Velika poduzeća su ona koja prelaze dva uvjeta iz definicije srednjih poduzeća.

Prema veličini u smislu Zakona o poticanju razvoja malog gospodarstva (NN 121/16) razlikuju se mikro, mali i srednji subjekti malog gospodarstva.

Mikrosubjekti malog gospodarstva su fizičke i pravne osobe iz članka 2. ovoga Zakona, koje:

- 1) prosječno godišnje imaju zaposleno manje od 10 radnika;
- 2) prema financijskim izvještajima za prethodnu godinu ostvaruju godišnji poslovni prihod u iznosu protuvrijednosti do 2 000 000,00 eura, ili imaju ukupnu aktivu ako su obveznici poreza na dobit, odnosno imaju dugotrajnu imovinu ako su obveznici poreza na dohodak, u iznosu protuvrijednosti do 2 000 000,00 eura.

Mali subjekti malog gospodarstva su fizičke i pravne osobe iz članka 2. ovoga Zakona, koje:

- 1) prosječno godišnje imaju zaposleno manje od 50 radnika;
- 2) prema financijskim izvještajima za prethodnu godinu ostvaruju godišnji poslovni prihod u iznosu protuvrijednosti do 10 000 000,00 eura, ili imaju ukupnu aktivu ako su obveznici poreza na dobit, odnosno imaju dugotrajnu imovinu ako su obveznici poreza na dohodak, u iznosu protuvrijednosti do 10 000 000,00 eura.

Srednji subjekti malog gospodarstva su fizičke i pravne osobe iz članka 2. ovoga Zakona koje:

- 1) prosječno godišnje zapošljavaju između 50 i 249 radnika;
- 2) imaju godišnji poslovni prihod u iznosu protuvrijednosti od 10 000 000,00 eura do 50 000 000,00 eura, ili imaju ukupnu aktivu ako su obveznici poreza na dobit, odnosno imaju dugotrajnu imovinu ako su obveznici poreza na dohodak, u iznosu protuvrijednosti od 10 000 000,00 eura do 43 000 000,00 eura i u poslovanju su neovisni.

Iako su Zakon o računovodstvu i Zakon o poticanju razvoja malog gospodarstva izmijenjeni stupili na snagu 1. 1. 2017., odnosno 31. 12. 2016. godine, nisu usuglašeni vezano za pokazatelje iznos prihoda i iznos ukupne aktive. Pokazatelji razvrstavanja poduzeća prema veličini su prema Zakonu o poticanju razvoja malog gospodarstva u skladu s Preporukom Komisije 2003/361/EC od 6. svibnja 2003. godine.

2.1.3. Trgovačka društva prema pravno ustrojbenim oblicima

Trgovačka društva prema pravno ustrojbenim oblicima mogu biti: dionička društva (d.d.), društva s ograničenom odgovornošću (d.o.o.), jednostavna društva s

ograničenom odgovornošću (j.d.o.o.), javna trgovačka društva, glavne podružnice inozemnih trgovačkih društava ili inozemnih trgovaca pojedinaca i ostali pravno ustrojbeni oblici. U tablici broj 1 prikazana je struktura trgovačkih društava prema pravno ustrojbenim oblicima i aktivnosti.

Tablica 1. Trgovačka društva prema pravno ustrojbenim oblicima i aktivnosti, stanje 31. prosinca 2015.

	Registrirani	Aktivni
Dionička društva	1 369	1 188
Društva s ograničenom odgovornošću	145 664	127 996
Jednostavna društva s ograničenom odgovornošću	24 288	24 277
Javna trgovačka društva	376	303
Glavne podružnice inozemnih trgovačkih društava	739	547
Ostali pravno ustrojbeni oblici	262	212
Ukupno	172 698	154 523

Izvor: DZS, https://www.dzs.hr/Hrv_Eng/publication/2015/11-01-01_04_2015.htm (26.08.2018.)

Udio aktivnih poduzeća u ukupnom broju registriranih poduzeća 2015. godine iznosio je oko 87 %. Posljednjih pet godina taj udio je naglo porastao zbog akcije brisanja neaktivnih poduzeća iz Sudskog registra trgovačkih društava. To je omogućeno izmjenama Zakona o sudskom registru, članak 70 (NN 148/13). Jedan od najčešćih razloga brisanja je ako poduzeće tri godine zaredom nije objavilo svoje godišnje financijske izvještaje s propisanom dokumentacijom, a propisana im je obveza objavljivanja izvještaja ili ako nema imovinu, odnosno ako ima imovinu neznatne vrijednosti.

U 2015. godini najveći udio u ukupnom broju trgovačkih društava čine društva s ograničenom odgovornošću (d.o.o.) i to 82,83 %. Zbog pristupanja Republike Hrvatske Europskoj uniji i obveze usklađivanja zakona, 2012. godine Zakonom o trgovačkim društvima (NN 111/12) uvodi se novi oblik trgovačkog društva. Riječ je o jednostavnom društvu s ograničenom odgovornošću (j.d.o.o.). Cilj uvođenja ovog oblika trgovačkog društva je olakšavanje poslovanja i pojednostavljenje osnivanja trgovačkog društva. Udio jednostavnih društava s ograničenom odgovornošću (j.d.o.o.) u ukupnom broju trgovačkih društava od 15,71 % (j.d.o.o.) govori u prilog tomu da je ovakav oblik

trgovačkog društva bio prijeko potreban hrvatskom pravnom sustavu. Ispod 1 % čine dionička društva (0,77 %), javna trgovačka društva (0,20 %), glavne podružnice inozemnih trgovačkih društava (0,35 %) i ostali pravno ustrojbeni oblici (0,14 %).

2.2. Struktura, veličina i sastav malih i srednjih poduzeća u Republici Hrvatskoj i odabranim zemljama EU-a

Podatci prikazani u ovom poglavlju o broju poduzeća, broju zaposlenih i dodanoj vrijednosti za Republiku Hrvatsku prikupljeni su iz statističke baze podataka Državnog zavoda za statistiku, a za zemlje Europske unije iz statističke baze podataka EUROSTAT-a. Državni zavod za statistiku definira dodanu vrijednost prema troškovima proizvodnih čimbenika kao bruto zaradu od poslovnih aktivnosti poduzeća prilagođenu za operativne subvencije i indirektne poreze, izračunana u bruto izrazu (bez oduzimanja amortizacije). Prihod i rashod klasificiran kao financijski isključen je iz dodane vrijednosti (DZS, 2015b).

2.2.1. Strukturno-poslovni pokazatelji poduzeća u Republici Hrvatskoj

U 2015. godini bilo je aktivno 146 637 poduzeća s 989 598 zaposlenih osoba. Ta poduzeća ostvarila su dodanu vrijednost u iznosu od 161 487 506 tisuća kuna. U tablici broj 2 prikazan je ukupan broj poduzeća, ukupan broj zaposlenih osoba i dodana vrijednost prema troškovima proizvodnih čimbenika prema veličini poduzeća u Republici Hrvatskoj u 2015. godini.

Tablica 2. Ukupan broj poduzeća, ukupan broj zaposlenih osoba i dodana vrijednost prema veličini poduzeća u 2015. godini

	Poduzeća		Zaposlenost		Dodana vrijednost (000')	
Veličina	Broj	%	Broj	%	Broj	%
Mikro	134 026	91,4	302 817	30,6	29 229 239	18,1
Mala	10 411	7,1	198 909	20,1	31 813 039	19,7
Srednja	1 760	1,2	185 055	18,7	33 427 914	20,7
MSP	146 197	99,7	687 771	69,5	94 470 192	58,5
Velika	440	0,3	301 827	30,5	67 017 315	41,5
Ukupno	146 637	100	989 598	100	161 487 506	100

Izvor: Izrada autorice prema javno dostupnim podacima na www.dzs.hr (29.08.2017.)

Iz tablice broj 2 vidljivo je da najveći broj poduzeća čine mikropoduzeća i to s udjelom od 91,4 % u ukupnom broju poduzeća. U 2015. godini mikro, mala i srednja poduzeća zapošljavaju 687 771 zaposlenika što čini udio od 69,50 % u ukupnom broju zaposlenih osoba. U strukturi mikro, malih i srednjih poduzeća najviše zapošljavaju mikropoduzeća i to 302 817 osoba što čini 30,6 % u ukupnom broju zaposlenih osoba. Mikropoduzeća zapošljavaju za više od 100 000 zaposlenika u odnosu na mala i srednja poduzeća. Najvišu dodanu vrijednost ostvaruju velika poduzeća, i to duplo više od mikropoduzeća, malih poduzeća i srednjih poduzeća odnosno 41,5 % u ukupno ostvarenoj dodanoj vrijednosti.

Mala i srednja poduzeća u Hrvatskoj u prosjeku zapošljavaju 5 zaposlenika. Mikropoduzeća u prosjeku zapošljavaju 2 zaposlenika, mala poduzeća u prosjeku zapošljavaju 19 zaposlenika, dok srednja poduzeća u prosjeku zapošljavaju 105 zaposlenika. Prosječna dodana vrijednost po zaposleniku u mikropoduzeću iznosila je 96 524 HRK, u malom poduzeću 159 937 HRK, a u srednjem poduzeću 180 638 HRK.

2.2.1.1. Broj poduzeća prema gospodarskoj djelatnosti i veličini poduzeća

Tablica 3 prikazuje podatke o ukupnom broju poduzeća razvrstanih prema gospodarskoj djelatnosti i veličini poduzeća u Republici Hrvatskoj. U 2015. godini najveći broj poduzeća čine mikropoduzeća (91,40 %) u kojima je najzastupljeniji sektor trgovina na veliko i na malo; popravak motornih vozila i motocikla s udjelom od 25,77 %. Sektor trgovina na veliko i na malo; popravak motornih vozila i motocikla ima najveći broj poduzeća u poduzećima svih veličina. Nakon mikropoduzeća slijede mala poduzeća (7,10 %), zatim srednja poduzeća (1,20 %) i velika poduzeća (0,30 %).

Sektor trgovine na veliko i malo ima udio od 25,46 % u ukupnom broju poduzeća, a sektor stručne, znanstvene i tehničke djelatnosti 16,08 %. Djelatnost pružanja smještaja te pripreme i usluživanja hrane ima udio od 13,50 %, prerađivački sektor 13,45 % i građevinarstvo 11,99 % u ukupnom broju poduzeća.

Kod malih i srednjih poduzeća, nakon sektora trgovine na veliko i malo (25,49 %), najzastupljeniji broj poduzeća je u stručnim, znanstvenim i tehničkim djelatnostima s udjelom od 16,13 %, zatim u djelatnosti pružanja smještaja te pripreme i usluživanja hrane (13,52 %), prerađivačkom sektoru (13,38 %) i građevinarstvu (12,00 %).

Tablica 3. Broj poduzeća prema gospodarskoj djelatnosti i veličini poduzeća u 2015. godini

	Broj poduzeća	MSP				Velika
		Ukupno	Mikro	Mala	Srednja	
Ukupno	146 637	146197	134026	10411	1 760	440
Rudarstvo i vađenje	233	230	176	47	7	3
Prerađivački sektor	19 716	19 558	16 344	2 563	651	158
Opskrba električnom energijom, plinom, parom i klimatizacija	573	567	507	51	9	6
Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom...	853	840	469	269	102	13
Građevinarstvo	17 575	17 557	15 905	1 424	228	18
Trgovina na veliko i na malo; popravak motornih vozila i motocikla	37 340	37 265	34 539	2 390	336	75
Prijevoz i skladištenje	8 562	8 528	7 860	548	120	34
Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	19 790	19 770	18 444	1 207	119	20
Informacije i komunikacije	6 417	6 404	5 891	449	64	13
Poslovanje nekretninama	3 954	3 950	3 792	142	16	4
Stručne, znanstvene i tehničke djelatnosti	23 575	23 575	22 598	904	73	0
Administrativne i pomoćne uslužne djelatnosti	6 504	6 478	5 977	416	85	26
Popravak računala i predmeta za osobnu uporabu i kućanstvo	1 545	1 545	1 497	43	5	-

Izvor: Izrada autorice prema javno dostupnim podacima na www.dzs.hr (29.8.2017.)

2.2.1.2. Zaposlenost prema gospodarskoj djelatnosti i veličini poduzeća

Prosječno europsko poduzeće zapošljava najviše šest zaposlenika (Europska komisija, 2016: 7). Tablica 4 prikazuje broj zaposlenih osoba prema gospodarskoj djelatnosti i veličini poduzeća u Republici Hrvatskoj. U gospodarstvu najveću zaposlenost stvaraju mikropoduzeća koja zapošljavaju 302 817 osoba što je 30,60 % u ukupnom broju zaposlenih. Vrlo blizu su velika poduzeća koja zapošljavaju 30,50 % osoba. Mala poduzeća zapošljavaju 20,10 % osoba, dok srednja poduzeća zapošljavaju najmanje, odnosno 18,70 % ukupno zaposlenih osoba. Po broju zaposlenih osoba najvažniji je prerađivački sektor koji zapošljava 25,89 % zaposlenika, zatim trgovina na veliko i na malo s 22,93 % zaposlenika, građevinarstvo s 10,08 % zaposlenika, djelatnosti pružanja smještaja te pripreme i usluživanja hrane s 9,76 % zaposlenika te prijevoz i skladištenje s 8,53 % zaposlenika.

Kod malih i srednjih poduzeća najveću zaposlenost također stvara prerađivački sektor s 23,69 % ukupno zaposlenih osoba, zatim trgovina na veliko i malo s 22,23 %, građevinarstvo s 12,56 %, djelatnosti pružanja smještaja te pripreme i usluživanja hrane s 11,91 %, te stručne, znanstvene i tehničke djelatnosti s 9,98 % ukupno zaposlenih osoba.

Tablica 4. Broj zaposlenih osoba prema gospodarskoj djelatnosti i veličini poduzeća u 2015. godini

	Broj zaposlenih osoba	MSP				Velika
		Ukupno	Mikro	Mala	Srednja	
Ukupno	989 598	687 771	302817	198909	185055	301827
Rudarstvo i vađenje	12 261	2 195	466	1 091	638	10 066
Prerađivački sektor	256 173	162 926	40 988	52 259	69 679	93 247
Opskrba električnom energijom, plinom, parom i klimatizacija	14 893	2 889	849	1 191	849	12 004
Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom...	23 367	18 343	1 402	6 286	10 655	5 024
Građevinarstvo	99 790	86 418	37 521	27 043	21 954	13 372
Trgovina na veliko i na malo; popravak motornih vozila i motocikla	226 889	152 923	76 462	44 243	32 218	73 966
Prijevoz i skladištenje	84 413	40 349	18 486	9 961	11 902	44 064
Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	96 570	81 891	48 864	21 149	11 878	14 679
Informacije i komunikacije	39 209	27 133	11 920	8 548	6 666	12 076
Poslovanje nekretninama	11 315	10 421	6 020	2 738	1 663	894
Stručne, znanstvene i tehničke djelatnosti	71 681	68 670	45 302	16 128	7 168	3 011
Administrativne i pomoćne uslužne djelatnosti	49 102	29 265	11 735	7 955	9 575	19 837
Popravak računala i predmeta za osobnu uporabu i kućanstvo	3 935	3 935	2 900	681	354	-

Izvor: Izrada autorice prema javno dostupnim podatcima na www.dzs.hr (pristupljeno 29.8.2017.)

2.2.1.3. Dodana vrijednost prema gospodarskoj djelatnosti i veličini poduzeća

U tablici broj 5 prikazana je dodana vrijednost prema troškovima proizvodnih čimbenika prema gospodarskoj djelatnosti i veličini poduzeća u Republici Hrvatskoj. Po ostvarenoj dodanoj vrijednosti najvažnija su velika poduzeća koja ostvaruju dodanu vrijednost od 41,5 % u ukupno ostvarenoj dodanoj vrijednosti, zatim slijede srednja poduzeća (20,7 %), pa mala poduzeća (19,7 %) i na kraju mikropoduzeća (18,1 %).

Po stvaranju dodane vrijednosti najvažniji je prerađivački sektor koji ostvaruje 23,22 % u ukupno ostvarenoj dodanoj vrijednosti, zatim trgovina na veliko i na malo s 19,63 %, prijevoz i skladištenje s 10,30 %, građevinarstvo s 8,07 %, stručne, znanstvene i tehničke djelatnosti s 7,26 %, informacije i komunikacije s 7,24 % te djelatnosti pružanja smještaja te pripreme i usluživanja hrane s 7,09 %. Ostvarena dodana vrijednost po sektorima najvećim dijelom prati redoslijed broja zaposlenih pa su tako prerađivački sektor i trgovina na veliko i malo najznačajniji sektori po oba pokazatelja. Po ostvarenoj dodanoj vrijednosti među prvih pet sektora našle su se i informacije i komunikacije.

U malim i srednjim poduzećima najvažnije dvije djelatnosti po stvaranju dodane vrijednosti su trgovina na veliko i na malo (22,08 %) i prerađivački sektor (21,43 %). Nakon njih slijede stručne, znanstvene i tehničke djelatnosti (11,78 %), građevinarstvo (11,11 %), te djelatnosti pružanja smještaja te pripreme i usluživanja hrane (8,03 %).

Tablica 5. Ukupna dodana vrijednost i udjeli prema gospodarskoj djelatnosti i veličini poduzeća u 2015. godini

	Dodana vrijednost ³	MSP				Velika
		Ukupno	Mikro	Mala	Srednja	
Ukupno	161.487.506	94.470.191	29.229.238	31.813.039	33.427.914	67.017.315
Rudarstvo i vađenje	6 242 752	674 217	243 467	280 924	149 826	5 568.535
Prerađivački sektor	37 492 198	20 245 787	3 336 806	6 636 119	10 272 862	17 246 411
Opskrba el. energijom...	8 972 874	1 651 009	646 047	610 155	394 806	7 321 865
Opskrba vodom...	4 416 317	3 166 499	225 232	1 037 834	1 907 849	1 249 818
Građevinarstvo	13 027 329	10 500 027	2 527 302	3 738 843	4 233 882	2 527 302
Trgovina na veliko i na malo...	31 707 482	20 863 523	6 912 231	7 800 041	6 151 252	10 843 959
Prijevoz i skladištenje	16 632 427	6 403 484	1 862 832	2 428 334	2 112 318	10 228 943
Djelatnosti pružanja smještaja...	11 442 444	7 586 340	2 826 284	2 368 586	2 391 471	3 856 104
Informacije i komunikacije	11 696 093	5 543 948	1 497 100	1 801 198	2 245 650	6 152 145
Poslovanje nekretninama	2 956 641	2 859 072	2 004 603	641 591	212 878	97 569
Stručne, znanstvene i tehničke djelatnosti	11 727 581	11 129 474	5 711 332	3 283 723	2 134 420	598 107
Administrativne i pomoćne uslužne djelatnosti	4 751 481	3 373 552	1 183 119	1 192 622	997 811	1 377 929
Popravak računala...	421 887	421 887	208 834	29 532	183 521	-

Izvor: Izrada autorice prema javno dostupnim podacima na www.dzs.hr (29.8.2017.)

³ Dodana vrijednost prema troškovima proizvodnih čimbenika, tis. kuna

2.2.2. Strukturno poslovni pokazatelji poduzeća u zemljama Europske unije

Za usporedbu strukturno-poslovnih pokazatelja poduzeća Republike Hrvatske odabrana su poduzeća zemalja koje su imale i imaju izravan utjecaj na geopolitički i geoekonomske razvoj Republike Hrvatske. To su šest država koje su zajedno činile Socijalističku Federativnu Republiku Jugoslaviju: Slovenija, Hrvatska, Bosna i Hercegovina, Srbija, Crna Gora i Makedonija i dvanaest država članica Inicijative triju mora⁴. Za usporedbu su prikazani i strukturno-poslovni pokazatelji Velike Britanije te prosjek država članica Europske unije. U tablici broj 6 prikazan je broj poduzeća navedenih zemalja prema njihovoj veličini⁵.

Tablica 6. Broj poduzeća u odabranim zemljama Europske unije prema veličini poduzeća u 2015. godini

	Mikro		Mali		Srednji		Veliki	
EU	21800000	92,76%	1400000	5,96%	227976	0,97%	45524	0,19 %
Hrvatska	134 007	91,39%	10 450	7,13%	1 799	1,23%	381	0,26%
Slovenija	127 603	94,71%	5 800	4,31%	1 112	0,83%	212	0,16%
Austrija	280 850	87,13%	35 165	10,91%	5 228	1,62%	1 082	0,34%
Mađarska	504 904	94,09%	26 529	4,94%	4 323	0,81%	854	0,16%
Češka	961 287	96,03%	31 574	3,15%	6 629	0,66%	1 558	0,16%
Slovačka	414 630	96,53%	12 044	2,81%	2 319	0,54%	531	0,12%
Poljska	1 534 086	95,49%	54 369	3,38%	14 913	0,93%	3 191	0,20%
Estonija	61 513	90,30%	5 377	7,89%	1 062	1,56%	172	0,25%
Latvija	100 216	91,40%	7 792	7,11%	1 434	1,31%	200	0,18%
Litva	172 527	92,52%	11 405	6,12%	2 199	1,18%	337	0,18%
Rumunjska	405 493	88,51%	42 909	9,37%	8 078	1,76%	1 642	0,36%
Bugarska	298 559	91,52%	22 751	6,97%	4 240	1,30%	669	0,21%
BIH	59 540	90,49%	4 991	7,59%	1 076	1,64%	193	0,29%
Makedonija	49 502	90,43%	4 340	7,93%	739	1,35%	157	0,29%
Vel. Brit.	1 734 989	89,39%	171 361	8,29%	28 167	1,45%	6 430	0,33%

Izvor: Izrada autorice prema javno dostupnim podacima Eurostata na <http://ec.europa.eu/> (21.08.2018.)

⁴ Države članice Inicijative tri mora su: Hrvatska, Slovenija, Austrija, Mađarska, Češka, Slovačka, Poljska, Estonija, Latvija, Litva, Rumunjska i Bugarska.

⁵ Podaci za Crnu Goru i Srbiju nisu dostupni

Iz tablice 6 vidi se da mikropoduzeća u većini država Europske unije čine preko 90 % ukupnog broja poduzeća i da su okosnica gospodarstva svih zemalja. Udio malih poduzeća kreće se u rasponu od 2,81 % u Slovačkoj do 10,91 % u Austriji. Udio srednjih poduzeća kreće se oko 1,00 %, a velika poduzeća čine oko 0,20 % u ukupnom broju poduzeća. U tablici broj 7 dan je prikaz broja zaposlenih u promatranim zemljama prema njihovoj veličini⁶.

Tablica 7. Broj zaposlenih u odabranim zemljama Europske unije prema veličini poduzeća u 2015. godini

	Mikro		Mali		Srednji		Veliki	
	Broj zaposlenih	%	Broj zaposlenih	%	Broj zaposlenih	%	Broj zaposlenih	%
EU	40000000	29,10	15149787	11,02	23445743	17,06	46257142	33,66
Hrvatska	302 932	30,61	199 378	20,15	185 223	18,72	302 065	30,52
Slovenija	211 510	35,77	109 891	18,58	114 319	19,33	155 622	26,32
Austrija ⁷	700 318	25,21	677 395	24,38	535 523	19,27	865 209	31,14
Mađarska	883 235	34,02	499 126	19,22	428 799	16,52	785 076	30,24
Češka	1 122 543	31,25	628 299	17,49	678 432	18,89	1 162 623	32,37
Slovačka	620 979	41,32	221 142	14,71	236 629	15,75	424 162	28,22
Poljska	3 212 130	37,13	1 144 916	13,23	1 549 796	17,91	2 745 221	31,73
Estonija	125 250	30,20	101 993	24,59	97 083	23,41	90 437	21,80
Latvija	211 934	33,46	152 140	24,02	139 147	21,97	130 230	20,56
Litva	267 620	28,64	225 734	24,16	215 449	23,06	225 637	24,15
Rumunjska	876 403	22,48	854 172	21,91	821 025	21,06	1 346 599	34,54
Bugarska	564 629	29,53	450 325	23,55	414 487	21,68	482 475	25,24
BIH	134 933	28,12	101 307	21,11	107 022	22,30	136 608	28,47
Makedonija ⁸	125 694	33,19	83 496	22,05	76 492	20,20	93 055	24,57
Vel. Brit.	3 527 754	18,36	3 710 474	19,32	3 035 262	15,80	8 936 228	46,52

Izvor: Izrada autorice prema javno dostupnim podacima Eurostata na <http://ec.europa.eu/>

(21.8.2018.)

Iz tablice 7 vidljivo je da najviše zapošljavaju mikropoduzeća. Iznimke su Austrija, Češka, Rumunjska, Bosna i Hercegovina i Velika Britanija gdje najveći broj zaposlenih

⁶ Podaci za Crnu Goru i Srbiju nisu dostupni.

⁷ Podatci za Austriju za 2015. godinu nisu dostupni pa su uzeti za 2016. godinu.

⁸ Podatci za Makedoniju za 2015. godinu nisu dostupni pa su uzeti za 2016. godinu.

imaju velika poduzeća. U Velikoj Britaniji velika poduzeća zapošljavaju 2,5 puta više nego mikropoduzeća. Nakon mikropoduzeća po broju zaposlenih slijede velika poduzeća zatim srednja i mala poduzeća. U tablici broj 8 prikazana je dodana vrijednost prema veličini poduzeća u promatranim zemljama za 2015. godinu⁹.

Tablica 8. Dodana vrijednost u odabranim zemljama Europske unije prema veličini poduzeća u 2015. godini

	Mikro		Mali		Srednji		Veliki	
	Dodana vrijednost	%	Dodana vrijednost	%	Dodana vrijednost	%	Dodana vrijednost	%
EU	1400400	19,91	1234158	17,55	1299579	18,48	3061606	53,53
Hrvatska	3 832	18,07	4 187	19,74	4 387	20,68	8 804	41,51
Slovenija	4 410	22,81	3 805	19,68	4 234	21,90	6 885	35,61
Austrija ¹⁰	35 559	19,14	38 934	20,96	42 133	22,68	69 174	37,23
Mađarska	10 156	18,26	9 127	16,41	10 216	18,36	26 128	46,97
Češka	17 717	19,55	13 277	14,65	18 936	20,89	40 703	44,91
Slovačka	7 009	20,66	4 758	14,03	6 232	18,37	15 920	46,94
Poljska	29 722	15,81	26 005	13,83	40 408	21,49	91 859	48,86
Estonija	2 751	25,91	2 492	23,47	2 782	26,20	2 592	24,41
Latvija	2 195	20,75	2 390	22,59	2 825	26,70	3 170	29,97
Litva	2 714	17,28	3 576	22,77	4 433	28,22	4 984	31,73
Rumunjska	8 432	15,47	9 356	17,16	10 686	19,60	26 050	47,78
Bugarska	4 667	20,27	4 931	21,42	5 260	22,85	8 161	35,45
BIH	821	21,95	836	22,35	757	20,24	1 327	35,48
Makedonija	1 556	21,70	1 586	22,12	1 561	21,77	2 467	34,41
Vel. Brit.	264 917	18,82	217 447	15,45	228 931	16,26	696 457	49,47

Izvor: Izrada autorice prema javno dostupnim podacima Eurostata na <http://ec.europa.eu/>

(22.8.2018.)

Najveću dodanu vrijednost u promatranim zemljama imaju velika poduzeća. Iznimka je Estonija gdje najveću dodanu vrijednost imaju srednja poduzeća. Iako kod druge dvije priбалтичке države najveću dodanu vrijednost imaju velika poduzeća, one prate

⁹ Podatci za Crnu Goru i Srbiju nisu dostupni.

¹⁰ Podatci za Austriju za 2015. godinu nisu dostupni pa su uzeti za 2016. godinu.

trend Estonije pa je razlika u dodanoj vrijednosti između srednjih i velikih poduzeća vrlo mala (oko 3 %) u odnosu na ostale zemlje.

Najviše rangirane države prema pokazatelju proizvodnosti, odnosno dodanoj vrijednosti su Velika Britanija, Poljska, Austrija i Češka. Slijede ih Mađarska, Rumunjska, Slovačka, Bugarska, Hrvatska i Slovenija. Najniže rangirane države su: Litva, Estonija, Latvija, Bosna i Hercegovina i Makedonija.

2.3. Ključne razlike malih i srednjih poduzeća i velikih poduzeća

Ranije su dane definicije i kriteriji razvrstavanja poduzeća na mikro, mala i srednja poduzeća. Kriteriji za razvrstavanje poduzeća na mikro, male i srednja poduzeća u Hrvatskoj definirani su Zakonom o računovodstvu (NN 120/16) i Zakonom o poticanju razvoja malog gospodarstva (NN 121/16) dok su kriteriji za velika poduzeća definirani Zakonom o računovodstvu (NN 120/16):

- 1) poduzeća koja prelaze granične pokazatelje u najmanje dva od tri uvjeta iz stavka 4. ovoga članka (ukupna aktiva 150 000 000,00 kuna; prihod 300 000 000,00 kuna i prosječan broj radnika tijekom poslovne godine – 250 radnika);
- 2) banke, štedne banke, stambene štedionice, institucije za elektronički novac, društva za osiguranje, društva za reosiguranje, leasing-društva, društva za upravljanje UCITS fondovima, društva za upravljanje alternativnim investicijskim fondovima, UCITS fondovi, alternativni investicijski fondovi, mirovinska društva koja upravljaju obveznim mirovinskim fondovima, mirovinska društva koja upravljaju dobrovoljnim mirovinskim fondovima, dobrovoljni mirovinski fondovi, obvezni mirovinski fondovi te mirovinska osiguravajuća društva, društva za dokup mirovine, faktoring-društva, investicijska društva, burze, operatori MTP-a, središnja klirinška depozitarna društva, operatori središnjeg registra, operatori sustava poravnjanja i/ili namire i operatori Fonda za zaštitu ulagatelja neovisno o tome ispunjavaju li uvjete iz točke 1. ovog stavka.

Prema Orsagu (2002) razlike između malih i velikih poduzeća ogledaju se sa stajališta potencijalnih investitora i sa stajališta financijskog upravljanja. Razlike sa stajališta investitora su:

- Nelikvidnost dionica

- problem troška kapitala
- skučenost izvora financiranja
- likvidnost poslovanja.

Za dionice velikih, javno držanih dioničkih društava, likvidnost je normalna pretpostavka dok je za dionice malih privatno držanih poduzeća u domeni teorijskih pretpostavki. Razlike u likvidnosti dionica odražavaju se na razlike u trošku kapitala, izvorima financiranja i likvidnosti poslovanja. Trošak kapitala utemeljuje se na tržišnim vrijednostima instrumenata financiranja poduzeća. No, kada tržišne vrijednosti instrumenata financiranja poduzeća ne postoje i/ili kada nisu transparentne, utvrđivanje troška kapitala za takvo poduzeće izuzetno je diskutabilno. Nelikvidnost dionica malih poduzeća odražava se i na skučenost njihovih izvora financiranja jer su mala poduzeća pretežno orijentirana na samofinanciranje. Zbog skučenosti izvora financiranja malih poduzeća i nelikvidnosti instrumenata financiranja, temeljni problem malih poduzeća je likvidnost poslovanja i održavanje dnevne solventnosti (Orsag, 2002).

Razlike sa stajališta financijskog upravljanja su (Orsag, 2002):

- Vlasnik-menadžer
- problem agenata
- osposobljenost menadžera
- predvidivost poslovanja / opstanak.

Velikim poduzećima upravljaju profesionalni menadžeri kao agenti vlasnika dok malim poduzećima po pravilu upravljaju samo vlasnici. Zbog toga kod malih poduzeća može doći do promjene ciljeva poslovanja poduzeća. Kod malih poduzeća vlasnik i menadžer su jedna te ista osoba pa ciljevi vlasnika-menadžera mogu prevagnuti nad ciljevima maksimalizacije vrijednosti poduzeća. Problem malog poduzeća je povezan s osposobljenošću menadžera za korištenje relativno sofisticiranih metoda financijskog odlučivanja. Poslovanje malog poduzeća nije dobro povijesno dokumentirano, niti mu je budućnost predvidiva kao kod velikih poduzeća pa je otežano predviđanje očekivanih novčanih tokova (Orsag, 2002).

U tablici 9 su prikazani kvalitativni pokazatelji koji razlikuju mala i srednja poduzeća od velikih poduzeća sažeti od strane UNIDO-a, Organizacije za industrijski razvoj Ujedinjenih nacija.

Tablica 9. Kvalitativni kriteriji u malim i srednjim poduzećima i velikim poduzećima

Kategorije	MSP	Velika poduzeća
Menadžment	Vlasnik-menadžer Funkcije povezane s osobnostima	Profesionalni menadžeri Podjela rada prema predmetima
Zaposlenici	Nedostatak zaposlenika sa sveučilišnom diplomom Svestrano znanje	Većina zaposlenika sa sveučilišnom diplomom Specijalizirano znanje
Organizacija	Neformalna komunikacija	Formalna komunikacija
Prodaja	Neizvjesna i nedefinirana konkurentska pozicija	Jaka konkurentska pozicija
Odnos s kupcima	Nestabilan odnos	Temelji se na dugoročnim ugovorima
Proizvodnja	Radno intenzivna	Kapitalno intenzivna, ekonomija razmjera
Istraživanje i razvoj	Slijede tržište, intuitivni pristup	Institucionaliziran
Financije	Pretežno samofinanciranje	Razvedenost izvora financiranja

Izvor: UNIDO (u Berisha i Široka Pula, 2015 prema Yon and Evans, 2011)

Mala i srednja poduzeća su najvećim dijelom u privatnom vlasništvu gdje vlasnik poduzeća najčešće samostalno upravlja poduzećem. U velikim poduzećima funkcija vlasnika i menadžera je odvojena. Menadžer donosi odluke u ime vlasnika pa su mogući sukobi između vlasnika i menadžera zbog različitih ciljeva.

Mala i srednja poduzeća nemaju strogo definirane kriterije stupnja obrazovanja pri zapošljavanju. S obzirom na to da je riječ o malom broju zaposlenih (mala i srednja poduzeća u Republici Hrvatskoj prosječno zapošljavaju 5 zaposlenika) najčešći cilj malog poduzeća je zapošljavanje vlasnika i članova obitelji s financijskog stajališta. Kriterij pri zapošljavanju nije sveučilišna diploma nego osiguranje stalnog radnog mjesta članovima obitelji. „U izvještajima SBA Fact Sheet i GEM podaci pokazuju da veliki postotak pojedinaca u Hrvatskoj otvaranje poduzeća smatra načinom izlaska iz nezaposlenosti, a ne načinom pokretanja poslovanja“ (Ministarstvo poduzetništva i

obrta, 2013: 45). Grablowsky (1984) ističe da si mala poduzeća obično ne mogu priuštiti zapošljavanje iskusnih stručnjaka koji bi upravljali važnijim poslovnim funkcijama kao ni diversifikaciju talentiranog osoblja koji su prisutni u velikim poduzećima. Unutar malih i srednjih poduzeća prevladava neformalna komunikacija dok u velikim poduzećima zbog veće i složenije organizacijske strukture prevladava formalna komunikacija.

Za razliku od velikih poduzeća, mala i srednja poduzeća nemaju jaku konkurentsku poziciju na tržištu jer mogu ispuniti zahtjeve samo malog dijela tržišta. Zbog velike konkurencije mala i srednja poduzeća imaju nestalne odnose s kupcima, jer kupci idu od ponuđača do ponuđača u potrazi za boljim uvjetima. Uvjete prodaje najčešće definiraju kupci. Poduzeća ponuđači često ovise o malom broju kupaca ili čak o jednom kupcu (mikropoduzeća iz sektora proizvodnje). Velika poduzeća imaju veliki broj kupaca i manju konkurenciju pa mogu diktirati uvjete prodaje i eliminirati rizične kupce. Odnosi velikih poduzeća s kupcima temelje se na dugoročnim ugovorima, povjerenju i iskustvu.

Za mala i srednja poduzeća karakteristična je radno intenzivna proizvodnja jer ona nemaju dovoljno kapitala pa će u proizvodnju ulagati više rada, a manje kapitala. Velika poduzeća imaju manje poteškoća pristupu kapitalu pa je za njih karakteristična kapitalno intenzivna proizvodnja, odnosno u proizvodnju će ulagati više kapitala, a manje rada. „Veća poduzeća imaju lakši pristup kapitalu i mogu se osloniti na ekonomiju obujma“ (Dimitrić et al., 2018). Mala i srednja poduzeća nemaju resursa za istraživanje tržišta pa slijede intuiciju u pristupu tržišta.

Sa stajališta financijskog upravljanja mala i srednja poduzeća u pravilu imaju skuplje i ograničenije uvjete financiranja u odnosu na velika poduzeća. Prema Cvijanović et al. (2008: 79, u Sruk 2007) „pristup izvorima financiranja i povoljan trošak financiranja bitne su pretpostavke za osnutak, tekuće poslovanje, ekspanziju i razvitak poduzeća. Te su pretpostavke značajnije za mala i srednja poduzeća jer se ona u pravilu više suočavaju s problemom nedostatka izvora financiranja“.

Europska komisija (2016: 5) navodi jedinstvene probleme s kojima se suočavaju mala i srednja poduzeća:

- „neuspjeh tržišta u pružanju usluga: prava mala i srednja poduzeća često se suočavaju s tržišnim neuspjesima što čini okruženje u kojem rade i natječu se

s drugim zahtjevnijim sudionicima. Tržišni neuspjesi mogu nastati u područjima kao što su financije (posebno poduzetnički kapital), istraživanje, inovacije ili propisi u području zaštite okoliša. Mala i srednja poduzeća mogu naići na poteškoće u pristupu financijskim sredstvima i/ili ulaganjima u istraživanje i inovacije ili im mogu nedostajati resursi za usklađivanje s propisima u području zaštite okoliša;

- strukturne prepreke: mala i srednja poduzeća često moraju prevladati strukturne prepreke kao što je manjak upravljačkih i tehničkih vještina, krutost tržišta rada i ograničeno znanje o prilikama za međunarodno širenje“.

Na temelju ankete poslovanja koju je provela Svjetska banka usporedbom 15 ograničenja, među najvažnijim ograničenjima malih i srednjih poduzeća diljem regije i u zemljama prema razinama dohotka su korupcija, porezne stope, politička nestabilnost i neformalna konkurencija. Srednja poduzeća prema definiciji IFC-a kažu da trebaju više kvalificiranih i obrazovanih radnika. Pristup financiranju često se prepoznaje kao „najveća prepreka“ kada poduzeća moraju izabrati samo jednu prepreku (IEG: 2014).

Prema istraživanju *Annual Global Working Capital Survey* (2015) mala i srednja poduzeća trebaju više gotovine od ostalih jer:

- njihova sposobnost generiranja novca od poslovnih aktivnosti je manja;
- njihov trošak duga je veći, a stvaranje novca skuplje i
- njihov prinos na kapital zaostaje.

3. GOSPODARSTVO REPUBLIKE HRVATSKE

U ovom poglavlju definiran je pojam tranzicije kojim se označavaju zemlje u tranziciji te glavne sastavnice tranzicijskog procesa. Prema tranzicijskim pokazateljima, koje je razvila Europska banka za obnovu i razvoj, analiziran je napredak Republike Hrvatske i odabranih zemalja u procesu tranzicije. Poseban osvrt dan je na poduzetničke probleme malih i srednjih poduzeća u Republici Hrvatskoj te na institucionalnu potporu za mala i srednja poduzeća u Republici Hrvatskoj. Na kraju trećeg poglavlja analizirao se pristup financiranju i ispitivali su se različiti kriteriji koji određuju financiranje u pojedinoj zemlji.

Govoreći o Hrvatskoj u kontekstu post-tranzicijskog gospodarstva i zemljama regije, konkretno se misli na šest država koje su zajedno činile Socijalističku Federativnu Republiku Jugoslaviju, a to su: Slovenija, Hrvatska, Bosna i Hercegovina, Crna Gora, Srbija i Makedonija. Raspad jugoslavenske zajednice, uz sve njezine suprotnosti i proturječnosti, značio je i napuštanje socijalističkog modela upravljanja i uvođenje pluralističkog društva u svim državama koje su nastale disolucijom te države. Privatizacija državnih poduzeća, sloboda tržišnog natjecanja i sloboda investicijskog ulaganja, osnovne su odlike demokratskog društva koje su usvojile sve ove države. Transformaciju društva i demokratizaciju društva u tržišnom gospodarstvu, najuspješnije su provele Hrvatska i Slovenija koje su i inače bile najrazvijenije republike u bivšoj državnoj zajednici.

3.1. Tranzicija

Tranzicija je pojam kojim se označavaju tranzicijske zemlje, odnosno zemlje koje su u prelazu iz komandnog gospodarstva u tržišno gospodarstvo. „Tranzicija je svjetski (ne samo regionalni proces), koji obuhvaća sve oblasti ljudskog života, a ne samo ekonomiju. To je put k stvaranju poduzetničkog društva, zasnovanog na znanju i informatici, kooperaciji rada i kapitala, uz prisustvo kooperativne i poduzetničke države“ (Unković i Kordić, 2014). Raspadom socijalizma, prestaje podjela zemalja na kapitalističke i socijalističke i uvodi se nova podjela zemalja na razvijene zemlje, zemlje u tranziciji i nerazvijene zemlje (Unković i Kordić, 2014).

3.1.1. Glavne sastavnice tranzicijskog procesa

Glavne sastavnice tranzicijskog procesa dogovorile su se prilično rano. One su bile (IMF, 2000):

- Liberalizacija: proces koji omogućava slobodno utvrđivanja većine cijena na tržištu i ukidanje i/ili smanjivanje trgovinskih barijera u vanjskotrgovinskom poslovanju.
- Makroekonomska stabilizacija: proces kontrole i smanjenja visoke inflacije tijekom vremena koja se javlja kao posljedica procesa liberalizacije. Taj proces zahtijeva kontrolu nad državnim proračunom, odnosno eliminiranje proračunskog deficita, kontrolu ukupne količine novca i kredita u optjecaju te održivu platnu bilancu.
- Restrukturiranje i privatizacija: proces stvaranja održivog financijskog sektora i promjena vlasništva poduzeća iz državnog u privatno.
- Pravne i institucionalne reforme: nužne su za redefiniranje uloge države u tim gospodarstvima, uspostavljanje vladavine prava te uvođenja odgovarajuće politike tržišnog natjecanja.

Unković i Kordić (2014) dijele istočnoeuropske, centralnoeuropske i južnoeuropske bivše socijalističke zemlje u tri grupe, uvažavajući kriterij način pristupanja tranziciji:

1. Prva grupa: Češka, Poljska, Mađarska, Slovenija, Slovačka, Hrvatska i pribaltičke zemlje. U ovim zemljama vlast je pokazala nedvosmisleno opredjeljenje za tržišni način privređivanja i u njima je privatizacija, kao osnovna strategija tranzicije, podmakla ili je ušla u završnu fazu.
2. Druga grupa: Rusija, Bjelorusija, Ukrajina, Armenija, Gruzija, Bugarska, Rumunjska, Makedonija i Albanija. U ovim zemljama vlast je, barem u deklarativnom smislu, bila odana ciljevima tranzicije, ali se privatizacija odvijala relativno sporo zbog jakih unutrašnjih otpora.
3. Treća grupa: Moldavija, Kazahstan, Uzbekistan, Tadžikistan, Azerbajdžan. U ovim zemljama vlast je na prvim postsocijalističkim izborima konstituirana tek tijekom 1994., pa je utjecaj nekadašnje sovjetske nomenklature ostao i dalje snažan, tako da ni političko opredjeljenje vlasti za tranziciju, ni njeno provođenje do sada nisu bili značajnijih razmjera.

Govoreći o zemljama u tranziciji obično se misli na zemlje središnje i istočne Europe te zemlje bivšeg Sovjetskog Saveza. Iako su Kina i neke zemlje Azije i Afrike također tranzicijske zemlje, u ovom doktorskom radu se većinom koristi klasifikacija IMF (2000)

koji je na sljedeći način klasificirao tranzicijske ekonomije u Europi i bivšem Sovjetskom Savezu:

- CEE (Central and Eastern European economies): Albanija, Bugarska, Hrvatska, Češka, Makedonija, Mađarska, Poljska, Rumunjska, Slovačka, Slovenija;
- Baltičke zemlje: Estonija, Latvija i Litva;
- CIS (Commonwealth of Independent States): Armenija, Azerbajdžan, Bjelorusija, Gruzija, Kazahstan, Kirgistan, Moldavija, Rusija, Tadžikistan, Turkmenistan, Ukrajina i Uzbekistan.

3.1.2. Klasifikacijski sustav procesa tranzicije

Europska banka za obnovu i razvoj razvila je 1994. godine klasifikacijski sustav koji procjenjuje napredak zemalja u procesu tranzicije. Riječ je o sljedećim tranzicijskim pokazateljima (EBRD, 2014):

- privatizacija velikih razmjera;
- privatizacija malih razmjera;
- upravljanje i restrukturiranje poduzeća;
- liberalizacija cijena;
- trgovinski i devizni sustav i
- politika konkurencije.

U tablici 10 prikazane su vrijednosti tranzicijskih pokazatelja u odabranim zemljama u 2014. godini.

Mjerna ljestvica pokazatelja kreće se od 1 do 4+, pri čemu 1 predstavlja malu ili nikakvu promjenu iz krutog centralno planiranog gospodarstva, a 4+ predstavlja standarde industrijalizirane tržišne ekonomije (EBRD, 2014).

Pokazatelj privatizacije velikih razmjera u vrijednosti 3 označava da je više od 25 % imovine velikih poduzeća u privatnom vlasništvu ili u procesu privatizacije (pri čemu je proces dosegao razinu u kojoj je država efikasno ustupila svoja vlasnička prava), ali eventualno s velikim neriješenim pitanjima u pogledu korporacijskog upravljanja. Pokazatelj u vrijednosti 4 označava da je više od 50 % državnih poduzeća i imovine u privatnom vlasništvu te da postoji značajan napredak u upravljanju tim poduzećima (EBRD, 1994). Prema ovom pokazatelju najuspješnije su se pokazale Mađarska,

Češka, Slovačka, Estonija, Litva i Bugarska. Hrvatska se s vrijednošću ovog pokazatelja od 3,7 nalazi u rangu s Poljskom, Latvijom i Rumunjskom.

Tablica 10. Tranzicijski pokazatelji po zemljama u 2014. godini

	Privatizacija velikih razmjera	Privatizacija malih razmjera	Upravljanje i restrukturiranje poduzeća	Liberalizacija cijena	Trgovinski i devizni sustav	Politika konkurencije
Hrvatska	3,7	4,3	3,3	4,0	4,3	3,3
Slovenija	3,0	4,3	3,0	4,0	4,3	2,7
Mađarska	4,0	4,3	3,7	4,0	4,0	3,3
Češka ¹¹	4,0	4,3	3,3	4,3	4,3	3,0
Slovačka	4,0	4,3	3,7	4,3	4,0	3,3
Poljska	3,7	4,3	3,7	4,3	4,3	3,7
Estonija	4,0	4,3	3,7	4,3	4,3	3,7
Latvija	3,7	4,3	3,3	4,3	4,3	3,7
Litva	4,0	4,3	3,0	4,3	4,3	3,7
Rumunj.	3,7	3,7	2,7	4,3	4,3	3,3
Bugarska	4,0	4,0	2,7	4,3	4,3	3,0
BIH	3,0	3,0	2,0	4,0	4,0	2,3
Makedon.	3,3	4,0	2,7	4,3	4,3	2,7
Crna Gora	3,3	3,7	2,3	4,0	4,3	2,3
Srbija	2,7	3,7	2,3	4,0	4,0	2,3

Izvor: EBRD, <https://www.ebrd.com/> (29.8.2018.)

Prema pokazatelju privatizacije malih razmjera Hrvatska je u najvišem rangu 4 + zemalja. Vrijednost pokazatelja 4 + označava standarde i performanse tipične za napredna industrijska gospodarstva gdje mala poduzeća nisu u državnom vlasništvu (EBRD, 1994). Većina zemalja je dosegla razinu 4 ili 4 +, osim Rumunjske, Srbije, Crne Gore i BIH.

Pokazatelj upravljanja i restrukturiranja poduzeća u vrijednosti 3 označava značajne i kontinuirane akcije za učvršćivanje proračunskih ograničenja i učinkovito promicanje

¹¹ Za Češku su dostupni podaci za 2007. godinu.

korporacijskog upravljanja (na primjer, privatizacija u kombinaciji s čvrstim kreditnim i subvencijskim politikama i/ili provedbom stečajnog zakona) (EBRD, 1994). Hrvatska se prema ovom pokazatelju u vrijednosti 3,3 nalazi u rangu s Latvijom. Bolje rezultate od Hrvatske su ostvarile Mađarska, Češka, Slovačka, Poljska i Estonija.

Pokazatelj liberalizacije cijena u vrijednosti 4 označava opsežnu liberalizaciju cijena pri čemu je u velikoj mjeri ukinuta državna nabava po netržišnim cijenama (ostaje samo mali broj administrativnih cijena) (EBRD, 1994). Promatrane države imaju vrijednost ovog pokazatelja 4,0 ili 4,3. Hrvatska ima 4,0 i nalazi se u rangu sa Slovenijom, Mađarskom, BiH, Crnom Gorom i Srbijom.

Pokazatelj trgovinski i devizni sustav u vrijednosti 4 + označava standarde i norme djelovanja naprednih industrijskih gospodarstava, uklanjanje većine tarifnih barijera te članstvo u WTO-u (*World Trade Organization*) (EBRD, 1994). Većina zemalja ima vrijednost pokazatelja 4,3, uključujući i Hrvatsku, izuzev Mađarske, Slovačke, BiH i Srbije koje imaju vrijednost ovog pokazatelja 4,0.

Pokazatelj politike konkurencije u vrijednosti 3 označava prisutnost nekih provedbenih radnji radi smanjenja zlouporabe tržišne snage i promicanje konkurentskog okruženja, uključujući slamanje dominantnih konglomerata te značajno smanjenje ulaznih ograničenja (EBRD, 1994). Hrvatska se s vrijednosti ovog pokazatelja od 3,3 nalazi u rangu s Mađarskom, Slovačkom i Rumunjskom. Bolju konkurentsku politiku imaju Poljska, Estonija, Latvija i Litva.

Zajedničke politike za regiju srednje i istočne Europe kao elementi strategije rasta pojavljuju se u izvještaju *Regional Economic Issues* iz listopada 2013. godine i travnja 2014. godine (IMF, 2014):

- Jačanje poslovnog okruženja smatra se ključnim čimbenikom strategije rasta u cijeloj regiji. Ono uključuje korporacijsko upravljanje, prava vlasništva i provedbu ugovora, administrativne reforme i „rezanje“ birokracije, zakon o stečaju i politiku tržišnog natjecanja. Isto tako, nužno je privlačenje direktnih inozemnih investicija, a za neke zemlje potrebne su pravne i administrativne reforme.
- Uravnoteženiji sastav fiskalne konsolidacije između rashoda i prihoda, te mjere za jačanje administracije i usklađivanje poreza. U mnogim zemljama demografski pritisci ukazuju na potrebu reformi mirovinskih sustava.

- Visoki neprofitni zajmovi (NPL) naglašavaju potrebu za snažnom i neovisnom supervizijom bankovnog sektora, poboljšanje insolventnih okvira i reforme pravosuđa. Oživljavanje rasta kredita i širenje pristupa financiranja malih i srednjih poduzeća i dalje je veliki problem u mnogim zemljama.
- Povećanje poticaja za sudjelovanje na tržištu rada i smanjenje neusklađenosti vještina, uz upotrebu aktivnih politika tržišta rada.

Hrvatska je, uz Sloveniju, na početku 90-ih godina bila među najrazvijenijim i najbolje pripremljenim tranzicijskim državama srednje Europe za tranziciju pa se je očekivao znatno veći napredak u procesu tranzicije. Haramija i Njavro (2016) pronalaze uzrok tomu što tranzicija iz komunističkog u demokratski politički sustav nije donijela željene rezultate u gospodarstvu u pet čimbenika:

- „loša naslijeđena struktura gospodarstva, odnosno prisutnost političkog utjecaja na gospodarstvo;
- institucionalno nasljeđe komunizma (loš rad institucija; golema i neučinkovita administracija, birokratizirani pristup, prenormiranost i korupcija);
- loše provedena privatizacija;
- nedostatna pomoć Zapada (prioritet kvantiteta, a ne kvaliteta promjena);
- nerazvojne namjene stranih investicija u zemlje u tranziciji.“

3.2. Okruženje u kojem se nalazi malo gospodarstvo Republike Hrvatske

Mnoga međunarodna istraživanja mjere i rangiraju zemlje na ljestvici radi prikazivanja zemalja koje imaju najpovoljnije, odnosno najmanje povoljne uvjete poslovanja. Jedan od najvažnijih ciljeva globalnih istraživanja je donošenje raznih nacionalnih mjera i politika za otklanjanje nedostataka zemalja u svojim ekonomijama i na taj način jačanje svojih konkurentskih pozicija. Neka od najpoznatijih međunarodnih istraživanja su: izvještaj Svjetske banke *Doing Business*, Godišnjak svjetske konkurentnosti IMD-a (*Institute of Management Development*), Izvještaj o globalnoj konkurentnosti WEF-a (*World Economic Forum*), Izvještaj projekta Global Entrepreneurship Monitor (GEM) i drugi. U nastavku su opisani neki od rezultata navedenih istraživanja koji ukazuju na moguće probleme u ekonomijama promatranih zemalja.

3.2.1. Međunarodna istraživanja u poslovnom okruženju

Izveštaj *Doing Business* je godišnji izvještaj Svjetske banke čiji je cilj istražiti i analizirati propise vezane za ocjenu jednostavnosti poslovanja. Izvještaj uključuje 190 zemalja svijeta i ocjenjuje poslovanje u deset tematskih područja, i to: pokretanje poslovanja, ishođenje građevinske dozvole, opskrba električnom energijom, uknjižba vlasništva, dobivanje kredita, zaštita manjinskih ulagača, plaćanje poreza, prekogranično trgovanje, rješavanje trgovinskih sporova i rješavanje insolventnosti. Prema najnovijem izvještaju *Doing Business* iz 2018. godine Hrvatska je zauzela 51. mjesto od ukupno 190 rangiranih zemalja svijeta. 2017. godine Hrvatska je bila na 43. mjestu. U tablici 11 prikazano je rangiranje Hrvatske u svih deset tematskih područja za 2017. i 2018. godinu.

Tablica 11. „Doing Business“ pokazatelji za Hrvatsku za 2017. i 2018. godinu

Pokazatelji	2017.	2018.
Pokretanje poslovanja	95.	87.
Ishođenje građevinske dozvole	128.	126.
Opskrba električnom energijom	68.	75.
Uknjižba vlasništva	62.	59.
Dobivanje kredita	75.	77.
Zaštita manjinskih ulagača	27.	29.
Plaćanje poreza	49.	95.
Prekogranično trgovanje	1.	1.
Rješavanje trgovinskih sporova	7.	23.
Rješavanje insolventnosti	54.	60.

Izvor: Doing Business, <http://www.doingbusiness.org/rankings> (6.9.2018.)

U odnosu na 2017. godinu, prema *Doing Business* izvještaju, Hrvatska bilježi napredak u 2018. godini u tri pokazatelja, i to u: pokretanju poslovanja za osam mjesta, ishođenju građevinske dozvole za dva mjesta te uknjižbi vlasništva za tri mjesta. Lošije rezultate bilježi u šest pokazatelja, i to u: opskrbi električnom energijom za sedam mjesta, dobivanju kredita za dva mjesta, zaštiti manjinskih ulagača za dva mjesta, rješavanju insolventnosti za šest mjesta, rješavanju trgovinskih sporova za šesnaest mjesta te

plaćanju poreza za četrdeset i šest mjesta. U kategoriji prekogranično trgovanje zadržala je prošlogodišnje prvo mjesto i nalazi se u rangu najuspješnijih zemalja. U kategoriji plaćanja poreza bilježi pad za 46 mjesta jer nije uzeta u obzir porezna reforma koja je stupila na snagu 1. 1. 2017. godine. U sljedećem izvještaju bit će uključena jer je u izvještaju iz 2018. godine promatrano razdoblje od 1. 1. do 31.12. 2016. godine. Prema *Doing Business* izvještaju najveći problemi u Hrvatskoj su prisutni u tromosti ishođenja građevinskih dozvola.

U tablici 12 prikazan je ukupan rang jednostavnosti poslovanja Hrvatske i odabranih zemalja Europske unije te rangiranje prema pokretanju poslovanja i dobivanju kredita. U Hrvatskoj, uz ishođenje građevinske dozvole i plaćanje poreza, rezultati *Doing Business*-a ukazuju na određene probleme u pokretanju poslovanja i dobivanju kredita.

U ukupnom poretku jednostavnosti poslovanja Hrvatska se nalazi na 51. mjestu, a odmah ispred nje su rangirane Bugarska, Mađarska i Rumunjska. Najlošije rezultate bilježi Bosna i Hercegovina, a najbolje Baltičke zemlje i Makedonija. U pokretanju poslovanja Hrvatska se nalazi na 87. mjestu i to u blizini Slovačke i Češke. Najbolje rezultate prema navedenom pokazatelju ostvaruju opet Baltičke zemlje i Makedonija, a najlošije Bosna i Hercegovina, Poljska i Bugarska. S obzirom na to da promatrane zemlje imaju slabije razvijena tržišta kapitala, njihova poduzeća se najviše financiraju iz bankarskih kredita i kredita dobavljača. Iz prikazanih rezultata vidljivo je da je dostupnost kredita u svim promatranim zemljama pri vrhu ljestvice, odnosno promatrane države po pokazatelju dobivanja kredita nalaze se među prvih 30 % zemalja od ukupno 190 promatranih država izuzev Slovenije koja se nalazi na 105. mjestu.

Tablica 12. Rangiranje Hrvatske i odabranih zemalja Europske unije prema *Doing Business* pokazateljima za 2018. godinu

	Ukupan rang jednostavnosti poslovanja	Pokretanje poslovanja	Dobivanje kredita
Makedonija	11.	22.	12.
Estonija	12.	12.	42.
Litva	16.	27.	42.
Latvija	19.	21.	12.
Poljska	27.	120.	29.
Češka	30.	81.	42.
Slovenija	37.	46.	105.
Slovačka	39.	83.	55.
Crna Gora	42.	60.	12.
Srbija	43.	32.	55.
Rumunjska	45.	64.	20.
Mađarska	48.	79.	29.
Bugarska	50.	95.	42.
Hrvatska	51.	87.	77.
BIH	86.	175.	55.

Izvor: Doing Business, www.doingbusiness.org/rankings (6.9.2018.)

Izveštaj Svjetskog ekonomskog foruma (*World Economic Forum*) o globalnoj konkurentnosti definira faktore konkurentnosti na temelju kojih rangira 137 gospodarstva svijeta. Faktori konkurentnosti su grupirani u tri osnovne skupine, i to: osnovni faktori, faktori efikasnosti i faktori inovacija i sofisticiranosti. Rezultati izvještaja temelje se na anketi gospodarstvenika, statističkim podacima i podacima međunarodnih organizacija. Cilj izvještaja je spoznaja konkurentskih slabosti zemalja te njihovom jačanju. Hrvatska je u posljednjem izvještaju 2017 - 2018. godine zauzela, kao i prošle godine, 74. mjesto. U odnosu na prošlu godinu, Hrvatska je poboljšala konkurentnost u području makroekonomskog okruženja, zdravlja i osnovnog obrazovanja, tehnološke spremnosti i veličine tržišta. Prema ovom istraživanju, ali i

drugim međunarodnim istraživanjima, nužne su reforme u području razvoja institucija. U tablici 13 prikazano je dvanaest faktora Indeksa globalne konkurentnosti i rangiranje Hrvatske prema njima.

Tablica 13. Indeks globalne konkurentnosti i faktori konkurentnosti za Hrvatsku za 2017. – 2018. godinu

Indeks globalne konkurentnosti	74.
<i>Podindeks A: Osnovni faktori</i>	<i>58.</i>
- Institucije	102.
- Infrastruktura	48.
- Makroekonomsko okruženje	60.
- Zdravlje i osnovno obrazovanje	44.
<i>Podindeks B: Faktori efikasnosti</i>	<i>69.</i>
- Visoko obrazovanje i osposobljavanje	60.
- Efikasnost tržišta roba	99.
- Efikasnost tržišta rada	107.
- Razvoj financijskog tržišta	95.
- Tehnološka spremnost	43.
- Veličina tržišta	77.
<i>Podindeks C: Faktori inovacija i sofisticiranosti</i>	<i>99.</i>
- Poslovna sofisticiranost	82.
- Inovativnost	106.

Izvor: WEF, <http://www.aik-invest.hr/> (5.9.2018.)

Prema izvještaju o globalnoj konkurentnosti, napredak institucija najviše otežava opterećenje državne regulative, efikasnost pravnog okvira u rješavanju sporova, efikasnost pravnog okvira u zahtjevnim propisima, transparentnost vladinih politika i drugo. U infrastrukturi prisutne su nepovoljne pretplate na mobilne telefone, dok su s druge strane kvalitete ceste visoko rangirane (19.). U makroekonomskom okruženju najlošije je pozicioniran državni dug (115.). U četvrtom faktoru *Zdravlje i osnovno*

obrazovanje najlošije je rangirana kvaliteta osnovnog obrazovanja (71.), dok je prevencija HIV-a najbolje rangirana (1.).

U podindeksu B prvi faktor *Visoko obrazovanje i osposobljavanje* rangiran je na 60. mjestu. Unutar navedenog faktora najlošije se stoji s ulaganjem u obuku osoblja (130.), a najbolje sa stopom upisa u tercijarno obrazovanje. Efikasnost tržišta roba je loša (99.) zbog troškova poljoprivredne politike, utjecaja oporezivanja na poticaje za ulaganja, opsega tržišne dominacije i drugo. Tržište rada je neefikasno (107.) zbog loše suradnje u odnosima radnik-poslodavac, kapaciteta zemlje da privuče i zadrži talente, zapošljavanja i prakse i drugo. Razvoj financijskog tržišta najviše koči nedovoljna dostupnost investicijskog kapitala kao i nedovoljna dostupnost i pristupačnost financijskih usluga. U tehnološkoj spremnosti najlošije su rangirane direktne inozemne investicije (111.), a najbolje rasprostranjenost interneta i pretplate za internet (38.).

Podindeks C uključuje faktor 11 *Poslovna sofisticiranost* i faktor 12 *Inovacije*. Poslovna sofisticiranost rangirana je na 82. mjestu unutar koje je najbolje rangirana lokalna kvaliteta dobavljača (50.), a najlošije stanje razvoja klastera (130.) kao i spremnost delegiranja ovlasti. Inovacije se nalaze na 106. mjestu gdje je najlošije rangirana nabava napredne tehnologije (134.), a najbolje PCT patent (42.).

Prema Izvještaju o globalnoj konkurentnosti (WEF, 2017: 110) rangirani su čimbenici za poslovanje u Hrvatskoj od najviše problematičnih do najmanje problematičnih¹²: neefikasna vladina birokracija (21.8¹³), nestabilna politika (13.4), porezni propisi (12.4), korupcija (11.5), porezne stope (11.0), nedovoljna sposobnost inovacije (5.2), pristup financiranju (5.0), ograničavajući propisi o radu (5.0), nedovoljno obrazovana radna snaga (3.7), nestabilnost vlasti/državni udari (3.3), loša radna etika u nacionalnoj radnoj snazi (3.2), kriminal i krađa (2.4), neadekvatna infrastruktura (1.4), devizni propisi (0.3), loše javno zdravstvo (0.3) i inflacija (0.0).

U tablici 14 prikazan je ukupni indeks globalne konkurentnosti, osnovni faktori, faktori efikasnosti i faktori inovacija i sofisticiranosti za Hrvatsku i odabrane zemlje Europske unije.

¹² Rangiranje je izvršeno na temelju ankete ispitanika Izvršnog mišljenja Svjetskog gospodarskog foruma.

¹³ Rezultati su ponderi odgovora ispitanika.

Tablica 14. Indeks globalne konkurentnosti 2017. – 2018.

	Ukupni indeks globalne konkurentnosti	Osnovni faktori	Faktori efikasnosti	Faktori inovacija i sofisticiranosti
Estonija	29	22	27	35
Češka	31	30	29	32
Poljska	39	45	34	59
Litva	41	34	40	44
Slovenija	48	35	53	37
Bugarska	49	59	50	73
Latvija	54	43	49	68
Slovačka	59	52	44	56
Mađarska	60	64	45	79
Rumunjska	68	72	58	107
Hrvatska	74	58	69	99
Albanija	75	71	80	76
Crna Gora	77	80	72	92
Srbija	78	74	82	104
BIH	103	91	100	119

Izvor: WEF, <http://www.aik-invest.hr/> (7.9.2018.)

Među promatranim zemljama Hrvatska u ukupnom poretку prema indeksu globalne konkurentnosti bilježi 77. mjesto. Nalazi se u skupini s Rumunjskom, Albanijom, Crnom Gorom i Srbijom. Najbolje rezultate bilježe Estonija i Češka, a najlošije Bosna i Hercegovina.

3.2.2. Poduzetnički problemi malih i srednjih poduzeća u Republici Hrvatskoj

Rezultati međunarodnih istraživanja upućuju na nedovoljnu razinu aktivnosti u pokretanju novih poslovnih pothvata, mali udio rastućih poduzeća, administrativne prepreke za provođenje poduzetničke aktivnosti, nedovoljnu razvijenost financijskog tržišta te nedostatak edukacije usmjerene na razvoj poduzetničkih znanja i vještina (Cepor, 2017: 86).

U izvještaju Europske komisije SBA Fact Sheet analiziraju se rezultati pojedinačnih zemalja o promjenama u okruženju koje su relevantne za mala i srednja poduzeća i to u devet tematskih područja¹⁴. Hrvatska se nalazi ispod prosjeka Europske unije u šest od devet SBA područja. Ostvarila je iznadprosječne rezultate u državnim potporama i javnoj nabavi te u internacionalizaciji dok njezina uspješnost za poduzetništvo i odgovorna uprava su u tri najslabije države Europske unije (Europska komisija, 2017c). U tablici 15 prikazan je prosjek bodova Europske unije i Hrvatske po svim elementima koji utječu na ukupan rang u području poduzetništva.

Tablica 15. Varijacije od prosjeka Europske unije u području poduzetništva, mjereno standardnom devijacijom

	EU prosjek	Hrvatska
Poduzetnička aktivnost u ranoj fazi	7,8	8,41
Ženska poduzetnička aktivnost u ranoj fazi	5,45	5,6
Stopa vlasništva osnovanih poduzeća	6,7	4,2
Poduzetništvo pokrenuto prilikom	47,9	39,8
Poduzetnička namjera	12,1	18,17
Poduzetništvo kao poželjan izbor karijere	56,9	62,2
Visok status dan uspješnom poduzetništvu	66,6	45,6
Pozornost medija poduzetništvu	53,3	47,2
Poduzetništvo u osnovnoj školi	2,02	1,61
Poduzetništvo u srednjoj školi	2,79	2,33
Udio poduzeća s visokim rastom	9,19	10,61

Izvor: <http://ec.europa.eu/> (9.9.2018.)

Hrvatska se u ovom području nalazi među tri najslabije države Europske unije. Poduzetnička aktivnost i ženska poduzetnička aktivnost u ranoj fazi su blago iznad prosjeka Europske unije. Poduzetnička namjera, poduzetništvo kao poželjan izbor karijere i udio poduzeća s visokim rastom su iznad prosjeka Europske unije. S druge strane, udio ljudi koji se slažu s izjavom da u svojoj zemlji uspješni poduzetnici imaju visoki status je najniži u Europskoj uniji. Poduzetništvo u programima osnovnih i srednjih škola je dosta ispod prosjeka Europske unije što ukazuje na nedostatak sustavnog obrazovanja u poduzetništvu. Unatoč slaboj medijskoj pozornosti

¹⁴ poduzetništvo, druga prilika, odgovorna uprava, državna potpora i javna nabava, pristup financiranju, jedinstveno tržište, vještine i inovacije, okolina i internacionalizacija

posvećenoj uspješnom poduzetništvu te slabom statusu uspješnih poduzetnika poduzetništvo se i dalje smatra poželjnim izborom karijere.

U području „*Druga šansa*“ koje se odnosi na ponovno vraćanje u posao nakon bankrota, Hrvatska je ispod prosjeka Europske unije. Potrebno je dosta vremena da se riješe problemi insolventnosti, a troškovi koji prate cijeli proces su vrlo visoki. Strah od poslovnog neuspjeha povećava se, a Hrvatska još uvijek ne vodi nacionalnu kampanju smanjenja stigme od poslovnog neuspjeha (Europska komisija, 2017c).

Ograničeni napredak Hrvatske u provedbi SBA politika može se objasniti (Europska komisija, 2017c):

- dugotrajnim negativnim gospodarskim trendovima, osobito između 2008. i 2013. godine;
- umjerenim gospodarskim rezultatima u 2014. – 2015.;
- institucionalnim okvirom koji nije dovoljno usmjeren na male i srednje poduzetnike;
- političkom i državnom nestabilnosti.

Prema najnovijem izvještaju *Doing Business 2018*. Hrvatska je u pokretanju poslovanja rangirana na 87. mjesto i nalazi se među promatranim zemljama koje ostvaruju najslabije rezultate prema tom pokazatelju (Bosna i Hercegovina, Poljska, Bugarska i Hrvatska). Za pokretanje poslovanja poduzeću u Hrvatskoj je potrebno osam procedura, sedam dana, trošak od 7,2 % dohotka po glavi stanovnika i minimalni kapital od 12,5 % dohotka po stanovniku.

Problemi koji su najviše prisutni u malim i srednjim poduzećima u Europskoj uniji odnose se na pronalazak kupaca (24 %), dostupnost stručnog osoblja i iskusnog menadžerskog kadra (23 %), konkurencija (13 %), propisi (12 %) i troškovi proizvodnje ili rada (12 %). U tablici 16 su prikazani najveći problemi prisutni u poslovanju malih i srednjih poduzeća u Hrvatskoj i odabranim zemljama.

Mala i srednja poduzeća u Europskoj uniji kao jedan od najvažnijih problema najčešće navode pronalaženje kupaca za svoje proizvode i usluge (24 %) dok poduzetnici u Hrvatskoj pronalaženje kupaca najrjeđe navode kao najvažniji problem (3 %). Drugi najvažniji problem u zemljama Europske unije je pronalaženje iskusnih menadžera i stručnog osoblja (23 %). U Slovačkoj, Estoniji, Hrvatskoj, Austriji, Češkoj i drugim

zemljama je to trenutno najvažniji problem. Treći najvažniji problem u Europskoj uniji je konkurencija (13 %), a u Hrvatskoj su to propisi (22 %). Mala i srednja poduzeća u Europskoj uniji najčešće navode kao najvažniji problem pristup financiranju (7 %), dok u Hrvatskoj ga navodi 10 % poduzetnika (Europska komisija, 2017f).

Tablica 16. Najvažniji problemi u Hrvatskoj i odabranim zemljama u 2017. godini

	pronalaženje kupaca	konkurencija	pristup financiranju	troškovi proizvodnje ili rada	iskusni menadžeri i stručno osoblje	propisi	drugo
Austrija	28 %	8 %	6 %	11 %	29 %	11 %	6 %
Mađarska	26 %	8 %	7 %	13 %	27 %	5 %	13 %
Rumunjska	24 %	9 %	9 %	14 %	20 %	15 %	8 %
EU 28	24 %	13 %	7 %	12 %	23 %	12 %	8 %
Češka	22 %	8 %	6 %	8 %	33 %	11 %	12 %
Slovenija	20 %	12 %	7 %	12 %	26 %	15 %	9 %
Litva	19 %	22 %	10 %	14 %	15 %	7 %	12 %
Latvija	19 %	17 %	11 %	12 %	18 %	10 %	13 %
Poljska	19 %	13 %	7 %	12 %	23 %	16 %	10 %
Bugarska	18 %	17 %	7 %	9 %	27 %	13 %	9 %
Slovačka	11 %	14 %	5 %	6 %	38 %	12 %	14 %
Estonija	5 %	24 %	6 %	17 %	36 %	7 %	5 %
Hrvatska	3 %	12 %	10 %	7 %	30 %	22 %	16 %
Crna Gora	16 %	14 %	15 %	6 %	18 %	20 %	10 %
Srbija	6 %	15 %	9 %	10 %	24 %	17 %	19 %

Izvor: ec.europa.eu, <https://ec.europa.eu/> (10.9.2017.)

Najčešći uzroci prekida poslovne aktivnosti u Hrvatskoj tijekom 2015. godine bili su povezani s pitanjima porezne politike i administrativnog opterećenja (30,2 %), zatim problemi u pristupu financijskim resursima (20,8 %) te osobni ili obiteljski razlozi (16,4 %) (Cepor, 2017: 19).

3.2.3. Institucionalna potpora za mala i srednja poduzeća u Republici Hrvatskoj

Važan dio svog portfelja Svjetska banka je usmjerila za podršku malim i srednjim poduzećima. Podrška malim i srednjim poduzećima od Svjetske banke ima više oblika, od kojih svaki ima za cilj poduprijeti rast malih i srednjih poduzeća. Mala i srednja poduzeća u zemljama u razvoju dobivaju milijarde dolara od multilateralnih i bilateralnih donatora, kao i od nacionalnih vlada, a Grupa Svjetske banke je samo jedan od financijera podrške aktivnosti malim i srednjim poduzećima (IEG, 2014).

U Hrvatskoj, uz Ministarstvo poduzetništva i obrta (MINPO) i HAMAG INVEST čija je osnovna zadaća pružiti potporu sektoru malih i srednjih poduzeća, postoje i mnoga druga ministarstva (Ministarstvo gospodarstva, Ministarstvo turizma, Ministarstvo regionalnog razvoja) koja kroz svoje različite programe imaju isto za cilj pružiti potporu malim i srednjim poduzećima.

Razvoj sektora malih i srednjih poduzeća i poduzetništva u Hrvatskoj usmjeravan je kroz sljedeće nacionalne politike i programe (Cepor, 2017: 31):

- Strategija razvoja poduzetništva u Republici Hrvatskoj 2013. – 2020.
- Strateški plan Ministarstva poduzetništva i obrta za razdoblje 2015. – 2017.
- Program poticanja poduzetništva i obrta – Poduzetnički impuls 2015.
- Strategija razvoja poduzetništva žena u Republici Hrvatskoj 2014. – 2020.
- Strategija razvoja klastera u Republici Hrvatskoj 2011. – 2020.
- Strategija poticanja inovacija Republike Hrvatske 2014. – 2020.
- Akcijski plan podrške izvozu 2014. – 2015.
- Akcijski plan za smanjenje administrativnog opterećenja gospodarstva.

Područje državne potpore i javne nabave prati se u godišnjem izvještaju Europske komisije SBA Fact Sheet. Prema izvještaju Europske komisije SBA Fact Sheet za Hrvatsku, Hrvatska se u području državne potpore i javne nabave nalazi među prvih pet članica Europske unije. Prema kriteriju sudjelovanja poduzeća u javnim natječajima, Hrvatska (51) se nalazi značajno iznad prosjeka Europske unije (37). Prema kriteriju poduzeća koje podnose prijedloge na javni natječaj putem elektroničkog sustava (e-nabava) Hrvatska se također nalazi iznad prosjeka Europske

unije. Prema kriteriju prosječne odgode plaćanja javnih tijela, Hrvatska se nalazi ispod prosjeka što ju konkretno stavlja među tri države Europske unije koje imaju najdulje dane plaćanja.

U 2016. godini i prvom tromjesečju 2017. godine provedene su četiri značajne nove mjere, i to (Europska komisija, 2017c):

- Komercijalizacija inovacija u poduzetništvu;
- Izmjene programa dodjele državnih potpora za razvoj malog i srednjeg poduzetništva;
- Izmjene programa dodjele potpora male vrijednosti namijenjenih poboljšanju konkurentnosti i učinkovitosti malih i srednjih poduzeća u područjima s razvojnim posebnostima kroz informacijske i komunikacijske tehnologije i
- Inovacije novoosnovanih malih i srednjih poduzeća.

Najznačajnije, usvojen je Nacionalni program dodjele bespovratnih sredstava za poduzetništvo koji je donio pozitivne rezultate, a donesen je i novi Zakon o javnoj nabavi.

3.3. Financiranje malih i srednjih poduzeća

Mnoga međunarodna istraživanja analiziraju pristup financiranju i ispituju različite kriterije koji određuju financiranje u pojedinoj zemlji. Izvještaj Svjetske banke *Doing Business* u poglavljima „dobivanje kredita“ i „zaštita manjinskih ulagača“ bavi se pitanjem financiranja malih i srednjih poduzeća. U području dobivanja kredita mjere se zakonska prava zajmoprimaca i zajmodavaca kroz jedan skup pokazatelja i izvještavanje o kreditnim informacijama kroz drugi skup pokazatelja. Prvi skup pokazatelja mjeri postoje li određene značajke koje olakšavaju kreditiranje u okviru primjenjivih kolaterala i stečajnih zakona. Drugi skup pokazatelja mjeri pokrivenost, opseg i dostupnost kreditnih informacija putem pružatelja usluga kreditnih izvještaja. Prema posljednjem izvještaju *Doing Business 2018*, Hrvatska je u dobivanju kredita rangirana na 77. mjesto. U području zaštite manjinskih ulagača mjeri se zaštita manjinskih ulagača od sukoba interesa kroz jedan skup pokazatelja i prava dioničara u korporacijskom upravljanju kroz drugi skup pokazatelja. Hrvatska se u tom području nalazi na 29. mjestu.

Izvještaj *SBA Country Fact Sheets* analizira devet kriterija u odnosu na pristup financiranju. Prema posljednjem izvještaju 2017. *SBA Country Fact Sheet Croatia*, Hrvatska bilježi lošije rezultate u odnosu na prethodnu godinu i nalazi se ispod prosjeka Europske unije. U šest kriterija je ispod prosjeka Europske unije i to s financiranjem kapitala za nova i rastuća poduzeća, financiranjem poslovnih anđela novih i rastućih poduzeća, potrebnim vremenom za plaćanje, većim brojem odbijenih zahtjeva za kreditima i neprihvatljivih kreditnih ponuda te jačinom pravnog indeksa. U tri kriterija je iznad prosjeka Europske unije i to sa spremnošću banaka da daju zajam, pristupu javnoj financijskoj potpori, uključujući jamstva, te troškom zaduživanja malih kredita u odnosu na velike kredite.

Izvještaj *Global Entrepreneurship Monitor* (GEM) navodi i rangira razloge izlaska poduzeća iz poslovanja po regijama. Najčešći razlozi koji se navode su prodaja poduzeća, neprofitabilnost, problemi s financiranjem, druga prilika, izlaz, umirovljenje, osobni razlozi, nezgode i birokracija. Prema posljednjem izvještaju GEM-a (2017/18) Hrvatska se nalazi na 20. mjestu s obzirom na problem financiranja u kontekstu razloga izlaska poduzeća iz poslovanja. Problem financiranja kao razlog izlaska poduzeća iz poslovanja najmanje imaju Švedska (48.) i Njemačka (45.), a najviše Bosna i Hercegovina (6.). Bugarska (7.) i Italija (8.). Vezano za poduzetničke financije Hrvatska se nalazi ispod prosjeka i to na 35. mjestu.

Svjetska banka je utvrdila da mala i srednja poduzeća imaju manju vjerojatnost da će moći pristupiti financijskim sredstvima, gdje postoji nekoliko okolnosti (IEG: 2014):

- bankarski sektor je visoko koncentriran i ograničen konkurencijom;
- bankovne regulatorne politike nisu adekvatne;
- zaštita imovinskih prava je slaba;
- pravni sustavi su neučinkoviti ili kruti;
- kreditne informacije su slabe.

Pristup financiranju najvažnija je briga za 10 % hrvatskih malih i srednjih poduzeća u usporedbi sa 7 % poduzeća na razini Europske unije. 2009. godine pristup financiranju bio je najvažnija briga za 36 % hrvatskih malih i srednjih poduzeća, a 2013. godine za 19 % malih i srednjih poduzeća (Europska komisija, 2017d).

3.3.1. Najvažniji oblici financiranja

Bankovni krediti su najvažniji oblici vanjskog financiranja, posebno za mala i srednja poduzeća. Glavnom financijskom preprekom smatra se dobivanje početnog kapitala (Cepor, 2017). Od travnja do rujna 2017. godine 25 % malih i srednjih poduzeća u Hrvatskoj je podnijelo zahtjev za bankovni kredit, a 11 % malih i srednjih poduzeća nije podnijelo zahtjev zbog straha od odbijanja. U tom razdoblju niti jedan zahtjev nije odbijen, a 6 % poduzeća dobilo je kredit u manjem iznosu od zahtijevanog. Niti jedno poduzeće nije odbilo ponudu bankovnog kredita zbog previsoke cijene. U Europskoj uniji u istom razdoblju 26 % malih i srednjih poduzeća podnijelo je zahtjev za bankovni kredit, a 5 % malih i srednjih poduzeća nije podnijelo zahtjev zbog straha od odbijanja. U tom razdoblju odbijeno je 5 % zahtjeva, a 11 % poduzeća dobilo je kredit u manjem iznosu od zahtijevanog. 1 % poduzeća je odbilo ponudu bankovnog kredita zbog previsoke cijene (Europska komisija, 2017d). Unatoč činjenici da malim i srednjim poduzećima nije odbijen niti jedan zahtjev za kredit, za razliku od malih i srednjih poduzeća u Europskoj uniji, kod hrvatskih poduzetnika puno više je prisutan strah od odbijanja nego kod poduzetnika u ostalim zemljama Europske unije.

Analiza financiranja duga pokazuje da postoje problemi oko bankovnih kredita i jamstava koje banke nude malim i srednjim poduzećima (Ministarstvo poduzetništva i obrta, 2013):

- financiranje duga gotovo da nije dostupno novootvorenim poduzećima izuzev putem programa HBOR-a za novootvorena poduzeća;
- s obzirom na nedostatak imovine i drugih kolaterala malih i srednjih poduzeća financiranje duga im je uvelike nedostupnije nego velikim poduzećima;
- komercijalne banke zanemaruju mala i srednja poduzeća zbog percepcije o slabom upravljanju te poslovnoj i pravnoj nesigurnosti;
- komercijalne banke nisu sklone u velikoj mjeri apsorbirati komponentu fiksnih troškova vezanu uz ispitivanje boniteta poduzeća i nadzora kredita koji se daju malim i srednjim poduzećima.

IFC objašnjava svoj bankarski program malog i srednjeg poduzetništva navodeći da „pristup financijskim uslugama za mala i srednja poduzeća je i dalje ozbiljno ograničen“ i da mala i srednja poduzeća „igraju važnu ulogu u stvaranju radnih mjesta i stvaranju

prihoda za ljude s niskim prihodima; oni pridonose ekonomskom rastu, socijalnoj stabilnosti i doprinose razvoju dinamičnog privatnog sektora“ (IEG: 2014).

Najvažniji oblici financiranja malih i srednjih poduzeća u Hrvatskoj su leasing, kreditne linije, bankovni krediti i subvencionirani bankovni krediti. U posljednjih šest mjeseci najviše su se koristile kreditne linije, leasing i unutarnji izvori financiranja. U tablici 17 dani su najvažniji oblici financiranja malih i srednjih poduzeća u Hrvatskoj koji su se koristili u prošlosti i koji se razmatraju za korištenje u budućnosti.

Tablica 17. Najvažniji oblici financiranja malih i srednjih poduzeća u Hrvatskoj u 2017. godini

	Relevantni	Nedavno korišteni
Leasing	54 %	18 %
Kreditne linije	52 %	23 %
Subvencionirani bankovni krediti	47 %	7 %
Bankovni krediti	47 %	15 %
Unutarnji izvori financiranja	39 %	18 %
Temeljni kapital	26 %	0 %
Ostali zajmovi	19 %	5 %
Trgovački krediti	17 %	2 %
Factoring	n.a.	5 %

Izvor: ec.europa.eu, <https://ec.europa.eu/> (09.09.2018.)

U Europskoj uniji kreditne linije ostaju najvažniji oblik financiranja za mala i srednja poduzeća (53 % poduzeća ih je prijavilo kao najvažnije, a 35 % ih je zapravo koristilo u posljednjih šest mjeseci). Bankovni krediti i leasing su najvažniji oblici financiranja za 48 % europskih malih i srednjih poduzeća (Europska komisija, 2017e).

Veličina poduzeća i razina dohotka zemlje utječu na dobivanje bankovnog kredita (IEG: 2014). Veličina dobivenih kredita značajno varira među zemljama. U zemljama Europske unije najviše se koriste krediti u iznosu od € 25 000 – 100 000, a najmanje mali krediti do € 25 000. U tablici 18 prikazana je veličina dobivenih kredita u promatranim zemljama.

Tablica 18. Veličina kredita malih i srednjih poduzeća u promatranim zemljama u 2017. godini

	< € 25 000	€ 25 000 – 100 000	€ 100 000 – 250 000	€ 250 000 – 1 000 000	> € 1000000
Austrija	15 %	21 %	12 %	27 %	25 %
Mađarska	8 %	19 %	14 %	31 %	17 %
Slovenija	18 %	20 %	15 %	26 %	17 %
Češka	5 %	27 %	19 %	16 %	25 %
EU 28	11 %	25 %	21 %	23 %	17 %
Poljska	19 %	17 %	16 %	21 %	19 %
Litva	12 %	16 %	17 %	20 %	18 %
Bugarska	5 %	21 %	34 %	19 %	14 %
Slovačka	28 %	28 %	11 %	19 %	12 %
Rumunjska	7 %	23 %	40 %	21 %	7 %
Hrvatska	23 %	15 %	28 %	13 %	8 %
Crna Gora	7 %	14 %	43 %	7 %	26 %
Srbija	37 %	25 %	13 %	9 %	10 %

Izvor: ec.europa.eu, <https://ec.europa.eu/> (10.09.2018.)

Male kredite (< € 25 000) najviše koriste mala i srednja poduzeća u Hrvatskoj, Slovačkoj i Srbiji i to značajno iznad prosjeka Europske unije. Veliki krediti (> € 1 000 000) najviše se koriste u Crnoj Gori, Austriji i Češkoj.

U posljednje tri godine kamatne stope na prekoračenje i kreditnu liniju malih i srednjih poduzeća mijenjaju se različito u zemljama Europske unije. U 2017. godini kamate su najviše iznosile u Grčkoj (6,1 %) i Latviji (3,7 %), a najmanje u Francuskoj (1,1 %) i Luxemburgu (0,8 %). U Hrvatskoj su iznosile 2,9 % što je smanjenje u odnosu na prethodnu godinu (3,1 %), ali je još uvijek znatno iznad prosjeka Europske unije (2,0 %) (Europska komisija, 2017f).

3.3.2. Namjena korištenja vanjskih oblika financiranja

Mala i srednja poduzeća u Europskoj uniji koriste vanjske oblike financiranja za fiksna ulaganja (38 %), zalihe i ostali obrtni kapital (33 %), zapošljavanje i osposobljavanje

zaposlenika (15 %), razvoj i pokretanje novih proizvoda ili usluga (14 %), u ostale svrhe (12 %) i u refinanciranje ili otplaćivanje obveza (11 %) (Europska komisija, 2017f). U tablici 19 su prikazani rezultati u fiksnu imovinu i zalihe i obrtni kapital s obzirom na to da su navedene kategorije prijavljene kao najčešće korištene svrhe vanjskog financiranja.

Tablica 19. Vanjsko financiranje korišteno za ulaganja u fiksnu imovinu i zalihe i obrtni kapital malih i srednjih poduzeća u 2017. godini

	Fiksna imovina	Zalihe i ostali obrtni kapital
Austrija	50 %	41 %
Češka	49 %	44 %
Slovenija	49 %	35 %
Latvija	43 %	41 %
Slovačka	41 %	48 %
Rumunjska	38 %	42 %
EU	38 %	33 %
Poljska	36 %	35 %
Hrvatska	36 %	21 %
Bugarska	34 %	42 %
Litva	33 %	40 %
Estonija	27 %	30 %
Mađarska	16 %	15 %
Srbija	38 %	34 %
Crna Gora	36 %	44 %
Albanija	31 %	45 %

Izvor: ec.europa.eu, <https://ec.europa.eu/> (11.9.2018.)

U fiksnu imovinu putem vanjskih oblika financiranja najviše ulažu Austrija, Češka i Slovenija, a najmanje Mađarska i Estonija. U obrtni kapital najviše ulažu Slovačka i Albanija, a najmanje Mađarska i Hrvatska (Europska komisija, 2017f).

36 % hrvatskih malih i srednjih poduzeća koristili su vanjske oblike financiranja za fiksnu imovinu, 21 % za zalihe i obrtni kapital, 14 % za razvoj novih proizvoda, 16 %

za zapošljavanje i osposobljavanje zaposlenika, 12 % za refinanciranje obveza, a 17 % utrošilo se u druge svrhe (Europska komisija 2017d).

Promjene koje su najviše utjecale na čimbenike koji najviše utječu na dostupnost vanjskog financiranja malih i srednjih poduzeća su: opći gospodarski izgledi, javna financijska potpora, perspektiva poduzeća, vlastiti kapital, kreditna povijest, kreditiranje banaka, poslovni partneri koji daju trgovački kredit, investitori koji ulažu u kapital ili vrijednosnice. U 2017. godini u zemljama Europske unije sve su promjene bile poboljšane osim javne financijske potpore (Europska komisija, 2017f).

4. UPRAVLJANJE OBRTNIM KAPITALOM

Četvrto poglavlje daje teorijski okvir upravljanja obrtnim kapitalom. Prvo su definirani koncepti obrtnog kapitala i to koncept bruto obrtnog kapitala, koncept neto obrtnog kapitala te koncept neto operativnog obrtnog kapitala. Nakon toga slijedi određenje upravljanja obrtnim kapitalom u sklopu kojeg će se analizirati utvrđivanje optimalne veličine i strukture obrtnog kapitala te učinkovito upravljanje obrtnim kapitalom. Na kraju poglavlja dan je koncept upravljanja tekućom imovinom i tekućim obvezama.

4.1. Koncepti obrtnog kapitala

Obrtni kapital, odnosno radni kapital dio je imovine kojom se koristi poduzeće za potrebe svoga poslovanja i načina financiranje te imovine. Većina autora tradicionalno definira obrtni kapital kao investicije poduzeća u tekuću imovinu. No, upravljanje obrtnim kapitalom je puno kompleksnije od samih investicija u tekuću imovinu jer uključuje međuovisnost investiranja i financiranja tekuće imovine. Sa stajališta financiranja razlikujemo bruto obrtni kapital i neto obrtni kapital. Bruto obrtni kapital podrazumijeva ukupnu tekuću imovinu i njezino financiranje, a neto obrtni kapital podrazumijeva dio tekuće imovine i njezino financiranje (Orsag, 2015).

Pojam obrtni kapital najčešće se poistovjećuje s tekućom imovinom (Sen i Oruc, 2009; Brigham i Ehrhardt, 2011) dok Tepšić (1985) obrtni kapital poistovjećuje s pojmom obrtna sredstva. Pri tome obrtna sredstva definira kao „poslovna sredstva koja se jednokratnim upotrebama troše u poslovnim procesima i čija se vrijednost preobrazi iz novčanog oblika preko robnih oblika ponovno u novac najmanje jednom u toku godine“ (Tepšić, 1985:13). Bendeković et al. (2007) navode ako poslovni ciklus traje dulje od godinu dana, onda se pri definiranju tekuće imovine uzima razdoblje trajanja poslovnog ciklusa. U obrtna sredstva ulaze sirovine i drugi materijal namijenjen proizvodnji, sredstva za rad, vrijednosti utrošene u proizvodnju koja još nije dovršena, zatim poluproizvodi i gotovi proizvodi, trgovačka roba, potraživanja od kupaca i drugih dužnika i novčana sredstva namijenjena za pribavljanje spomenutih materijalnih sredstava i isplate akontacija (Tepšić, 1985). Kod poistovjećivanja obrtnog kapitala s tekućom imovinom i s obrtnim sredstvima zanemareno je njihovo financiranje, što nije u skladu s potpunom definicijom upravljanja obrtnim kapitalom.

Tepšić (1985) smatra da bi racionalno bilo iskazivati u bilanci posebno obrtnu imovinu u dvije podskupine, i to:

1. obrtna sredstva i
2. ostala obrtna imovina.

U prvu skupinu ušla bi samo ona obrtna imovina koja u smislu definicije obrtnih sredstava čini ta sredstva, dakle, koja stalno cirkuliraju tokom godine u smislu Marxova obrasca $N-R...P...R1-N1$. To su novčana obrtna sredstva, zalihe, potraživanja od kupaca, kratkoročni financijski plasmani. Sve ostalo bi bila ostala obrtna imovina. Tako bi se dobila solidna osnovica za analiziranje obrtnih sredstava i na nivou poduzeća i na nivou sektora.

Obrtna će se sredstva u sektoru proizvodnje obično nalaziti u sljedećim glavnim skupinama i podskupinama (Tepšić, 1985):

- novac i surogati novca: gotovina i novac u banci, valute, devize, čekovi, mjenice, akceptni nalozi, obveznice, blagajnički zapisi i drugi vrijednosni papiri;
- prijelazni oblici novca u robu: avansi dobavljačima za obrtna sredstva, različite akontacije radnicima, krediti dani kooperantima, aktivna vremenska razgraničenja troškova proizvodnje i drugo;
- zaliha sirovina, materijala i sitnog inventara: sirovine i materijali, gorivo i mazivo, nabavljeni poluproizvodi i dijelovi, materijal u obradi, doradi i manipulaciji, sitan inventar, ambalaža i autogume;
- proizvodnja u toku i poluproizvodi: proizvodnja u toku, poluproizvodi vlastite proizvodnje, nedovršeni proizvodi;
- zaliha gotovih proizvoda i robe: zaliha gotovih proizvoda, zaliha trgovačke robe u skladištima, zaliha trgovačke robe u poslovnim jedinicama;
- prijelazni oblici robe u novac: potraživanja od kupaca za prodane proizvode i usluge, kreditni odnosi s privrednim i drugim organizacijama za prodanu robu, kreditni odnosi s neposrednim potrošačima za prodanu robu i
- prijelazni oblici novca u novac: kratkoročni depoziti, kratkoročni krediti (plasmani).

Nastavno na potonje, ilustrirat će se funkcija obrtnih sredstava kroz ciklus obrtnih sredstava u proizvodnom poduzeću. Ciklus obrtnih sredstava, odnosno tokovi sredstava započinju *novcem*, jer je sredstva koja se koriste u poslovanju poduzeća

potrebno nabaviti, a potom i platiti. Da bi se pokrenula proizvodnja, potrebno je nabaviti materijale i sirovine. Uobičajeno se materijal nabavlja tako da se naručuje od dobavljača, a obveza plaćanja se podmiruje nakon nekog vremena po isporuci istih ili iznimno *avansno*. Proces nabave materijala završava njegovim uskladištenjem pri čemu nastaju *zalihe materijala*. Materijal se koristi u procesu proizvodnje gdje se postupno transformira u proizvodnju u toku i gotove proizvode. Za vrijeme procesa proizvodnje isplaćuju se plaće radnicima, podmiruju troškovi električne energije i obavlja se niz drugih isplata. Svi utrošci u proizvodnji koji su nužni da bi se zgotovili proizvodi, a koji još uvijek nisu završeni, nazivaju se *proizvodnjom u toku*. Proizvodnja proizvoda završava njihovim uskladištenjem te na taj način nastaje novi oblik obrtnih sredstava *zalihe gotovih proizvoda*. Gotovi proizvodi će se postupno prodavati. Prodaja se najčešće ne obavlja gotovinskim isplatama već na trgovački kredit, koji se kao obrtno sredstvo naziva *potraživanje od kupaca*. Naplatom potraživanja poduzeće ponovno dolazi do novca i na taj način se završava kruženje novca angažiranog za nabavu tekuće imovine (Orsag, 2015).

Na svakom koraku ciklusa obrtnih sredstava postoje povezani troškovi koji predstavljaju oportunitetne troškove obrtnog kapitala. Svrha upravljanja obrtnim kapitalom je uravnotežiti te troškove i održavati optimalne razine novca, sirovina i gotovih proizvoda (Arnold, 2008 u Lamberg i Vålming, 2009). Da bi se moglo govoriti o uspješnom poslovanju novac koji je rezultat poslovanja, odnosno zadnji korak ciklusa obrtnih sredstava mora biti veći od uloženog novca s kojim je započeo ciklus obrtnih sredstava (Orsag, 2015). Ilustrirani ciklus obrtnih sredstava je tipičan za proizvodna poduzeća, ali se može upotrijebiti i za poduzeća drugih djelatnosti ispuštajući neke od navedenih koraka (Lamberg i Vålming, 2009).

Različiti autori s obzirom na svrhu korištenja obrtnih sredstava koriste različite podjele obrtnih sredstava. Obrtna sredstva se prema svojem ekonomskom sadržaju mogu podijeliti na obrtna sredstva u robnom obliku, i obrtna sredstva u novčanom obliku. Obrtna sredstva prema fazama ciklusa obrtaja dijele se na obrtna sredstva u fazi proizvodnje i obrtna sredstva u fazi prometa. Obrtna sredstva prema sustavu pribavljanja dijele se na stalna obrtna sredstva i nestalna ili izvanredna obrtna sredstva.

4.1.1. Bruto obrtni kapital

Bruto ili ukupni obrtni kapital može se proučavati iz različitih perspektiva. Bradt (u Tepšić, 1985) razlikuje bruto obrtni kapital za koji kaže da je drugi termin za tekuću imovinu i neto obrtni kapital za koji kaže da predstavlja ostatak tekuće imovine nakon što se od tog iznosa odbiju tekuće obaveze. Prema Bradtu i bruto i neto obrtni kapital ne uključuju komponentu njihova financiranja. Tradicionalno se u širem smislu bruto obrtni kapital poistovjećuje s obrtnim kapitalom koji se definira kao investicije poduzeća u tekuću imovinu. No, uzimajući u obzir međuovisnost investiranja u tekuću imovinu i financiranja tekuće imovine, bruto obrtni kapital uključuje ukupnu tekuću imovinu poduzeća i način financiranja ukupne tekuće imovine (Orsag, 2015).

Obrtni kapital je pojam koji u svakodnevnoj konverzaciji nosi sa sobom različito značenje. Prema Van Horne i Wachowicz (2014) računovođe i financijski analitičari pod pojmom obrtni kapital podrazumijevaju različito značenje. Financijski analitičari pri uporabi pojma obrtni kapital obično podrazumijevaju bruto obrtni kapital, odnosno misle na tekuću imovinu kada govore o obrtnom kapitalu. Računovođe pod istim pojmom podrazumijevaju neto obrtni kapital, odnosno razliku između tekuće imovine i tekućih obveza.


4.1.2. Permanentna i privremena tekuća imovina

Prema vremenu u kojem se bruto obrtni kapital koristi, razlikuje se permanentni bruto obrtni kapital ili permanentna tekuća imovina i privremeni bruto obrtni kapital ili privremena tekuća imovina. Permanentna tekuća imovina obuhvaća minimalnu razinu ulaganja u tekuću imovinu koja je potrebna poduzeću kako bi ostvarilo prodaju, a sve iznad toga privremena je tekuća imovina (Pepur et al., 2015).

Van Horne i Wachowicz (2002) definiraju permanentnu tekuću imovinu poduzeća kao količinu tekuće imovine koju poduzeće treba kako bi ispunilo svoje minimalne dugoročne potrebe. Permanentna je tekuća imovina vrlo slična fiksnoj imovini poduzeća iz dva razloga. S jedne strane jer je investicija u tu imovinu dugoročna, a s druge strane jer će se razina potrebne permanentne tekuće imovine povećavati proporcionalno s povećanjem fiksne imovine poduzeća. Razlika permanentne tekuće imovine i fiksne imovine je što se permanentna tekuća imovina stalno mijenja (Van Horne i Wachowicz, 2002). Pod permanentnom tekućom imovinom podrazumijevaju se sve skupine zaliha, i to; materijal, proizvodnja u toku, gotovi proizvodi i trgovačka

roba, dok se privremena tekuća imovina odnosi na novac, unovčive vrijednosne papire i naplativa potraživanja od kupaca i drugih dužnika (Orsag, 2003). S obzirom na dugoročne potrebe permanentne tekuće imovine, a vodeći se načelima likvidnosti i solventnosti, ista se mora financirati iz kvalitetnih izvora, odnosno dugoročnih dugova i vlastitog kapitala (Orsag, 2015).

Van Horne i Wachowicz (2002) definiraju privremenu tekuću imovinu poduzeća kao investiciju u tekuću imovinu koja se mijenja zavisno o sezonskim potrebama. Privremena tekuća imovina često se naziva i privremeno vezanom imovinom jer se odnosi na onaj dio tekuće imovine koji se iznova veže i oslobađa, odnosno povećava i smanjuje. Povećanje, odnosno smanjenje navedenog dijela tekuće imovine ovisi o sezonskim i cikličkim kretanjima kojima je podložno poslovanje poduzeća (Bendeković et al., 2007). Kod financiranja privremene tekuće imovine preporuča se voditi načelom profitabilnosti koje traži da se povremene potrebe financiraju iz kratkoročnih izvora (Orsag, 2015). Na slici 1 prikazana je permanentna i privremena tekuća imovina u vrijeme stagnacije prodaje i stalno rastuće prodaje.



Slika 1. Permanentna i privremena tekuća imovina


Izvor: Pepur et al. (2015)

Poduzeća kod kojih prodaja stagnira, imat će konstantna ulaganja u permanentnu tekuću imovinu, odnosno imaju stalnu permanentnu tekuću imovinu. Kod rastućih poduzeća, odnosno, poduzeća koja bilježe rast prodaje, permanentna tekuća imovina

će blago rasti i to u skladu s rastom prodaje. I kod jednog i kod drugog poduzeća privremena tekuća imovina je promjenjiva, odnosno fluktuirajuća kroz vrijeme.

4.1.3. Neto obrtni kapital

Neto obrtni kapital odnosi se samo na dio tekuće imovine i na način njezina financiranja (Orsag, 2015). Neto obrtni kapital uobičajeno se definira kao razlika tekuće imovine i tekućih obveza poduzeća (Sen i Oruc, 2009; Brigham i Ehrhardt, 2011; Gitman i Zutter, 2011; Orsag, 2015), odnosno dio tekuće imovine koji se financira dugoročno. Zbog toga je omogućeno da taj dio tekuće imovine bude dugoročno prisutan u poslovanju poduzeća pa se zbog svoje dugoročne prisutnosti još naziva i permanentnom tekućom imovinom (Orsag, 2015). Neto obrtni kapital pokazuje koliko dugoročnog kapitala poduzeće mora investirati za financiranje svojih obrtnih sredstava (Rehn, 2012). Na slici 2 prikazan je položaj neto obrtnog kapitala u bilanci poduzeća.



Slika 2. Položaj neto obrtnog kapitala u bilanci poduzeća

Izvor: Potnik Galić (2008)

Poduzeće može imati pozitivan i negativan neto obrtni kapital. Na slici 2 prikazana je bilanca poduzeća koje ima pozitivan neto obrtni kapital, odnosno gdje je tekuća imovina veća od tekućih obveza. Dakle, poduzeće će imati pozitivan neto obrtni kapital ako je njegova tekuća imovina veća od njegovih tekućih obveza (Atseye et al., 2015),

što znači da će ono svoju tekuću imovinu djelomično dugoročno financirati i tu će prevladavati načelo sigurnosti (Orsag, 2015). Pozitivan neto obrtni kapital ukazuje da je poduzeće u dobrom financijskom zdravlju i da može platiti svoje kratkoročne dugove prodajom svoje tekuće imovine, odnosno naplatom potraživanja od kupaca (Seyoum et al., 2016).

Poduzeće će imati negativan neto obrtni kapital ako su tekuće obveze poduzeća veće od njegove tekuće imovine (Atseye et al., 2015, Rehn, 2012). U tom slučaju koristit će se kratkoročni izvori sredstava za financiranje dugotrajne imovine (Gitman i Zutter, 2011) i tu će prevladavati načelo profitabilnosti uz rizik nedovoljne fluktuacije tekuće imovine (Orsag, 2015). Negativan obrtni kapital ukazuje da poduzeće ne može podmiriti svoje dužničke obveze čak i ako proda svoju tekuću imovinu (Seyoum et al., 2016). Potencijalno moguće je da neto obrtni kapital bude jednak nuli, odnosno da se tekuća imovina izjednači s tekućim obvezama.

U skladu s navedenim može se zaključiti da će poduzeće biti likvidnije što je veći pozitivan neto obrtni kapital i obratno (Gitman i Zutter, 2011). Kada je obrtni kapital u crvenom, to je signal da se operativna učinkovitost poduzeća smanjuje ili da ne generira dovoljno prodaje, a u najgorem slučaju negativni obrtni kapital može rezultirati stečajem za poduzeće. Zbog toga je obrtni kapital dobar pokazatelj investitorima hoće li ulagati u poduzeće ili ne (Seyoum et al., 2016). Akoto et al. (2013) smatraju da je najvažnije pitanje upravljanja obrtnim kapitalom održavanje likvidnosti u svakodnevnom poslovanju poduzeća. To je ključno kako bi se spriječili vjerovnici i dobavljači od neopravdanog pritiska na upravljanje i time osiguralo nesmetano poslovanje poduzeća.

4.1.4. Neto operativni obrtni kapital

Neto operativni obrtni kapital predstavlja razliku operativne tekuće imovine i operativnih tekućih obveza poduzeća. Operativna tekuća imovina je tekuća imovina koja se koristi u operativnim aktivnostima poduzeća pri čemu ne nosi prihod od kamata. Ona uključuje novac za operativne potrebe, utržive vrijednosne papire koji su supstituti operativnog novca, potraživanja od kupaca i zalihe. Operativne tekuće obveze su obveze koje proizlaze iz redovitog poslovanja poduzeća kao što su obveze prema dobavljačima. Sve tekuće obveze koje nose sa sobom trošak kamata ne smatraju se operativnim tekućim obvezama (Brigham i Ehrhardt, 2011).

Damodaran (2010) definira nenovčani obrtni kapital čija se definicija može poistovjetiti s neto operativnim obrtnim kapitalom. Nenovčani obrtni kapital je razlika nenovčane tekuće imovine i tekućih obveza. U tekuće obveze ne uključuje dug jer ga smatra oblikom financiranja, a ne dijelom obrtnog kapitala. Damodaran (2006) isključuje novac iz nenovčanog obrtnog kapitala sve dok on ne gubi na vrijednosti, odnosno dok njegova stopa prinosa nije manja od tržišne stope prinosa, odnosno dok nije upotrijebljen radi zarade pa time i izložen mogućnosti gubitka vrijednosti. Damodaran (2006) tekućim obvezama smatra obveze prema dobavljačima, kredite dobavljača i sve druge obveze koje ne nose sa sobom trošak kamate, a koje utječu na novčani tok.

Neto operativni obrtni kapital ili nenovčani obrtni kapital definira se kao suma zaliha i potraživanja od kupaca umanjena za obveze prema dobavljačima. Neto operativni obrtni kapital financira se kratkoročnim dugom, dugoročnim dugom ili vlasničkom glavnicom (Monto, 2013). Fokus ovog doktorskog rada je na neto operativnom obrtnom kapitalu, odnosno na nenovčanom obrtnom kapitalu koji u odnosu na neto obrtni kapital isključuje financijski obrtni kapital.

4.2. Određenje upravljanja obrtnim kapitalom

Teorija korporacijskih financija može se raščlaniti na tri glavna područja i to: budžetiranje kapitala, struktura kapitala i upravljanje obrtnim kapitalom. Odluke o budžetiranju kapitala i strukturi kapitala odnose se na financiranje i upravljanje dugoročnim investicijama i njihovim prinosima. Upravljanje obrtnim kapitalom odnosi se na financiranje i upravljanje kratkoročnim investicijskim odlukama poduzeća (Sharma i Kumar, 2011).

Sen i Oruc (2009) iznose da je upravljanje obrtnim kapitalom u financijskoj literaturi zanemareno u odnosu na dugoročne financijske odluke. Tradicionalno, većina literature o korporacijskim financijama u velikoj se mjeri usmjerila na proučavanje dugoročnih financijskih odluka kao što su odluke o strukturi kapitala, dividendama, procjeni vrijednosti poduzeća i drugo (Garcia-Teruel i Martinez Solano, 2007; Sen i Oruc, 2009; Bellouma, 2010; Sharma i Kumar, 2011; Gul et al., 2013).

Upravljanje obrtnim kapitalom može se raščlaniti na upravljanje bruto obrtnim kapitalom i upravljanje neto obrtnim kapitalom. Upravljanje bruto obrtnim kapitalom odnosi se na investicijske odluke o iznosu i strukturi tekuće imovine i financijske odluke o načinu i obliku njezina financiranja. Navedeno podrazumijeva kombinaciju

kratkoročnog i dugoročnog financiranje tekuće imovine. Pa tako, poduzeće može financirati svoju tekuću imovinu različitim sredstvima kao što su kratkoročni dug, dugoročni dug ili kapital. Uz uvjet da je sve ostalo konstantno, obrtni kapital poduzeća će se povećavati kada se tekuća imovina financira kroz izvore koji nisu tekući (Seyoum et al., 2016).

U literaturi pod upravljanjem obrtnim kapitalom najčešće se misli na upravljanje neto obrtnim kapitalom, odnosno na kratkoročno upravljanje financijskim zahtjevima poduzeća (Ganesan, 2007; Ross et al., 2008; Sharma i Kumar, 2011). Ako se upravljanje obrtnim kapitalom precizno definira kao upravljanje neto obrtnim kapitalom, sadržaj tog pojma postaje vrlo precizan jer obuhvaća investicije u tekuću imovinu i korištenje kratkoročnih ili tekućih obveza. U skladu s navedenim upravljanje obrtnim kapitalom, odnosno neto obrtnim kapitalom, promatra se kao upravljanje likvidnošću poduzeća (Orsag, 2015). Bellouma (2010) naglašava da je upravljanje obrtnim kapitalom ključno za kratkoročnu solventnost i opstanak poduzeća te da u skladu s time poduzeće mora brzo i učinkovito reagirati kako bi se suočilo s neočekivanim promjenama u gospodarstvu.

U središtu je zanimanja obrtnog kapitala način na koji poduzeća koriste i upravljaju obrtnim kapitalom (Shin i Soenen, 1998). U 1980-ima i prije toga, bila je dominantna ideja o upravljanju individualnim komponentama obrtnog kapitala. U većini poduzeća, pojedinačnim komponentama obrtnog kapitala upravljali su menadžeri po različitim središtima odgovornosti (Pogue et al., 1983 u Korent, 2018). Ganesan (2007) ističe da je pojedinačno upravljanje svake komponente obrtnog kapitala izuzetno važno za financijsko zdravlje poduzeća svih sektora. No, svrha upravljanja obrtnim kapitalom je očuvanje ravnoteže između svih pojedinih komponenti obrtnog kapitala (Deloof, 2003), jer će upravljanje pojedinom komponentom obrtnog kapitala utjecati na ostale komponente obrtnog kapitala. Mnogi autori u svojim radovima dokazuju međusobnu zavisnost pojedinih komponenti obrtnog kapitala što upućuje na njihovo udruženo promatranje. Bougheas et al. (2008) pokazuju da zalihe imaju veliki, negativan i značajan utjecaj na potraživanja od kupaca.

Moyer et al. (2006, u Korent, 2018) precizno definiraju koncept upravljanja obrtnim kapitalom za koji kažu da predstavlja kontinuirani proces koji uključuje brojne svakodnevne poslovne aktivnosti i odluke koje se odnose na razinu tekuće imovine u ukupnoj imovini, udjele pojedinačnih komponenti tekuće imovine u ukupnoj strukturi

tekuće imovine, strukturu kratkoročnog i dugoročnog financiranja tekuće imovine, te kojim se kratkoročnim instrumentima financirati i u kojim omjerima.

Seidman (2004; u Nigatu, 2015) navodi četiri glavne svrhe korištenja obrtnog kapitala. Prva i najkritičnija upotreba obrtnog kapitala je osiguranje stalnog ulaganja u tekuću imovinu za pokriće tekućih troškova kao što su isplate plaća i plaćanje dobavljačima. Poduzeću je također potreban obrtni kapital za različita avansna plaćanja kao što su licence, police osiguranja ili sigurnosni depoziti. Druga svrha obrtnog kapitala je rješavanje sezonskih ili cikličkih financijskih potreba. Budući da većina poduzeća ne prima predujam za prodaju svojih proizvoda ili usluga, iste moraju financirati kupnju sirovina i materijala, proizvodnju i prodaju proizvoda prije naplate potraživanja od kupaca. Treće, obrtni kapital je potreban za održavanje rasta poduzeća. Za proširenje poslovanja nisu dovoljna samo ulaganja u nova postrojenja ili strojeve, nego i ulaganja u rast prodaje. Rast prodaje zahtijeva veća ulaganja u zalihe, potraživanja, radnike i druge oblike obrtnih sredstava. Četvrta svrha korištenja obrtnog kapitala je očuvanje konkurentnosti unaprjeđenjem poslovanja i poduzimanjem aktivnosti kao što su aktivnosti za razvoj novih proizvoda ili istraživanje novih tržišta. U razdobljima visoke konkurencije, poduzeća trebaju integrirati spomenute aktivnosti u svoje poslovanje na trajnoj osnovi. Posljedično, vjerojatnije je očekivati da će takve aktivnosti uzrokovati manje iznose ponavljajućih troškova, a ne povremena velika ulaganja. Sukladno tomu, ta ulaganja moraju se rješavati financiranjem obrtnim kapitalom (Seidman, 2004 u Nigatu, 2015).

Smith (1980) je među prvima ukazao na važnost upravljanja obrtnim kapitalom zbog njegovih učinaka na profitabilnost i rizik poduzeća, a shodno s tim i na njegovu vrijednost. Nakon njega javljaju se i mnogi drugi autori koji ukazuju na važnost upravljanja obrtnim kapitalom. Deelof (2003), Garcia-Teruel i Martinez-Solano (2007), Archavli et al. (2012) i mnogi drugi naglašavaju važnost upravljanja obrtnim kapitalom zbog njegova utjecaja na profitabilnost poduzeća, a shodno s tim i na tržišnu vrijednost poduzeća (Deelof, 2003; Archavli et al., 2012; Kieschnick et al. 2013). Također, brojni istraživači u svojim studijama ističu važnost upravljanja obrtnim kapitalom u odnosu na likvidnost (Deelof, 2003; Shin i Soenen, 1998) i solventnost poduzeća (Bellouma, 2010).

4.2.1. Učinkovito upravljanje obrtnim kapitalom

U literaturi o korporacijskim financijama postoji zajedničko mišljenje o važnosti upravljanja obrtnim kapitalom. Archavli et al. (2012) naglašavaju važnost upravljanja obrtnim kapitalom kako bi se osigurala bolja učinkovitost poduzeća. U središtu upravljanja obrtnim kapitalom je odnos između učinkovitosti upravljanja obrtnim kapitalom i profitabilnosti poduzeća. Učinkovito upravljanje obrtnim kapitalom uključuje planiranje i kontrolu tekućih obveza i tekuće imovine na način da se izbjegavaju prekomjerna i nedostatna ulaganja u tekuću imovinu (Sen i Oruc, 2009).

U relevantnim studijama najčešće se za mjeru učinkovitosti upravljanja obrtnim kapitalom koristi ciklus konverzije novca (*Cash Conversion Cycle*) (Sen i Oruc, 2009; Nobanee et al., 2011; Gul et al., 2013). Ciklus konverzije novca predstavlja dane potrebne za pretvaranje novčanog odljeva u novčani priljev, odnosno vrijeme u kojem je novac vezan u poslovnim aktivnostima poduzeća (Talonpoika et al., 2014), odnosno prosječno vrijeme između izdataka za kupnju sirovina i materijala i prikupljanja potraživanja od kupaca (Nobanee et al., 2011).

Ciklus konverzije novca sastoji se od tri temeljne komponente, i to: dana vezivanja zaliha, dana naplate potraživanja od kupaca i dana plaćanja obveza prema dobavljačima (Gitman i Zutter, 2011). Te su komponente glavne stavke operativnog obrtnog kapitala. No, postoje i druge stavke obrtnog kapitala koje mogu imati značajan utjecaj na učinkovito upravljanje operativnim obrtnim kapitalom poput primljenih ili plaćenih predujmova (Talonpoika et al., 2014). Duljina trajanja ciklusa konverzije novca utvrđuje se zbrajanjem dana vezivanja zaliha i dana naplate potraživanja od kupaca te oduzimanjem obveza prema dobavljačima (Brigham i Ehrhardt, 2005).

Brigham i Ehrhardt (2005) ilustriraju ciklus konverzije novca u pet koraka:

1. Poduzeća će naručiti i primiti materijale potrebne za proizvodnju određene količine proizvoda koju očekuju da će prodati. S obzirom na to da većina poduzeća kupuje materijale na trgovački kredit, ova transakcija će stvoriti obvezu prema dobavljačima. Međutim, takva kupnja neće imati neposredni efekt novčanog toka.
2. Za pretvorbu materijala u gotove proizvode u procesu proizvodnje nužno je upotrijebiti rad. Plaće neće biti u cijelosti isplaćene u vrijeme obavljanja posla pa će na isti način kao i obveze prema dobavljačima nastati obračunate plaće.

3. Gotovi proizvodi će se postupno prodavati, ali najčešće putem trgovačkog kredita. Stoga će prodaja na trgovački kredit biti stvaranje potraživanja od kupaca, a ne neposredni priljev gotovine.
4. U nekom trenutku prije priljeva gotovine, poduzeće mora isplatiti svoje obveze prema dobavljačima i obračunate plaće. Taj odljev mora biti financiran.
5. Ciklus će biti završen kada poduzeće naplati svoja potraživanja od kupaca. U to vrijeme poduzeće može isplatiti kredit koji je korišten za financiranje proizvodnje, pa tada može ponoviti ciklus.

Ciklus konverzije novca omogućava pojedinačno i sveobuhvatno promatranje komponentni obrtnog kapitala, odnosno zaliha, potraživanja od kupaca i obveza prema dobavljačima. Lamberg i Vålming (2009) navode da skraćivanje ciklusa konverzije novca može biti sredstvo za poboljšanje profitabilnosti poduzeća. U skladu s njima Nobanee et al. (2011) iznose da skraćivanje ciklusa dovodi do visoke profitabilnosti jer se poboljšava učinkovitost korištenja obrtnog kapitala.

Brigham i Ehrhard (2005) ističu da bi trebalo skratiti ciklus konverzije novca koliko god je moguće, a da se pri tome ne ugrozi poslovanje poduzeća. Nude tri načina skraćivanja ciklusa konverzije novca. Prvi je smanjivanje dana vezivanja zaliha ubrzavanjem proizvodnje i prodaje proizvoda, zatim smanjenje razdoblja naplate potraživanja od kupaca ubrzavanjem njihova prikupljanja i naposljetku produljenje razdoblja odgode plaćanja usporavanjem vlastitih plaćanja drugim poduzećima. Može se zaključiti da se učinkovitost upravljanja obrtnim kapitalom temelji na načelu ubrzanja potraživanja što je više moguće i usporavanju isplata što je više moguće (Nobanee et al., 2011).

U Nobanee et al. (2011) Gentry et al. (1990) tvrde da je kratki ciklus konverzije novca neizravno povezan s vrijednošću poduzeća. Kratki ciklus konverzije novca ukazuje da poduzeće prikuplja potraživanja od kupaca što je brže moguće i odgađa isplate dobavljačima što je duže moguće. To vodi do relativno visoke neto sadašnje vrijednosti novčanog toka i relativno visoke vrijednosti poduzeća. S druge strane, prilikom skraćivanja ciklusa konverzije novca poduzeće mora voditi računa da ne izgubi kupce zbog strožih uvjeta plaćanja, ne naruši odnose s dobavljačima zbog rastezanja plaćanja te u trenucima veće potrebe za zalihama ne dođe do pomanjkanja zaliha na

skladištu, a time i zastoja u procesu proizvodnje. Deloof (2003) ističe da svako dodatno rastezanje ciklusa vodi k zaključavanju novca u obrtna sredstva.

Hofmann i Belin (2011, u Ramljak, 2018) razlikuju tradicionalni pristup od pristupa lanca opskrbe ili logističkog lanca. Prema Hofmann i Belin „obilježje tradicionalnog pristupa je da se upravljanje obrtnog kapitala sagledava isključivo iz vlastite perspektive u smislu da, ako se radi o poduzeću koje je u ulozi kupca, ono nastoji što više odgoditi plaćanje, odnosno ako je riječ o poduzeću prodavatelju, da što više ubrza naplatu. Na taj način poduzeća rade jedno protiv drugoga pa se takav odnos može okarakterizirati suboptimalnim. Jednostavno prebacivanje tereta s jednog poduzeća na drugo može ugroziti kontinuitet poslovanja s poslovnim partnerima. Unaprjeđenje ovakvih manjkavosti vidi se u većem stupnju kooperacije i koordinacije međusobnih partnera u lancu opskrbe radi dugoročne suradnje“.

4.2.2. Optimalna veličina i struktura obrtnog kapitala

Prema Van Horne i Wachowicz (2002) određivanje optimalne razine ulaganja u tekuću imovinu i određivanje odgovarajuće strukture kratkoročnog i dugoročnog financiranja tekuće imovine dva su ključna pitanja kojim se treba baviti menadžment poduzeća pri uspješnom upravljanju obrtnim kapitalom. Optimum obrtnih sredstava ostvarit će se kad se s nekim minimalno angažiranim obrtnim sredstvima postignu maksimalni rezultati (Tepšić, 1985). Filbeck i Krueger (2005) i Sen i Oruc (2009) navode da je optimalna razina ona u kojoj se postiže ravnoteže između rizika i učinkovitosti. Sen i Oruc (2009) ističu da razina obrtnog kapitala ukazuje koliko poduzeće želi preuzeti rizika dok Filbeck i Krueger (2005) navode i drugi aspekt „optimalnog“, a to je stupanj do kojeg se loši financijski rezultati mogu povezati s neoptimalnim učincima. Glavni cilj upravljanja obrtnim kapitalom je održavanje optimalne ravnoteže između svake od komponenti obrtnog kapitala. Upravljanje obrtnim kapitalom usmjereno je na utvrđivanje optimalne razine obrtnog kapitala, odnosno na izbjegavanje stvaranja nepotrebnih viškova i manjkova obrtnih sredstava te ako dođe do istih, na njihovu eliminaciju.

U središtu problema obrtnog kapitala je optimalizacija obrtnog kapitala, odnosno potrebna razina i struktura obrtnog kapitala poduzeća koja će maksimizirati bogatstvo vlasnika. Preniska razina likvidnosti neće dobro utjecati na sigurnost poslovanja poduzeća, a mogući narušeni kontinuitet u poslovanju može prouzročiti gubitke poduzeća. Likvidnost, odnosno ulaganje u obrtni kapital treba se povećavati do razine

koja će osigurati najveći povrat poduzeću, odnosno vlasnicima. Ako se ta razina prijeđe, odnosno dođe do prekomjerne likvidnosti, to će utjecati na smanjenje profitabilnosti jer će oportunitetni troškovi od prekomjernog ulaganja u tekuću imovinu premašiti koristi pa će doći do smanjenja profitabilnosti.

U određivanju optimalne veličine i strukture obrtnih sredstava za predmet optimalizacije trebaju se uzeti obrtna sredstva u svim fazama kružnog toka, a za kriterij maksimalizacija financijskog rezultata. Da bi se postigla optimalna kombinacija veličine i strukture obrtnih sredstava, raspoloživa obrtna sredstva trebaju biti jednaka potrebnim po svim vrstama, podskupinama i skupinama, i to količinski i cjenovno. Dok se kod količina ne mogu mijenjati zahtjevi, jer bi moglo doći do problema u kontinuitetu poslovanja, kod cijena se mogu veće nabavne cijene jednih vrsta materijala kompenzirati nižim nabavnim cijenama drugih vrsta materijala ili promjenom dobavljača, a time i uvjeta nabave (Tepšić, 1985). Veličina potreba poduzeća za obrtnim sredstvima ovisit će o obujma vrijednosnog ulaganja u ukupnom iznosu i po svim fazama i podfazama procesa obrta vrijednosti obrtnih sredstava te o dužini trajanja kružnog kretanja ukupnih obrtnih sredstava, odnosno trajanja obrta po fazama i podfazama kružnog toka izraženih brojem dana ili koeficijentom obrtaja (Tepšić, 1985).

Vrlo je teško odrediti optimalnu razinu i strukturu obrtnih sredstava po svim vrstama, podskupinama i skupinama i to u svim fazama kružnog toka. No kada bi poduzeće i uspjelo izračunati optimume svih obrtnih sredstava u svim fazama kružnog toka, nemoguće je dugoročno odrediti i zadržati univerzalnu i nepromjenjivu veličinu i strukturu obrtnog kapitala. Prvo, mijenjaju se uvjeti poslovanja unutar poduzeća kao što su promjene uvjeta plaćanja, kreditnih politika, sezonske oscilacije i drugo. Drugo, mijenja se okruženje u kojem poduzeće posluje poput promjene tržišnih cijena, kamatnih stopa, fiskalnih nameta i drugo (Tepšić, 1985). Tepšić (1985) ističe da treba imati na umu misao Dadajana koji kaže da se „optimalnim naziva takvo rješenje koje je u danim privrednim uvjetima najbolje, tj. najefikasnije“. Veličina i struktura obrtnog kapitala je optimalna sve dok se dinamika poslovanja ne promijeni uzrokovana promjenama unutar ili izvan poduzeća.

4.2.3. Odstupanja od optimalne veličine i strukture obrtnih sredstava

Potonje implicira da je optimalnu veličinu i strukturu obrtnog kapitala u praksi vrlo teško postići. Problem postizanja optimalizacije veličine i strukture obrtnih sredstava dolazi

još više do izražaja u djelatnostima u kojima ima i po nekoliko tisuća vrsta i podvrsta obrtnih sredstava. Kada bi se utvrđivala optimalna veličina svake vrste obrtnog sredstva vrlo vjerojatno bi trošak utvrđivanja svih optimalnih veličina obrtnih sredstava premašio uštede dobivene optimalizacijom.

Prema Tepšić (1985) najčešći razlozi pojave neravnoteže između ukupno raspoloživih i ukupno potrebnih obrtnih sredstava, odnosno viškova i manjkova jesu: promjene vrijednosti obujma ulaganja u proces proizvodnje nastale zbog promjena cijena materijala ili zbog promjena količine uzrokovane povećanom ili smanjenom potrošnjom; promjene u trajanju obrtaja obrtnih sredstava zbog, na primjer, izmijenjenih uvjeta nabave; poremećaji u strukturi obrtnih sredstava zbog, na primjer, poteškoća u prodaji doći će do pomanjkanja novčanih sredstava; promjene kvalitete poslovanja uzrokovane promjenama odnosa rezultata ulaganja (outputa) i ulaganja (inputa); promjene odnosa obrtnih sredstava u funkciji i izvan funkcije uzrokovane izmjenama tehnološkog procesa, zahtjeva tržišta, uvjeta financiranja i sličnih okolnosti u poslovanju; te promjene rokova dospijeca prema izvorima financiranja.

Uz utvrđivanje razloga zbog kojih je došlo do viškova, odnosno manjkova obrtnih sredstava, nužno je da poduzeće analizira i utjecaj istih na financijski rezultat poduzeća. Viškovi materijalnih oblika obrtnih sredstava utječu nepovoljno na financijski rezultat poduzeća jer s jedne strane izazivaju rast troškova zaliha, dok s druge strane dolazi do opadanja tržišne vrijednosti zaliha (Tepšić, 1985). Prema Makori i Jagongo (2013) viškovi materijalnih oblika obrtnih sredstava smanjuju troškove mogućih prekida u procesu proizvodnje i gubitka posla zbog nestašice proizvoda te smanjuju rizik od nestašica zaliha (Raheman i Nasr, 2007; Gill et al., 2010).

S druge strane, manjkovi zaliha gotovih proizvoda različito će utjecati na financijski rezultat poduzeća od manjkova zaliha materijala. Manjkovi zaliha gotovih proizvoda mogu povoljno utjecati na financijski rezultat poduzeća dok će manjkovi zaliha materijala sasvim sigurno nepovoljno utjecati na financijski rezultat poduzeća. U slučaju nestašice potrebnih materijala u procesu proizvodnje doći će do zastoja u procesu proizvodnje. Smanjenje obujma proizvodnje utjecat će na povećanje fiksnih troškova po jedinici proizvoda, a posljedično i na smanjenje financijskog rezultata (Tepšić, 1985).

Viškovi novčanih sredstava s jedne strane utjecat će povoljno na solventnost poduzeća dok će s druge strane utjecati nepovoljno na financijski rezultat poduzeća. Viškovi

novčanih sredstava mogu biti poželjni jer će utjecati povoljno na solventnost zato što će poduzeće u svakom momentu moći podmiriti dospjele obveze. S druge strane, takvi viškovi su nepovoljni zbog toga što raspolaganje njima izaziva troškove koji se sastoje najmanje od kamata koje se plaćaju izvorima. Viškovi neiskorištenih novčanih sredstava praktički umanjuju prihode jer se moglo zaraditi na njima u visini kamate zarađene oročavanjem kod banaka, kreditiranjem drugih subjekata, u visini kasa-skonta zbog promptnog plaćanje faktura dobavljačima i drugo. Manjkovi novčanih sredstava povećavaju ukupne troškove jer se zbog nemogućnosti pravovremenog podmirenja obveza plaćaju zatezne kamate i eventualni sudski troškovi i tako se smanjuje financijski rezultat poduzeća. Manjkovi novčanih obrtnih sredstava mogu nepovoljno utjecati na financijski rezultat i putem smanjenja obujma proizvodnje i poslovanja ako se dobavljačima robe i usluga mora platiti unaprijed (Tepšić, 1985).

Viškovi potraživanja od kupaca i drugih dužnika (obrotna sredstava u tzv. prelaznom obliku robe u novac) utjecat će nepovoljno na financijski rezultat zato što izazivaju dodatne troškove u visini redovnih kamata koji se plaćaju izvorima, a postoji i mogućnost plaćanja zateznih kamata. Nepravovremena naplata sadrži u sebi rizik da se potraživanje neće djelomično ili u cijelosti moći naplatiti. Manjkovi obrtnih sredstava u obliku potraživanja od kupaca utjecat će povoljno na financijski rezultat ako su rezultat bolje naplativosti. Međutim, ako su ti manjkovi rezultat pada prodaje, a time i pojave viškova gotovih proizvoda, utjecat će nepovoljno na financijski rezultat poduzeća (Tepšić, 1985). Gill et al. (2010) navode da nenaplaćena potraživanja mogu voditi problemima u toku novca za poduzeće.

Viškovi avansa dobavljačima robe i usluga (obrotna sredstava prelaznog oblika novca u robu) izazivaju dodatne troškove u obliku kamata na kredit i određeni stupanj rizika da se neće primiti protuvrijednost u robu (Tepšić, 1985). Emery (1987) navodi da kupac dobiva uštede troškova jer su cijene niže. Za razliku od viškova, manjkovi mogu biti i poželjni ako nemaju za posljedicu nemogućnost nabave potrebnih sirovina, materijala, usluga i drugog. Manjkovi avansnog plaćanja dobavljačima, odnosno kasno plaćanje računa može biti vrlo skupo ako je poduzeće ponudilo popust za rane uplate (Petersen i Rajan, 1995; Wilner, 2000; Deloof, 2003; Raheman i Nasr, 2007; Gill et al., 2010).

„Manjkovi obrtnih sredstava u pravilu su nepovoljniji u fazi ulaganja sredstava u proces proizvodnje, a manje nepovoljni u fazama koje slijede nakon faze proizvodnje. Viškovi obrtnih sredstava su nepovoljniji nakon faze proizvodnje, a manje su nepovoljni u

fazama koje prethode proizvodnji. Odstupanja od optimuma obrtnih sredstava u pravilu nepovoljno utječu na financijski rezultat poduzeća, no tek analizom svakog pojedinog viška ili manjka može se utvrditi i njegovo stvarno značenje“ (Tepšić, 1985: 60).

Budući da u inflaciji cijene rastu, a vrijednost novca pada, logičan zaključak je da su viškovi materijalnih oblika obrtnih sredstava povoljniji za financijski rezultat u uvjetima inflacije nego u uvjetima tržišnog ekvilibrija. Tako inflacija „ispravlja“ opadanje tržišne vrijednosti zaliha robe i izravna je na nominalnu vrijednost. Viškovi novčanih sredstava u inflaciji su nepovoljniji nego u stabilnim uvjetima zato što će se za istu svotu novca u budućnosti moći kupiti manje dobara nego danas. Viškovi potraživanja od kupaca također su nepovoljniji u uvjetima inflacije, nego pri stabilnim kretanjima zbog opadanja kupovne moći novca u inflaciji. Moguće je da će se poduzeću u uvjetima inflacije više isplatiti povećati svoje zalihe gotovih proizvoda, nego da ih proda na kredit. Viškovi obveza prema dobavljačima ne moraju nužno nepovoljno utjecati na financijski rezultat u inflaciji ako se osigura da se dobije ista količina robe u trenutku isporuke koja se mogla kupiti po cijenama u trenutku plaćanja. Manjkovi obveza prema dobavljačima će biti poželjni ako ne budu utjecali na zastoje u nabavi sirovina, materijala, usluga i sl., odnosno ako ne budu nepovoljno utjecali na obujam proizvodnje (Tepšić, 1985). Iz svega navedenog može se zaključiti da je u inflaciji povoljnije raspolagati materijalnim vrijednostima jer im cijene rastu, a u deflaciji novcem jer vrijednost novca raste.

4.2.4. Mjere i metode za optimalizaciju obrtnih sredstava

Tepšić (1985) smatra da prilikom utvrđivanja optimalne razine obrtnih sredstava treba ukazati na povezanost veličina raspoloživih i potrebnih obrtnih sredstava. Veličinu i strukturu potrebnih obrtnih sredstava trebalo bi planirati na temelju prošlih razina obrtnih sredstava i tokova poslovanja. Ako se je racionalno poslovalo u prošlosti vrlo vjerojatno će doći do racionalnog poslovanja u budućnosti gdje će se planirati potrebe na manjoj razini. Racionalno poslovanje obrtnim sredstvima bazira se na principu ekonomičnosti, odnosno da se što manjom masom obrtnih sredstava ostvare planirani rezultati. Polazeći od principa ekonomičnosti poslovanje obrtnim sredstvima može se racionalizirati smanjenjem vrijednosnog obujma ulaganja obrtnih sredstava i to uštedama na kojima se ne smanjuje kvaliteta gotovih proizvoda, ne snižavaju prodajne cijene i financijski rezultat (npr. zamjena skupljih materijala jeftinijim, zamjena skupljih

tehnoloških metoda jeftinijim i drugo) te ubrzanjem kružnog kretanja vrijednosti u tehnološkom procesu (Tepšić, 1985).

Tepšić (1985) prikazuje jedan općevažeći postupak radi ostvarivanja optimalne veličine i strukture obrtnih sredstava, a on obuhvaća sljedeće aktivnosti: planiranje i računanje potrebnih obrtnih sredstava po najvažnijim vrstama, skupinama i u ukupnom iznosu; utvrđivanje raspoloživih obrtnih sredstava po najvažnijim vrstama, skupinama i u ukupnom iznosu; uspoređivanje raspoloživih s potrebnim obrtnim sredstvima po najvažnijim vrstama, skupinama i u ukupnom iznosu te iskazivanje odstupanja; određivanje ekonomskog značenja odstupanja; donošenje poslovnih odluka kojima će se na najpovoljniji način eliminirati navedena odstupanja; i provođenje odluka o eliminaciji odstupanja.

Planiranje potreba za obrtnim sredstvima podrazumijeva planiranje svih vrsta, skupina i podskupina obrtnih sredstava, pri čemu se mora voditi računa o brzini kojom obrtna sredstva cirkuliraju u kružnom toku. Treba se osigurati optimalna razina ulaganja u tekuću imovinu koja je potrebna poduzeću kako bi nesmetano provodio kontinuitet kružnog kretanja poslovnog ciklusa. Idealno bi bilo kada bi poduzeće više puta godišnje planiralo i prilagođavalo obrtna sredstva stvarnim potrebama. No, to ima smisla dok trošak planiranja obrtnih sredstava ne premaši uštede utvrđivanja optimalne razine obrtnog kapitala (Tepšić, 1985).

Neće svako pojedino odstupanje biti predmetom eliminacije zato što se raspoloživa obrtna sredstva utvrđuju u nekom trenutku, dok se potrebna obrtna sredstva utvrđuju za određeno razdoblje i predstavljaju prosječnu veličinu u promatranom razdoblju. Zbog toga je i normalno da se raspoloživa i potrebna obrtna sredstva ne izjednačuju i uspoređuju u svakom trenutku. Višak bilo kojeg oblika obrtnih sredstava može se eliminirati tako da se jedan oblik obrtnog sredstva pretvori u drugi oblik obrtnog sredstva (prodaja na kredit ili za gotovinu, utroškom u proizvodnji) i vraćanjem sredstva izvorima financiranja. Manjkovi obrtnih sredstava mogu se eliminirati tako da se kratkoročne obveze prema izvorima financiranja pretvore u dugoročne obaveze i angažiranjem dodatnih sredstava od izvora financiranja (Tepšić, 1985).

4.3. Upravljanje tekućom imovinom

Imovinu poduzeća dijelimo na fiksnu i tekuću imovinu. Fiksna imovina se još naziva i dugotrajna imovina jer je njezin vijek trajanja duži od godinu dana. Ovisno o pojavnom

obliku, fiksna imovina dijeli se na: nematerijalnu imovinu, materijalnu imovinu, dugotrajnu financijsku imovinu i potraživanja. Fiksnu imovinu čine sredstva za rad koja se namjeravaju upotrebljavati u dugom roku pa se još nazivaju i osnovnim sredstvima. Tekuća imovina se još naziva i kratkotrajna imovina jer se za nju očekuje da će promijeniti svoj pojavni oblik unutar jedne godine te da će se u istom razdoblju pretvoriti u novac. Obilježje tekuće imovine je da se jednokratnim upotrebama troši u poslovnim procesima poduzeća. Tekuću imovinu čine predmeti rada pa istu nazivamo i obrtnim sredstvima (Orsag, 2015). Uzimajući u obzir karakter pojavnog oblika obrtna će se sredstva u proizvodnom poduzeću obično nalaziti u sljedećim glavnim skupinama i podskupinama: pojavni oblici novčanog karaktera, pojavni oblici prelaznog karaktera novca u robu, pojavni oblici materijalnog karaktera i pojavni oblici prelaznog karaktera robe u novac (Tepšić, 1985).

Većina obrtnih sredstava vezana je u potraživanjima od kupaca i zaliham. S obzirom na fokus ovog doktorskog rada u nastavku ja dan osvrt na pojavne oblike obrtnih sredstava zalihe i potraživanja od kupaca.

4.3.1. Upravljanje potraživanjima od kupaca

Potraživanja od kupaca su prijelazni oblik obrtnih sredstava koji nastaje na kraju tokova sredstava, prije svega kao posljedica prodaje roba i usluga na trgovački kredit (Orsag, 2015). Trgovački kredit, s jedne strane može dati dobavljač pri čemu nastaju potraživanja od kupaca, dok ga s druge strane može primiti kupac pri čemu nastaju obveze prema dobavljačima (Baveld, 2012). Potraživanja od kupaca su iznosi koje kupci duguju poduzeću za kupljenu robu ili usluge na trgovački kredit.

Bhattacharya (2014) navodi teorije koje objašnjavaju razloge odobravanja trgovačkog kredita, a to su: teorija financiranja, teorija likvidnosti, teorija financijskih poteškoća, teorija garantiranja kvalitete, teorija transakcijskih troškova, teorije cjenovne diskriminacije, teorija diferencijacije proizvoda i teorija tržišne moći. Prema teoriji likvidnosti, poduzeća s negativnim novčanim tokovima daju više trgovačkih kredita. Prema teoriji financijskih poteškoća kupci iskorištavaju poduzeće koje je u financijskim poteškoćama pa mu plaćaju još sporije pri čemu poduzeće zapada još dublje u financijske poteškoće. Teorija garantiranja kvalitete temelji se na prethodnoj kontroli kupca kvalitete proizvoda. Teorija transakcijskih troškova kaže da uporaba trgovačkog kredita može smanjiti transakcijske troškove između kupca i dobavljača koji imaju

redovite transakcije. Teorije diferencijacije proizvoda tumači da će trgovački kredit diferencirati proizvod od konkurentskog proizvoda (Bhattacharya, 2014).

Uobičajeni rok naplate potraživanja od kupaca je 8 dana iako se taj rok može produljiti na 30, 60 ili 90 dana. Plaćanje u prvih 8 dana smatra se ranim plaćanjem pa poduzeća plaćanje u tom razdoblju nerijetko tretiraju kao gotovinsko razdoblje te u skladu s time daju gotovinski popust. Svrha gotovinskog popusta je ubrzavanje naplate, no isti će biti opravdan ako trošak popusta ne premaši oportunitetne uštede (Monto, 2013).

Prema Van Horne i Wachowicz (2002: 252) „politike naplate i kreditiranja poduzeća uključuju odluke o: kvaliteti prihvaćenog kupca, duljini kreditnog razdoblja, veličini gotovinskog popusta koji poduzeća odobravaju, bilo kakvim posebnim uvjetima poput sezonskih datiranja, te razini troškova naplate“. Kao i kod ostalih oblika tekuće imovine, financijski menadžer mora održavati optimalnu razinu, odnosno ravnotežu između profitabilnosti i rizika. „Smanjivanjem kreditnih standarda poduzeće može potaknuti potražnju, koja bi, potom, trebala povećati prodaju i zarade. No, postoji trošak održavanja dodatnih potraživanja, kao i povećani rizik od gubitaka na nenaplaćena potraživanja“ (Van Horne i Wachowicz, 2002: 246).

Prema Van Horne i Wachowicz (2002), troškovi održavanja dodatnih potraživanja su:

- administrativni troškovi provjeravanja dodatnih računa;
- oportunitetni trošak odvajanja sredstava na investiciju u dodatna potraživanja umjesto u neku drugu investiciju i
- trošak loših dugova u smislu sporosti naplate i dijela potraživanja koji nije naplaćen.

Postavlja se pitanje do koje razine poduzeće može odobriti dodatna potraživanja. S jedne strane poduzeće ima povećanu prodaju dok s druge strane ima dulje prosječne dane naplate potraživanja što znači da će novac biti dulje vezan za potraživanja. Prvo, poduzeće će odobriti dodatna potraživanja do razine do koje mu navedeni troškovi ne premašuju profitabilnost dodatne prodaje. Drugo, poduzeće će ulagati u dodatna potraživanja sve dok mu je ta investicija profitabilnija od neke druge investicije. Rezultati istraživanja *European Payment Practices 2017*¹⁵ pokazuju da što kupac ima

¹⁵ Istraživanje „European Payment Practices 2017“ proveo je nezavisni institut za istraživanje tržišta Kantar TNS u ime EOS Grupe. Podaci su prikupljeni od 3.200 tvrtki u 16 zemalja deseti put zaredom.

duže razdoblje na raspolaganju za plaćanje, vjerojatnije je da će doći do kašnjenja. Pa tako najkraće uvjete plaćanja ima Njemačka od 24 dana, ali i najlikvidnija plaćanja pri čemu udio pravovremenih plaćanja u poduzećima čini 83 %. Grčka ima najduže uvjete plaćanja od 47 dana, ali i najmanji udio pravovremenih plaćanja od 74 %. Poduzeća moraju biti vrlo oprezna pri utvrđivanju granice plaćanja jer bi zadržavanje kupca pod svaku cijenu moglo rezultirati stvaranju loše prakse plaćanja. S druge strane, u uvjetima velike konkurencije, dobavljači često ne mogu utjecati niti na cijenu niti na količinu, nego im uvjete prodaje nameću kupci.

Kada govorimo o trošku loših dugova, poduzeća često osiguravaju svoja potraživanja jer je jedan od najvećih poslovnih rizika rizik da se potraživanja ne naplate. Postoje brojni sistemski i nesistemski rizici zbog kojih do sada kupac uredan platiša može postati rizičan kupac. Neki od njih su narušena likvidnost kupca zbog drugih poslovnih procesa, stečaj, neuspješna ovrha, politički sukobi u zemlji izvoza i mnogi drugi. Prema istraživanju EOS Grupe (2017) ukupno 41 % europskih poduzeća redovito surađuje s pružateljima usluge naplate potraživanja. U Hrvatskoj pružatelji usluga naplate potraživanja nadoknadili su više od 10 % prihoda poduzećima.

Prema istraživanju EOS Grupe (2017) poduzeća često reagiraju na neplaćanje računa, osobito ona u istočnoj Europi, smanjivanjem broja zaposlenika i podizanjem cijena. Korisnici koji ne plaćaju račune prije svega štete onima koji plaćaju na vrijeme, a onda i samima sebi. U Hrvatskoj 30 % poduzeća reagira podizanjem cijena na kašnjenja i neplaćanja računa, te 22 % poduzeća smanjivanjem broja zaposlenika i stopiranjem zapošljavanja. S druge strane, u Njemačkoj tek 4 % poduzeća reagira na kašnjenja i neplaćanja povećanjem cijena te 6 % poduzeća poduzima korake smanjivanja broja zaposlenika.

Posljedice kašnjenja u plaćanju i neplaćanja u Hrvatskoj su: viši troškovi kamata (42 %); poteškoće s likvidnošću (35 %) i smanjenje prihoda (38 %). S druge strane, poslovni rizici kao posljedica kašnjenja u plaćanju i neplaćanja su: stopiranje ulaganja (29 %) i ugrožena opstojnost (14 %) (EOS Grupa, 2017).

4.3.2. Upravljanje zalihama

Zalihe su materijalni oblici obrtnih sredstava. U ovu skupinu obrtnih sredstava ubrajaju se zalihe sirovina i materijala, zalihe proizvodnje u toku, zalihe gotovih proizvoda i zalihe trgovačke robe. Zalihe trgovačke robe su zalihe tuđih proizvoda ili poluproizvoda koje poduzećima u djelatnosti trgovine predstavljaju temeljne zalihe dok proizvodnim poduzećima služe za kompletiranje vlastitih gotovih proizvoda ili kompletiranje složene isporuke dobavljačima (Orsag, 2015).

Zalihe su pozicija kratkotrajne, odnosno tekuće imovine. Prema kriteriju likvidnosti su najmanje likvidna tekuća imovina, i to od najmanje likvidnih zaliha sirovina i materijala, proizvodnje u toku i poluproizvoda do najlikvidnijih zaliha gotovih proizvoda i zaliha trgovačke robe. Iako su gotovi proizvodi visoko likvidne zalihe, oni moraju proći kroz proces prodaje i naplate da bi se pretvorili u novac i sa sobom nose rizik poslovanja od nemogućnosti ostvarenja prodaje i naplate. Vrste zaliha koje poduzeće posjeduje te važnost njihovim upravljanjem, primarno ovisi o sektoru u kojem poduzeće posluje (Mengesha, 2014). U skladu s time upravljanje zalihama bit će od veće važnosti u poduzećima koja se bave proizvodnjom te poduzećima koja se bave trgovinom u odnosu na ostala poduzeća. Fokus ovoga doktorskog rada je na poduzećima iz sektora koji u svojoj strukturi tekuće imovine imaju veliku razinu zaliha.

Različiti autori navode nekoliko motiva držanja zaliha pa tako Gupta i Gupta (2015) navode transakcijski motiv držanja zaliha, motiv opreznosti, odnosno sigurnosni motiv, špekulativni motiv, kompenzacijski motiv i ugovorni zahtjev. Transakcijski motiv držanja zaliha ima intenciju da se smanji broj transakcija, odnosno narudžbi što većim količinama narudžbe, a time i troškovi naručivanja. Veća količina narudžbe imat će za posljedicu manji ukupni trošak narudžbe zbog većeg količinskog popusta i manjeg troška prijevoza po jedinici proizvoda, ali će istovremeno troškovi skladištenja biti veći. Vrijedi i obrnuto, što je manja količina narudžbe, troškovi će skladištenja biti manji, ali će zato biti ukupni trošak narudžbe i trošak prijevoza po jedinici proizvoda veći. Zato se treba pronaći optimum između količine narudžbe i ukupnog troška zaliha, odnosno količinu zaliha pri kojoj one imaju minimalne ukupne troškove (Van Horne i Wachowicz, 2002). Van Horne i Wachowicz (2002) zaključuju kako se korištenje povećava, tako se optimalna veličina narudžbe, i prosječna razina zaliha povećavaju manjim postotkom. Također zaključuju da ukupni troškovi nabave variraju inverzno s veličinom narudžbe, dok ukupni troškovi držanja variraju direktno s veličinom narudžbe.

Kao što je ranije spomenuto, poduzeća drže više razine zaliha i iz oprezonosnih, odnosno sigurnosnih razloga. Sigurnosne zalihe su zalihe koje se drže u pripravi kao zaštitni jastuk zbog nesigurnosti potražnje i vremena potrebnog za razdoblje narudžbe. Kada naručiti zalihe, odnosno koliko vremena ostaviti između narudžbe i isporuke zaliha, posebno dolazi do izražaja kada je riječ o uvozu gdje je potrebno duže vrijeme da roba pristigne na skladište. No, to predviđanje dodatno otežava potrošnja, odnosno proizvodnja koja je podložna oscilacijama u ovisnosti o potražnji proizvoda (Van Horne i Wachowicz, 2002). Prema Van Horne i Wachowicz (2002) na visinu sigurnosnih zaliha utjecat će sljedeći čimbenici: nesigurnost povezana s predviđenom potražnjom za zaliham; nesigurnost razdoblja narudžbe kako bi se popunile zalihe; trošak nedostatka robe koji može rezultirati zastojem u proizvodnji, izgubljenom prodajom, nezadovoljnim potrošačima i mogućnosti njihova odlaska što može utjecati i na buduću prodaju; i trošak držanja dodatnih zaliha.

Rahenan i Nasr (2007) i Gill et al. (2010) ističu da držanje visokih razina zaliha smanjuje rizik od nestašice zaliha, dok Makori i Jagongo (2013) navode da držanje visokih razina zaliha smanjuje troškove mogućih prekida u procesu proizvodnje i gubitka posla zbog nestašice proizvoda. Van Horne i Wachowicz (2002) navode tradicionalne prednosti držanja visokih razina zaliha poput bržih ispunjavanja narudžbi. Visoka razina držanja zaliha na skladištu bit će potaknuta i špekulativnim motivom. Špekulativni motiv temelji se na gomilanju zaliha u količinama znatno većim od potrebnih jer se očekuje rast njihovih cijena u budućnosti te u skladu s time i ostvarivanje dodatnih profita (Bhattacharya, 2014).

Van Horne i Wachowicz (2002) isto tako navode i nedostatke držanja visoke razine zaliha poput ukupnog troška držanja zaliha koji uključuje trošak skladištenja, rukovanja, i osiguranja te opasnost od zastarijevanja. Nastavno na potonje, poslovanje bez zaliha moglo bi se smatrati idealnim usklađivanjem poslovnih aktivnosti glede upravljanja obrtnim kapitalom. No zbog rizika vezanih uz nesmetanu cirkulaciju sredstava u poslovnim procesima nužno je formirati određene rezerve novca. Zalihe i rezerve moraju biti upravo tolike da su profitabilnost i sigurnost poslovanja najbolje usklađene jer će tada i vrijednost toga poslovanja biti najveća (Orsag, 2015). Preduvjet dobrog upravljanja zaliham je njihovo planiranje pa će optimalna količina narudžbe za određeni artikl ovisiti o prognoziranom korištenju tog artikla, troškovima nabave i trošku držanja. Ekonomska količina narudžbe predstavlja količinu zaliha pri kojoj će se

minimizirati ukupni trošak zaliha tijekom planskog razdoblja poduzeća (Van Horne i Wachowicz, 2002).

Toyota je razvila metodu *Just-in-Time* (krat. JIT) kojoj je osnovni cilj proizvodnja ili nabava proizvoda u točno određeno vrijeme kada je proizvod potreban. U tom slučaju zalihe svih vrsta bi se morale smanjiti na minimum, a u nekim slučajevima bi bile i na nuli. Smanjenje troškova držanja zaliha jedan je od glavnih motiva razvoja JIT sustava (Van Horne i Wachowicz, 2002).

Poduzeća na zalihamo mogu imati nekoliko tisuća različitih artikala. Što je veći broj različitih artikala na zalihamo to je upravljanje njima teže i kompleksnije. S obzirom na to da postoje velike razlike između zaliha po pitanju cijene, dinamike potrošnje, dinamike i rizika nabave i slično, pri upravljanju zalihamo moraju se uvažiti navedene razlike. Stoga će se zalihe grupirati u skupine prema važnosti pri čemu će se svakom skupinom posebno upravljati i kontrolirati. Nastavno na potonje razvija se ABC metoda kontrole zaliha koja kontrolira zalihe prema njihovoj važnosti, odnosno vrijednosti i udjelu u ukupnim zalihamo. Zalihe najveće važnosti će se najčešće nadzirati jer nose najveću vrijednost i udio u ukupnim zalihamo.

4.4. Upravljanje tekućim obvezama

Za financiranje obrtnog kapitala, odnosno tekuće imovine, tekuće obveze su najvažniji oblik financiranja. Važnost upotrebe tekućih obveza za financiranje tekuće imovine ogleda se u prednostima i nedostacima u odnosu na dugoročne dugove i glavnice. Prednosti upotrebe tekućih obveza su veća fleksibilnost i niži troškovi financiranja. Nedostaci upotrebe tekućih obveza leže u povećanom riziku od njihove primjene koji se ogleda kao rizik od refinanciranja i kamatni rizik, odnosno rizik od promijene kamatnih stopa. Prilikom donošenja odluka o obliku financiranja tekuće imovine poduzeće uvažava međuovisnost rizika i nagrade (Orsag, 2015). Kratkoročno financiranje može biti spontano ili formalno. Pod oblicima spontanog, odnosno neformalnog kratkoročnog financiranja podrazumijeva se uobičajeni trgovački kredit dobavljača i akumulirani rashodi, odnosno narastajuće stavke. Narastajuće stavke su uobičajene isplate plaća, uobičajeno plaćanje poreza i neraspodijeljena tekuća dobit. Oblici ugovorenog, odnosno formalnog kratkoročnog financiranja su bankovni krediti koji mogu biti osigurani i neosigurani, faktoring te komercijalni papiri. Neosigurano se davanje zajmova uglavnom svodi na zajmove komercijalnih banaka po kreditnim linijama, ugovorom o obnavljajućem kreditu, ili na osnovi transakcija. Osigurani

kratkoročni poslovni zajmovi se najčešće osiguravaju temeljem potraživanja od kupaca i zaliha. Komercijalni papir je neosigurana kratkoročna zadužnica koja se najčešće prodaje na tržištu novca, ali se isto tako može prodati izravno investitorima te preko posrednika. Umjesto zalaganja potraživanja poduzeće se može baviti naplatom, odnosno prodajom potraživanja kako bi došla do gotovine (Van Horne i Wachowicz, 2002).

Poduzeća mogu usvojiti različite politike financiranja. Na odluku o načinu i strukturi financiranja na poduzeće će utjecati različiti faktori kao što su: tržište na kojem poduzeće posluje, sektor u kojem poduzeće posluje, ukupni troškovi financiranja, poslovni rizik, financijski rizik, dostupnost, vrijeme, fleksibilnost, kolateral, namjena zaduživanja, kompenzirajući saldo i drugi.

Ako poduzeća posluju u zemljama za koje su karakteristična razvijena financijska tržišta, lakše će doći do izvora financiranja, odnosno imat će više alternativa za dobivanje sredstava iz vanjskih izvora. Ako poduzeća posluju u manje razvijenim zemljama za koje su karakteristična manje razvijena tržišta kapitala i bankocentričan financijski sustav, sužen im je izbor vanjskih izvora financiranja. Takva poduzeća se najviše financiraju putem bankarskih kredita te su ovisna o kratkoročnom financiranju općenito (Garcia-Teruel i Martinez-Solano, 2007), a posebno o trgovačkom kreditu. Poduzeća koja posluju u stabilnom makroekonomskom okruženju mogu prihvatiti veći rizik koji ide uz agresivniju strategiju financiranja dok poduzeća koja posluju u neizvjesnom tržišnom okruženju su sklonija konzervativnoj strategiji financiranja koja za sebe veže manji rizik, ali i manju profitabilnost. Stoga je izuzetno važno i treba uzeti u obzir u kojoj zemlji poduzeće posluje. La Porta et al. (1997) tumače da zemlje sa slabijom zaštitom ulagača imaju manja i ograničenije tržišta kapitala, što financiranje bankarskim i trgovačkim kreditima čini atraktivnije.

Sektor u kojem poduzeće posluje imat će veliki utjecaj na strategiju financiranja zbog različitog trajanja ciklusa obrtnih sredstava poduzeća unutar različitih sektora. Sektori s kraćim ciklusom obrtnih sredstava zbog brže naplate potraživanja moći će prihvatiti veći rizik financiranja, odnosno koristiti agresivniju strategiju financiranja. Poduzeća koja u svojoj bilanci imaju veći udio dugotrajne imovine, više će se financirati iz dugoročnih izvora, dok će se poduzeća s manjim udjelom dugotrajne imovine više financirati kratkoročnim dugom.

Poduzeće može usvojiti pristup zaštite financiranju koji podrazumijeva da se svaka vrsta imovina financira s dugom približno istog datuma dospelja. To bi značilo da se sezonske potrebe financiraju kratkoročnim dugom, stalna tekuća imovina dugoročnim dugom te fiksna, odnosno dugotrajna imovina također dugoročnim dugom. Dugoročni se dug ne bi smio koristiti za financiranje kratkoročnih potreba jer bi poduzeće plaćalo kamate za sredstva i onda kad ih ne bi koristilo. Nepotrebno je da se koristi dugoročno financiranje za sezonske potrebe i u vrijeme sezonskih utihnuća. Pristupom zaštite financiranja raspored se posudbi prilagođava sezonskim potrebama, odnosno kada poduzeće uđe u razdoblje sezonskih potreba imovine posuđuje se na kratki rok te se te posudbe otplaćuju gotovinom koja se oslobađa trenutnom prodajom i naplatom potraživanja (Van Horne i Wachowicz, 2002).

Kada se govori o dospelju plaćanja, što je kraći rok između dospelja plaćanja obveza to je veći rizik da poduzeće neće moći podmiriti svoje obveze. Kamate na dugoročni dug obično su veće od kamata na kratkoročni dug, ali je poduzeću lakše otplaćivati dug s dužim rokovima između dospelja plaćanja obveza. Dva su najčešća rizika kratkoročnog financiranja za poduzeće: nemogućnost refinanciranja kratkoročnog kredita i promjenjivost kamatnih stopa (Orsag, 2015) pogotovo za poduzeća koja posluju u nestabilnom makroekonomskom okruženju. Van Horne i Wachowicz (2002) navode da će kratkoročno financiranje najvjerojatnije uroditi višim zaradama od dugoročnog jer će se dug otplatiti u razdobljima kada ne bude potreban. Ponekad kratkoročni kamatnjaci mogu premašiti dugoročne stope no takva situacija je samo privremena jer se kratkoročne posudbe neprekidno prevrću, odnosno refinanciraju pri dospelju.

Može se zaključiti da financiranje dugotrajne imovine kratkoročnim dugom nosi visok rizik, ali i visoku profitabilnost. Financiranje tekuće imovine dugoročnim dugom rezultirat će niskim rizikom, ali i niskom profitabilnosti. Tekuća imovina financirana kratkoročnim dugom i dugotrajna imovina dugoročnim dugom rezultirat će umjerenim rizikom i umjerenom profitabilnošću (Van Horne i Wachowicz, 2002).

Tekuće obveze su najvažniji oblik financiranja malih i srednjih poduzeća. Pri upravljanju tekućim obvezama nužno je voditi računa o prednostima, odnosno nedostacima dugoročnog naspram kratkoročnog financiranja. Kao neke od najvažnijih prednosti tekućih obveza navode se: fleksibilnost, odnosno mogućnost prilagođavanja potrebama poduzeća, niži troškovi pribavljanja kratkoročnih kredita zbog manjeg rizika

vraćanja te bolji odnosi s bankarima. Nedostaci tekućih obveza su: rizik refinanciranja – banka svakodnevno prati poslovanje poduzeća po prometu žiro računa i čim primijeti nove poslovne rizike neće prolongirati kredit i rizik promjenjivosti kamatnih stopa – prilikom obnavljanja kratkoročnog kredita poduzeća nemaju garanciju zadržavanja prethodno ugovorene kamatne stope (Van Horne i Wachowicz, 2002; Orsag, 2015). Veće tekuće obveze povećavaju profitabilnost poduzeća s jedne strane, dok s druge strane smanjuju likvidnost poslovanja pa samim time se povećava i rizik poslovanja.

4.4.1. Spontano financiranje

Spontano financiranje nastaje iz uobičajenog toka poslovnih aktivnosti poduzeća. Trgovački kredit dobavljača je najčešći oblik spontanog financiranja jer takvo financiranje nije rezultat sklapanja ugovora o financiranju. Također, spontano financiranje nastaje i u svim drugim uobičajenim slučajevima odgođenih plaćanja kao što su isplate plaća, poreza i slični drugi izdaci (Orsag, 2015).

4.4.1.1. Trgovački kredit dobavljača

Trgovački kredit dobavljača ili odgoda plaćanja obveza prema dobavljačima je najčešći oblik spontanog financiranja i najveći izvor kratkoročnih sredstava posebno za mala i srednja poduzeća kojima je teže doći do ostalih izvora financiranja. Kreditiranje se odvija za razdoblje od kada je kupcu isporučena roba ili usluga do trenutka njihova plaćanja. Iako je ovaj oblik financiranja najpogodniji za kupca prvenstveno zbog njegove fleksibilnosti, jednostavnosti i jeftinoće, predugo odgađanje plaćanja obveza prema dobavljačima može narušiti odnos između kupca i dobavljača, a time i buduće poslovanje.

Van Horne i Wachowicz (2002: 284) razlikuju tri tipa trgovačkog kredita:

1. Otvoreni račun je najčešći tip trgovačkog kredita i kod njega kupac ne potpisuje nekakav formalni dokument o zaduženju.
2. Obveze po izdanim vlastitim vrijednosnicama je tip trgovačkog kredita gdje kupac potpisuje zadužnicu kao dokaz dugovanja prodavatelju.
3. Trgovački akcepti je oblik gdje prodavatelj vuče mjenicu na kupca, što nalaže da kupac plati mjenicu na neki budući datum.

Orsag (2015) sa stajališta troškova financiranja, trgovačke kredite dijeli na slobodne trgovačke kredite i naplatne trgovačke kredite. Slobodni trgovački krediti ne sadržavaju

nikakav trošak financiranja. Njima bi se mogao eventualno imputirati oportunitetni trošak ako bi postojala mogućnost ostvarivanja trgovačkog popusta zbog avansnih plaćanja. U pravilu, to je obveza plaćanja u razdoblju od osam dana, koja se može produljiti do razdoblja od devedeset dana, a iznad tog razdoblja potrebno je sklopiti ugovor o robnom kreditu. Može se zaključiti da što su rokovi plaćanja dulji, to će poduzeće imati veću korist od ovakvog oblika financiranja, i obrnuto.

Za razliku od slobodnih trgovačkih kredita, naplatni trgovački krediti nose određeni trošak financiranja. Trgovački su krediti, u pravilu, naplatni kada se odnose na produljenje roka plaćanja iznad onoga uobičajenog (osam dana). Taj se trošak financiranja trgovačkog kredita može iskazati kao: diskont, ako je plaćanje unutar uobičajenog (ako se ne plati u npr. osam dana, platit će se puna cijena robe, odnosno cijena bez diskonta); ili kamata koja se plaća na odgodu plaćanja. Tako se naplatni trgovački kredit može označiti i razlikom razdoblja plaćanja ukupnog i slobodnog trgovačkog kredita (Orsag, 2015).

Uvjeti prodaje se kod trgovačkog kredita mogu svrstati u nekoliko širih kategorija prema „neto razdoblju“ unutar kojega se očekuje plaćanje, i prema uvjetima gotovinskog rabata, ako on postoji (Van Horne i Wachowicz, 2002):

- COD i CBD – Nema trgovačkog kredita. COD (engl. cash on delivery of goods) označava plaćanje u gotovini odmah nakon isporuke robe. CBD (engl. cash before delivery) označava plaćanje prije isporuke kako bi dobavljač izbjegao rizik da kupac odbije primiti robu.
- Neto razdoblje – Nema gotovinskog rabata. Dobavljač odredi neko razdoblje unutar kojeg mu kupac mora platiti (npr. „net 30“).
- Neto razdoblje – Gotovinski rabat. Uz odobreni kredit, dobavljač može ponuditi gotovinski rabat ako se račun plati u ranom dijelu neto razdoblja. Uvjeti „3/10, net 30“ znače da dobavljač nudi 3 posto rabata ako se račun plati unutar 10 dana. U protivnom, kupac mora platiti ukupan iznos unutar 30 dana.
- Sezonsko datiranje – U sezonskom poslu, prodavatelji često rabe datiranje kako bi potaknuli kupce da izvrše narudžbe prije prodavačke groznice.

Različiti autori u svojim radovima navode odrednice ponude trgovačkog kredita:

- Trgovački kredit može voditi visokoj prodaji, jer omogućuje kupcima provjeru količine i procijenu kvalitete proizvoda prije plaćanja (Lee i Stowe, 1993; Long et al., 1993; Deelof i Jegers, 1996; Petersen i Rayan, 1997; Deloof, 2003; Gill et al., 2010);
- Odobravanje trgovačkih kredita pomaže poduzećima u stvaranju dobrih odnosa s kupcima (Wilner, 2000);
- Odobravanjem trgovačkih kredita dobavljači imaju prednosti u odnosu na ostale financijske institucije u financiranju rastućih poduzeća s tekućim gubicima. Dobavljač će imati prednost u kontroli kupca jer može povući robu i ponovno je prodati. Dobavljač će imati prednost u vidu stjecanja informacija o poslovnim aktivnostima kupca te navedena poduzeća mogu postati izvorom budućeg poslovanja (Petersen i Rayan, 1997).

Također, mnogi autori navode odrednice potražnje trgovačkog kredita:

- Korištenje trgovačkog kredita omogućuje pristup kapitalu poduzećima koja mu ne mogu pristupiti kroz tradicionalne kanale (Petersen i Rayan, 1997);
- Trgovački kredit je jeftin i fleksibilan izvor financiranja za kupce, pogotovo za rizične kupce (Petersen i Rayan, 1997; Deloof, 2003; Raheman i Nasr, 2007);
- Nema formalnog pregovaranja s dobavljačem o uvjetima kredita niti sklapanja formalnog ugovora (Van Horne i Wachowicz, 2002);
- Poduzeće s financijskim poteškoćama može iskoristiti vjerovnika u slučaju kada vjerovnik ovisi o dužniku, odnosno kada je dobavljač najveći dio svojih proizvoda i usluga usmjerio prema jednom kupcu (Wilner, 2000);
- Zaostajanje isplate dobavljačima omogućuje poduzeću veća ulaganja u zalihe, a time i veću prodaju (Makori i Jagongo, 2013);
- Korištenje trgovačkog kredita će izazvati dodatne troškove za poduzeće ako je dobavljač ponudio avansni popust (Tepšić, 1985; Petersen i Rayan, 1995; Wilner, 2000; Deloof, 2003; Raheman i Nasr, 2007; Gill et al., 2010);
- Zakašnjelo plaćanje dobavljačima će izazvati dodatne troškove ako se plaćaju visoki penali, odnosno zatezne kamate za neplaćanje u roku (Tepšić, 1985; Petersen i Rayan, 1995).

Kao što je prije rečeno, troškovi trgovačkog kredita su u visini diskonta u slučaju kada je dobavljač ponudio avansni popust te zatezne kamate u slučaju kada kupac nije platio u roku svoju dospjelu obvezu. Ako kupac ne iskoristi ponuđeni avansni popust tada postoji oportunitetni trošak u visini ponuđenog, a neiskorištenog diskonta koji će biti manji što je razdoblje plaćanja duže. Na primjer, poduzeće će imati manji oportunitetni trošak u slučaju uvjeta prodaje „2/10, net 45“, nego „2/10, net 30“, jer će 15 dana duže koristiti trgovački kredit. Što se duže koristi trgovački kredit, to će oportunitetni trošak neiskorištenja avansnog popusta opadati. Ako je kupac platio svoju obvezu izvan razdoblja trajanja trgovačkog kredita, za posljedicu može očekivati plaćanje zateznih kamata, pogoršanje odnosa s dobavljačima te također oportunitetni trošak u vidu neiskorištenja avansnog popusta. Ako kupac ima ponuđene uvjete „2/10, net 30“, najpovoljnije mu je u slučaju korištenja avansnog popusta platiti deseti dan te u slučaju neiskorištavanja avansnog popusta platiti trideseti dan, jer će tada najduže koristiti slobodni, odnosno naplatni trgovački kredit. Prilikom donošenja odluke o korištenju trgovačkog kredita, troškovi korištenja trgovačkog kredita ne smiju premašiti njegove koristi (Orsag, 2015).

4.4.1.2. Narastajuće stavke

Kao i trgovački kredit dobavljača, narastajuće stavke predstavljaju spontani izvor kratkoročnog financiranja. Narastajuće stavke su obveze koje su obračunate, a nisu još plaćene. Karakteristike ovog oblika spontanog kratkoročnog financiranja su: beskamatno financiranje, kontinuitet financiranja i ovisnost o obujmu poslovanja. Orsag (2015) navodi ključno obilježje ovog oblika spontanog financiranja, a to je da ono nastaje spontano samim poslovanjem društva zbog uobičajenih vremenskih razlika obračuna i plaćanja obračunatih iznosa. Navodi da je takvo financiranje bez troškova, a njegovo značenje fluktuirá s fluktuacijama poslovne aktivnosti, iako ima određenu komponentu permanentnosti. Iako ovisi o obujmu poslovne aktivnosti, njegovo značenje ovisi i o uobičajenim razdobljima obračuna i plaćanja obračunatih iznosa spontano nastalih obveza. Kako se plaćaju stari akumulirani rashodi, novi se rashodi obračunavaju te za poduzeće takvo financiranje postaje konstantno (Van Horne i Wachowicz, 2002).

Oblici spontanog financiranja uporabom narastajućih stavki iz poslovanja poduzeća jesu (Orsag, 2015):

- obračunane plaće
- obračunani porezi i
- neraspodijeljeni dio dobiti.

Ovaj oblik spontanog financiranja imat će veći utjecaj za poduzeća koja odgađaju plaćanje svojih obračunanih obveza na što dulji rok, odnosno ona koja imaju duže razdoblje između dana obračuna obveza i dana plaćanja obveza. Poduzeća koja imaju manje razdoblje između obračuna obveza i plaćanja obveza, imat će manju korist od ovakvog oblika financiranja. Posebno treba biti oprezan ako poduzeća počnu imati problema s likvidnošću da ne odgađaju na duže vrijeme isplatu plaća i plaćanje poreza jer posljedice mogu biti pogubne za poduzeće, poput stečaja i likvidacije.

4.4.2. Ugovoreno financiranje

Ugovoreno financiranje može biti osigurano i neosigurano financiranje. Kod osiguranog financiranja nužno je postojanje kolaterala u obliku potraživanja, vrijednosnica i zaliha, dok se neosigurano financiranje temelji na kreditnoj sposobnosti zajmoprimca. Prema Van Horne i Wachowicz (2002) neosigurani izvori financiranja pretežno imaju niže kamatne stope, jer samo zajmoprimci visoke kreditne sposobnosti mogu dobiti sredstva bez osiguranja. Također, zajmodavac će ukalkulirati trošak nadziranja zaloga zajmoprimcu u obliku viših kamata. Osim bankovnih kredita koji mogu biti osigurani i neosigurani, izvor neosiguranog kratkoročnog financiranja su komercijalni zapisi i najvećim dijelom faktoring.

4.4.2.1. Kratkoročni krediti banaka

Bankovni kredit kao oblik kratkoročnog financiranja može biti osiguran i neosiguran. Neosiguran kredit pogodan je i za poduzeće slabije kreditne sposobnosti. Također, poduzeće koje je u stanju dobiti neosigurani kredit može dati zalog u zamjenu za nižu kamatnu stopu jer u pravilu osigurani krediti nose nižu kamatu od neosiguranih (Shim i Siegel, 2007). Manja su poduzeća često prisiljena financirati dio potrebe svoje trajne tekuće imovine kratkoročnim dugom, jer imaju problema u privlačenju financiranja dugoročnim dugovanjima. Često to poprima oblik bankovnih kreditnih linija koje se obrću uvijek iznova (Van Horne i Wachowicz, 2002). „Brži porast mase kredita za obrtna sredstva od rasta fizičkog obujma proizvodnje, realizacije, cijena i drugih indikatora privrednih kretanja ukazuje na to da je vršen stalan pritisak na izvore obrtnih

sredstava, ali i na činjenicu da se taj problem nije mogao uspješno riješiti samo intervencijama izvana“ (Tepšić, 1985:2).

Bankarski, kao i svaki drugi sektor, pod utjecajem je vanjskih i unutarnjih činitelja podložan promjenama, a u posljednje vrijeme su posebno izraženi sistemski rizici poput kreditnog rizika, valutnog rizika, rizika promjene kamatnih stopa, visoke eurizacije i drugo. Posljednje dvije godine banke bilježe smanjenu profitabilnost uzrokovanu nastalim gubicima zbog konverzije kredita u švicarskim francima u kredite u eurima. No banke se ponovno oporavljaju zbog rješavanja loših kredita. Iako se pristup malih i srednjih poduzeća financiranju poboljšava, u zadnjem istraživanju o pristupu poduzeća financiranju upućuje se na to da hrvatska mala i srednja poduzeća u tom području imaju više problema nego poduzeća u Europskoj uniji. Poboljšano financiranje malih i srednjih poduzeća očekuje se zahvaljujući europskim strukturnim i investicijskim fondovima, ali drugi potencijalni izvori financiranja uglavnom su neiskorišteni (Europska komisija, 2017b: 29). Informacije kolaju brže nego ikad prije pa se danas u jednom danu objavi više *tweetova* nego prije deset godina u cijeloj godini (Europska komisija, 2017a). Tržište se prilagođava novim tehnologijama, automatizaciji i uslugama pa tako i banke nude sve više usluga kako bi privukle što veći broj klijenata.

Bitna obilježja kratkoročnih bankovnih kredita mogu se sagledati kroz sljedeće rokove i uvjete njihova sklapanja (Orsag, 2015):

- dospijeće;
- fleksibilnost;
- kolateral;
- kompenzirajući saldo i
- trošak bankovnog kredita.

Kratkoročni bankovni krediti dospijevaju unutar jedne godine, a najčešće u roku do tri mjeseca te imaju mogućnost obnavljanja. U poslovanju kratkoročni krediti se najčešće koriste za financiranje tekućih potreba poslovanja pa imaju obilježje obnovljivosti te se u tom smislu upotrebljavaju u roku i duljem od godinu dana. Najveći rizik je usmjeren na mogućnost promjene kamatnih stopa i nemogućnost obnavljanja.

Fleksibilnost bankovnog kredita ogleda se u mogućnosti njegova prilagođavanja potrebama poslovanja. Sa stajališta fleksibilnosti razlikuju se sljedeći bankovni krediti (Orsag, 2015):

- Fiksni kredit – Najnepovoljniji kredit u pogledu fleksibilnosti. Korisnik ga diže u maksimalnom iznosu i tu se javlja problem neiskorištenih sredstava za vrijeme smanjenih potreba korisnika.
- Okvirni kredit – Odobrava se do određenog iznosa koji se ne smije premašiti, ali se pušta u tečaj prema potrebama korisnika i time se rješava problem neiskorištenih sredstava.
- Revolving ili obnavljajući krediti – Korisnik kredita može se stalno ponovno zaduživati do maksimalnog iznosa kredita nakon vraćanja dijela ili cijelog iznosa kredita.

Mogućnost prekoračenja na računu je osnovni oblik financiranja obrtnog kapitala. Dok se prekoračenje smatra nužnošću, za mala i srednja poduzeća je logično istovremeno imati otvorenu kreditnu liniju revolving (obnovljivog) kredita (Cvijanović, 2007: 85).

U pravilu, kratkoročni se krediti vraćaju jednokratno istekom kreditnog aranžmana. Iznimno je moguće ugovaranje vraćanja kredita u ratama jer bi se zbog kratkog roka trajanja financijskog odnosa vraćanja u ratama znatno povećala administracija kreditnog odnosa. U pravilu su bankovni krediti osigurani krediti kod kojih se osiguranja može obaviti zalogom robe ili zalogom isprave o vlasništvu robe, zalogom vrijednosnih papira ili drugih utrživih pokretnina te zalogom samih potraživanja (Orsag, 2015).

Troškovi bankovnog kredita su: kamate koje mogu biti jednostavne ili složene, trošak kompenzirajućeg salda, trošak obrade kreditnog zahtjeva i drugi troškovi poput administrativnih troškova (npr. javnobilježnički troškovi) i raznih naknada koje banka obračunava prilikom odobravanja kredita. Kod kratkoročnih kredita u pravilu se primjenjuje jednostavni kamatni obračun, dok se kod dugoročnih kredita obično primjenjuje složeni kamatni obračun.

Kreditna linija je oblik financiranja u kojem poduzeće može pozajmljivati i otplaćivati po potrebi, sve dok iznos zajma ne premašuje kreditni limit (Brealey et al., 2007). „Kreditna je linija neformalni dogovor između banke i određenog komitenta koji određuje svotu neosiguranog zajma što će ga banka dopustiti poduzeću da duguje u bilo koje vrijeme. Obično se kreditne linije otvaraju za jednogodišnje razdoblje i

spremljene su za obnavljanje odmah nakon što banka primi posljednje godišnje izvješće“ (Van Horne i Wachowicz, 2002: 292).

4.4.2.2. Faktoring

Faktoring je oblik kratkoročnog financiranja koji se obavlja putem specijalizirane financijske institucije koja se naziva faktorom. To je specifična financijska transakcija temeljena na prodaji potraživanja. Drugim riječima, faktoring je prodaja kratkoročne, u pravilu, neosigurane aktive faktoru uz određenu proviziju. Faktor je specijalizirana financijska institucija za pružanje usluga kratkoročnog financiranja potraživanja poduzeća (Orsag, 2015). Faktor pruža uslugu faktoringa dobavljaču, koji je vjerovnik predmeta faktoringa, uz naplatu ugovorene naknade. Kupac je dužnik predmeta faktoringa.

Faktoring ima sljedeća obilježja (Orsag, 2015):

1. financiranje;
2. naplata;
3. preuzimanje kreditnog rizika;
4. administrativni poslovi.

Jedno od osnovnih obilježja faktoringa je financiranje jer faktor plaća veći dio vrijednosti fakture svojim komitentima i to prije dospjeća fakture pri čemu na sebe preuzima i kreditni rizik. Na taj način komitenti puno ranije dolaze do naplate svojih potraživanja, ali umanjnih za naknadu faktoru (Orsag, 2015). Faktor će za svoje komitente također obaviti sve potrebne predradnje da do naplate potraživanja dođe, kao što su opomene, bilo telefonskim bilo pismenim putem, te će po potrebi koristiti i sve instrumente prisilne naplate potraživanja. Faktor može pružiti i dodatnu uslugu preuzimanja kreditnog rizika što znači da će isplatiti iznos potraživanja svom komitentu i u slučaju ako ga ne uspije naplatiti od kupca. Prema Zakonu o faktoringu (NN, 41/16), predmeti faktoringa mogu biti s pravom ili bez prava na regres. Kod regresnog faktoringa dobavljač jamči pružatelju usluga faktoringa za obvezu kupca, a kod bezregresnog faktoringa cjelokupni rizik naplate tereti pružatelja usluga faktoringa. Ako faktor ne pruža uslugu preuzimanja kreditnog rizika, onda će se u tom slučaju raditi o zalogu potraživanja, a ne prodaji potraživanja (Orsag, 2015).

Ovakav oblik financiranja, posebno je značajan za mala poduzeća koja imaju većih teškoća kod naplate potraživanja jer nemaju dovoljno kadrova specijaliziranih za proces prodaje, kontrole i naplate, a posebno rizične naplate. Trošak financiranja faktoring aranžmana viši je od troškova kratkoročnih bankovnih kredita. S obzirom na skroman kreditni rejting malih i srednjih poduzeća i suženost izbora kratkoročnog financiranja, faktoring se može djelomično pojaviti i kao iznuđeni izbor. S obzirom na to da se kod faktoringa radi o prodaji kratkoročne neosigurane imovine, to će također povećati troškove faktoring aranžmana jer faktor mora osigurati rezerve za pokriće kreditnih rizika (Orsag, 2015). U Republici Hrvatskoj faktoring je relativno nova financijska usluga, dok je u zemljama s razvijenim tržištima kapitala faktoring vrlo čest izvor kratkoročnog financiranja. U Hrvatskoj su poslovne banke najčešći faktori.

4.4.3. Komercijalni zapisi

Nasuprot financiranja putem bankarskih kredita, poduzeća se mogu financirati emisijom vrijednosnih papira. Komercijalni zapis je kratkoročni vrijednosni papir, odnosno neosigurani instrument kratkoročnog financiranja čiji su emitenti velike korporacije visokog kreditnog rejtinga. Komercijalni zapis je instrument tržišta novca vrlo kratkog dospjeća, do 270 dana. Komercijalni zapis se pretežno prodaje uz diskont pa kupci zarađuju na razlici tržišne i nominalne cijene. Kupci komercijalnih zapisa su institucionalni investitori poput investicijskih fondova, mirovinskih fondova, osiguravajućih društava, poslovnih banaka i drugi. Poduzeće može emitirati komercijalne zapise izravnom ponudom investitorima ili neizravno putem dilera ili investicijskih bankara.

Karakteristike komercijalnog zapisa (Orsag, 2015):

- niska likvidnost jer imaju slabo razvijeno sekundarno tržište pa samim time nemaju visoku utrživost;
- visoke nominalne vrijednosti jer su isključivo orijentirani na institucionalne investitore, a time im se smanjuju i troškovi emisije;
- pretežno se prodaju uz diskont jer uobičajeno ne nose kamatu za vrijeme do dospjeća;
- u pravilu su neosigurani kratkoročni vrijednosni papiri stoga je njihov rizik isključivo vezan za rejting njihova izdavatelja;

- često se emitiraju u vremenskim serijama, odnosno karakterizira ih refinanciranje pri čemu trošak emisije opterećuje samo prvu seriju.

Prednosti kratkoročnog financiranja komercijalnim zapisima (Orsag, 2015):

- jeftinije financiranje jer se izbjegavaju banke kako posrednici;
- izbjegavanje kompenzirajućeg salda jer za emisiju komercijalnih zapisa nije potreban;
- emisija komercijalnih zapisa nije ograničena iznosom kao kratkoročni bankarski krediti i
- prestiž tvrtke emitenta jer samo najbolje tvrtke dužnici imaju pristup tržištu komercijalnih zapisa.

Nedostaci kratkoročnog financiranja komercijalnim zapisima (Orsag, 2015):

- tržište komercijalnih zapisa dostupno je samo velikim tvrtkama;
- dobri odnosi s bankama zbog pribavljanja kratkoročnih kredita i
- nerazvijeno sekundarno tržište komercijalnih zapisa, odnosno njihov nizak stupanj likvidnosti.

5. STRATEGIJE UPRAVLJANJA OBRTNIM KAPITALOM

U središtu je zanimanja obrtnog kapitala način na koji poduzeća koriste obrtni kapital. Način upravljanja obrtnim kapitalom može imati značajan utjecaj i na likvidnost i na profitabilnost poduzeća (Shin i Soenen, 1998). Poduzeće može provoditi konzervativnu ili agresivnu strategiju upravljanja obrtnim kapitalom. Konzervativna strategija upravljanja obrtnim kapitalom favorizira sigurnost poslovanja, dok agresivna strategija upravljanja obrtnim kapitalom forsira profitabilnost naspram sigurnosti (Orsag, 2003). Ako poduzeće želi poboljšati svoju likvidnost, povećat će razinu ulaganja u obrtni kapital što će se odraziti na manju profitabilnost, a time i na veću sigurnost poslovanja, odnosno manji rizik. Ako poduzeće želi preuzeti veći rizik radi povećanja profitabilnosti, smanjit će razinu ulaganja u obrtni kapital. Agresivna strategija obrtnog kapitala je povezana s većim prinosom i rizikom, dok je konzervativna strategija obrtnog kapitala povezana s nižim rizikom i prinosom. Agresivnoj strategiji su sklonija poduzeća koja posluju u stabilnom makroekonomskom okruženju dok su konzervativnoj strategiji sklonija poduzeća koja posluju u neizvjesnom tržišnom okruženju (Baveld, 2012). U uvjetima sigurnosti kada se mogu bolje predvidjeti prihodi od prodaje, troškovi, naplata potraživanja, poduzeća drže minimalne količine obrtnog kapitala radi minimiziranja troškova. U uvjetima nesigurnog okruženja povećavaju se potrebe za obrtnim kapitalom zbog stvaranja rezervi sigurnosti što vodi do povećanja troškova i većih potreba za eksternim financiranjem (Orsag, 2015).

Postoji konzervativnost i agresivnost u investicijskoj i financijskoj strategiji upravljanja obrtnim kapitalom. Odnosom tekuće imovine i ukupne imovine dolazi se do zaključka kakvu strategiju investiranja poduzeće provodi. Također, odnosom tekućih obveza i ukupne imovine dolazi se do zaključka kakvu strategiju financiranja poduzeće provodi. Politika financiranja obrtnog kapitala mjeri se relativnom agresivnošću / konzervativnošću korištenja tekućih obveza za financiranje imovine obrtnog kapitala (Nigatu, 2015).

5.1. Strategije investiranja u obrtnom kapitalu

Poduzeće može imati agresivnu ili konzervativnu strategiju investiranja obrtnog kapitala. Konzervativna strategija investiranja je usmjerena k sigurnosti poslovanja, a agresivna strategija investiranja ima za cilj ostvarivanje visoke stope prinosa.

Konzervativna strategija investiranja podrazumijeva višu razinu ulaganja u tekuću imovinu, odnosno veću likvidnost što pretpostavlja niži rizik, ali i manji prinos. Veća tekuća imovina podrazumijeva veće zalihe, veća ulaganja u dodatna potraživanja, veću financijsku imovinu i veću količinu raspoloživog novca. Veća likvidnost rezultira većom sigurnosti u poslovanju pa će tako veće zalihe umanjiti rizik nastajanja zastoja u procesu proizvodnje, veća ulaganja u dodatna potraživanja mogu potaknuti veću prodaju te veća količina raspoloživog novca će umanjiti rizik od nemogućnosti podmirenja neplaniranih troškova. No isto visoke zalihe mogu rezultirati visokim troškovima održavanja zaliha kao i povećanim rizikom od njihova zastarijevanja. Ulaganja u dodatna potraživanja nose sa sobom povećani rizik loših dugova u smislu sporosti naplate ili djelomično nenaplaćenih potraživanja. Prevelika količina raspoloživog novca nosi sa sobom oportunitetni trošak u visini kamatnih stopa na štednju.


Agresivna strategija investiranja podrazumijeva minimalnu razinu ulaganja u tekuću imovinu. Cilj agresivne strategije investiranja je stvaranje velikih zarada. Radi povećanja prihoda od prodaje poduzeća će više kapitala uložiti u ubrzanje prodaje i proizvodnje pa neće stvarati nepotrebne zalihe, plaćanje računa odgodit će što je dulje moguće, a kreditne standarde povećati čime će umanjiti troškove održavanja povećanih potraživanja kao i rizike od mogućnosti nenaplaćenih potraživanja. No velike zarade nose sa sobom velike rizike poslovanja, a mala likvidnost nosi sa sobom i nesigurnost u poslovanju. Male zalihe mogu uzrokovati probleme u procesu proizvodnje i prodaje, nedavanje dobrih kreditnih standarda može rezultirati gubitkom kupaca, a neraspologanje dovoljnom količinom novca može dovesti do problema s likvidnosti u slučaju potrebe za podmirivanjem neplaniranih troškova. Agresivnu strategiju investiranja koristit će poduzeća koja posluju u sigurnom poslovnom okruženju, odnosno kada su im uvjeti poslovanja lako procenjivi i predvidivi.

5.2. Strategije financiranja obrtnog kapitala

Poduzeće može imati agresivnu ili konzervativnu strategiju financiranja obrtnog kapitala. Financiranje obrtnog kapitala povezano je prije svega s principom sigurnosti koji zahtijeva usklađivanje vremenske strukture potreba poduzeća za sredstvima i strukture dospijuća obveza poduzeća (Orsag, 2015: 606).

Konzervativna strategija financiranja podrazumijeva dugoročno financiranje dijela fluktuirajuće imovine gdje prevladava princip sigurnosti nad principom profitabilnosti.

Mnoga poduzeća koriste konzervativnu strategiju financiranja kako bi se smanjili rizici s kojima je suočen temeljni princip upravljanja obrtnim kapitalom, princip samolikvidirajućih obveza (Orsag, 2015).



Slika 3. Konzervativna strategija upravljanja obrtnim kapitalom


Izvor: Orsag (2015)

Na slici 3 je prikazana konzervativna strategija financiranja obrtnog kapitala. Na zasjenčanom dijelu slike vidljivo je da se formiraju rezerve sigurnosti u trenutku sezonskih utihnuća, odnosno stvaraju se viškovi u vremenu minimalnih potreba poduzeća za sredstvima. Na taj način poduzeća, s jedne strane, umanjuju rizik od prekida kontinuiteta poslovanja dok s druge strane, stvaraju oportunitetni trošak neiskorištenih sredstava (Orsag, 2015).

Agresivna strategija financiranja podrazumijeva korištenje kratkoročnih izvora sredstava za financiranje dugoročno vezane imovine i tu prevladava načelo profitabilnosti naspram načela likvidnosti zbog nedovoljnog fundiranja tekuće imovine. Jedan od glavnih ciljeva korištenja agresivne strategije financiranja jesu moguće uštede korištenjem jeftinijih kratkoročnih pozajmica nasuprot skupljih dugoročnih dugova (Orsag, 2015). Najveći rizik korištenja agresivne strategije financiranja je nemogućnost obnavljanja kratkoročnih pozajmica što za posljedice može imati:

- insolventnost poduzeća popraćena zateznim kamatama i sudskim troškovima;
- nemogućnost nabave proizvodnih inputa jer dobavljači otkazuju isporuke zbog neplaćanja i
- promjena stajališta investitora o sigurnosti ulaganja u takvo poduzeće (Orsag, 2015).

Drugi najveći rizik je promjena kamatnih stopa uslijed refinanciranja, odnosno da se ne dobiju pozajmice po istim uvjetima po kojima su se dobile prvi put. Ponekad povećanje kamatnih troškova nastalih uslijed refinanciranja može porasti iznad planiranih ušteda postignutih dugoročnim financiranjem.




Slika 4. Agresivna strategija upravljanja obrtnim kapitalom

Izvor: Orsag (2015)

Na slici 4 je prikazana agresivna strategija financiranja obrtnog kapitala. Osjenčana je površina permanentna imovina te se vidi da se veći dio financira iz dugoročnih izvora dok se manji dio financira iz kratkoročnih izvora.

5.3. Umjerena politika

Umjerena strategija financiranja nalazi se između konzervativne i agresivne strategije financiranja i ona primjenjuje pristup usklađivanja dospijeća, odnosno *hedging* pristup. Usklađivanje dospijeća znači da se svaka imovina financira financijskim instrumentom s približno istim datumom dospijeća. Stalne komponente tekuće imovine i sva fiksna imovina bili bi financirani dugoročnim dugom ili kroz dioničke uloge dok bi kratkoročne ili sezonske promjene u tekućoj imovini bile financirane kratkoročnim dugom (Van Horne, Wachowicz, Jr., 2002).



Slika 5. Potrebe za financiranjem i imovinom tijekom vremena: umjerena strategija financiranja i usklađivanje dospijeća

Izvor: Van Horne i Wachowicz (2014)

Na slici 5 se vidi da se samo kratkoročne sezonske potrebe financiraju iz kratkoročnih izvora. Preporuka je poduzeću da u vrijeme sezonskih utihnuća otplaćuje samo tekuće obveze na dugoročni dug. U vremenu sezone, odnosno povećanih potreba za sredstvima preporuča se kratkoročno zaduživanje koje će se otplaćivati naplatom potraživanja od prodaje robe ili usluga u tijeku sezone.

Strategija upravljanja obrtnim kapitalom poduzeća može se karakterizirati kao agresivna, umjerena ili konzervativna samo ako se uspoređuje sa strategijom upravljanja obrtnog kapitala sličnog poduzeća. Nema apsolutnih mjerila o tome što se može smatrati agresivnom ili konzervativnom strategijom upravljanja obrtnim kapitalom, ali ove karakteristike su korisne za analizu na koji način pojedina poduzeća pristupaju operativnom problemu upravljanja obrtnim kapitalom (Nigatu, 2015).

Niz godina održavanje likvidnosti je bio jedan od glavnih ciljeva poduzeća i financijskih menadžera jer održavanje preniske likvidnosti poduzeća utječe nepovoljno na sigurnost i rizik poduzeća dok održavanje previsoke razine likvidnosti utječe nepovoljno na profitabilnost poduzeća. Profitabilnost i likvidnost su važni ciljevi za svako poduzeće i napuštanje jednog cilja u korist drugog može stvoriti ozbiljne probleme za poduzeće. Profitabilnost je dugoročni cilj svakog poduzeća jer je potrebna za opstanak poduzeća na tržištu i poduzeće neće najvjerojatnije nastaviti poslovati bez

dobiti. S druge strane, likvidnost je relativno kraći cilj koji treba biti usmjeren da zaštiti poduzeće od stečaja i likvidacije (Scharf, 1984 u Nigatu, 2015).

5.4. Pokazatelji obrtnog kapitala

Obrtni kapital se najčešće interpretira kroz pokazatelje aktivnosti, likvidnosti i profitabilnosti.

5.4.1. Pokazatelji obrtaja imovine

Pokazatelji obrtaja imovine stavljaju u odnos promet i imovinu čime pokazuju koliko brzo i efikasno poduzeće upravlja svojim resursima i aktivnostima imovine. Kod svih pokazatelja promet je uvijek iskazan po neto prodajnim cijenama osim kod pokazatelja obrtaja zaliha gdje se iskazuje prema trošku nabave. Kod interpretacije ovih pokazatelja ne postoje univerzalne veličine, jer se struktura i veličina imovine razlikuje po sektorima. Pokazatelji će se interpretirati u odnosu na prethodne godine, slična poduzeća ili unutar sektora.

U nastavku je dan kratak pregled pokazatelja obrtaja imovine:

- 1) pokazatelj obrtaja tekuće imovine;
- 2) pokazatelj obrtaja neto obrtnog kapitala;
- 3) pokazatelj obrtaja potraživanja;
- 4) dani naplate potraživanja;
- 5) pokazatelj obrtaja zaliha;
- 6) dani vezivanja zaliha;
- 7) pokazatelj obrtaja obveza prema dobavljačima;
- 8) dani plaćanja obveza prema dobavljačima;
- 9) operativni ciklus i
- 10) ciklus konverzije novca.

Pokazatelj obrtaja tekuće imovine pokazuje koliko se puta tekuća imovina obrne tijekom godine, odnosno koliko efikasno poduzeće koristi svoju tekuću imovinu u stvaranju prihoda. Poželjno je da pokazatelj bude što veći. Ako pokazatelj obrtaja tekuće imovine ima tendenciju povećavanja, znači da se smanjuje prosječno trajanje obrtaja. Računa se kao:

$$\text{Pokazatelj obrtaja tekuće imovine} = \text{prihod od prodaje} / \text{prosječna tekuća imovina}$$

Pokazatelj obrtaja neto obrtnog kapitala pokazuje koliko efikasno poduzeće koristi neto obrtni kapital za generiranje prihoda. Računa se kao:

$$\text{Pokazatelj obrtaja neto obrtnog kapitala} = \text{prihod od prodaje} / \text{neto obrtni kapital}$$

Ako se napravi inverzija, odnosno obrtni kapital podijeli s iznosom prodaje, dobiva se informacija koliko se obrtnog kapitala mora staviti na raspolaganje za svaku dodatno generiranu jedinicu novca (Vater et al., 2016 u Ramljak, 2018).

Pokazatelj obrtaja potraživanja, dani naplate potraživanja, pokazatelj obrtaja zaliha, dani vezivanja zaliha, pokazatelj obrtaja obveza prema dobavljačima i dani plaćanja obveza prema dobavljačima objašnjeni su u potpoglavlju *Varijable u modelu* (6.2.) pa će ovdje biti izostavljeni iz analize.

Operativni ciklus je vrijeme proteklo od nabave zaliha, neovisno o trenutku plaćanja, do trenutka naplate potraživanja. Računa se kao:

$$\text{Operativni ciklus} = \text{dani naplate potraživanja} + \text{dani vezivanja zaliha}$$

Ciklus konverzije novca je vrijeme između odljeva novca u korist plaćanja obveza prema dobavljačima i zaposlenicima i priljeva novca od naplate potraživanja od kupaca. Cilj je minimizirati vrijeme između plaćanja obveza i naplate potraživanja. Za razliku od prethodno prikazanih statičnih pokazatelja, ovaj pokazatelj ima dinamični karakter jer uzima u obzir određeno razdoblje. Uz ovu prednost, ovaj pokazatelj ima i određene nedostatke kao npr. različiti izbori poduzeća u odabiru metoda vrednovanja zaliha koje će različito utjecati na vrijednost pokazatelja.

Računa se kao razlika između operativnog ciklusa i dana plaćanja obveza prema dobavljačima, odnosno:

$$\text{Ciklus konverzije novca} = \text{dani naplate potraživanja} + \text{dani vezivanja zaliha} - \text{dani plaćanja obveze prema dobavljačima}$$

5.4.2. Pokazatelji likvidnosti

Likvidnost ima višeznačnu upotrebu (Orsag, 2015: 593):

- likvidnost investicijske imovine;
- likvidnost poslovne imovine i

- likvidnost poslovanja.

Likvidnost investicijske imovine je sposobnost vrijednosnih papira da se pretvore u novac po očekivanoj cijeni. Likvidnost poslovne imovine mjeri se potrebnim vremenom da se imovina pretvori u novac kroz redovnu cirkulaciju u poslovnim procesima. Likvidnost pojedinih dijelova poslovne imovine ovisi o tome u kojoj se od faza poslovnih procesa nalazi ta imovina. Na primjer, potraživanjima od kupaca je potrebna samo jedna faza poslovnoga procesa, naplata, da bi se pretvorila u novac dok su zalihamu potrebne dvije faze i to, prodaja i naplata. Likvidnost poslovanja je sposobnost cirkulacije imovine u poslovnim procesima poduzeća bez zastoja, i to u planiranim iznosima i planiranom dinamikom (Orsag, 2015: 594-595).

U nastavku je dan kratak pregled pokazatelja likvidnosti:

- 1) pokazatelj tekuće likvidnosti;
- 2) pokazatelj ubrzane likvidnosti;
- 3) pokazatelj trenutne likvidnosti i
- 4) pokazatelj financijske stabilnosti.

Pokazatelj tekuće likvidnosti je sposobnost poduzeća da tekućom imovinom podmiri svoje tekuće obveze. Ovaj pokazatelj ne bi smio biti manji od dva. Ako je ovaj pokazatelj značajno veći od dva, trebalo bi provjeriti obrtaj zaliha poduzeća. U sektorima u kojima zalihe čine veliki dio tekuće imovine primjereniji pokazatelj će biti pokazatelj ubrzane likvidnosti. Izračunava se:

$$\text{Pokazatelj tekuće likvidnosti} = \text{tekuća imovina} / \text{tekuće obveze}$$

Pokazatelj ubrzane likvidnosti je nadopuna prethodnog pokazatelja. S obzirom na to da zalihamu treba dulje ili kraće vrijeme da se pretvore u novac, ovaj pokazatelj isključuje zalihe iz analize. Ovaj pokazatelj treba biti minimalno jedan. Računa se kao omjer tekuće imovine, pri čemu se isključuju zalihe i tekućih obveza, odnosno:

$$\text{Pokazatelj ubrzane likvidnosti} = (\text{tekuća imovina} - \text{zalihe}) / \text{tekuće obveze}$$

Ili

$$\text{Pokazatelj ubrzane likvidnosti} = (\text{potraživanja} + \text{novac}) / \text{tekuće obveze}$$

Pokazatelj trenutne likvidnosti je sposobnost poduzeća da iz svoje najlikvidnije imovine, novca, podmiri svoje tekuće obveze. Ovaj pokazatelj ne bi smio biti manji od 0,1. Računa se kao omjer novca i tekućih obveza, odnosno:

$$\text{Pokazatelj trenutne likvidnosti} = \text{novac} / \text{tekuće obveze}$$

Pokazatelj financijske stabilnosti pokazuje u kojoj se mjeri obrtni kapital financira iz dugoročnih izvora. Ako je ovaj pokazatelj manji od jedan, znači da je dugotrajna imovina poduzeća manja od dugoročnih obveza i da se dio dugoročnih izvora koristi za financiranje obrtnog kapitala. Ako je pokazatelj veći od jedan, znači da se dio dugotrajne imovine financira iz kratkoročnih izvora, što ukazuje na nedostatak obrtnog kapitala. Računa se kao omjer dugotrajne imovine i kapitala i dugoročnih obveza, odnosno:

$$\text{Pokazatelj financijske stabilnosti} = \text{dugotrajna imovina} / (\text{kapital} + \text{dugoročne obveze})$$

5.4.3. Pokazatelji profitabilnosti

Pokazatelji profitabilnosti mjere stupanj prinosa na uloženo. Profitabilnost se bazira na kategorijama prihoda i rashoda, odnosno za izračune se koriste informacije iz izvještaja o dobiti. Postoje različiti pokazatelji profitabilnosti koji se mogu koristiti kao mjera profitabilnosti poduzeća.

Najčešće korišteni pokazatelji profitabilnosti poduzeća su:

- 1) stopa prinosa imovine ili ROA;
- 2) stopa prinosa kapitala ili ROE;
- 3) bruto profitna marža;
- 4) operativna profitna marža i
- 5) neto profitna marža.

Prva dva pokazatelja su izražena kao stope prinosa i oni mjere stupanj zarade na ukupno uloženu imovinu poduzeća, odnosno kapital.

Stopa prinosa imovine (ROA) predstavlja prinos od uložene imovine, odnosno, pokazuje kako efikasno poduzeće upravlja raspoloživom imovinom. Računa se kao omjer zarada prije kamata i poreza i prosječne ukupne imovine, odnosno:

$$\text{ROA} = \text{zarade prije kamata i poreza} / \text{prosječna ukupna imovina}$$

Stopa prinosa kapitala (ROE) pokazuje godišnji prinos na temelju uloženog kapitala vlasnika, odnosno kolika je zarada na jednu jedinicu uloženog vlastitog kapitala. Mjeri se kao omjer zarada poslije poreza i prosječnog kapitala vlasnika.

$$\text{ROE} = \text{zarade poslije poreza} / \text{prosječni kapital vlasnika}$$

Sljedeća tri pokazatelja mjere profitnu snagu poduzeća za pokriće proizvodnih troškova, administrativnih troškova, troškova kamata, poreza, razvoja poduzeća i drugo.

Bruto profitna marža pokazuje koliko prihoda ostaje poduzeću nakon pokrića proizvodnih troškova, a za pokriće administrativnih troškova, troškova kamata, poreza i za razvoj poduzeća. Formula za izračun je:

$$\text{Bruto profitna marža} = \text{bruto dobit} / \text{prihod od prodaje}$$

Operativna profitna marža pokazuje koliko je prihoda ostalo za financiranje financijskih obveza poduzeća nakon podmirenja proizvodnih i administrativnih troškova. Uz ROA-u ovaj pokazatelj se najčešće koristi prilikom usporedbe rezultata različitih analiza poduzeća između različitih zemalja zbog anuliranja utjecaja porezne politike. Računa se kao:

$$\text{Operativna profitna marža} = \text{zarade prije kamata i poreza} / \text{prihod od prodaje}$$

Neto profitna marža pokazuje kolika je neto dobit od ukupno realiziranog posla, a s kojim možemo slobodno raspolagati bilo za isplatu vlasnicima ili za reinvestiranje. Računa se:

$$\text{Neto profitna marža} = \text{neto dobit} / \text{prihod od prodaje}$$

5.5. Utjecaj sektora na upravljanje obrtnima kapitalom


Filbeck i Krueger (2005) navode da se politike obrtnog kapitala poduzeća razlikuju među sektorima i mijenjaju unutar svakog sektora tijekom vremena. Sva poduzeća nemaju jednaku potrebu za obrtnim sredstvima. Visina obrtnih sredstava ovisi o: obujmu, vrijednosti i asortimanu proizvodnje i usluga; tehnološkom procesu proizvodnje i pružanja usluga; uvjetima opskrbe sirovinama i materijalima; uvjetima naplate prodanih proizvoda ili usluga i uvjetima podmirivanja obveza prema drugima (doprinosi, plaće radnika) i drugim.

U istraživanju *Annual Global Working Capital Survey*¹⁶ (PWC, 2015) navode se četiri glavna čimbenika koji utječu na zahtjeve obrtnog kapitala:

1. Sektor u kojem poduzeće djeluje. Potrebe za obrtnim kapitalom su različite u različitim sektorima. Također, postoji i veliki jaz između poduzeća unutar istog sektora, jer su neka poduzeća više ili manje vješta od drugih u upravljanju obrtnim kapitalom.
2. Gospodarska razvijenost regije. Poduzeća koja posluju u razvijenim gospodarstvima uspješnije upravljaju novcem i obrtnim kapitalom od poduzeća koja posluju u brzo rastućim gospodarstvima.
3. Veličina poduzeća. Velika poduzeća bolje upravljaju obrtnim kapitalom dok mala poduzeća imaju veću potrebu za učinkovitim upravljanjem obrtnim kapitalom kako bi financirali svoj rast.
4. Važnost upravljanja novcem i obrtnim kapitalom. Često se menadžment okreće bankama ili investitorima u pronalaženju izvora financiranja obrtnog kapitala umjesto da pažnju usmjeri na pronalaženje načina stvaranja više slobodnih novčanih tokova.

Na slici 6 prikazan je medijan dana potrebnih poduzeću da pretvori svoja obrtna sredstva u prihode od prodaje po sektorima.

¹⁶ Ova studija pruža pregled performansi globalnog obrtnog kapitala i temelji se na istraživanju 10.215 najvećih tvrtki u svijetu.




Slika 6. Medijan dana potrebnih za pretvorbu obrtnih sredstava u prihode od prodaje

Izvor: pwc (2015)

Najmanji medijan od šest dana ima hotelijerska industrija, odnosno polovici poduzeća je potrebno šest ili više dana da pretvori obrtna sredstva u prihode od prodaje, a polovici poduzeća šest ili manje dana. Najveći medijan ima farmaceutska industrija u kojoj je polovici poduzeća potrebno devedeset i dva dana ili više da pretvore obrtna sredstva u prihode od prodaje, a polovici poduzeća devedeset dva dana ili manje. Maloprodaja i potrošačka industrija imaju medijan od četrdeset i osam dana, industrija proizvodnje šezdeset i devet dana, a građevinska industrija, kao i metalna industrija, sedamdeset i jedan dan.

Na slici 7 prikazani su donji i gornji kvartili dana potrebnih za pretvorbu obrtnih sredstava u prihode od prodaje po sektorima.




Slika 7. Kvartili potrebnih dana za pretvorbu obrtnih sredstava u prihode od prodaje

Izvor: pwc (2015)

Najmanja razlika između gornjega i donjega kvartila od 34 dana prisutna je u prijevoznicičkoj industriji, a najveća od 106 dana u zrakoplovnoj industriji. Maloprodajna i potrošačka industrija imaju raspon između gornjeg i donjeg kvartila, isto kao i metalna industrija, 74 dana, industrija proizvodnje ima raspon od 78 dana, a građevinska industrija od 81 dan.

Ganesan (2007) navodi da će se poduzeća koja posluju u manje konkurentskom sektoru fokusirati na minimiziranje potraživanja radi povećanja novčanog toka. S druge strane, poduzeća koja posluju u konkurentnijem sektoru, imat će relativno višu razinu potraživanja. Na slici 8 prikazani su medijani i donji i gornji kvartili dana naplate potraživanja po sektorima.



Slika 8. Medijan i kvartili dana naplate potraživanja po sektorima

Izvor: pwc (2015)


Najmanji medijan od petnaest dana ima hotelijerska industrija, odnosno polovici poduzeća je potrebno petnaest ili više dana da naplati svoja potraživanja, a polovici poduzeća petnaest ili manje dana. Najveći medijan ima građevinska industrija u kojoj je polovici poduzeća potrebno sedamdeset i tri dana ili više da naplate svoja potraživanja, a polovici poduzeća sedamdeset tri dana ili manje. Maloprodaja i potrošačka industrija imaju medijan od trideset i jedan dan, a industrija proizvodnje šezdeset i tri dana.

Najmanja razlika između gornjega i donjega kvartila od 29 dana prisutna je u hotelijerskoj industriji i prijevozničkoj industriji, a najveća od 66 dana u građevinskoj industriji. Maloprodajna i potrošačka industrija imaju raspon između gornjeg i donjeg kvartila, isto kao i tehnološka industrija, 46 dana, a industrija proizvodnje isto kao i automobilska industrija, ima raspon od 54 dana.

Prema istraživanju EOS Grupe (2017) postotak plaćanja izvršenih na vrijeme u cijeloj Europi kontinuirano blago raste od 2007. godine. Poduzeća trpe financijske gubitke unatoč činjenici da danas 78 % svih kupaca plaća svoje račune na vrijeme. 19 % svih

faktura plaća se prekasno dok se 3 % nepodmirenih potraživanja ne uspijeva nikada naplatiti. U istočnoj Europi prosječni postotak neplaćenih računa bio je čak 4 % dok su najlošije prakse plaćanja bile u Grčkoj, Rusiji, Rumunjskoj, Bugarskoj i Slovačkoj. Očekivano Njemačka i Švicarska imaju najveći broj uplata na vrijeme.

Na slici 9 prikazani su medijani i donji i gornji kvartili dana vezivanja zaliha po sektorima.



Slika 9. Medijan i kvartili dana vezivanja zaliha po sektorima


Izvor: pwc (2015)

Najmanji medijan od pet dana imaju prijevoznačka industrija i industrija zabave i medija, odnosno polovica poduzeća ima pet ili više dana vezivanja zaliha, a polovica poduzeća pet ili manje dana. Najveći medijan ima farmaceutska industrija u kojoj polovica poduzeća ima 116 ili više dana vezivanja zaliha, a polovica poduzeća 116 ili manje dana. Maloprodajna i potrošačka industrija imaju medijan od 70 dana, industrija proizvodnje ima medijan od 56 dana, a građevinska industrija od 54 dana.

Najmanja razlika između gornjega i donjega kvartila od 24 dana prisutna je u industriji zabave i medija, a najveća od 107 dana u zdravstvenoj industriji. Maloprodajna i

potrošačka industrija imaju raspon između gornjeg i donjeg kvartila 79 dana, industrija proizvodnje 87 dana, a građevinska industrija ima raspon od 90 dana.

Na slici 10 prikazani su medijani i donji i gornji kvantili dana plaćanja obveza prema dobavljačima po sektorima.



Slika 10. Medijan i kvantili dana plaćanja dobavljača po sektorima


Izvor: pwc (2015)

Najmanji medijan od 34 dana ima hotelijerska industrija, odnosno polovici poduzeća je potrebno 34 ili više dana da plati svoje obveze prema dobavljačima, a polovici poduzeća 34 ili manje dana. Najveći medijan ima komunikacijska industrija u kojoj je polovici poduzeća potrebno 67 dana ili više dana da plate svoje obveze prema dobavljačima, a polovici poduzeća 67 ili manje dana. Maloprodajna i potrošačka industrija imaju medijan od 47 dana, industrija proizvodnje 49 dana, a građevinska industrija, isto kao i automobilska industrija, 57 dana.

Najmanja razlika između gornjega i donjega kvartila od 32 dana prisutna je u hotelijerskoj industriji, a najveća od 77 dana u komunikacijskoj industriji. Maloprodajna i potrošačka industrija imaju raspon između gornjeg i donjeg kvartila 47 dana, industrija

proizvodnje isto kao i farmaceutska industrija 57 dana, a građevinska industrija ima raspon od 60 dana.

Na slici 11 prikazan je ciklus konverzije novca po sektorima.



Slika 11. Ciklus konverzije novca po sektorima

Izvor: Izrada i izračun autorice prema izvještaju pwc (2015)

Najbrži ciklus konverzije novca od 5 dana ima energetska industrija, a najsporiji ciklus konverzije novca od 101 dan ima zrakoplovna, obrambena i sigurnosna industrija. Maloprodaja i potrošačka industrija imaju ciklus konverzije novca 78 dana, industrija proizvodnje 84 dana, građevinska industrija 96 dana.

Sektori koji se analiziraju u ovom doktorskom radu, maloprodaja i potrošačka industrija, industrija proizvodnje i građevinska industrija, nalaze se među sektorima koji imaju najdulje cikluse konverzije novca pa je time kod njih veća važnost upravljanja obrtnim kapitalom.

Problemi upravljanja obrtnim kapitalom prisutni su kako u razvijenim zemljama, tako i u zemljama u razvoju, tranzicijskim zemljama i post-tranzicijskim zemljama. Ono što je specifično za poduzeća koja posluju u slabije razvijenim zemljama jest stupanj u kojem se neriješenost problema obrtnih sredstava odražava na poslovanje i poslovne

rezultate poduzeća, zatim način i oblici isplivljavanja problema te putovi, sredstva, mjere i metode koje se primjenjuju i koje bi trebalo primjenjivati radi rješavanja tog problema. Neke od osnovnih razlika poduzeća koja posluju u razvijenim zemljama u odnosu na tranzicijske zemlje su: specifična uloga plana u reguliranju privrednih tokova, organizacija privrednog sistema na samoupravnim principima, međusobna povezanost i ovisnost poduzeća i banaka, uloga tržišta i cijena u reguliranju privrednih tokova itd. (Tepšić, 1985:1-2).

6. MODEL UTJECAJA UPRAVLJANJA OBRTNIM KAPITALOM NA PROFITABILNOST MALIH I SREDNJIH PODUZEĆA U REPUBLICI HRVATSKOJ

U okviru ovog poglavlja, polazeći od induktivnog pristupa, provelo se je empirijsko istraživanje na odabranom uzorku. U svrhu dokazivanja glavnih i pomoćnih hipoteza panel analizom podataka ispitao se je utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća, rasta prodaje, rasta BDP-a, stope inflacije i sektora na profitabilnost malih i srednjih poduzeća. Panel analizom podataka ispitao se je utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća, rasta prodaje, rasta BDP-a i stope inflacije na profitabilnost malih i srednjih poduzeća pojedinačno u četiri sektora, i to u: građevinarstvu, prerađivačkom sektoru, trgovini na malo i trgovini na veliko. Fokus ovog rada je na malim i srednjim poduzećima sektora koji čine najveći udio u strukturi malih i srednjih poduzeća i istovremeno imaju veliku razinu obrtnog kapitala u strukturi ukupne imovine.

6.1. Definiranje uzorka i podaci

Predmetom su istraživanja mala i srednja poduzeća u Republici Hrvatskoj čija se imovina sastoji najvećim dijelom od tekuće imovine i koja se najviše financira iz kratkoročnih izvora. U radu se provela odgovarajuća panel analiza na uzorku od 276 malih i srednjih poduzeća za razdoblje od 2011. do 2015. godine, u četiri različita sektora koji čine najveći udio u ukupnom broju malih i srednjih poduzeća, i to u sektoru trgovine na veliko, sektoru trgovine na malo, prerađivačkom sektoru i građevinarstvu. Sektor trgovine na veliko, sektor trgovine na malo, prerađivački sektor i građevinarstvo sudjeluju s oko 47 % udjela u ukupnom broju poduzeća; s oko 55 % u ukupnom broju zaposlenih; s oko 65 % u ukupnom prihodu i s oko 50 % u ukupnim rezultatima poslovanja.

Koristili su se sekundarni podaci prikupljeni iz financijskih izvještaja pojedinačnog poduzeća. Podaci su se prikupljali s internetskih stranica FINA-e iz Registra godišnjih financijskih izvještaja i Sudskog registra, osim rasta BDP-a i stope inflacije koji su dobiveni s internetske stranice Državnog zavoda za statistiku¹⁷. Uzorak je napravljen sa stajališta raspoloživosti podataka tako da su se uzela samo ona poduzeća kod kojih

¹⁷ Državni zavod za statistiku. Dostupno na: <https://www.dzs.hr/>, Pristup: 01.3.2018.

se moglo doći do svih stavki potrebnih za analizu, i to za cijelo razdoblje promatranja. Analiza se zasniva na knjigovodstvenim podacima raspoloživim samo na godišnjoj razini. Podaci za razdoblja kraća od jedne godine mogu se dobiti isključivo u poduzeću pa se na taj način nije mogla raditi analiza. Iz analize su se izostavili sektori koji čine ispod 10 % u ukupnom broju malih i srednjih poduzeća i sektori s tekućom imovinom koja čini manje od 20 % ukupne imovine. Podaci su analizirani u programskom paketu STATA 14.

S obzirom na to da se je formirao uzorak na temelju FINA-ine baze podataka, koristila se je definicija malih i srednjih poduzeća prema Zakonu o računovodstvu (NN 120/16, čl.5). Slijedom navedenog mala i srednja poduzeća su sva poduzeća koja ne prelaze granične pokazatelje u sljedeća dva od tri uvjeta: ukupna aktiva 150 000 000,00 kuna; prihod 300 000 000,00 i prosječan broj radnika tijekom poslovne godine – 250 radnika.

6.2. Varijable u modelu

Nakon pregleda mnogobrojne literature i znanstvenih studija, odabrane su najbolje odgovarajuće varijable koje su korištene za mjerenje utjecaja obrtnog kapitala na visinu profitabilnosti malih i srednjih poduzeća. U odgovarajućem je panel-modelu zavisna varijabla profitabilnost, a nezavisne varijable potraživanja od kupaca, zalihe i obveze prema dobavljačima dok su kontrolne varijable veličina poduzeća, rast prodaje, sektor, inflacija i BDP.

U tablici 20 su opisane zavisna, nezavisne i kontrolne varijable koje su korištene u modelu.

Tablica 20. Varijable s punim nazivom, pokratama i objašnjenjem

Varijabla	Kratika	Objašnjenje
Prinos na imovinu	ROA	omjer zarada prije kamata i poreza i prosječne ukupne imovine izražen u decimalnom broju
Dani naplate potraživanja	DNP	omjer broja dana u godini i obrtaja potraživanja
Dani vezivanja zaliha	DVZ	omjer broja dana u godini i obrtaja zaliha
Dani plaćanja dobavljača	DPOD	omjer broja dana u godini i obrtaja obveza prema dobavljačima
Veličina poduzeća	VEL	logaritam prodaje
Rast prodaje	RPR	postotna promjena prodaje u odnosu na prethodnu godinu izražena u decimalnom broju
Sektor	SEKT	pripadnost sektoru
Stopa inflacije	INF	postotak inflacije u tekućoj godini u odnosu na prethodnu godinu izražen u decimalnom broju
Rast BDP-a	BDP	postotak rasta BDP-a u tekućoj godini u odnosu na prethodnu godinu izražen u decimalnom broju

Izvor: Izrada autorice

6.2.1. Zavisna varijabla

Zavisna objašnjena varijabla je profitabilnost. Za mjeru zavisne varijable profitabilnost koristi se prinos na imovinu (ROA) (prema Garcia-Teruel i Martinez-Solano, 2007; Sen i Oruc, 2009; Sharma i Kumar 2011; Baveld, 2012; Gul et al., 2013; Makori i Jagongo, 2013; Tauringana i Afrifa, 2013; Enqvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi). Stopa prinosa na imovinu govori koliko se zarada ostvaruje angažiranom imovinom neovisno o tomu koliki je udio financiran iz vlastitih izvora, a koliki iz tuđih izvora. Stopa prinosa na imovinu je uzeta za mjeru profitabilnosti kako bi bila usporediva s drugim istraživanjima, a većina istraživanja pretpostavlja da je kratkoročno kreditiranje u domeni odluke o financiranju, a ne odluke o upravljanju obrtnim kapitalom i zato se uzima stopa prinosa na imovinu, a ne stopa prinosa na kapital (ROE). S druge strane, uvijek je bolje u izračunu koristiti zarade prije kamata i poreza u cilju točnije usporedbe pokazatelja među zemljama kako bi se izbjegli različiti utjecaji poreza na rezultat poslovanja zbog različitih poreznih politika među zemljama.

ROA se računa prema sljedećoj formuli:

$$ROA = ZPKP / \overline{UI}$$

gdje je:

ROA – prinos na imovinu;

ZPKP – zarade prije kamata i poreza

$\overline{UI}$ – prosječna ukupna imovina

6.2.2. Nezavisne varijable

Za mjeru nezavisne varijable potraživanja od kupaca koriste se dani naplate potraživanja od kupaca (prema Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Sen i Oruc, 2009; Gill et al., 2010; Mathuva, 2010; Raheman et al., 2010; Sharma i Kumar 2011; Baveld, 2012; Akoto et al., 2013; Gul et al., 2013; Makori i Jagongo, 2013; Tauringana i Afrifa, 2013; Wesley et al., 2013; Almazari, 2014; Enqvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi). Dani naplate potraživanja predstavljaju prosječno vrijeme potrebno za naplatu potraživanja od kupaca. Cilj je svakog poduzeća da navedeni pokazatelj bude što niži, a njegova veličina je određena sektorom u kojem poduzeće posluje. Ako poduzeće brzo naplaćuje svoja potraživanja, novac će biti dostupan za obrtanje radi stvaranja veće prodaje što će u konačnici rezultirati većom profitabilnošću. Većina autora u svojim znanstvenim studijama dobiva negativan odnos između potraživanja od kupaca i profitabilnosti što pokazuje da duži dani naplate potraživanja od kupaca rezultiraju manjom profitabilnošću, i obrnuto (Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Gill et al., 2010; Mathuva, 2010; Akoto et al., 2013; Gul et al., 2013; Tauringana i Afrifa, 2013; Wesley et al., 2013; Almazari, 2014; Nigatu, 2015 i drugi). Sharma i Kumar (2011) u svojoj studiji dobivaju pozitivan odnos između profitabilnosti i potraživanja od kupaca. Također, mnogi autori u svojim studijama ne dobivaju značajnu povezanost između potraživanja od kupaca i profitabilnosti poduzeća (Sen i Oruc, 2009; Raheman et al., 2010; Makori i Jagongo, 2013; Enqvist et al., 2014; Seyoum et al., 2016 i drugi).

Dani naplate potraživanja računaju se prema sljedećoj formuli:

$$DNP = \text{broj dana u godini} / \text{obrtaj potraživanja}$$

Pokazatelj obrtaja potraživanja pokazuje koliko puta poduzeće naplati svoja potraživanja tijekom jedne godine. Što je pokazatelj veći, naplata potraživanja je brža. Pokazatelj obrtaja potraživanja računa se prema sljedećoj formuli:

Pokazatelj obrtaja potraživanja = prihod od prodaje / prosječno stanje potraživanja

Kada se objedine gornje dvije formule dobije se izračun dana naplate potraživanja prema sljedećoj formuli:

$$\text{DNP} = (\text{prosječno stanje potraživanja} / \text{prihod od prodaja}) * 365$$

Na temelju gore navedenih istraživanja definirana je prva pomoćna hipoteza:

H1.1. Postoji značajan i negativan utjecaj potraživanja od kupaca na visinu profitabilnosti poduzeća.

Očekuje se da će sporija naplata potraživanja od kupaca utjecati na smanjenje profitabilnosti poduzeća.

Za mjeru nezavisne varijable zalihe koriste se dani vezivanja zaliha (prema Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Sen i Oruc, 2009; Gill et al., 2010; Mathuva, 2010; Raheman et al., 2010; Sharma i Kumar 2011; Baveld, 2012; Gul et al., 2013; Makori i Jagongo, 2013; Tauringana i Afrifa, 2013; Wesley et al., 2013; Almazari, 2014; Enqvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi). Dani vezivanja zaliha pokazuju koliko se dugo zalihe zadržavaju na skladištu od trenutka njihova nabavljanja do trenutka njihove prodaje, odnosno prosječno vrijeme potrebno za nabavu i prodaju zaliha. U pravilu što je ovaj pokazatelj niži to bolje, a njegova je veličina određena sektorom u kojem poduzeće posluje. Dugo zadržavanje zaliha na skladištu može biti rezultatom manje prodaje ili lošim upravljanjem zalihami što će rezultirati smanjenjem profitabilnosti. Većina autora u svojim znanstvenim studijama dobiva negativan odnos između zaliha i profitabilnosti što pokazuje da veća ulaganja u zalihe rezultiraju manjom profitabilnošću, i obrnuto (Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Sen i Oruc, 2009; Raheman et al., 2010; Sharma i Kumar, 2011; Gul et al., 2013; Almazari, 2014; Enqvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi). Mathuva (2010) i Makori i Jagongo (2013) u svojim studijama dobivaju pozitivan odnos između profitabilnosti i zaliha, odnosno veća ulaganja u zalihe rezultiraju većom profitabilnošću poduzeća. Oni zaključuju da uprava može stvoriti vrijednost za svoje dioničare povećanjem svojih zaliha na razumnu razinu. Gill et al. (2010), Tauringana i Afrifa (2013) i Wesley et al. (2013) ne dobivaju značajan odnos između zaliha i profitabilnosti poduzeća.

Dani vezivanja zaliha računaju se prema sljedećoj formuli:

$$DVZ = \text{broj dana u godini} / \text{obrtaj zaliha}$$

Pokazatelj obrtaja zaliha pokazuje koliko se puta zalihe obrnu, odnosno prodaju tijekom jedne godine. Što je pokazatelj obrtaja zaliha veći, razdoblje držanja zaliha na skladištu je kraće. Pokazatelj obrtaja zaliha računa se prema sljedećoj formuli:

$$\text{Pokazatelj obrtaja zaliha} = \text{troškovi nabave prodane robe} / \text{prosječne zalihe}$$

Kada se objedine gornje dvije formule dobije se izračun dana vezivanja zaliha prema sljedećoj formuli:

$$DVZ = (\text{prosječne zalihe} / \text{troškovi nabave prodane robe}) * 365$$

Na temelju gore navedenih istraživanja definirana je druga pomoćna hipoteza:

H1.2. Postoji značajan i negativan utjecaj zaliha na visinu profitabilnosti poduzeća.

Očekuje se da će duže vrijeme zadržavanja zaliha na skladištu utjecati na smanjenje profitabilnosti poduzeća.

Za mjeru nezavisne varijable obveze prema dobavljačima koriste se dani plaćanja dobavljača (prema Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Sen i Oruc, 2009; Gill et al., 2010; Mathuva, 2010; Raheman et al., 2010; Sharma i Kumar 2011; Baveld, 2012; Akoto et al., 2013; Gul et al., 2013; Makori i Jagongo, 2013; Tauringana i Afrifa, 2013; Wesley et al., 2013; Almazari, 2014; Enqvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi). Dani plaćanja dobavljača pokazuju koliko dana je potrebno poduzeću da plati nabavljene zalihe, odnosno podmiri svoje obveze prema dobavljačima. Obveze prema dobavljačima jedan su od glavnih izvora vanjskog financiranja, pogotovo u zemljama s manje razvijenim tržištima kapitala, pa će tako mnoga poduzeća odgoditi plaćanje svojih obveza što dulje sve dok troškovi korištenja trgovačkog kredita ne premaše korist korištenja istog. Iako većina istraživača u svojim studijama očekuje pozitivan odnos između obveza prema dobavljačima i profitabilnosti, odnosno da će duže odgađanje plaćanja obveza prema dobavljačima rezultirati većom profitabilnosti, većina njih dobiva negativan odnos između profitabilnosti i obveza prema dobavljačima (Deelof, 2003; Raheman i Nasr, 2007; Sen i Oruc, 2009; Sharma i Kumar, 2011; Tauringana i Afrifa, 2013; Almazari, 2014; Enqvist et al., 2014; Seyoum et al., 2016 i drugi). Istraživači poput Mathuva (2010), Gul et al. (2013) i Makori i Jagongo (2013) pronalaze pozitivan odnos između obveza prema dobavljačima i profitabilnosti, odnosno veće obveze prema

dobavljačima rezultiraju većom profitabilnošću, i obrnuto. Oni su skloni razmišljanju da poduzeća mogu oduljiti svoje plaćanje vjerovnicima ako to ne napreže njihov odnos. Također, mnogi istraživači u svojim studijama ne dobivaju značajnu povezanost između obveza prema dobavljačima i profitabilnosti (Garcia-Teruel i Martinez-Solano, 2007; Gill et al., 2010; Raheman et al., 2010; Akoto et al., 2013; Wesley et al., 2013; Nigatu, 2015 i drugi). Ovakvi rezultati ukazuju da se odnosi između čimbenika upravljanja obrtnim kapitalom na razini poduzeća i visine profitabilnosti poduzeća razlikuju između država.

Dani plaćanja dobavljačima računaju se prema sljedećoj formuli:

$$DPD = \text{broj dana u godini} / \text{obrtaj obveza prema dobavljačima}$$

Pokazatelj obrtaja obveza prema dobavljačima pokazuje koliko puta poduzeće plati svoje obveze prema dobavljačima tijekom jedne godine. Poduzeće teži što duže odgoditi svoje obveze, ali pritom ne ugrožavajući svoj odnos s dobavljačima te koristi eventualne popuste za rane uplate. Pokazatelj obrtaja obveza prema dobavljačima računa se prema sljedećoj formuli:

$$\text{Pokazatelj obrtaja obveza prema dobavljačima} = \frac{\text{troškovi nabave prodane robe}}{\text{prosječno stanje obveza prema dobavljačima}}$$

Kada se objedine gornje dvije formule dobije se izračun dana plaćanja obveza prema dobavljačima prema sljedećoj formuli:

$$DPD = (\text{prosječno stanje obveza prema dobavljačima} / \text{troškovi nabave prodane robe}) * 365$$

Na temelju gore navedenih istraživanja definirana je treća pomoćna hipoteza:

H1.3. Postoji značajan i pozitivan utjecaj obveza prema dobavljačima na visinu profitabilnosti poduzeća.

Očekuje se da će duže odgađanje plaćanja obveza prema dobavljačima utjecati na povećanje profitabilnosti poduzeća.

6.2.3. Kontrolne varijable

Prva kontrolna varijabla je veličina poduzeća. Za varijablu veličina poduzeća koristi se mjera prirodni logaritam prodaje (prema Deelof, 2003; Raheman i Nasr, 2007; Gill et al., 2010; Mathuva, 2010; Raheman et al., 2010; Baveld, 2012; Gul et al., 2013; Wesley

et al., 2013; Almazari, 2014; Enqvist et al., 2014; Seyoum et al., 2016 i drugi). Očekuje se da će rast veličine poduzeća utjecati na povećanje profitabilnosti poduzeća. Većina istraživača, u skladu sa svojim očekivanjima, pronalaze pozitivan odnos između profitabilnosti i veličine poduzeća, odnosno kako veličina poduzeća raste tako se i profitabilnost poduzeća povećava (Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Raheman et al., 2010; Akoto et al., 2013; Gul et al., 2013; Makori i Jagongo, 2013; Almazari, 2014 i drugi). Gill et al. (2010) i Wesley et al. (2013) ne dobivaju značajan odnos između veličine poduzeća i profitabilnosti poduzeća dok Enqvist et al. (2014) dobivaju negativnu povezanost između veličine poduzeća i visine profitabilnosti poduzeća.

Na temelju gore navedenih istraživanja definirana je četvrta pomoćna hipoteza:

H1.4. Postoji značajan i pozitivan utjecaj veličine poduzeća na visinu profitabilnosti poduzeća.

Očekuje se da će rast poduzeća, mjeren prirodnim logaritmom prodaje, utjecati na povećanje profitabilnosti poduzeća.

Druga kontrolna varijabla je rast prodaje. Za kontrolnu varijablu rast prodaje mjera je postotna promjena prodaje u odnosu na prethodnu godinu (prema Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman et al., 2010; Sharma i Kumar 2011; Baveld, 2012; Gul et al., 2013; Makori i Jagongo, 2013; Wesley et al., 2013; Seyoum et al. 2016 i drugi). Očekuje se da će rast prodaje poduzeća utjecati na povećanje profitabilnosti poduzeća. Većina istraživača, u skladu sa svojim očekivanjima, pronalaze pozitivan odnos između profitabilnosti poduzeća i rasta prodaje, odnosno kako raste prodaja tako se povećava i profitabilnost poduzeća (Garcia-Teruel i Martinez-Solano, 2007; Raheman et al., 2010; Gul et al., 2013; Makori i Jagongo, 2013 i drugi). Wesley et al. (2013) ne dobivaju značajan odnos između rasta prodaje poduzeća i visine profitabilnosti poduzeća.

Na temelju gore navedenih istraživanja definirana je peta pomoćna hipoteza:

H1.5. Postoji značajan i pozitivan utjecaj rasta prodaje poduzeća na visinu profitabilnosti poduzeća.

Očekuje se da će rast prodaje poduzeća, mjeren postotnom promjenom prodaje u odnosu na prethodnu godinu, utjecati na povećanje visine profitabilnosti poduzeća.

Strategija upravljanja obrtnim kapitalom mora biti prilagođena i specifična za svaki sektor posebno zbog različitog trajanja poslovnog ciklusa između sektora pa će tako iste razine obrtnog kapitala imati različiti utjecaj na visinu profitabilnosti poduzeća između različitih sektora. Zbog toga je za treću kontrolnu varijablu izabrana varijabla sektor (pripadnost industriji) (prema Deelof, 2003; Filbeck i Krueger, 2005; Garcia-Teruel i Martinez-Solano, 2007; Banos-Caballero et al., 2010; Baveld, 2012). Umjesto varijable sektor uvedene su tri dodatne *dummy* varijable za 3 sektora, i to za prerađivački sektor, sektor trgovine na malo i sektor trgovine na veliko dok je građevinarstvo ostao kao referentni sektor.

Na temelju gore navedenog definirana je šesta pomoćna hipoteza koja glasi:

H1.6. Postoji značajan utjecaj sektora na visinu profitabilnosti poduzeća.

Očekuje se različiti utjecaj čimbenika upravljanja obrtnim kapitalom na razini poduzeća na visinu profitabilnosti malih i srednjih poduzeća između različitih sektora.

Četvrta kontrolna varijabla je inflacija (prema Nigatu, 2015). Za varijablu inflacija koristi se postotak inflacije u tekućoj godini u odnosu na prethodnu godinu izražena u decimalnom broju. U inflaciji cijene rastu, a vrijednost novca opada, odnosno dolazi do pada kupovne moći novca gdje se za istu svotu novca može kupiti manje dobara. U uvjetima inflacije je povoljnije imati veće količine zaliha jer im cijene rastu dok su veća potraživanja od kupaca nepovoljnija. Nigatu (2015) navodi da prema nedavnoj teoriji o asimetričnosti informacija na kreditnom tržištu povećanje stope inflacije spušta realnu stopu prinosa ne samo na novac nego na imovinu općenito.

Na temelju navedenog definirana je sedma pomoćna hipoteza koja glasi:

H1.7. Postoji značajan utjecaj inflacije na visinu profitabilnosti poduzeća.

Očekuje se da će povećanje inflacije utjecati na smanjenje visine profitabilnosti poduzeća.

Pogoršanje makroekonomskih uvjeta može utjecati na naplatu potraživanja. S jedne strane, poduzeća pate od smanjene sposobnosti generiranja novca iz njihovog poslovanja, a banke mogu smanjiti ponudu kredita poduzećima. Kao rezultat toga broj dana potraživanja može se povećati. S druge strane, ako poduzeća imaju više poteškoća u osiguranju financijskih sredstava, ona bi mogla ponuditi manje kredita svojim klijentima (Garcia-Teruel i Martinez-Solano, 2010). U skladu s time može se

zaključiti da promjene ekonomskih uvjeta u zemlji utječu na visinu profitabilnosti poduzeća pa se kao peta kontrolna varijabla koristi BDP (prema Garcia-Teruel i Martinez-Solano, 2007; Mathuva, 2010; Enqvist et al., 2014; Nigatu, 2015). Enqvist et al. (2014) su u svojoj studiji pokazali da je odnos između potraživanja od kupaca i visine profitabilnosti poduzeća različit tijekom gospodarskih kriza i ekonomskog *booma*. Njihovi rezultati su pokazali da se za vrijeme slabijih gospodarskih prilika povećava značajnost između potraživanja od kupaca i visine profitabilnosti poduzeća, i to u negativnom smjeru. Oni objašnjavaju da tijekom gospodarskih kriza manje profitabilna poduzeća povećavaju poticaje za prodaju proširenjem trgovačkog kredita kupcima pri čemu dolazi do povećanja dana naplate potraživanja od kupaca. Enqvist et al. (2014), također, dobivaju veći značaj negativnog odnosa između zaliha i profitabilnosti poduzeća za vrijeme slabijih gospodarskih prilika. No, iako dokazuju veći značaj negativnog odnosa između zaliha i profitabilnosti i potraživanja i profitabilnosti za vrijeme ekonomskih kriza, ipak, ne dobivaju značajan utjecaj ekonomskog *booma* na odnose istih. Shodno tomu zaključuju da upravljanje obrtnim kapitalom ima puno veću važnost za vrijeme ekonomskih kriza nego za vrijeme ekonomskog *booma*. Garcia-Teruel i Martinez-Solano (2010) pronalaze pozitivan odnos između potraživanja od kupaca i ekonomskog rasta, ali je ekonomski utjecaj te varijable vrlo ograničen.

Na temelju gore navedenog definirana je osma pomoćna hipoteza koja glasi:

H1.8. Postoji značajan utjecaj BDP-a na visinu profitabilnosti poduzeća.

Očekuje se značajan utjecaj BDP-a na visinu profitabilnosti poduzeća.

6.3. Panel analiza

Kada se istovremeno analiziraju vremenska i prostorna komponenta neke pojave kaže se da je provedena panel analiza. Ona je jedna od najčešće korištenih statističkih metoda u znanstvenim istraživanjima. Prije pojave panel analize podaci su se mogli analizirati samo odvojeno: trebalo se odlučiti koristi li se samo prostorna ili samo vremenska komponenta. Pritom je najveći problem bio dostupnost dovoljno velikog broja podataka potrebnih za preciznu analizu (Aljinović i Marasović, 2012).

Panel analiza podataka riješila je taj problem i omogućila da se analiziraju podaci uzimajući u obzir istovremeno i prostornu i vremensku komponentu. Time se zavisna varijabla mijenja i po jedinicama promatranja i po vremenu pa su dobivene procjene

preciznije. Ako su za svaku jedinicu promatranja za sve varijable u svim vremenskim jedinicama dostupni svi podaci kaže se da se raspolaže s balansiranim podacima. Ako za neku jedinicu nedostaje određeni podatak tada imamo nebalansirane podatke.

Panel analiza podataka ima prednosti i nedostatke. Neke od prednosti su da zbog velikog broja podataka podaci umanjuju pristranost parametara i da se umanjuje problem multikolinearnosti (visokog stupnja korelacije između nezavisnih varijabli). Ipak da bi dobiveni rezultati bili precizni analizirani podaci trebaju biti homogeni. U slučaju heterogenosti podataka može se dogoditi da rezultati pogrešno ukažu na nepostojanje statistički značajnih varijabli u modelu.

6.3.1. Združeni model

Analiza podataka uobičajeno počinje združenim modelom

$$Y_{it} = \alpha + \beta_1 \cdot X_{it1} + \beta_2 \cdot X_{it2} + \dots + \beta_K \cdot X_{itK} + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

u kojem Y_{it} predstavljaju opažene vrijednosti zavisne varijable, X_{itk} su vrijednosti nezavisnih varijabli za $k = 1, \dots, K$, k predstavlja redni broj zavisne varijable, i jedinicu promatranja, a t vremensko razdoblje. K je ukupan broj nezavisnih varijabli, N broj jedinica promatranja, a T broj vremenskih razdoblja.

Parametar α je konstantni član. U združenom modelu njegova vrijednost jednaka je za sve promatrane jedinice.

Parametri β_k su pripadni parametri uz k -tu nezavisnu varijablu X_k . ε_{it} su greške relacije promatrane jedinice i u vremenu t za koje vrijedi pretpostavka da su nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i konstantnom varijancom σ_e^2 . Vrijedi i pretpostavka da su X_{itk} nezavisne s ε_{it} za svaki i, t, k .

Združeni model služi kao uvod u analizu jer ima određena ograničenja poput toga da model ne pretpostavlja različitosti među promatranim jedinicama. Budući da su zadani podaci o svakoj jedinici kroz nekoliko razdoblja postoji mogućnost korelacije pogrešaka relacije u različitim razdobljima. Također se može očekivati korelacija pogrešaka relacije i nezavisnih varijabli. Standardne pogreške su često podcijenjene pa se neke varijable mogu pokazati statistički značajnima iako to zapravo nisu (Škrabić Perić, 2012). Iz navedenih razloga analiziraju se i ostali modeli.

6.3.2. Model s fiksnim efektom

Model s fiksnim efektom je linearni model u kojem za razliku od združenog modela konstantni član α nije jedinstven, već svaka jedinica promatranja ima svoj konstantni član α_i koji je neovisan o vremenu.

Model ima oblik

$$Y_{it} = \alpha_i + \beta_1 \cdot X_{it1} + \beta_2 \cdot X_{it2} + \dots + \beta_K \cdot X_{itK} + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

gdje Y_{it} predstavljaju opažene vrijednosti zavisne varijable, X_{itk} su vrijednosti nezavisnih varijabli za $k = 1, \dots, K$ k predstavlja redni broj zavisne varijable, i jedinicu promatranja, a t vremensko razdoblje. K je ukupan broj nezavisnih varijabli, N broj jedinica promatranja, a T ukupni broj promatranih vremenskih razdoblja.

Parametar α_i je konstantni član. U modelu s fiksnim efektom njegova vrijednost može biti različita za svaku promatranu jedinicu.

Parametri β_k su pripadni parametri uz k -tu nezavisnu varijablu X_k . ε_{it} su pogreške relacije promatrane jedinice i u vremenu t za koje vrijedi pretpostavka da su nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i konstantnom varijancom σ_e^2 .

Vrijedi i pretpostavka da su X_{itk} nezavisne s ε_{it} za svaki i, t, k kao i da su sve nezavisne varijable promjenjive u vremenu (Wooldridge, 2012).

Za razliku od združenog modela u kojem se procjenjuje jedan konstantni član α u modelu s fiksnim efektom procjenjuje se po jedan konstantan član α_i za svaku od N promatranih jedinica, odnosno $N-1$ član više nego u združenom modelu. Time je smanjen broj stupnjeva slobode što je jedan od nedostataka ovog modela. Nedostatak je i nemogućnost upotrebe nezavisnih varijabli koje su nepromjenjive u vremenu, poput pripadnosti određenom sektoru, spola ili pripadnosti religiji (Mamić, 2015).

Ispitivanje opravdanosti upotrebe fiksnog modela u odnosu na združeni model obavlja se F-testom. Testna veličina iznosi:

$$F = \frac{(SSE_{zdr} - SSE_{fik})/(N - 1)}{SSE_{fik}/(NT - N - k)}$$

gdje SSE_{zdr} predstavlja sumu kvadrata odstupanja u združenom modelu, a SSE_{fik} sumu kvadrata odstupanja u fiksnom modelu. Nulta hipoteza pretpostavlja da su fiksni efekti svih jedinica promatranja jednaki. Ako se ne odbaci nulta hipoteza izvodi se

zaključak da model s fiksnim efektima nije adekvatan, tj. da je primjerenije koristiti združeni model s jednakim konstantnim članom za sve jedinice promatranja. Ako se pak nulta hipoteza odbaci zaključuje se da združeni model nije prikladan jer varijacija zavisne varijable ovisi o specifičnostima svake promatrane jedinice.

6.3.3. Model sa slučajnim efektom

Model sa slučajnim efektom pretpostavlja postojanje razlika u odabranim jedinicama, ali te razlike su slučajne. Model ima oblik:

$$Y_{it} = \mu + \beta_1 \cdot X_{it1} + \beta_2 \cdot X_{it2} + \dots + \beta_K \cdot X_{itK} + \alpha_i + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

gdje Y_{it} predstavljaju opažene vrijednosti zavisne varijable, X_{itk} su vrijednosti nezavisnih varijabli za $k = 1, \dots, K$ k predstavlja redni broj zavisne varijable, i jedinicu promatranja, a t vremensko razdoblje. K je ukupan broj nezavisnih varijabli, N broj jedinica promatranja, a T ukupni broj vremenskih razdoblja.

Parametar μ je konstantni član, a α_i predstavlja slučajni efekt za svaku promatranu jedinicu. Model pretpostavlja da su α_i nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i konstantnom varijancom σ_α^2 .

Parametri β_k su pripadni parametri uz k -tu nezavisnu varijablu X_k . ε_{it} su pogreške relacije promatrane jedinice i u vremenu t za koje vrijedi pretpostavka da su nezavisno i identično distribuirane slučajne varijable sa sredinom 0 i konstantnom varijancom σ_ε^2 . Vrijedi i pretpostavka da su X_{itk} nezavisne s ε_{it} , kao i nezavisnost X_{itk} s α_i te nezavisnost ε_{it} s α_i za svaki i, t, k .

Ako zbrojimo slučajni efekt za svaku promatranu jedinicu α_i s pogreškama relacije ε_{it} dobije se nova pogreška relacije v_{it} . Budući da postoji korelacija među pogreškama relacije između istih jedinica promatranja u različitim vremenima promatranja OLS metoda nije prikladna za procjene parametara pa se koristi generalizirana metoda najmanjih kvadrata (GLS) koja uklanja navedene korelacije. Dobiveni procjenitelji su konzistentni kada ili N ili T ili oboje teže u beskonačnost. Budući da ima manji gubitak stupnjeva slobode u odnosu na model s fiksnim efektom, procijenjeni parametri su efikasniji. Slučajni model je prikladan za veliku vrijednost N i malu vrijednost T (Wooldridge, 2012).

Uobičajeno je provođenje je LM testa (Lagrangeov multiplikator test) kojim se ispituje opravdanost korištenja modela sa slučajnim efektom u odnosu na združeni model. LM test ispituje varijancu slučajnog efekta jedinica promatranja.

LM testna veličina je

$$LM = \frac{NT}{2(T-1)} \left[\frac{\sum_i [\sum_t \hat{e}_{it}]^2}{\sum_i \sum_t \hat{e}_{it}^2} \right]$$

gdje su $\hat{e}_{it}$ OLS pogreške relacije.

Pretpostavka nulte hipoteze glasi da je varijanca slučajnog efekta jedinica promatranja jednaka nuli, odnosno da ne postoji heterogenost među promatranim jedinicama. Tada je korištenje modela sa slučajnim efektom nepotrebno. U slučaju odbacivanja nulte hipoteze zaključuje se da je varijanca slučajnog efekta jedinica veća od nule i potvrđuje se opravdanost korištenja modela sa slučajnim efektom (Breusch i Pagan, 1980).

Ako je testovima utvrđena opravdanost primjene modela s fiksnim efektom i modela sa slučajnim efektom u odnosu na združeni model, slijedi odabir između navedena dva modela. Budući da model s fiksnim efektom, za razliku od modela sa slučajnim efektom, dopušta proizvoljnu korelaciju između α_i i X_{itk} , postoji stav da je model s fiksnim efektom često prikladniji procjenitelj. Ipak model sa slučajnim efektom je primjenjiv u brojnim slučajevima. Ako je jedna od zavisnih varijabli nepromjenjiva u vremenu, model s fiksnim efektom nije moguće primijeniti. Često se u praksi procijene parametri oba modela, a odluka se donosi na temelju Hausmanovog testa koji ispituje razliku između koeficijenata oba modela.

Testna veličina je

$$W = \frac{(\hat{\beta}_{fik}^* - \hat{\beta}_{slu}^*)^2}{Var(\hat{\beta}_{fik}^*) - Var(\hat{\beta}_{slu}^*)}$$

Nulta hipoteza pretpostavlja da nema značajne razlike između koeficijenata u oba modela i tada su oba procjenitelja konzistentna, ali je model sa slučajnim efektom prikladniji jer je efikasniji. Ako se odbaci nulta hipoteza tada model sa slučajnim efektom nije konzistentan pa je adekvatan model s fiksnim efektom (Škrabić Perić, 2012). Nulta hipoteza se prihvaća i u slučaju da je varijabilnost podataka toliko velika da se ne može ustanoviti statistički značajna razlika u parametrima oba procjenitelja (Wooldridge, 2012).

6.3.4. Regresijska dijagnostika

Problem multikolinearnosti se javlja ako su dvije ili više nezavisnih varijabli u manjoj ili većoj mjeri linearno zavisne ili približno linearno zavisne. Savršena multikolinearnost se javlja ako su nezavisne varijable linearno zavisne. Češće se javlja problem približne multikolinearnosti kad su dvije ili više varijabli visoko korelirane. Tada su standardne pogreške procijenjenih parametara nerealno velike, što može navesti na pogrešan zaključak da su pojedine nezavisne varijable nesignifikantne. Multikolinearnost se ispituje korelacijskom matricom između parova nezavisnih varijabli. Ozbiljan problem multikolinearnosti postoji kad su vrijednosti Pearsonovog koeficijenta korelacije

$$r = \frac{\sum_{i=1}^N \sum_{t=1}^T ((X_{itk} - \bar{X}_k) \cdot (X_{itl} - \bar{X}_l))}{\sqrt{\sum_{i=1}^N \sum_{t=1}^T (X_{itk} - \bar{X}_k)^2} \cdot \sqrt{\sum_{i=1}^N \sum_{t=1}^T (X_{itl} - \bar{X}_l)^2}}, k \neq l$$

veće od 0,9 ili manje od -0,9 (Belsey et al., 2013). Problemu multikolinearnosti se prilazi ovisno o cilju istraživanja. Ako je cilj prognoza vrijednosti zavisne varijable na osnovu regresijskog modela problem multikolinearnosti se može zanemariti. U ostalim slučajevima problemu se pristupa rigoroznije, npr. da se poveća veličina uzorka, da se varijable transformiraju u oblik diferencija $\Delta X_i = X_t - X_{t-1}$ ili omjera $\frac{X_t}{X_{t-1}}$ ili da se iz modela isključi jedna od visoko koreliranih varijabli (Bahovec i Erjavec, 2009).

Homoskedastičnost podrazumijeva da pogreške relacije ε_{it} imaju konstantnu varijancu σ_e^2 . Ako je narušena pretpostavka o konstantnoj varijanci prisutan je problem heteroskedastičnosti. U tom slučaju procjenitelji su nepristani i konzistentni, ali nisu efikasni i ne može se utvrditi ispravna vrijednost standardnih pogrešaka. Modificiranim Wald testom ispituje se prisutnost problema heteroskedastičnosti. Nulta hipoteza pretpostavlja da homoskedastičnost, odnosno konstantnu varijancu, dok se odbacivanjem nulte hipoteze zaključuje da je prisutan problem heteroskedastičnosti (Baum, 2001).

Ako postoji prisutnost heteroskedastičnosti i/ili autokorelacije standardne pogreške mogu se korigirati izračunavanjem standardnih pogrešaka koje su robustne. U praksi uglavnom nije poznata struktura heteroskedastičnosti (Yamano, 2009) pa se preporuča koristiti klasterirane podatke.

Problem autokorelacije se javlja ako pretpostavka o nezavisnosti grešaka relacije nije ispunjena. Problem se često javlja kad se analizira vremenski niz podataka. Nad

podacima je proveden Wooldrigov test za otkrivanje autokorelacije. Nulta hipoteza pretpostavlja nepostojanje autokorelacije pogrešaka relacije. Odbacivanje nulte hipoteze ukazuje na problem postojanja autokorelacije i u tom slučaju može biti prikladnija upotreba dinamičkih modela. Tada bi model bio oblika:

$$Y_{it} = \mu + \gamma \cdot Y_{i,t-1} + \beta_1 \cdot X_{it1} + \beta_2 \cdot X_{it2} + \dots + \beta_K \cdot X_{itK} + \alpha_i + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Uvođenje zavisne varijable s pomakom $Y_{i,t-1}$ dovodi do korelacije između $Y_{i,t-1}$ i α_i . Rješenje tog problema predložili su korištenjem generalizirane metode momenata Arellano i Bond (AB procjenitelj) (Arellano i Bond, 1991) i njegovom poboljšanom verzijom Blundell i Bond (BB procjenitelj) (Blundell i Bond, 1998).

6.4. Empirijska analiza

Na početku analize napravljena je deskriptivna statistička analiza podataka. Za sve varijable navedene su aritmetička sredina, standardna devijacija, minimalna i maksimalna vrijednost te broj opažanja svake varijable. Aritmetička sredina računa se izrazom: $\bar{x} = \frac{\sum_{i=1}^N x_i}{N}$, a standardna devijacija uzorka $\sigma = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N-1}$.

Umjesto varijable Sektor uvedene su 3 dodatne *dummy* varijable za 3 sektora: varijabla PRER s vrijednošću 1 ako poduzeće pripada prerađivačkom sektoru, a 0 ako pripada ostalim sektorima, varijabla TRGM s vrijednošću 1 ako poduzeće pripada sektoru trgovine na malo, a 0 ako pripada ostalim sektorima, varijabla TRGV s vrijednošću 1 ako poduzeće pripada sektoru trgovine na veliko, a 0 ako pripada ostalim sektorima, dok je građevinarstvo ostao kao referentni sektor.

Potom je postavljen osnovni model 1 za sve sektore zajedno, kao i dodatni modeli za sva četiri sektora pojedinačno. Za svaku od 5 analiza postavljena su tri osnovna panel-modela: združeni model, model s fiksnim efektima i model sa slučajnim efektima.

6.4.1. Svi sektori zajedno

Predmetom su istraživanja mala i srednja poduzeća u Republici Hrvatskoj. Na početku su promatrani svi sektori zajedno, i to četiri različita sektora koja čine najveći udio u ukupnom broju malih i srednjih poduzeća, i to sektor trgovine na veliko, sektor trgovine na malo, prerađivački sektor i građevinarstvo za razdoblje od 2011. do 2015. godine.

6.4.1.1. Deskriptivna statistika

Analiza se je započela deskriptivnom statistikom koja osim aritmetičke sredine i standardne devijacije svih varijabli prikazuje i njihove minimalne i maksimalne vrijednosti kao i ukupan broj opažanja, ukupan broj promatranih jedinica i broj razdoblja. Sve vrijednosti prikazane su za cijeli skup podataka (overall), ali i između jedinica (between) i unutar promatrane jedinice (within).

Tablica 21. Deskriptivna statistika za sve sektore zajedno

Varijabla		Aritmetička sredina	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost	Broj opažanja
ROA	Overall	0,0884943	0,1630554	-0,497219	2,396413	N = 1380
	Between		0,1046428	-0,2118538	0,8826069	n = 276
	Within		0,1251747	-0,5296716	1,882115	T = 5
DNP	Overall	63,15416	49,12015	0,2747547	342,0538	N = 1380
	Between		46,12385	0,3618379	278,8284	n = 276
	Within		17,07484	-15,28314	196,2664	T = 5
DVZ	Overall	79,69976	104,3281	0,6413468	930,9683	N = 1380
	Between		99,49547	1,019088	788,1379	n = 276
	Within		31,83901	-156,9592	437,75	T = 5
DPOD	Overall	70,91456	51,55904	1,028011	380,814	N = 1380
	Between		46,62542	2,123173	317,4717	n = 276
	Within		22,15201	-85,24964	243,7062	T = 5
VEL	Overall	7,79957	0,309215	6,381289	8,748257	N = 1380
	Between		0,2985514	6,450961	8,686576	n = 276
	Within		0,0820949	7,466658	8,198523	T = 5
RPR	Overall	0,0618562	0,2257467	-0,5494	1,659051	N = 1380
	Between		0,1100395	-0,2576387	0,5754846	n = 276
	Within		0,1972004	-0,6117998	1,36877	T = 5
INF		0,01398	0,01504	-0,00500	0,03400	T = 5
BDP		0,00608	0,01085	-0,00720	0,02327	T = 5

Izvor: Izrada autorice prema izračunima STATE

Istraživanje je obuhvatilo 276 poduzeća kroz 5 godina. Podaci su balansirani, dakle za svaku jedinicu promatranja bili su poznati svi podaci za svih 5 razdoblja. Ukupno je u analizi 1380 opservacija, odnosno 276 poduzeća promatrano u razdoblju od 5 godina: 66 poduzeća pripada sektoru građevinarstvo, 67 prerađivačkom sektoru, 64 trgovini na malo i 79 trgovini na veliko.

Zavisna varijabla *ROA* ima prosječnu vrijednost 0,0885, odnosno 8,85 % uz prosječno odstupanje od prosjeka 0,1631, tj. 16,31 %. *ROA* varira od -0,2119 do 0,8826 među

poduzećima, odnosno od -0,5297 do 1,8821 unutar poduzeća. Veće variranje zabilježeno je unutar poduzeća (0,1252) nego među poduzećima (0,1046).

Varijabla *dani naplate potraživanja* ima prosječnu vrijednost 63,15 dana u rasponu od minimalne vrijednosti 0,27 dana do maksimalne 342,05 dana. Veća standardna devijacija uočava se među poduzećima (46,12), nego unutar poduzeća (17,07).

Prosječna vrijednost varijable *dani vezivanja zaliha* iznosi 79,70 dana, uz prosječno odstupanje od prosjeka 104,33. Veće odstupanje zabilježeno je između poduzeća (99,50) nego unutar poduzeća (31,84).

Varijabla *dani plaćanja dobavljača* ima prosječnu vrijednost 70,92 dana, uz standardnu devijaciju 51,56 te raspon od 1,03 do 380,81. Veća standardna devijacija primijećena je između poduzeća (46,63) nego unutar poduzeća (22,15).

Prosječna *veličina poduzeća* iznosila je 7,80 uz standardnu devijaciju 0,31 i raspon od 6,38 do 8,75. Veće prosječno odstupanje od prosječne vrijednosti zabilježeno je između poduzeća (0,30) nego unutar poduzeća (0,08).

Prosječni godišnji *rast prodaje* iznosi 0,0619 odnosno 6,19 % uz veliku standardnu devijaciju od 0,2257, tj. 22,57 %. Tako velika varijacija uobičajena je na hrvatskom tržištu. Zanimljivo je da je veća standardna devijacija *rasta prodaje* zabilježena unutar poduzeća (0,1972) nego između poduzeća (0,1100).

Prosječna vrijednost *stope inflacije* u promatranom razdoblju iznosila je 1,40 %, a kretala se u rasponu od -0,50 do 3,40 %. BDP je od 2010. do 2015. godine prosječno rastao 0,61 %, u rasponu od -0,72 % do 2,33 %.

6.4.1.2. Spearmanov koeficijent korelacije

Spearmanov koeficijent korelacije je neparametrijski test koji se koristi za određivanje snage i smjera povezanosti između dvije varijable. Spearmanov koeficijent korelacije koristi se ako podaci:

- nisu normalno distribuirani;
- postoje outlieri (ekstremne vrijednosti);
- jedna ili više varijabli je ordinalna (npr. podaci su u formatu ranga).

Postupak računanja Spearmanovog koeficijenta korelacije je sljedeći: unutar svake varijable posebno podaci rangiraju se od najmanjeg do najvećeg. Formula prema kojoj se računa Spearmanov koeficijent korelacije je sljedeća:

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}$$

Gdje je $d_i, i = 1, \dots, n$, razlika rankova varijabli x_i i y_i : $d_i = R(x_i) - R(y_i)$

Ako je Spearmanov koeficijent korelacije poprimio vrijednost 1, govori se o potpunoj pozitivnoj korelaciji ranga. Ako je vrijednost -1 znači da se radi o potpunoj negativnoj korelaciji ranga (Šošić, 2006).

Tablica 22. Razdioba vrijednosti Spearmanovog koeficijenta korelacije

Apsolutna vrijednost koeficijenta korelacije	Jačina povezanosti između varijabli
$0 < r < 0,2$	Neznatna korelacija
$0,2 < r < 0,5$	Relativno slaba korelacija
$0,5 < r < 0,8$	Srednje jaka korelacija
$0,8 < r < 1$	Jaka korelacija

Izvor: Papić (2014)

Kako bi se utvrdila povezanost između *ROA* i varijabli *dani naplate potraživanja*, *dani vezivanja zaliha* i *dani plaćanja dobavljača* izračunat je Spearmanov koeficijent korelacije. Rezultati su prikazani u tablici.

Tablica 23. Spearmanov koeficijent korelacije – svi sektori zajedno

			Y_ROA_indeks
Spearman's rho	X1_Dani_Naplate_Potrazivanja	Correlation Coefficient	-0,054*
		Sig. (2-tailed)	0,045
		N	1380
	X2_Dani_Vezivanja_Zaliha	Correlation Coefficient	-0,056*
		Sig. (2-tailed)	0,039
		N	1380
	X3_Dani_Placanja_Dobavljacka	Correlation Coefficient	-0,246**
		Sig. (2-tailed)	0,000
		N	1380

*korelacija je značajna na razini 0,05 ($p < 0,05$); **korelacija je značajna na razini 0,01 ($p < 0,01$)

Izvor: Izrada autorice prema izračunima STATE

Kod analize podataka za sve sektore zajedno dobivena je neznatna negativna povezanost između *dana naplate potraživanja* i *ROA* ($r = -0,054$, $p < 0,05$), te između *dana vezivanja zaliha* i *ROA* ($r = -0,056$, $p < 0,05$), dok je između *dana plaćanja dobavljača* i *ROA* korelacija relativno slaba i negativna ($r = -0,246$, $p < 0,001$). Može se zaključiti da su niže vrijednosti navedenih varijabli povezane s višim vrijednostima varijable *ROA*. Svakako treba uzeti u obzir da su korelacije slabe do neznatne.

6.4.1.3. Panel analiza svih sektora zajedno

Potom su postavljena tri osnovna panel modela: združeni model, model s fiksnim efektima i model sa slučajnim efektima. Umjesto varijable *sektor* uvedene su 3 dodatne *dummy* varijable za 3 sektora: varijabla *PRER* s vrijednošću 1 ako poduzeće pripada *prerađivačkom sektoru*, a 0 ako pripada ostalim sektorima, varijabla *TRGM* s vrijednošću 1 ako poduzeće pripada sektoru *trgovine na malo*, a 0 ako pripada ostalim sektorima, varijabla *TRGV* s vrijednošću 1 ako poduzeće pripada sektoru *trgovine na veliko*, a 0 ako pripada ostalim sektorima, dok je *građevinarstvo* ostao kao referentni sektor.

Združeni model:

$$ROA_{it} = \alpha + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \beta_8 \cdot PRER + \beta_9 \cdot TRGM + \beta_{10} \cdot TRGV + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Model s fiksnim efektom:

$$ROA_{it} = \alpha_i + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \beta_8 \cdot PRER + \beta_9 \cdot TRGM + \beta_{10} \cdot TRGV + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Model sa slučajnim efektom:

$$ROA_{it} = \mu + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \beta_8 \cdot PRER + \beta_9 \cdot TRGM + \beta_{10} \cdot TRGV + \alpha_i + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Rezultati sva tri modela prikazani su u tablici.

Tablica 24. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima

	Združeni	Fiksni	Slučajni
DNP	0,00011 (0,00012)	-0,00043 (0,00037)	0,000025 (0,000121)
DVZ	-0,00012*** (0,00004)	-0,00006 (0,00005)	-0,000113*** (0,000039)
DPOD	-0,00032*** (0,00010)	-0,00009 (0,00014)	-0,000280*** (0,000097)
VEL	-0,00028 (0,0238)	-0,0126 (0,0548)	-0,00035 (0,02405)
RPR	0,0512*** (0,0190)	0,0198 (0,0194)	0,0361** (0,0156)
INF	-0,00613* (0,00364)	-0,00485 (0,00436)	-0,00586 (0,00371)
BDP	-0,00357 (0,00456)	-0,00249 (0,00475)	-0,00317 (0,00458)
PRER	0,0307* (0,0178)	0 (.)	0,0308* (0,0178)
TRGM	0,0384*** (0,0136)	0 (.)	0,0350** (0,0141)
TRGV	0,0527*** (0,0142)	0 (.)	0,0539*** (0,0142)
KONSTANTA	0,0923 (0,1781)	0,23296 (0,41921)	0,0954 (0,180)
R2	0,0458	0,0109	
$\rho(\text{rho})$		0,3638	0,2395
Ftest		0,0000	
LM test			0,0000
Hausman test		0,1963	
Wald test		0,0000	
Wooldridge test		0,8828	
corr (u _i , X _b)		-0,1269	
Broj opažanja	1380	1380	1380
Broj jedinica	276	276	276

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$, vrijednosti u zagradama su korigirane (clusterirane robustne) standardne pogreške

Izvor: Izrada autorice prema izračunima STATE

Napravljena su tri modela: združeni model, model s fiksnim efektima i model sa slučajnim efektima. Opravdanost upotrebe modela s fiksnim efektom u odnosu na

zduženi model potvrđena je F-testom ($p < 0,01$). Opravdanost korištenja modela sa slučajnim efektom u odnosu na zduženi model potvrđena je LM-testom ($p < 0,01$). Budući da su u modelu korištene *dummy* varijable za pripadnost sektoru prikladniji je model sa slučajnim u odnosu na model s fiksnim efektom. Hausmanov je test to potvrdio ($p > 0,05$). Rezultat je u skladu s očekivanjima jer je velika varijabilnost podataka karakteristika hrvatskog tržišta, tako da se prema Wooldbridgegu ne može ustanoviti statistički značajna razlika u parametrima oba procjenitelja (Wooldridge, 2012).

Model je potvrdio negativan utjecaj varijable *dani vezivanja zaliha* ($p < 0,01$) na zavisnu varijablu *ROA* što znači da duže vrijeme zadržavanja zaliha na skladištu utječe na smanjenje profitabilnosti poduzeća. Također, potvrđen je i negativan utjecaj varijable *dani plaćanja dobavljača* ($p < 0,01$) na *ROA-u* što znači da duže odgađanje plaćanja obveza prema dobavljačima utječe na smanjenje profitabilnosti poduzeća. Varijabla *sektor* se također pokazala statistički značajnom: sektori *trgovina na veliko* ($p < 0,01$), *trgovina na malo* ($p < 0,05$) i *prerađivački sektor* ($p < 0,01$) imaju veću profitabilnost u odnosu na referenti sektor *građevinarstvo*. Od kontrolnih varijabli *rast prodaje* ($p < 0,05$) ima pozitivan utjecaj na zavisnu varijablu *ROA* što znači da rast prodaje utječe na povećanje profitabilnosti poduzeća.

Hipoteza H1 je djelomično prihvaćena jer se nije pokazao statistički značajan utjecaj varijable *dani naplate potraživanja* ni *veličine poduzeća* na *profitabilnost poduzeća*. Također, *BDP* i *inflacija* se nisu pokazali statistički značajnim.

6.4.1.4. Regresijska dijagnostika svih sektora zajedno

Budući da je vrijednosti modificiranog Waldovog testa $p < 0,01$ može se zaključiti da postoji problem heteroskedastičnosti. Problem je uklonjen korištenjem naredbe *cluster*. Rezultat Wooldridgeovog testa ukazuje na nepostojanje autokorelacije prvog reda. Eventualno postojanje problema multikolinearnosti ispitano je korelacijskom matricom.

U tablici 25 su prikazani koeficijenti korelacije i pripadna razina signifikantnosti. Svi koeficijenti nalaze se u rasponu od -0,6 do 0,6 što ukazuje na nepostojanje problema multikolinearnosti.

Tablica 25. Korelacijska matrica parova nezavisnih varijabli

	DNP	DVZ	DPOD	VEL	RPR	INF	BDP	PRER	TRGM	TRGV
DNP	1,0000									
DVZ	-0,0252 (0,3503)	1,0000								
DPOD	0,2414* (0,0000)	0,1907* (0,0000)	1,0000							
VEL	-0,0744* (0,0057)	-0,0758* (0,0048)	-0,1868* (0,0000)	1,0000						
RPR	-0,1259* (0,0000)	-0,0728* (0,0068)	-0,1694* (0,0000)	0,1504* (0,0000)	1,0000					
INF	0,0993* (0,0002)	-0,0115 (0,6695)	0,1010* (0,0002)	-0,0532* (0,0483)	-0,0162 (0,5472)	1,0000				
BDP	-0,0544* (0,0432)	0,0058 (0,8296)	-0,0690* (0,0104)	0,0307 (0,2544)	0,0829* (0,0021)	-0,5843* (0,0000)	1,0000			
PRER	0,0432 (0,1084)	0,0984* (0,0003)	-0,0210 (0,4348)	-0,0971* (0,0003)	0,0371 (0,1686)	0,0007 (0,9806)	0,0001 (0,9981)	1,0000		
TRGM	-0,4073* (0,0000)	0,1015* (0,0002)	-0,0820* (0,0023)	0,0190 (0,4810)	-0,0308 (0,2529)	0,0006 (0,9812)	0,0001 (0,9982)	-0,3111* (0,0000)	1,0000	
TRGV	0,2130* (0,0000)	-0,0907* (0,0007)	-0,0761* (0,0047)	0,2077* (0,0000)	-0,0129 (0,6327)	0,0007 (0,9783)	0,0001 (0,9979)	-0,3585* (0,0000)	-0,3479* (0,0000)	1,0000

* $p < 0,5$

Izvor: Izrada autorice prema izračunima STATE

6.4.2. Sektor građevinarstvo

Građevinski sektor podrazumijeva gradnju stambenih i nestambenih zgrada, cesta i autocesta, cjevovoda za tekućine i plinove, vodovoda za električnu struju, vodnih građevina, pripremne radove na gradilištu, elektroinstalacijske radove i dr. Jedna od najčešćih podjela građevinskog sektora je podjela na visokogradnju i niskogradnju. Visokogradnja podrazumijeva gradnju stambenih objekata dok se niskogradnja odnosi na konstrukcije kao što su mostovi, tuneli, vodoprivredni objekti, brane i dr.

Građevinska poduzeća se mogu podijeliti na:

- poduzeća koja se bave uslužnom gradnjom – mogu biti angažirani od strane javnog (najčešće niskogradnja) ili privatnog sektora (najčešće visokogradnja);
- poduzeća koja grade za tržište – ona mogu ujedno biti i investitori i
- poduzeća koja grade za vlastite potrebe – ona mogu ujedno biti i investitori.

Građevinski sektor karakterizira dugo vrijeme produkcije, visoki inicijalni troškovi, dugotrajnost korištenja proizvoda, kompleksnost i imobilnost, inkontrolabilnost procesa građenja, postojanje neformalnog upravljačkog sustava i organizacije, niska razina standardizacije, visoka razina manualno-zanatske produkcije, diskontinuitet proizvodnje, nema čvrste proizvodne teorije u graditeljstvu te specifična tržišna struktura (prevladavaju mala poduzeća) (Bošković, 2002).

Ramljak (2018) ističe tri specifičnosti građevinskog sektora:

- orijentacija na podizvođače;
- primjena retencije ili sustege i
- teško sagledivi rizici.

Uobičajena praksa građevinskih poduzeća je angažiranje podizvođača. Jedan od najčešćih razloga angažmana podizvođača su radovi koji nisu u domeni građevinskog poduzeća te u slučaju dislociranosti gradilišta što je najčešći slučaj s međunarodnim projektima. Druga specifičnost građevinskog sektora je primjena retencije ili sustege (prisutna samo kod uslužnog građenja). Retencija predstavlja iznos koji klijent susteže od certificiranog iznosa radova koji dopijevaju na naplatu, a ti akumulirani iznosi će se isplatiti izvođaču tek kada se svi radovi završe. Retencija može negativno utjecati na likvidnost poduzeća, a taj negativan utjecaj se može umanjiti ugovaranjem retencije sa svojim podizvođačima. Teško sagledivi rizici se ogledaju u vrlo visokoj vrijednosti radova i dugom razdoblju realizacije ugovorenih projekata s vrlo malom mogućnošću kasnijeg utjecaja na ugovorenu cijenu zbog fluktuacije cijena materijala, troškova rada i uopće promjene vrijednosti cijene novca (Ramljak, 2018).

Za potrebe provođenja istraživanja prikupljeni su podaci za razdoblje od 2010. do 2015. godine što obuhvaća razdoblje nakon pojave recesije (2009-2014). Analizirana su poduzeća koja se prema Nacionalnoj klasifikaciji djelatnosti svrstavaju u područje

F. Građevinarstvo, i to: gradnja zgrada (41), gradnja građevina niskogradnje (42) i specijalizirane građevinske djelatnosti (43).

U sektoru građevinarstvo u 2015. godini bilo je ukupno 17.575 poduzeća, od čega je 17.557 bilo malih i srednjih poduzeća dok je velikih bilo samo 18 poduzeća. Građevinska poduzeća u ukupnom broju malih i srednjih poduzeća čine udio od 12 %. Broj zaposlenih osoba iznosio je 99 790, od čega je 86 418 zaposlenih osoba bilo u malim i srednjim poduzećima, a 13 372 zaposlene osobe u velikim poduzećima. U ukupnom broju malih i srednjih poduzeća broj zaposlenih iz ovoga sektora činio je udio od 12,56 %. U 2015. godini poduzeća su ostvarila dodanu vrijednost u iznosu od 13 027 329 od čega su mala i srednja poduzeća ostvarila dodanu vrijednost u iznosu 10 500 027, a velika u iznosu od 2 527 302. Unutar skupine malih i srednjih poduzeća građevinska poduzeća su ostvarila udio od 11,11 % u ukupnoj dodanoj vrijednosti (DZS, 2015b).

6.4.2.1. Deskriptivna statistika sektora građevinarstvo

Istraživanje je obuhvatilo 66 građevinskih poduzeća tijekom 5 godina promatranja što ukupno daje 330 opažanja. Deskriptivna statistika prikazuje aritmetičku sredinu, pripadnu standardnu devijaciju, minimalnu i maksimalnu vrijednost, ukupan broj opažanja, broj promatranih jedinica i broj razdoblja. Vrijednosti su prikazane za cijeli skup podataka (overall), između promatranih jedinica (between) i na razini jedne promatrane jedinice (within).

Prosječna vrijednost zavisne varijable *ROA* iznosi 0,0554 uz standardnu devijaciju 0,0970 na razini cijelog skupa, a 0,0539 između promatranih jedinica i 0,0809 unutar promatrane jedinice što ukazuje na veća odstupanja unutar nego između poduzeća.

Prosječna vrijednost varijable *dani naplate potraživanja* iznosi 74,88 dana, uz prosječno odstupanje od prosjeka 38,45 i raspon od 0,46 do 222,49 dana. Veća standardna devijacija zabilježena je između poduzeća (32,69) nego unutar poduzeća (20,55 dana).

Varijabla *dani vezivanja zaliha* imala je prosječnu vrijednost 60,50 dana i standardnu devijaciju 110,75 dana. Veća odstupanja zabilježena su između poduzeća sa standardnom devijacijom 105,47 dana, nego unutar poduzeća 35,74 dana.

Tablica 26. Deskriptivna statistika za građevinarstvo

Varijabla		Aritmetička sredina	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost	Broj opažanja
ROA	Overall	0,05537	0,09704	-0,22503	1,31052	N = 330
	Between		0,05387	-0,05387	0,27661	n = 66
	Within		0,08093	-0,20475	1,08929	T = 5
DNP	Overall	74,87955	38,44861	0,45808	222,4876	N = 330
	Between		32,69407	1,34603	166,1867	n = 66
	Within		20,55211	8,87525	158,8091	T = 5
DVZ	Overall	60,50283	110,7495	0,64135	840,5597	N = 330
	Between		105,4688	1,97869	539,482	n = 66
	Within		35,73558	-101,8721	361,5806	T = 5
DPOD	Overall	87,73183	48,72323	6,91451	283,9302	N = 330
	Between		42,02211	10,34638	201,8973	n = 66
	Within		25,09114	0,78415	207,393	T = 5
VEL	Overall	7,721695	0,28216	6,96047	8,53546	N = 330
	Between		0,26939	7,03611	8,27212	n = 66
	Within		0,08905	7,39921	8,02213	T = 5
RPR	Overall	0,064614	0,29824	-0,51087	1,65906	N = 330
	Between		0,10901	-0,16990	0,37891	n = 66
	Within		0,27787	-0,60904	1,37152	T = 5
INF		0,01398	0,01504	-0,00500	0,03400	T = 5
BDP		0,00608	0,01085	-0,00720	0,02327	T = 5

Izvor: Izrada autorice prema izračunima STATE

Prosječna vrijednost varijable *dani plaćanja dobavljača* iznosi 87,73 dana. Prosječno odstupanje od prosječne vrijednosti *dana plaćanja dobavljača* iznosi 48,72, a kreće se u rasponu od 6,91 do 283,93 dana. Veća standardna devijacija zabilježena je između poduzeća (42,02) nego unutar poduzeća (25,09 dana).

Prosječna *veličina poduzeća* iznosila je 7,72 uz standardnu devijaciju 0,28 i raspon od 6,96 do 8,54. Veće prosječno odstupanje od prosječne vrijednosti zabilježeno je između poduzeća (0,27) nego unutar poduzeća (0,09).

Prosječni godišnji *rast prodaje* poduzeća u sektoru *građevinarstvo* iznosio je 0,0646 uz standardnu devijaciju od 0,2982. Velika varijabilnost ne iznenađuje u tom sektoru, kao ni veća standardna devijacija zabilježena unutar poduzeća (0,2779) nego između poduzeća (0,1090).

6.4.2.2. Spearmanov koeficijent korelacije

Kako bi se utvrdila povezanost između *ROA* i varijabli *dani naplate potraživanja*, *dani vezivanja zaliha* i *dani plaćanja dobavljača* izračunat je Spearmanov koeficijent korelacije. Rezultati su prikazani u tablici 27.

Tablica 27. Spearmanov koeficijent korelacije – sektor građevinarstva

		Y_ROA_indeks
Spearman's rho	X1_Dani_Naplate_Potrazivanja	Correlation Coefficient
		Sig. (2-tailed)
		N
	X2_Dani_Vezivanja_Zaliha	Correlation Coefficient
		Sig. (2-tailed)
		N
	X3_Dani_Placanja_Dobavljacka	Correlation Coefficient
		Sig. (2-tailed)
		N

*korelacija je značajna na razini 0,05 ($p < 0,05$); ** korelacija je značajna na razini 0,01 ($p < 0,01$)

Izvor: Izrada autorice prema izračunima STATE

Iz tablice je vidljivo da postoji relativno slaba negativna korelacija između varijable *dani plaćanja dobavljača* i *ROA*, ($r = -0,307$, $p < 0,01$). Ako su *dani plaćanja dobavljača* manji onda je *ROA* veći. Varijable *dani vezivanja zaliha* i *dani naplate potraživanja* nisu značajno povezani s *ROA*.

6.4.2.3. Panel analiza sektora građevinarstvo

Nad podacima sektora *građevinarstvo* napravljena su 3 modela: združeni model, model s fiksnim efektom i model sa slučajnim efektom.

Združeni model:

$$ROA_{it} = \alpha + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Modeli s fiksnim efektom:

$$ROA_{it} = \alpha_i + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Modeli sa slučajnim efektom za sva četiri sektora pojedinačno:

$$ROA_{it} = \mu + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \alpha_i + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Rezultati su prikazani u tablici 28.

Tablica 28. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima

	Združeni	Fiksni	Slučajni
DNP	-0,00016 (0,00015)	-0,00058** (0,00025)	-0,00021 (0,00015)
DVZ	0,000014 (0,000039)	0,00015* (0,000083)	0,000021 (0,000041)
DPOD	-0,00026** (0,00010)	-0,000037 (0,00017)	-0,00023** (0,00011)
VEL	0,0461** (0,0218)	0,0432 (0,0515)	0,0479** (0,0221)
RPR	0,00248 (0,0168)	0,00437 (0,0191)	0,00393 (0,0164)
INF	-0,0105* (0,00626)	-0,00823 (0,00683)	-0,0104 (0,00642)
BDP	-0,0124* (0,00711)	-0,0114 (0,00758)	-0,0124* (0,00720)
KONSTANTA	-0,2440 (0,1683)	-0,2227 (0,3995)	-0,2587 (0,1710)
R^2	0,0713	0,0660	0,0557
$\rho(\rho)$		0,2988	0,1369
Ftest		0,0021	
LM test			0,0018
Hausman test		0,7929	
Wald test		0,0000	
Wooldridge test		0,1588	
corr (u _i , X _b)		-0,3046	
Broj opažanja	330	330	330
Broj jedinica	66	66	66

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$, vrijednosti u zagradama su korigirane (clusterirane robustne) standardne pogreške

Izvor: Izrada autorice prema izračunima STATE

Sukladno rezultatima provedenih testova odabran je prikladan model. Vrijednost F testa ($p < 0,01$) opravdala je upotrebu modela s fiksnim efektom u odnosu na združeni model. Rezultat LM testa ($p < 0,01$) opravdava korištenje modela sa slučajnim efektom u odnosu na združeni model. Nakon provedenog Hausman testa ($p > 0,05$) zaključeno je da je slučajni model najprikladniji. S obzirom na veliku nestabilnost građevinskog sektora i raspršenost promatranih podataka takav rezultat mogao se očekivati. Nije

bilo moguće ustanoviti statistički značajnu razliku u parametrima oba procjenitelja pa je model sa slučajnim efektom prikladniji (Wooldridge, 2012). Rezultat Wooldridgeovog testa ($p > 0,05$) upućuje da se ne može odbaciti nulta hipoteza o nepostojanju autokorelacije pogrešaka relacije.

Varijable *dani plaćanja dobavljača* ($p < 0,05$), *veličina poduzeća* ($p < 0,05$) i *rast BDP-a* ($p < 0,1$) su se pokazale statistički značajnima. *Dani plaćanja dobavljača* imaju negativan utjecaj na zavisnu varijablu *ROA* što znači da duže odgađanje plaćanja obveza prema dobavljačima utječe na smanjenje profitabilnosti poduzeća. *Veličina poduzeća* ima pozitivan utjecaj na *ROA-u* što znači da rast poduzeća utječe na povećanje profitabilnosti poduzeća. Varijabla *BDP* negativno utječe na *ROA-u* što znači da rast BDP-a utječe na smanjenje profitabilnosti poduzeća u ovom sektoru.

6.4.2.4. Regresijska dijagnostika sektora građevinarstvo

Ispitana je korelacija između varijabli u modelu. Rezultati su prikazani u tablici 29.

Tablica 29. Korelacijska matrica parova nezavisnih varijabli

	DNP	DVZ	DPOD	VEL	RPR	INF	BDP
DNP	1,0000						
DVZ	-0,1642* (0,0028)	1,0000					
DPOD	0,1425* (0,0095)	0,1159* (0,0354)	1,0000				
VEL	0,1903* (0,0005)	0,1527* (0,0054)	-0,1942* (0,0004)	1,0000			
RPR	-0,1933* (0,0004)	0,0012 (0,9832)	-0,2730* (0,0000)	0,1891* (0,0006)	1,0000		
INF	0,2503* (0,0000)	0,0002 (0,9977)	0,1217* (0,0271)	-0,0208 (0,7065)	0,0036 (0,9476)	1,0000	
BDP	-0,1187* (0,0311)	0,0151 (0,7846)	-0,1079 (0,0503)	0,0218 (0,6930)	0,1232* (0,0252)	-0,5816* (0,0000)	1,0000

* $p < 0,5$

Izvor: Izrada autorice prema izračunima STATE

U tablici 29 su prikazani koeficijenti korelacije i pripadna razina signifikantnosti. Svi koeficijenti nalaze se u rasponu od -0,6 do 0,6 što ukazuje na nepostojanje problema multikolinearnosti.

6.4.3. Prerađivački sektor

Djelatnosti ovog sektora su mehaničke, fizikalne ili kemijske transformacije materijala, tvari ili komponenti u nove proizvode. Sastavljanje ili montiranje sastavnih dijelova proizvedenih proizvoda smatra se proizvodnjom, osim u slučajevima gdje se aktivnost prikladno klasificira u sektor graditeljstvo. Proizvodni pogoni mogu obraditi materijale ili mogu ugovoriti s drugim poduzećima obradu materijala za njih. Obje vrste objekata uključene su u proizvodnju. Materijali koji se koriste mogu se kupiti direktno od proizvođača, dobivenih putem uobičajenih trgovačkih kanala, ili osiguranih prebacivanjem proizvoda iz jednog u drugi pogon koji je pod istim vlasništvom. Novi proizvod proizveden u pogonu može biti gotov u smislu da je spreman za upotrebu ili potrošnju ili može biti poluproizvod koji postaje input za pogon za daljnju proizvodnju. Podsektori u sektoru proizvodnje općenito odražavaju različite proizvodne procese koji se odnose na materijalne inpute, proizvodnu opremu i vještine zaposlenika (Executive office of the president of the United States, 2017).

Proizvodni objekti često obavljaju jednu ili više aktivnosti koje su klasificirane izvan sektora proizvodnje (npr. istraživanje i razvoj ili računovodstvo). Te usluge se tretiraju isto kao i proizvodne aktivnosti osim kada su te usluge pružene od drugog poduzeća. Granice proizvodnog i drugih sektora mogu biti pomalo mutne. Poduzeća proizvodnog sektora bave se transformacijom materijala u nove proizvode. Njihov izlaz je novi proizvod. Međutim, definicija onoga što čini novi proizvod može biti nešto subjektivno (ibid: 2017).

Analizirana su poduzeća koja se prema Nacionalnoj klasifikaciji djelatnosti svrstavaju u područje C Prerađivačka industrija, i to proizvodnja prehrambenih proizvoda i proizvodnja pića.

U prerađivačkom sektoru u 2015. godini bilo je ukupno 19 716 poduzeća, od čega je 19 558 bilo malih i srednjih poduzeća dok je velikih bilo 158 poduzeća. Prerađivačka poduzeća u ukupnom broju malih i srednjih poduzeća čine udio od 13,38 %. Broj zaposlenih osoba iznosio je 256 173, od čega je 162 926 zaposlenih osoba bilo u malim i srednjim poduzećima, a 93 247 zaposlene osobe u velikim poduzećima. U

ukupnom broju malih i srednjih poduzeća broj zaposlenih iz ovoga sektora činio je udio od 23,69 % što ga čini sektorom koji zapošljava najviše osoba unutar malih i srednjih poduzeća. U 2015. godini poduzeća su ostvarila dodanu vrijednost u iznosu od 37 492 198 od čega su mala i srednja poduzeća ostvarila dodanu vrijednost u iznosu 20 245 787, a velika u iznosu od 17 246 411 (DZS, 2015b). Unutar skupine malih i srednjih poduzeća prerađivačka poduzeća su ostvarila udio od 21,43 % u ukupnoj dodanoj vrijednosti što ih čini, uz trgovinu na veliko i malo, najvažnijim sektorom po ovom pokazatelju. Sharma i Kumar (2011) ističu da je učinkovitost upravljanja obrtnim kapitalom od vitalnog značaja za svako poduzeće, a posebno za poduzeća iz sektora proizvodnje.

6.4.3.1. Deskriptivna statistika prerađivačkog sektora

Istraživanje je obuhvatilo 67 poduzeća iz prerađivačkog sektora tijekom 5 godina. Podaci su balansirani pa je ukupno obuhvaćeno 335 opažanja. U tablici 31 su prikazane aritmetičke sredine, pripadne standardne devijacije, minimalna i maksimalna vrijednost svih varijabli u modelu, kao i ukupan broj opažanja, broj promatranih jedinica i broj razdoblja. Vrijednosti su prikazane za cijeli skup podataka (overall), između promatranih jedinica (between) i na razini jedne promatrane jedinice (within).

Prosječna vrijednost zavisne varijable *ROA* iznosi 0,0874 uz standardnu devijaciju 0,1872 na razini cijelog skupa, 0,1334 između promatranih jedinica i 0,1321 unutar promatrane jedinice. Rezultat ukazuje na približno jednaka odstupanja *ROA* između promatranih poduzeća i unutar poduzeća.

Prosječna vrijednost *dana naplate potraživanja* iznosi 66,90 dana, uz standardnu devijaciju od 41,93 dana te raspon od 0,33 dana do 211,97 dana. Standardna devijacija je veća između poduzeća ($\sigma = 39,34$), nego unutar poduzeća ($\sigma = 15,15$).

Varijabla *dani vezivanja zaliha* imala je prosječnu vrijednost od 97,82 dana, uz prosječno odstupanje od prosjeka 146,36 dana te raspon od 2,30 dana do 930,97 dana. Veća standardna devijacija je zabilježena između poduzeća ($\sigma = 140,139$), nego unutar poduzeća ($\sigma = 44,9248$).

Tablica 30. Deskriptivna statistika za prerađivački sektor

Varijabla		Aritmetička sredina	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost	Broj opažanja
ROA	Overall	0,08740	0,187155	-0,47677	2,19322	N = 335
	Between		0,13335	-0,21185	0,88261	n = 67
	Within		0,13213	-0,53076	1,73864	T = 5
DNP	Overall	66,90332	41,93054	0,32519	211,9695	N = 335
	Between		39,33519	0,58947	173,9544	n = 67
	Within		15,14737	6,04203	135,6181	T = 5
DVZ	Overall	97,8164	146,3625	2,30316	930,9683	N = 335
	Between		140,139	3,03467	788,1379	n = 67
	Within		44,9248	-138,8425	455,8667	T = 5
DPOD	Overall	68,99944	51,97049	4,19969	305,7783	N = 335
	Between		45,65897	11,74589	219,2422	n = 67
	Within		25,3211	-87,16476	241,7911	T = 5
VEL	Overall	7,74656	0,31880	6,38129	8,46065	N = 335
	Between		0,31007	6,45096	8,36157	n = 67
	Within		0,08152	7,41495	8,14551	T = 5
RPR	Overall	0,0766337	0,21679	-0,44712	1,24237	N = 335
	Between		0,11269	-0,12398	0,47859	n = 67
	Within		0,18561	-0,51483	1,17122	T = 5
INF		0,01398	0,01504	-0,00500	0,03400	T = 5
BDP		0,00608	0,01085	-0,00720	0,02327	T = 5

Izvor: Izrada autorice prema izračunima STATE

Prosječna vrijednost varijable *dani plaćanja dobavljača* je 69,00 dana uz standardnu devijaciju od 51,97 dana i raspon od 4,20 dana do 305,78 dana. Standardna devijacija je veće između poduzeća ($\sigma = 45,66$), nego unutar poduzeća ($\sigma = 25,32$).

Prosječna *veličina poduzeća* iznosila je 7,75 uz standardnu devijaciju 0,32 i raspon od 6,38 do 8,46. Veće prosječno odstupanje od prosječne vrijednosti zabilježeno je između poduzeća (0,31), nego unutar poduzeća (0,08).

Prosječni godišnji *rast prodaje* u prerađivačkom sektoru iznosi 0,0766, odnosno 7,66 % uz veliku standardnu devijaciju od 0,2168, tj 21,68 %. Tako velika varijacija uobičajena je na hrvatskom tržištu. Veća standardna devijacija *rasta prodaje* zabilježena unutar poduzeća (0,1856), nego između poduzeća (0,1127).

6.4.3.2. Spearmanov koeficijent korelacije

Kako bi se utvrdila povezanost između *ROA* i varijabli *dani naplate potraživanja*, *dani vezivanja zaliha* i *dani plaćanja dobavljača*, izračunat je Spearmanov koeficijent korelacije. Rezultati su prikazani u tablici 31.

Tablica 31. Spearmanov koeficijent korelacije – prerađivački sektor

		Y_ROA_indeks
Spearman's rho	X1_Dani_Naplate_Potrazivanja	Correlation Coefficient
		Sig. (2-tailed)
		N
	X2_Dani_Vezivanja_Zaliha	Correlation Coefficient
		Sig. (2-tailed)
		N
	X3_Dani_Placanja_Dobavljacka	Correlation Coefficient
		Sig. (2-tailed)
		N

*korelacija je značajna na razini 0,05 ($p < 0,05$); ** korelacija je značajna na razini 0,01 ($p < 0,01$)

Izvor: Izrada autorice prema izračunima STATE

Iz tablice je vidljivo da su sve varijable slabo i negativno povezane s *ROA*, što znači da poduzeća čiji su *dani naplate potraživanja* ($r = -0,128$, $p < 0,05$), *dani vezivanja zaliha* ($r = -0,219$, $p < 0,01$) i *dani plaćanja dobavljača* ($r = -0,257$, $p < 0,01$) manji, imaju nešto veću vrijednost *ROA*.

6.4.3.3. Panel analiza prerađivačkog sektora

Nad podacima *prerađivačkog sektora* napravljena su tri modela: združeni model, model s fiksnim efektom i model sa slučajnim efektom.

Združeni model:

$$ROA_{it} = \alpha + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Modeli s fiksnim efektom:

$$ROA_{it} = \alpha_i + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Modeli sa slučajnim efektom za sva četiri sektora pojedinačno:

$$ROA_{it} = \mu + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \alpha_i + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Rezultati su prikazani u tablici 32.

Tablica 32. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima.

	Združeni	Fiksni	Slučajni
DNP	0,00018 (0,00031)	0,00070 (0,00044)	0,00029 (0,00029)
DVZ	-0,00015** (0,00007)	-0,000035 (0,0000426)	-0,00013** (0,00006)
DPOD	-0,00039* (0,00021)	-0,00030* (0,00015)	-0,00032** (0,00016)
VEL	-0,09889 (0,06096)	-0,10088 (0,10111)	-0,02022 (0,58762)
RPR	0,11121** (0,04720)	0,10613*** (0,02448)	0,09336*** (0,02707)
INF	0,00190 (0,0055)	0,00141 (0,00524)	0,00209 (0,00552)
BDP	0,00286 (0,00864)	0,00295 (0,00924)	0,00292 (0,00910)
KONSTANTA	0,18304 (0,44484)	0,83412 (0,76126)	0,24849 (0,43155)
R^2	0,0516	0,0229	0,0167
$\rho(\rho)$		0,4614	0,3717
Ftest		0,0000	
LM test			0,0000
Hausman test		0,8587	
Wald test		0,0000	
Wooldridge test		0,3960	
corr (u _i , X _b)		-0,2077	
Broj opažanja	335	335	1380
Broj jedinica	67	67	67

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$, vrijednosti u zagradama su korigirane (clusterirane robustne) standardne pogreške

Izvor: Izrada autorice prema izračunima STATE

Nakon provedene analize odabran je najprikladniji model. Vrijednost F testa ($p < 0,01$) opravdalo je upotrebu modela s fiksnim efektom u odnosu na združeni model. Prema rezultatima LM testa ($p < 0,01$) opravdano je korištenje modela sa slučajnim efektom u odnosu na združeni model. Sukladno Hausman testu ($p > 0,05$) zaključeno je da je model sa slučajnim efektom najprikladniji. Taj rezultat je očekivan iz istog razloga kao i u prethodnim modelima – zbog velike varijacije među promatranim podacima.

Rezultat Wooldridgeovog testa ($p > 0,05$) upućuje da se ne može odbaciti nulta hipoteza o nepostojanju autokorelacije pogrešaka relacije.

Varijable *dani vezivanja zaliha* ($p < 0,05$), *dani plaćanja dobavljača* ($p < 0,05$) i *rast prodaje* ($p < 0,01$) su se pokazale statistički značajnima. *Dani vezivanja zaliha* imaju negativan utjecaj na zavisnu varijablu *ROA* što znači da duže vrijeme zadržavanja zaliha na skladištu utječe na smanjenje profitabilnosti poduzeća. *Dani plaćanja dobavljača* imaju negativan utjecaj na zavisnu varijablu *ROA* što znači da duže odgađanje plaćanja obveza prema dobavljačima utječe na smanjenje profitabilnosti poduzeća. Od kontrolnih varijabli *rast prodaje* ima pozitivan utjecaj na zavisnu varijablu *ROA*. Veći *rast prodaje* uzrokuje veću profitabilnost poduzeća.

6.4.3.4. Regresijska dijagnostika prerađivačkog sektora

Ispitana je korelacija između varijabli u modelu, a rezultati su prikazani u tablici 33.

Tablica 33. Korelacijska matrica parova nezavisnih varijabli

	DNP	DVZ	DPOD	VEL	RPR	INF	BDP
DNP	1,0000						
DVZ	0,1827* (0,0008)	1,0000					
DPOD	0,1757* (0,0012)	0,2399* (0,0000)	1,0000				
VEL	- 0,1345* (0,0137)	- 0,1304* (0,0170)	- 0,2549* (0,0000)	1,0000			
RPR	- 0,2305* (0,0000)	-0,0936 (0,0870)	- 0,1710* (0,0017)	0,1851* (0,0007)	1,0000		
INF	0,0165 (0,7632)	-0,0573 (0,2957)	0,0438 (0,4238)	-0,0553 (0,3126)	0,0508 (0,3543)	1,0000	
BDP	-0,0256 (0,6405)	0,0198 (0,7179)	-0,0368 (0,5018)	0,0229 (0,6763)	0,0549 (0,3164)	-0,5851* (0,0000)	1,0000

* $p < 0,5$

Izvor: Izrada autorice prema izračunima STATE

U tablici 33 su prikazani koeficijenti korelacije te pripadajuće razine značajnosti. Svi koeficijenti korelacije nalaze se u rasponu od -0,6 do 0,6 na temelju čega se može odbaciti pretpostavka o postojanju problema multikolinearnosti.

6.4.4. Sektor trgovina na malo

Sektor trgovine na malo obuhvaća poduzeća koja se bave prodajom robe na malo, općenito bez transformacija, i pružanje usluga vezanih uz prodaju robe. Proces maloprodaje je posljednji korak u distribuciji robe gdje su trgovci organizirani za prodaju robe u malim količinama široj javnosti. Ovaj sektor obuhvaća dvije glavne vrste trgovaca:

- trgovci u trgovinama i
- trgovci izvan trgovina.

Trgovci u trgovinama posluju s fiksne lokacije na prodajnim mjestima, koje su smještene i dizajnirane za privlačenje velike mase kupaca. Općenito, maloprodajne trgovine imaju veliki broj proizvoda i koriste masovno oglašavanje za privlačenje kupaca. Oni obično prodaju robu široj javnosti za osobnu ili kućnu potrošnju, ali neki se također služe i poslovnim i institucionalnim klijentima (npr. uredska oprema, računala). Pored maloprodajne robe, neke vrste maloprodajnih trgovina bave se pružanjem usluga nakon prodaje, kao što su popravci i instalacije (npr. trgovci automobila). Trgovci izvan trgovina (*Non-store retailers*), kao i obični trgovci, organizirani su kako bi služili široj javnosti, ali se njihove maloprodajne metode razlikuju. Poduzeća ovog podsektora dolaze do kupaca i tržišta robe metodama kao što su emitiranje televizijskih reklama (tv shop), emitiranje i objavljivanje oglasa s izravnim odgovorom, izdavanje letaka i elektroničkih kataloga, prodaja od vrata do vrata, kućne demonstracije, prodaja putem prenosivih štandova i distribucija putem automata (Executive office of the president of the United States, 2017).

Kupnja robe za preprodaju je karakteristika maloprodajnih objekata (npr. poljoprivredni proizvodi). Trgovci na veliko također se bave kupnjom robe za preprodaju, ali obično nisu organizirani da bi služili široj javnosti. Trgovci na veliko opskrbljuju institucionalne, industrijske, veleprodajne i maloprodajne klijente; njihovo poslovanje je općenito organizirano za kupnju, prodaju i isporuku robe u većim količinama. Međutim, *dealeri*, poljoprivrednim strojevima, teškim teretnim kamionima i slično, smatraju se veletrgovcima čak i ako prodaju te proizvode u pojedinačnim jedinicama (ibid: 2017).

U trgovini na veliko i na malo; popravak motornih vozila i motocikala (dalje u tekstu: trgovina na veliko i na malo) u 2015. godini bilo je ukupno 37 340 poduzeća, od čega je 37 265 bilo malih i srednjih poduzeća dok je velikih bilo 75 poduzeća. Trgovina na

veliko i na malo u ukupnom broju malih i srednjih poduzeća čini udio od 25,49 % što je čini najvažnijim sektorom po kriteriju broja poduzeća. Broj zaposlenih osoba iznosio je 226 889, od čega je 152 923 zaposlenih osoba bilo u malim i srednjim poduzećima, a 73 966 zaposlene osobe u velikim poduzećima. U ukupnom broju malih i srednjih poduzeća broj zaposlenih iz ovoga sektora činio je udio od 22,23 % što ga uz prerađivački sektor, čini sektorom koji zapošljava najviše osoba unutar malih i srednjih poduzeća. U 2015. godini poduzeća su ostvarila dodanu vrijednost u iznosu od 31 707 482 od čega su mala i srednja poduzeća ostvarila dodanu vrijednost u iznosu 20 863 523, a velika u iznosu od 10 843 959 (DZS, 2015b). Unutar skupine malih i srednjih poduzeća trgovina je ostvarila udio od 22,08 % u ukupnoj dodanoj vrijednosti što ju čini najvažnijim sektorom i po ovom pokazatelju.

Državni zavod za statistiku ne objavljuje ove pokazatelje posebno za trgovinu na veliko i posebno za trgovinu na malo. Unatoč tomu, u ovom radu se analizirala posebno trgovinu na veliko i posebno trgovinu na malo tako da su se odvojeno prikupljali financijski izvještaji po poddjelatnostima. U nastavku su analizirana poduzeća koja se prema Nacionalnoj klasifikaciji djelatnosti svrstavaju u područje G Trgovina na veliko i na malo; popravak motornih vozila i motocikala, i to poduzeća koja pripadaju podskupini 47 – Trgovina na malo, osim trgovine motornim vozilima i motociklima.

6.4.4.1. Deskriptivna statistika sektora trgovina na malo

Istraživanje je obuhvatilo 64 poduzeća iz sektora trgovine na malo tijekom 5 godina, odnosno ukupno 320 opažanja. U tablici 34 su prikazane aritmetičke sredine, pripadne standardne devijacije, minimalna i maksimalna vrijednost svih varijabli u modelu, ukupan broj opažanja, broj promatranih jedinica i broj razdoblja. Vrijednosti su prikazane za cijeli skup podataka (overall), između promatranih jedinica (between) i na razini jedne promatrane jedinice (within).

Prosječna vrijednost zavisne varijable *ROA* iznosi 0,09104 uz prosječno odstupanje od prosječne vrijednosti 0,1631 na razini cijelog skupa, 0,0939 između promatranih jedinica i 0,1337 unutar promatrane jedinice, što ukazuje na veća odstupanja unutar promatranog poduzeća.

Prosječna vrijednost *dana naplate potraživanja* iznosi 26,75 dana, uz standardnu devijaciju od 22,92 dana, s minimalnom vrijednosti od 0,27 dana i maksimalnom od

110,70 dana. Veća standardna devijacija zabilježena je između poduzeća ($\sigma = 22,02$ dana), nego unutar poduzeća ($\sigma = 6,80$ dana).

Tablica 34. Deskriptivna statistika za trgovinu na malo

Varijabla		Aritmetička sredina	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost	Broj opažanja
ROA	Overall	0,09104	0,16307	-0,37252	2,39641	N = 320
	Between		0,09390	-0,07564	0,60279	n = 64
	Within		0,13373	-0,44492	1,88467	T = 5
DNP	Overall	26,7508	22,91603	0,27475	110,7046	N = 320
	Between		22,02302	0,36183	98,21932	n = 64
	Within		6,79798	-4,25486	55,43198	T = 5
DVZ	Overall	98,96703	90,07674	0,91079	486,5826	N = 320
	Between		86,5516	2,30226	433,7316	n = 64
	Within		26,7689	-45,39499	314,1641	T = 5
DPOD	Overall	63,22284	47,41148	1,02801	270,1999	N = 320
	Between		43,63032	3,39954	224,7369	n = 64
	Within		19,18629	-60,59061	163,8383	T = 5
VEL	Overall	7,810252	0,31419	6,87099	8,56663	N = 320
	Between		0,30463	6,94605	8,50394	n = 64
	Within		0,08411	7,47734	8,18946	T = 5
RPR	Overall	0,0492059	0,17929	-0,5494	0,93615	N = 320
	Between		0,12505	-0,25764	0,57548	n = 64
	Within		0,12924	-0,42169	0,77527	T = 5
INF		0,01398	0,01504	-0,00500	0,03400	T = 5
BDP		0,00608	0,01085	-0,00720	0,02327	T = 5

Izvor: Izrada autorice prema izračunima STATE

Varijabla *dani vezivanja zaliha* ima prosječnu vrijednost 98,97 dana, prosječno odstupanje od prosjeka 90,08 dana te raspon od 0,91 do 486,58 dana. Veća standardna devijacija vidljiva je između poduzeća ($\sigma = 86,55$ dana), nego unutar poduzeća ($\sigma = 26,77$ dana).

Prosjek varijable *dani plaćanja dobavljača* je 63,22 dana, dok je standardna devijacija 47,41 dana. Najmanja vrijednost ove varijable je 1,03 dana, a najveća 270,20 dana. Veća standardna devijacija zabilježena je između poduzeća ($\sigma = 43,63$ dana), nego unutar poduzeća ($\sigma = 19,19$).

Prosječna *veličina poduzeća* iznosila je 7,81 uz standardnu devijaciju 0,31 i raspon od 6,87 do 8,57. Veće prosječno odstupanje od prosječne vrijednosti zabilježeno je

između poduzeća (0,30), nego unutar poduzeća (0,08). Prosječna odstupanja od prosječne vrijednosti *veličine poduzeća* su ista kao i kod prerađivačkog sektora.

Prosječni godišnji *rast prodaje* iznosi 0,0492 odnosno 4,92 % uz veliku standardnu devijaciju od 0,1793, tj 17,93 %. Zanimljivo je da je skoro pa ista standardna devijacija *rasta prodaje* zabilježena unutar poduzeća (0,1292) i između poduzeća (0,1251).

6.4.4.2. Spearmanov koeficijent korelacije

Kako bi se utvrdila povezanost između *ROA* i varijabli *dani naplate potraživanja*, *dani vezivanja zaliha* i *dani plaćanja dobavljača* izračunat je Spearmanov koeficijent korelacije. Rezultati su prikazani u tablici 35.

Tablica 35. Spearmanov koeficijent korelacije – sektor trgovine na malo

		Y_ROA_indeks
Spearman's rho	X1_Dani_Naplate_Potrazivanja	Correlation Coefficient
		Sig. (2-tailed)
		N
	X2_Dani_Vezivanja_Zaliha	Correlation Coefficient
		Sig. (2-tailed)
		N
	X3_Dani_Placcanja_Dobavljacka	Correlation Coefficient
		Sig. (2-tailed)
		N

*korelacija je značajna na razini 0,05 (p<0,05); ** korelacija je značajna na razini 0,01 (p<0,01)

Izvor: Izrada autorice prema izračunima STATE

Spearmanov koeficijent korelacije je relativno slab i negativan između varijabli *ROA* i *dana vezivanja zaliha* ($r = -0,272$, $p < 0,01$) te između *ROA* i *dana plaćanja dobavljača* ($r = -0,346$, $p < 0,01$). Na temelju ovih podataka može se zaključiti da ako su *dani vezivanja zaliha* i *dani plaćanja dobavljača* manji, onda je *ROA* veći.

6.4.4.3. Panel analiza sektora trgovine na malo

I nad podacima sektora *trgovine na malo* napravljena su tri modela: združeni model, model s fiksnim efektom i model sa slučajnim efektom.

Združeni model:

$$ROA_{it} = \alpha + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Modeli s fiksnim efektom:

$$ROA_{it} = \alpha_i + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Modeli sa slučajnim efektom:

$$ROA_{it} = \mu + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \alpha_i + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Rezultati su prikazani u tablici 36.

Tablica 36. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima

	Združeni	Fiksni	Slučajni
DNP	0,00041 (0,00031)	0,00032 (0,00080)	0,00040 (0,000306)
DVZ	-0,00013* (0,000080)	-0,000063 (0,000208)	-0,00014* (0,000078)
DPOD	-0,00057** (0,00024)	-0,00052 (0,000317)	-0,00057*** (0,00022)
VEL	-0,00753 (0,0460)	-0,0415 (0,0787)	-0,00900 (0,0460)
RPR	0,0950* (0,0495)	0,0218 (0,0378)	0,07254 (0,0460)
INF	-0,0162 (0,0107)	-0,0162 (0,0119)	-0,01605 (0,01072)
BDP	-0,0109 (0,0126)	-0,0100 (0,0127)	-0,01066 (0,01258)
KONSTANTA	0,213 (0,330)	0,474 (0,623)	0,22551 (0,33245)
R^2	0,0747	0,0321	0,0289
$\rho(\text{rho})$		0,26141	0,1301
Ftest		0,0033	
LM test			0,0019
Hausman test		0,9235	
Wald test		0,0000	
Wooldridge test		0,0110	
corr (u _i , X _b)		0,0419	0,1301
Broj opažanja	320	320	320
Broj jedinica	64	64	64

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$, vrijednosti u zagradama su korigirane (clusterirane robustne) standardne pogreške

Izvor: Izrada autorice prema izračunima STATE

Da bi se odabrao prikladan model provedeni su odgovarajući testovi. Vrijednost F testa ($p < 0,01$) opravdala je upotrebu modela s fiksnim efektom u odnosu na združeni model. Rezultat LM testa ($p < 0,01$) opravdava korištenje modela sa slučajnim efektom u odnosu na združeni model. Nakon provedenog Hausman testa ($p > 0,05$) zaključeno je da bi model sa slučajnim efektom bio najprikladniji. Ali rezultat Wooldridge testa ukazuje da se na razini signifikantnosti 0,01 ne može odbaciti hipoteza o nepostojanju autokorelacije prvog reda, dok se na razini signifikantnosti 0,05 može odbaciti. Zato su napravljeni dinamički modeli prikladni za ovo istraživanje ($N \rightarrow \infty, T$ relativno malen): Arellanov i Bondov procjenitelj (AB) (Arellano i Bond, 1991) i Blundellov i Bondov procjenitelj (BB) (Blundell i Bond, 1998). U oba modela lagirana vrijednost zavisne varijable ROA ipak se nije pokazala statistički značajna. Zato se može zaključiti da je prikladniji statički u odnosu na dinamički model. Dobivene vrijednosti AB i BB procjenitelja prikazane su u tablici 37.

Tablica 37. Koeficijenti i pripadajuće standardne pogreške u dinamičkim panel regresijskim modelima

	AB	BB
L.ROA	0,32759 (0,26623)	0,09728 (0,08948)
DNP	0,00096 (0,00094)	0,00256 (0,00275)
DVZ	0,00092*** (0,00034)	0,00100 (0,00062)
DPOD	-0,00082* (0,00047)	-0,00085 (0,00112)
VEL	0,08151 (0,10541)	-0,09946 (0,19014)
RPR	0,07211 (0,04631)	0,07321 (0,12343)
INF	-0,02107* (0,01079)	-0,02899*** (0,01089)
BDP	-0,02521** (0,01231)	-0,02711* (0,01610)
KONSTANTA	-0,61049 (0,82803)	0,79017 (1,49792)

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

Izvor: Izrada autorice prema izračunima STATE

Na temelju rezultata dinamičkih modela kao i rezultata F testa, LM testa i Hausman testa prikladnim se pokazao model sa slučajnim efektom. Varijable *dani vezivanja zaliha* ($p < 0,1$) i *dani plaćanja dobavljača* ($p < 0,01$) pokazale su se statistički značajnima. Obje varijable imaju negativan utjecaj na zavisnu varijablu *ROA* što znači da duže vrijeme zadržavanja zaliha na skladištu utječe na smanjenje profitabilnosti poduzeća i duže odgađanje plaćanja obveza prema dobavljačima utječe na smanjenje profitabilnosti poduzeća.

6.4.4.4. Regresijska dijagnostika sektora trgovine na malo

Ispitana je korelacija između varijabli u modelu, a rezultati su prikazani u tablici 38.

Tablica 38. Korelacijska matrica parova nezavisnih varijabli

	DNP	DVZ	DPOD	VEL	RPR	INF	BDP
DNP	1,0000						
DVZ	0,0442 (0,4312)	1,0000					
DPOD	0,3292* (0,0000)	0,3240* (0,0000)	1,0000				
VEL	-0,1632* (0,0034)	-0,1963* (0,0004)	-0,1103* (0,0487)	1,0000			
RPR	-0,0523 (0,3510)	-0,2340* (0,0000)	-0,2119* (0,0001)	0,1382* (0,0133)	1,0000		
INF	0,0575 (0,3049)	0,0050 (0,9287)	0,1155* (0,0390)	-0,0477 (0,3947)	0,0066 (0,9066)	1,0000	
BDP	-0,0261 (0,6423)	-0,0051 (0,9281)	-0,0711 (0,2047)	0,0241 (0,6678)	0,0449 (0,4230)	-0,5851* (0,0000)	1,0000

* $p < 0,5$

Izvor: Izrada autorice prema izračunima STATE

Na temelju prikazanih vrijednosti koeficijenta korelacije među parovima varijabli možemo odbaciti pretpostavku o postojanju problema multikolinearnosti.

6.4.5. Sektor trgovina na veliko

Sektor trgovine na veliko obuhvaća poduzeća koja se bave veleprodajom robe, općenito bez transformacije, te pružanje usluga vezanih za prodaju robe. Proces veleprodaje je srednji korak u distribuciji robe. Trgovci na veliko su organizirani da prodaju ili dogovore kupnju ili prodaju (Executive office of the president of the United States, 2017):

- a) robe za daljnju prodaju (roba koja se prodaje drugim veletrgovcima ili maloprodajnim lancima);

- b) kapitala ili trajno nekomercijalne robe i
- c) sirovina i potrošnog materijala koji se koriste u proizvodnji.

Trgovci na veliko prodaju robu drugim poduzećima i obično rade iz stovarišta ili ureda. Stovarišta i urede karakterizira mali ili nikakav prikaz robe. Osim toga, niti dizajn niti mjesto lokacije ne prodaju robu. Trgovci na veliko obično ne koriste oglašavanje usmjereno prema javnosti. Do klijenata obično dolazi putem telefona, osobnim marketingom, ili preko specijaliziranog oglašavanja koje može uključivati internetske i druge elektroničke načine. Poslovanje se najčešće odvija između veletrgovaca i klijenata koji imaju dugogodišnje poslovne odnose (ibid: 2017).

Ovaj sektor obuhvaća dva glavna tipa veletrgovaca (ibid: 2017):

- veletrgovce koji prodaju robu za vlastiti račun i
- elektronička tržišta poslovanja, agenti i brokeri koji organiziraju prodaju i kupnju za druge, obično za proviziju ili naknadu.

Poduzeća koja prodaju robu za vlastiti račun poznata su kao trgovci na veliko, distributeri, preprodavači, brodari i uvoz/izvoz trgovci. Veletrgovci obično održavaju svoje skladište gdje primaju i obrađuju robu za svoje kupce. Roba se općenito prodaje bez transformacije, ali može uključivati integralne funkcije, kao što su sortiranje, pakiranje, označavanje i druge marketinške usluge. Iako veletrgovina obično označava prodaju u velikim količinama, trajno nekomercijalna roba može biti prodana i u pojedinačnim jedinicama (npr. poljoprivredni strojevi, kamioni i šleperi, industrijski strojevi i drugi) (ibid: 2017).

U nastavku su analizirana poduzeća koja se prema Nacionalnoj klasifikaciji djelatnosti svrstavaju u područje G Trgovina na veliko i na malo; popravak motornih vozila i motocikala, i to poduzeća koja pripadaju podskupini 46 – Trgovina na veliko, osim trgovine motornim vozilima i motociklima.

6.4.5.1. Deskriptivna statistika sektora trgovina na veliko

Istraživanje je obuhvatilo 79 poduzeća iz sektora trgovine na veliko koje su promatrane tijekom 5 godina tako da je ukupan broj opažanja 395. U tablici 39 su prikazane aritmetička sredinu, pripadna standardna devijacija, najmanja i najveća vrijednost svih varijabli u modelu, kao i ukupan broj opažanja, broj promatranih jedinica i broj

razdoblja. Vrijednosti su prikazane za cijeli skup podataka (overall), između promatranih jedinica (between) i na razini jedne promatrane jedinice (within).

Tablica 39. Deskriptivna statistika za trgovinu na veliko

Varijabla		Aritmetička sredina	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost	Broj opažanja
ROA	Overall	0,11503	0,17982	-0,49721	1,89349	N = 395
	Between		0,11123	-0,06816	0,51962	n = 79
	within		0,14174	-0,33562	1,55522	T = 5
DNP	Overall	79,66993	61,78887	2,78343	342,0538	N = 395
	Between		58,45298	3,50526	278,8284	n = 79
	within		20,87586	1,23262	212,7822	T = 5
DVZ	Overall	64,76402	44,84801	0,65189	238,5898	N = 395
	Between		42,8883	1,01908	179,3326	n = 79
	within		13,80624	2,66327	131,1788	T = 5
DPOD	Overall	64,72017	53,71929	1,52585	380,814	N = 395
	Between		50,61168	2,12317	317,4717	n = 79
	within		18,71432	-27,48259	167,5276	T = 5
VEL	Overall	7,900939	0,29021	7,2948	8,74826	N = 395
	Between		0,28182	7,46650	8,68658	n = 79
	within		0,07487	7,66501	8,15749	T = 5
RPR	Overall	0,0572678	0,19463	-0,47110	0,97841	N = 395
	Between		0,09521	-0,12690	0,34849	n = 79
	within		0,17002	-0,45886	0,86897	T = 5
INF		0,01398	0,01504	-0,00500	0,03400	T = 5
BDP		0,00608	0,01085	-0,00720	0,02327	T = 5

Izvor: Izrada autorice prema izračunima STATE

Prosječna vrijednost zavisne varijable *ROA* iznosi 0,1150 uz standardnu devijaciju 0,1798 na razini cijelog skupa, 0,1112 između promatranih jedinica i 0,1417 unutar promatrane jedinice. Ovi rezultati ukazuju na veća odstupanja unutar promatranog poduzeća nego između poduzeća.

Prosječna vrijednost *dana naplate potraživanja* iznosi 79,67 dana, prosječno odstupanje od prosjeka je 61,79 dana, a raspon od 2,78 dana do 342,05 dana. Veća prosječna odstupanja su zapažena između poduzeća ($\sigma = 58,45$) nego unutar pojedinog poduzeća ($\sigma = 20,88$).

Varijabla *dani vezivanja zaliha* ima prosječnu vrijednost koja iznosi 64,76 dana, standardnu devijaciju u iznosu od 44,85 dana te raspon od 0,65 dana do 238,59 dana.

Veća prosječna odstupanja su zapažena između poduzeća ($\sigma = 42,89$) nego unutar poduzeća ($\sigma = 13,81$).

Prosječna vrijednost *dana plaćanja dobavljača* iznosi 64,72 dana, uz standardnu devijaciju koja iznosi 53,72 dana i raspon od 1,53 dana do 380,81 dana. Veća standardna devijacija je uočena između poduzeća ($\sigma = 50,61$) nego unutar poduzeća ($\sigma = 18,71$).

Prosječna *veličina poduzeća* iznosila je 7,90 uz standardnu devijaciju 0,29 i raspon od 7,29 do 8,75. Veće prosječno odstupanje od prosječne vrijednosti zabilježeno je između poduzeća (0,28) nego unutar poduzeća (0,07).

Prosječni godišnji *rast prodaje* iznosi 0,0573 odnosno 5,73 % uz veliku standardnu devijaciju od 0,1946, tj. 19,46 %. Veća standardna devijacija zabilježena je unutar poduzeća (0,1700), nego između poduzeća (0,0952).

6.4.5.2. Spearmanov koeficijent korelacije

Kako bi se utvrdila povezanost između *ROA* i varijabli *dani naplate potraživanja*, *dani vezivanja zaliha* i *dani plaćanja dobavljača* izračunat je Spearmanov koeficijent korelacije. Rezultati su prikazani u tablici 40.

Tablica 40. Spearmanov koeficijent korelacije – sektor trgovine na veliko

		Y_ROA indeks
Spearman's rho	X1_Dani_Naplate_Potrazivanja	Correlation Coefficient
		Sig. (2-tailed)
		N
	X2_Dani_Vezivanja_Zaliha	Correlation Coefficient
		Sig. (2-tailed)
		N
	X3_Dani_Placanja_Dobavljacka	Correlation Coefficient
		Sig. (2-tailed)
		N

*korelacija je značajna na razini 0,05 ($p < 0,05$); ** korelacija je značajna na razini 0,01 ($p < 0,01$)

Izvor: Izrada autorice prema izračunima STATE

U sektoru trgovine na veliko ne postoji značajna korelacija između ispitivanih varijabli.

6.4.5.3. Panel analiza sektora trgovina na veliko

Nad podacima sektora *trgovina na veliko* napravljena su tri modela: združeni model, model s fiksnim efektom i model sa slučajnim efektom.

Združeni model:

$$ROA_{it} = \alpha + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Modeli s fiksnim efektom:

$$ROA_{it} = \alpha_i + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Modeli sa slučajnim efektom za sva četiri sektora pojedinačno:

$$ROA_{it} = \mu + \beta_1 \cdot DNP_{it} + \beta_2 \cdot DVZ_{it} + \beta_3 \cdot DPOD_{it} + \beta_4 \cdot VEL_{it} + \beta_5 \cdot RPR_{it} + \beta_6 \cdot INF_t + \beta_7 \cdot BDP_t + \alpha_i + \varepsilon_{it}; i = 1, \dots, N, t = 1, \dots, T$$

Rezultati su prikazani u tablici 41.

Sukladno rezultatima provedenih testova odabran je prikladan model. Vrijednost F testa ($p < 0,01$) opravdala je upotrebu modela s fiksnim efektom u odnosu na združeni model. Rezultat LM testa ($p < 0,01$) opravdava korištenje modela sa slučajnim efektom u odnosu na združeni model. Nakon provedenog Hausman testa ($p > 0,05$) zaključeno je da je model sa slučajnim efektom najprikladniji. Rezultat Wooldridgeovog testa ($p > 0,05$) upućuje da se ne može odbaciti nulta hipoteza o nepostojanju autokorelacije pogrešaka relacije.

Varijabla *dani vezivanja zaliha* se pokazala statistički značajnom ($p < 0,05$) i ima negativan utjecaj na zavisnu varijablu *ROA* što znači da duže vrijeme zadržavanja zaliha na skladištu utječe na smanjenje profitabilnosti poduzeća. Ostale varijable nisu se pokazale statistički značajnima.

Tablica 41. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima

	Združeni	Fiksni	Slučajni
DNP	0,000078 (0,00017)	-0,00089 (0,00075)	-0,000055 (0,00017)
DVZ	-0,00045* (0,00023)	-0,00094* (0,00050)	-0,00054** (0,00025)
DPOD	-0,000071 (0,00023)	0,00035 (0,00048)	0,00000022 (0,00023)
VEL	-0,02967 (0,04694)	0,04669 (0,16561)	-0,02504 (0,04724)
RPR	0,03078 (0,04820)	-0,04681 (0,06250)	0,01167 (0,04100)
INF	-0,00094 (0,00589)	0,00293 (0,00925)	-0,00065 (0,00623)
BDP	0,00512 (0,00776)	0,00557 (0,00769)	0,00523 (0,00771)
KONSTANTA	0,37329 (0,37280)	-0,14960 (1,28128)	0,34922 (0,37464)
R^2	0,0182	0,0268	0,0115
$\rho(\text{rho})$		0,4028	0,2333
Ftest		0,0000	
LM test			0,0000
Hausman test		0,2147	
Wald test		0,0000	
Wooldridge test		0,2278	
corr (u_i , X_b)		-0,4837	
Broj opažanja	395	395	395
Broj jedinica	79	79	79

* $p < 0,1$, ** $p < 0,05$, *** $p < 0,01$, vrijednosti u zagradama su korigirane (clusterirane robustne) standardne pogreške

Izvor: Izrada autorice prema izračunima STATE

6.4.5.4. Regresijska dijagnostika sektora trgovina na veliko

Ispitana je korelacija između varijabli u modelu, a rezultati su prikazani u tablici 42. Na temelju prikazanih vrijednosti koeficijenta korelacije među parovima varijabli možemo odbaciti pretpostavku o postojanju problema multikolinearnosti.

Tablica 42. Korelacijska matrica parova nezavisnih varijabli

	DNP	DVZ	DPOD	VEL	RPR	INF	BDP
DNP	1,0000						
DVZ	0,0203 (0,6880)	1,0000					
DPOD	0,3069* (0,0000)	0,3024* (0,0000)	1,0000				
VEL	- 0,2024* (0,0001)	- 0,1519* (0,0025)	- 0,1012* (0,0443)	1,0000			
RPR	- 0,1213* (0,0159)	-0,0580 (0,2502)	-0,0591 (0,2414)	0,1366* (0,0065)	1,0000		
INF	0,1198* (0,0172)	0,0548 (0,2775)	0,1295* (0,0100)	-0,0889 (0,0777)	-0,1233* (0,0142)	1,0000	
BDP	-0,0670 (0,1840)	-0,0307 (0,5425)	-0,0686 (0,1735)	0,0541 (0,2831)	0,0931 (0,0647)	-0,5851* (0,0000)	1,0000

* $p < 0,5$

Izvor: Izrada autorice prema izračunima STATE

6.4.6. Kruskal-Wallis analiza

Testirane su hipoteze o postojanju razlike u danima naplate potraživanja, u danima vezivanja zaliha i danima plaćanja dobavljača između 4 sektora.

Za testiranje hipoteze korišten je Kruskal-Wallis test. Njime se testira postojanje razlika između tri ili više skupina. Kruskal-Wallis je neparametrijski test, koji se provodi kada ANOVA nije prikladna, posebno u prilikama kada varijable ne slijede normalnu distribuciju. Za Kruskal-Wallis test ta pretpostavka ne mora biti zadovoljena, jer se bazira na rangui i rangiranju podataka. Pretpostavke za Kruskal-Wallis test su: (1) izabrani su slučajni i nezavisni uzorci iz nekoliko osnovnih skupova, (2) osnovni skupovi jednako su raspoređeni, (3) vrijednosti su mjerenja na redosljednoj, intervalnoj ili numeričkoj skali, (4) testira se hipoteza da su uzorci izabrani iz jednako raspoređenih osnovnih skupova (Šošić, 2006). Podaci se poredaju po redu od najmanjeg do najvećeg i svima im se dodijeli rang (ignorirajući kojoj grupi pripadaju). Kada je rangiranje gotovo, podaci se ponovo razdijele u grupe kojima su originalno pripadali te se analiziraju (Field, 2009).

Posthoc analiza se sastoji od usporedbe parova, tj. uspoređuju se sve moguće kombinacije grupa (u ovom slučaju sektora) unutar varijable. Kada se obavlja više analiza na jednoj varijabli, povećava se mogućnost da će se pojaviti pogreška tipa I (povećava se vjerojatnost odbacivanja nulte hipoteze), a time i vjerojatnost da su značajni rezultati nastali slučajno. Kao dodatna zaštita od ove vrste pogreške provodi se Bonferroni korekcija. Bonferroni korekcija se radi tako da se α podijeli s brojem parova za usporedbe, npr. ako se radi 6 testova onda će umjesto α vrijednost $\alpha/6$ biti korištena kao novi kriterij značajnosti. Korigirajući razinu značajnosti (p) tako, osigurava se da sveukupna pogreška tipa I (α) ostane ispod razine od 0,05 (Field, 2009).

U tablici 43 je prikazana deskriptivna statistika varijable *dani naplate potraživanja* za sva četiri sektora.

Tablica 43. Dani naplate potraživanja – deskriptivna statistika

	N	Prosjek	Standardna devijacija	Min	Max	Prosječni rang
GRAD	330	74,87955	38,44861	0,45808	222,4876	844,33
PRER	335	66,90332	41,93054	0,32519	211,9695	755,02
TRGM	320	26,7508	22,91603	0,27475	110,7046	335,63
TRGV	395	79,66993	61,78887	2,78343	342,0538	794,75
Svi zajedno	1380	63,15416	49,12015	0,27475	342,0538	

Izvor: Izrada autorice

Testirane su hipoteze o postojanju razlike u *danima naplate potraživanja* između sektora građevinarstvo, prerađivačkog sektora, trgovine na malo i trgovine na veliko.

Hipoteze su sljedeće:

H0: Nema razlike u danima naplate potraživanja između navedena 4 sektora.

H1: Postoji razlika između barem dva sektora u danima naplate potraživanja.

Tablica 44. Kruskal-Wallis test

	Dani naplate potraživanja
Chi-Square	338,727
Stupnjevi slobode	3
P	<0,001

Izvor: Izrada autorice

Budući da je $p < 0,001$ prihvaća se H1 hipoteza da postoji razlika između barem dva sektora u danima naplate potraživanja.

Kako bi se odredilo koji se sektori međusobno razlikuju s obzirom na varijablu *dani naplate potraživanja*, provedena je posthoc analiza. S obzirom na postojanje 4 sektora (4 grupe), postoji 6 načina kombiniranja tih grupa koji su prikazani u tablici 45.

Tablica 45. Sve moguće kombinacije sektora

1. par	građevina i prerađivački sektor
2. par	građevina i trgovina na malo
3. par	građevina i trgovina na veliko
4. par	prerađivački sektor i trgovina na malo
5. par	prerađivački sektor i trgovina na veliko
6. par	trgovina na malo i trgovina na veliko

Izvor: Izrada autorice

Za svaki prikazani par proveden je dodatni Kruskal-Wallis test.

Tablica 46. Kruskal-Wallis test za sve moguće parove, pripadajuće p vrijednosti i korigirane p vrijednosti (dani naplate potraživanja)

	p vrijednost	p vrijednost (nakon Bonferroni korekcije)
TRGM – PRER	<0,001*	<0,001*
TRGM – TRGV	<0,001*	<0,001*
TRGM – GRAD	<0,001*	<0,001*
PRER – TRGV	0,180	1,000
PRER – GRAD	0,004*	0,023*
TRGV – GRAD	0,095	0,571

Izvor: Izrada autorice

Iz tablice 46 uočava se da se sektor trgovina na malo značajno razlikuje od prerađivačkog sektora, građevinarstva i trgovine na veliko i u usporedbi s rezultatima iz tablice 43 prihvaća se hipoteza da u sva tri slučaja sektor trgovina na malo ima manju razinu *dana naplate potraživanja*. Nadalje, značajno se razlikuju prerađivački sektor i građevinarstvo gdje prerađivački sektor ima manji broj *dana naplate potraživanja*.

U tablici 47 je prikazana deskriptivna statistika varijable *dani vezivanja zaliha* za sva četiri sektora.

Tablica 47. Dani vezivanja zaliha – deskriptivna statistika

	N	Prosjek	Standardna devijacija	Min	Max	Prosječni rang
GRAD	330	60,50283	110,7495	0,64135	840,5597	471,67
PRER	335	97,8164	146,3625	2,30316	930,9683	717,01
TRGM	320	98,96703	90,07674	0,91079	486,5826	847,68
TRGV	395	64,76402	44,84801	0,65189	238,5898	723,50
Svi zajedno	1380	79,69976	104,3281	0,64135	930,9683	

Izvor: Izrada autorice

Testirane su hipoteze o postojanju razlike u *danima vezivanja zaliha* između sektora građevinarstvo, prerađivačkog sektora, trgovine na malo i trgovine na veliko.

Hipoteze su sljedeće:

H0: Nema razlike u danima vezivanja zaliha između navedena četiri sektora.

H1: Postoji razlika između barem dva sektora u danima vezivanja zaliha.

Nakon provedene analize (Kruskal-Wallis testa) dobivena je empirijska razina signifikantnosti $p < 0,001$ te se može odbaciti H0 hipoteza o nepostojanju razlika između barem dva sektora u *danima vezivanja zaliha*.

Tablica 48. Kruskal-Wallis test

	Dani vezivanja zaliha
Chi-Square	153,478
Stupnjevi slobode	3
P	<0,001

Izvor: Izrada autorice

Kako bi se odredilo između kojih točno sektora postoji značajna razlika potrebno je napraviti posthoc analizu i posebno provesti Kruskal-Wallis test za sve moguće parove sektora.

Posthoc analiza je pokazala da sektor građevinarstvo ima u prosjeku manji broj *dana vezivanja zaliha* od prerađivačkog sektora, trgovine na malo i trgovine na veliko. Također, trgovina na malo ima veće dane vezivanja zaliha od prerađivačkog sektora i trgovine na veliko.

Tablica 49. Kruskal-Wallis test za sve moguće parove, pripadajuće p vrijednosti i korigirane p vrijednosti (dani vezivanja zaliha)

	p vrijednost	p vrijednost (nakon Bonferroni korekcije)
GRAD – PRER	<0,001*	<0,001*
GRAD – TRGV	<0,001*	<0,001*
GRAD – TRGM	<0,001*	<0,001*
PRER – TRGV	0,827	1,000
PRER – TRGM	<0,001*	<0,001*
TRGV – TRGM	<0,001*	<0,001*

Izvor: Izrada autorice

U tablici 50 je prikazana deskriptivna statistika varijable *dani plaćanja dobavljača* za sva četiri sektora.

Tablica 50. Dani plaćanja dobavljača – deskriptivna statistika

	N	Prosjek	Standardna devijacija	Min	Max	Prosječni rang
GRAD	330	87,73183	48,72323	6,91451	283,9302	855,77
PRER	335	68,99944	51,97049	4,19969	305,7783	668,90
TRGM	320	63,22284	47,41148	1,02801	270,1999	622,45
TRGV	395	64,72017	53,71929	1,52585	380,814	625,87
Sve zajedno	1380	70,91456	51,55904	1,02801	380,814	

Izvor: Izrada autorice

Testirane su hipoteze o postojanju razlike u *danima plaćanja dobavljača* između sektora građevinarstvo, prerađivačkog sektora, trgovine na malo i trgovine na veliko.

Hipoteze su sljedeće:

H0: Nema razlike u danima plaćanja dobavljača između navedena četiri sektora.

H1: Postoji razlika između barem dva sektora u danima plaćanja dobavljača.

Tablica 51. Kruskal-Wallis test

	Dani plaćanja dobavljača
Chi-Square	77,462
Stupnjevi slobode	3
P	<0,001

Izvor: Izrada autorice

Proveden je Kruskal-Wallis test i budući da je $p < 0,05$ prihvaća se H1 hipoteza da postoji značajna razlika između barem dva sektora u *danima plaćanja dobavljača*. Kako bi se odredilo koji točno sektori se značajno razlikuju prema *danima plaćanja dobavljača* radi se posthoc analiza podataka.

Tablica 52. Kruskal-Wallis test za sve moguće parove, pripadajuće p vrijednosti i korigirane p vrijednosti (dani plaćanja dobavljača)

	p vrijednost	p vrijednost (nakon Bonferroni korekcije)
TRGM – TRGV	0,909	1,000
TRGM – PRER	0,136	0,815
TRGM – GRAD	<0,001*	<0,001*
TRGV – PRER	0,146	0,876
TRGV – GRAD	<0,001*	<0,001*
PRER – GRAD	<0,001*	<0,001*

Izvor: Izrada autorice

Posthoc analiza je pokazala da sektor građevinarstvo ima u prosjeku veći broj dana plaćanja dobavljača od prerađivačkog sektora, trgovine na malo i trgovine na veliko.

6.5. Rezultati empirijskog istraživanja po hipotezama

U nastavku je dan prikaz rezultata istraživanja za sve sektore zajedno i za svaki sektor pojedinačno.

Tablica 53. Usporedni prikaz rezultata za sve sektore zajedno i za svaki sektor pojedinačno

	DNP	DVZ	DPOD	VEL	PPR	INF	BDP	SEKT
Svi sektori	Nema	Neg.	Neg.	Nema	Pozit.	Nema	Nema	Značajna
Građevinarstvo	Nema	Nema	Neg.	Pozit.	Nema	Nema	Neg.	
Prerađivački sektor	Nema	Neg.	Neg.	Nema	Pozit.	Nema	Nema	
Trgovina na malo	Nema	Neg.	Neg.	Nema	Nema	Nema	Nema	
Trgovina na veliko	Nema	Neg.	Nema	Nema	Nema	Nema	Nema	

Izvor: Izrada autorice

6.5.1. Prva temeljna radna hipoteza

Rezultati istraživanja djelomično potvrđuju prvu temeljnu radnu hipotezu koja glasi:

H1: Potraživanja od kupaca, zalihe, obveze prema dobavljačima, veličina poduzeća i rast prodaje na razini poduzeća utječu na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj.

Model je potvrdio utjecaj zaliha, obveza prema dobavljačima i rasta prodaje na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj dok se utjecaj potraživanja od kupaca i veličine poduzeća na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj nije potvrdio.

Statistički značajan nije se pokazao utjecaj varijable ***dani naplate potraživanja*** pa se prva pomoćna hipoteza odbacuje, a ona glasi:

H1.1. Postoji značajan i negativan utjecaj potraživanja od kupaca na visinu profitabilnosti poduzeća.

Rezultati pokazuju da smanjenje potraživanja nije utjecalo na povećanje profitabilnosti malih i srednjih poduzeća čime se nije potvrdila prva pomoćna hipoteza prve temeljne radne hipoteze kao niti prva temeljna radna hipoteza. Većina istraživača u svojim studijama pronalaze negativan odnos između potraživanja od kupaca i profitabilnosti poduzeća. No, kao i u ovom radu dosta istraživača očekuje negativan odnos između potraživanja od kupaca i profitabilnosti poduzeća, ali ne uspijeva pronaći značajnost u navedenom odnosu (Sen i Oruc, 2009; Raheman et al., 2010; Makori i Jagongo, 2013; Enqvist et al., 2014; Seyoum et al., 2016 i drugi).

Model je potvrdio negativan utjecaj varijable ***dani vezivanja zaliha*** na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj pri čemu se je potvrdila druga pomoćna hipoteza koja glasi:

H1.2. Postoji značajan i negativan utjecaj zaliha na visinu profitabilnosti poduzeća.

Rezultati pokazuju da smanjenje zaliha utječe na povećanje profitabilnosti malih i srednjih poduzeća, i obrnuto, čime se je potvrdila druga pomoćna hipoteza prve temeljne radne hipoteze i prva temeljna radna hipoteza. Rezultati su u skladu s rezultatima većine istraživača (Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Sen i Oruc, 2009; Raheman et al., 2010; Sharma i Kumar, 2011; Gul et al., 2013; Almazari, 2014; Enqvist et al., 2014; Nigatu, 2015; Seyoum et al., 2016 i drugi). Može se zaključiti da dugo zadržavanja zaliha na skladištu je ili rezultat manje prodaje ili lošeg upravljanja zalihama na skladištu, što će za posljedicu imati smanjenje profitabilnosti.

Model je potvrdio utjecaj varijable **dani plaćanja dobavljača**, ali negativan pri čemu se potvrđuje prva temeljna radna hipoteza, jer postoji značajnost utjecaja obveza prema dobavljačima na visinu profitabilnosti malih i srednjih poduzeća. No, treća pomoćna hipoteza prve temeljne radne hipoteze odbacuje se, jer postoji značajnost, ali suprotnog smjera. Treća pomoćna hipoteza glasi:

H1.3. Postoji značajan i pozitivan utjecaj obveza prema dobavljačima na visinu profitabilnosti poduzeća.

Rezultati pokazuju negativan smjer, odnosno, smanjenje obveza prema dobavljačima utječe na povećanje profitabilnosti malih i srednjih poduzeća. Isto kao i u ovom radu, većina istraživača u svojim studijama je očekivala pozitivan odnos između obveza prema dobavljačima i profitabilnosti poduzeća, odnosno, da će duže odgađanje plaćanja obveza prema dobavljačima rezultirati većom profitabilnosti. No, kao i u ovom radu većina autora dobiva negativan odnos između profitabilnosti i obveza prema dobavljačima (Deelof, 2003; Raheman i Nasr, 2007; Sen i Oruc, 2009; Sharma i Kumar, 2011; Tauringana i Afrifa, 2013; Almazari, 2014; Enqvist et al., 2014; Seyoum et al., 2016 i drugi). Negativan odnos može proizaći iz upotrebe viška novac, od rastezanja plaćanja dobavljačima, za podmirivanje vlastitih dugovanja i očuvanje postojećih radnih mjesta, a ne za povećanje prodaje. Isto tako, dolazi do nastajanja dodatnih troškova u vidu neiskorištenja popusta za rane uplate te visokih penala, odnosno zateznih kamata za neplaćanje u roku.

Statistički značajan se nije pokazao utjecaj varijable **veličina poduzeća** pa se četvrta pomoćna hipoteza odbacuje, a ona glasi:

H1.4. Postoji značajan i pozitivan utjecaj veličine poduzeća na visinu profitabilnosti poduzeća.

Rezultati pokazuju da rast veličine poduzeća nije utjecao na povećanje profitabilnosti malih i srednjih poduzeća čime se nije potvrdila četvrta pomoćna hipoteza prve temeljne radne hipoteze kao ni prva temeljna radna hipoteza. Dobiveni rezultati nisu u skladu s rezultatima većine istraživača koji pronalaze pozitivan odnos između profitabilnosti i veličine poduzeća. No, rezultati su u skladu s Gill et al. (2010) i Wesley et al. (2013) koji također ne dobivaju značajan odnos između veličine poduzeća i profitabilnosti poduzeća.

Rast prodaje ima pozitivan utjecaj na zavisnu varijablu ROA pri čemu je potvrđena peta pomoćna hipoteza koja glasi:

H1.5. Postoji značajan i pozitivan utjecaj rasta prodaje poduzeća na visinu profitabilnosti poduzeća.

Rezultati pokazuju da povećanje rasta prodaje poduzeća utječe na povećanje profitabilnosti malih i srednjih poduzeća čime se je potvrdila peta pomoćna hipoteza prve temeljne radne hipoteze i prva temeljna radna hipoteza. Rezultati su u skladu s rezultatima većine istraživača koji su pronašli pozitivan odnos između profitabilnosti poduzeća i rasta prodaje poduzeća (Garcia-Teruel i Martinez-Solano, 2007; Raheman et al., 2010; Gul et al., 2013; Makori i Jagongo, 2013 i drugi).

Varijabla **sektor** također se pokazala statistički značajnom: sektor trgovina na veliko, sektor trgovina na malo i prerađivački sektor imaju veću profitabilnost u odnosu na referentni sektor građevinarstvo čime se potvrdila i šesta pomoćna hipoteza koja glasi:

H1.6. Postoji značajan utjecaj sektora na visinu profitabilnosti poduzeća.

Statistički značajan nije se pokazao utjecaj **inflacije** pa se sedma pomoćna hipoteza odbacuje, a ona glasi:

H1.7. Postoji značajan utjecaj inflacije na visinu profitabilnosti poduzeća.

Rezultati pokazuju da inflacija nije utjecala na visinu profitabilnosti malih i srednjih poduzeća čime se nije potvrdila sedma pomoćna hipoteza prve temeljne radne hipoteze.

Također, statistički značajnim nije se pokazao niti utjecaj **BDP** pa se osma pomoćna hipoteza odbacuje, a ona glasi:

H1.8. Postoji značajan utjecaj BDP-a na visinu profitabilnosti poduzeća.

Rezultati pokazuju da BDP nije utjecao na visinu profitabilnosti malih i srednjih poduzeća čime se nije potvrdila osma pomoćna hipoteza prve temeljne radne hipoteze.

6.5.2. Druga temeljna radna hipoteza

Rezultati istraživanja djelomično potvrđuju drugu temeljnu radnu hipotezu koja glasi:

H2: Utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća i rasta prodaje poduzeća na visinu profitabilnosti malih i srednjih poduzeća je različit u različitim sektorima.

Potvrđene su druga, treća, četvrta, peta i sedma pomoćna hipoteza druge temeljne radne hipoteze jer se utjecaj zaliha, obveza prema dobavljačima, veličine poduzeća, rasta prodaje i BDP-a na visinu profitabilnosti poduzeća pokazao značajnim u pojedinim sektorima i različit u različitim sektorima, i to u građevinarstvu, prerađivačkom sektoru, trgovini na malo i trgovini na veliko. Prva i šesta pomoćna hipoteza druge temeljne radne hipoteze odbacuju se jer se u svim sektorima pokazalo da nema značajnog utjecaja potraživanja od kupaca i inflacije na visinu profitabilnosti malih i srednjih poduzeća.

6.5.2.1. Dani naplate potraživanja i profitabilnost po sektorima

Prva pomoćna hipoteza druge temeljne radne hipoteze glasi:

H2.1. Utjecaj potraživanja od kupaca na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

Prva pomoćna hipoteza druge temeljne radne hipoteze odbacuje se. Rezultati nisu pokazali značajan utjecaj potraživanja od kupaca na visinu profitabilnosti malih i srednjih poduzeća niti u jednom sektoru, čime se nije potvrdila prva pomoćna hipoteza druge temeljne radne hipoteze. Nigdje se nije dobila signifikantnost. Dobiveni rezultati nisu u skladu s rezultatima većine istraživača. U skladu s gore navedenim rezultatima odbacuje se druga temeljna radna hipoteza.

Očekivalo se da će dulji dani naplate potraživanja utjecati na smanjenje visine profitabilnosti poduzeća. No, rezultati su pokazali da niti u jednom sektoru nije došlo do značajnog utjecaja potraživanja od kupaca na visinu profitabilnosti poduzeća. S jedne strane, može se pretpostaviti negativan utjecaj kasnih uplata na visinu profitabilnosti poduzeća jer je novac dulje vezan za potraživanja i nije korišten za stvaranje novih prilika i profita, a tu su i visoki troškovi održavanja potraživanja. S druge strane može se pretpostaviti anuliranje tog negativnog utjecaja povećanom prodajom zbog boljih kreditnih uvjeta, podizanjem cijena (posebno izraženo kod post-tranzicijskih zemalja), neiskorištavanjem gotovinskog popusta od strane kupaca, naplaćivanjem redovnih i zateznih kamata zbog kašnjenja. Može se pretpostaviti da će

poduzeća zbog kašnjenja naplate potraživanja od kupaca odgoditi plaćanja svojih obveza.

Istraživanja koja je proveo *European Payment Practices* pokazuju da što kupac ima duže razdoblje na raspolaganju za plaćanje, vjerojatnije će doći do kašnjenja plaćanja. Pa tako najkraće uvjete plaćanja imaju najrazvijenije zemlje poput Njemačke, ali i najlikvidnija plaćanja dok post-tranzicijske zemlje imaju postavljene najduže uvjete plaćanja, ali i najmanji udio pravovremenih plaćanja. Stoga ne začuđuje činjenica da u post-tranzicijskim zemljama ne dolazi do smanjivanja kreditnih standarda zbog poticanja potražnje od strane poduzeća, nego zbog nametanja uvjeta plaćanja od strane kupaca što za posljedicu neće imati povećanje profitabilnosti. Naprotiv, očekuje se smanjenje profitabilnosti zbog visokih troškova održavanja potraživanja, a djelomično i nepovratnih gubitaka, odnosno trajno nenaplaćenih potraživanja.

Može se zaključiti da poduzeća u post-tranzicijskim zemljama ne diktiraju politiku naplate potraživanja od kupaca, nego je nameću kupci, a ona su primorana prihvatiti je kako bi zadržala konkurentsku poziciju na tržištu i kao posljedicu izbjegla gubitak kupaca, prodaje i prihoda. No, poduzeća trebaju biti oprezna pri utvrđivanju granice plaćanja i ne zadržavati kupca pod svaku cijenu da troškovi dodatnih potraživanja ne bi premašili profitabilnost dodatne prodaje.

Rezultati istraživanja koje je proveo EOS Survey ¹⁸ ukazuju da hrvatska poduzeća koriste nadoknađeni novac od zakašnjele naplate potraživanja za:

- podmirivanja vlastitih dugovanja – 52 %;
- očuvanje postojećih i kreiranje novih radnih mjesta – 35 %;
- širenje poslovanja – 33 %;
- ulaganje u istraživanje i razvoj – 28 % i
- ulaganje na financijska tržišta – 16 %.

Zabrinjavajući je podatak da 52 % naplaćenih istraživanja ide u podmirivanje vlastitih dugovanja, a ne u povećanje prodaje. Može se zaključiti da ako jedno poduzeće ne plaća svoja dugovanja u redovitom roku da će i ono biti u ciklusu neredovitih naplata potraživanja.

¹⁸ EOS Survey 'European Payment Practices' EOS / Kantar TNS 2017 – rezultati za Hrvatsku

6.5.2.2. Dani vezivanja zaliha i profitabilnost po sektorima

Druga pomoćna hipoteza druge temeljne radne hipoteze glasi:

H2.2. Utjecaj zaliha na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

Druga pomoćna hipoteza druge temeljne radne hipoteze prihvaća se. Rezultati su pokazali značajan utjecaj zaliha na visinu profitabilnosti malih i srednjih poduzeća u pojedinim sektorima i različit utjecaj zaliha na visinu profitabilnosti malih i srednjih poduzeća među sektorima čime se potvrdila druga pomoćna hipoteza druge temeljne radne hipoteze.

Dobiven je značajan i negativan odnos u prerađivačkom sektoru, sektoru trgovina na malo i sektoru trgovina na veliko što znači da smanjenje zaliha utječe na povećanje profitabilnosti poduzeća, odnosno duže vrijeme zadržavanja zaliha na skladištu rezultirat će manjom profitabilnosti poduzeća. To se može objasniti povećanjem ukupnih troškova zaliha (troškovi skladištenja, rukovanja, osiguranja i drugi) i opadanjem tržišne vrijednosti zaliha uslijed njihova zastarijevanja. Stvaranje viškova zaliha i preuzimanje većih ukupnih troškova zaliha posebno se može opravdati u prerađivačkom sektoru, jer se time umanjuju rizici od mogućih prekida u procesu proizvodnje, rizici od promjena cijena i oportunitetni troškovi. U suprotnome, pomanjkanje zaliha sirovina i materijala može dovesti do prekida u procesu proizvodnje što za posljedicu može izazvati visoke fiksne troškove po jedinici proizvoda. Prekid proizvodnje i nemogućnost isporuke gotovih proizvoda imat će za posljedicu gubitak posla te odlazak kupaca drugom proizvođaču pa samim time i gubitak buduće prodaje. Rezultati su u skladu s većinom istraživanja.

Rezultati nisu pokazali značajan utjecaj zaliha na visinu profitabilnosti malih i srednjih poduzeća u sektoru građevinarstvo. Kada govorimo o malim i srednjim građevinskim poduzećima radi se pretežno o poduzećima koja se bave uslužnom gradnjom. U uslužnom graditeljstvu materijal se nužno ne mora skladištiti te držati na stanju već se može odmah utrošiti, odnosno knjižiti na računu proizvodnje (Binefeld, 2004 u Ramljak, 2018). Ovakav računovodstveni tretman karakterističan je za manje projekte te projekte gdje se materijal nabavlja sukcesivno (češće u visokogradnji). Za velike projekte gdje se materijal nabavlja u velikim količinama i koji će se trošiti kroz više obračunskih razdoblja (češće u niskogradnji) evidentirat će se kao kratkotrajna imovina

do trenutka stvarne upotrebe (Ramljak, 2018). Mala i srednja poduzeća u sektoru građevinarstvo najvećim dijelom su podizvođači. Ako je poduzeće u statusu podizvođača ono je neminovno uslužni graditelj, a to znači da će u pravilu imati relativno manje zalihe od graditelja za tržište ili graditelja za vlastite potrebe, ali to nije imperativ. S obzirom na gore navedene specifičnosti zaliha malih i srednjih građevinskih poduzeća, nije se pokazao njihov utjecaj na visinu profitabilnosti poduzeća. Rezultati su u skladu s Gill et al. (2010), Tauringana i Afrifa (2013) i Wesley et al. (2013) koji također ne dobivaju značajan odnos između dana vezivanja zaliha i visine profitabilnosti poduzeća.

U skladu s gore navedenim rezultatima potvrđuje se druga temeljna radna hipoteza.

6.5.2.3. Dani plaćanja dobavljačima i profitabilnost po sektorima

Treća pomoćna hipoteza druge temeljne radne hipoteze glasi:

H2.3. Utjecaj obveza prema dobavljačima na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

Treća pomoćna hipoteza druge temeljne radne hipoteze prihvaća se. Rezultati su pokazali značajan utjecaj obveza prema dobavljačima na visinu profitabilnosti malih i srednjih poduzeća u pojedinim sektorima i različit utjecaj obveza prema dobavljačima na visinu profitabilnosti malih i srednjih poduzeća među sektorima, čime se potvrdila treća pomoćna hipoteza druge temeljne radne hipoteze.

Dobiven je značajan i negativan odnos u sektoru građevinarstvo, prerađivačkom sektoru i sektoru trgovina na malo što znači da smanjenje obveza prema dobavljačima utječe na povećanje profitabilnosti poduzeća, odnosno duže vrijeme odgode plaćanja obveza prema dobavljačima rezultirat će manjom profitabilnosti poduzeća. Negativan odnos između dana plaćanja obveza prema dobavljačima i visine profitabilnosti poduzeća ukazuje da poduzeća, pod prvo, nisu iskoristila popuste za rane uplate, a pod drugo, imala su velike troškove u obliku visokih penala za neplaćanje u roku odnosno zatezne kamate. Ovdje se radi o korištenju naplatnih kredita. Poduzeća su najvjerojatnije primorana odgoditi svoja plaćanja jer se nalaze u financijskim poteškoćama pa novac od odgode plaćanja ne ulažu u unaprjeđenje prodaje, nego za podmirenje svojih dugova, odnosno jedan dug zatvaraju otvaranjem drugog. S obzirom na to da se radi o malim i srednjim poduzećima, nije rijedak slučaj da vjerovnik ovisi o dužniku. Dobiveni rezultati su u skladu s istraživanjem *European Payment Practices*

čiji nalazi pokazuju da razvijene države čija poduzeća imaju najlikvidnija plaćanja i ostvaruju visoke zarade imaju i najkraće uvjete plaćanja. S druge strane, zemlje s poteškoćama u plaćanju i malim zaradama, imaju najduže uvjete plaćanja, odnosno duže razdoblje na raspolaganju za plaćanje koje rezultira manjim zaradama što je posebno izraženo kod post-tranzicijskih zemalja. Problem nastaje pri utvrđivanju granice uvjeta plaćanja, jer ako se prijeđe optimalna granica uvjeta plaćanja, dolazi do stvaranja loše prakse plaćanja koja se negativno reflektira na visinu profitabilnosti poduzeća.

Suprotno očekivanjima, rezultati nisu pokazali značajan utjecaj dana plaćanja obveza prema dobavljačima na visinu profitabilnosti malih i srednjih poduzeća u sektoru trgovina na veliko. Ovi rezultati mogu se objasniti različito dobivenim nalazima istraživača. Većina autora je dobila, suprotno svojim očekivanjima, negativan odnos između obveza prema dobavljačima i profitabilnosti poduzeća. No, ima i autora koji pronalaze pozitivan odnos između obveza prema dobavljačima i profitabilnosti poduzeća kao i onih koji nisu dobili značajnost između navedenog odnosa u svojim studijama što je u skladu s rezultatima ovoga istraživanja (Garcia-Teruel i Martinez-Solano, 2007; Gill et al., 2010; Raheman et al., 2010; Akoto et al., 2013; Wesley et al., 2013; Nigatu, 2015 i drugi). Pozitivan značajan odnos između dana plaćanja obveza prema dobavljačima i profitabilnosti poduzeća može se objasniti većom količinom sredstava na raspolaganju zbog kašnjenja u plaćanju. No, uvjet je da ta sredstva budu iskorištena u svrhu povećanja prodaje što će rezultirati povećanjem profitabilnosti. S druge strane, negativan odnos može se objasniti neiskorištavanjem popusta za rane uplate, plaćanjem visokih penala i zateznih kamata zbog kašnjenja u plaćanju te neiskorištavanjem viška sredstava za unaprijeđenje prodaje. U ovom sektoru je najvjerojatnije došlo do anuliranja ovih odnosa uzrokovanih navedenim prednostima i nedostacima odgode plaćanja. Cilj poduzeća ne bi trebao biti samo odgoda plaćanja, nego učinkovito i efikasno korištenje novca koje će poduzeću donijeti dodatne zarade. Ako do toga ne dođe, poduzeće će imati samo velike troškove zbog odgode plaćanja. U skladu s gore navedenim rezultatima potvrđuje se druga temeljna radna hipoteza.

6.5.2.4. Veličina poduzeća i profitabilnost po sektorima

Četvrta pomoćna hipoteza druge temeljne radne hipoteze glasi:

H2.4. Utjecaj veličine poduzeća na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

Četvrta pomoćna hipoteza druge temeljne radne hipoteze prihvaća se. Rezultati su pokazali značajan utjecaj veličine poduzeća na visinu profitabilnosti malih i srednjih poduzeća u samo jednom sektoru i različit utjecaj veličine poduzeća na visinu profitabilnosti malih i srednjih poduzeća među sektorima čime se potvrdila četvrta pomoćna hipoteza druge temeljne radne hipoteze.

Dobiven je značajan i pozitivan odnos u sektoru građevinarstvo što znači da rast veličine poduzeća utječe na povećanje profitabilnosti poduzeća. Dobiveni rezultati su u skladu s rezultatima većine istraživača koji pronalaze pozitivan odnos između profitabilnosti i veličine poduzeća (Deelof, 2003; Garcia-Teruel i Martinez-Solano, 2007; Raheman i Nasr, 2007; Raheman et al., 2010; Akoto et al., 2013; Gul et al., 2013; Makori i Jagongo, 2013; Almazari, 2014 i drugi). Rezultati nisu pokazali značajan utjecaj veličine poduzeća na visinu profitabilnosti malih i srednjih poduzeća u prerađivačkom sektoru, sektoru trgovina na malo i sektoru trgovina na veliko. Rezultati su u skladu s Gill et al. (2010) i Wesley et al. (2013) koji također ne dobivaju značajan odnos između veličine poduzeća i profitabilnosti poduzeća.

U skladu s gore navedenim rezultatima potvrđuje se druga temeljna radna hipoteza.

6.5.2.5. Rast prodaje i profitabilnost po sektorima

Peta pomoćna hipoteza druge temeljne radne hipoteze glasi:

H2.2. Utjecaj rasta prodaje na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

Peta pomoćna hipoteza druge temeljne radne hipoteze prihvaća se. Rezultati su pokazali značajan utjecaj rasta prodaje poduzeća na visinu profitabilnosti malih i srednjih poduzeća u samo jednom sektoru i različit utjecaj rasta prodaje na visinu profitabilnosti malih i srednjih poduzeća među sektorima čime se potvrdila peta pomoćna hipoteza druge temeljne radne hipoteze.

Dobiven je značajan i pozitivan odnos u prerađivačkom sektoru što znači da rast prodaje utječe na povećanje profitabilnosti poduzeća. Rezultati su u skladu s rezultatima većine istraživača. Rezultati nisu pokazali značajan utjecaj rasta prodaje na visinu profitabilnosti malih i srednjih poduzeća u sektoru građevinarstvo, sektoru

trgovina na malo i sektoru trgovina na veliko. Rezultati su u skladu s Wesley et al. (2013) koji također ne dobivaju značajan odnos između rasta prodaje poduzeća i visine profitabilnosti poduzeća.

U skladu s gore navedenim rezultatima potvrđuje se druga temeljna radna hipoteza

6.5.2.6. Inflacija

Šesta pomoćna hipoteza druge temeljne radne hipoteze glasi:

H2.6. Utjecaj inflacije na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

Šesta pomoćna hipoteza druge temeljne radne hipoteze odbacuje se. Rezultati nisu pokazali značajan utjecaj inflacije na visinu profitabilnosti malih i srednjih poduzeća niti u jednom sektoru, čime se nije potvrdila šesta pomoćna hipoteza druge temeljne radne hipoteze. Naime nigdje se nije dobila signifikantnost. Stopa inflacije u promatranom razdoblju kretala se u rasponu od -0,50 do 3,40 % što nije bio dovoljno veliki raspon koji bi utjecao na visinu profitabilnosti poduzeća. U skladu s gore navedenim rezultatima odbacuje se druga temeljna radna hipoteza.

6.5.2.7. BDP

Sedma pomoćna hipoteza druge temeljne radne hipoteze glasi:

H2.7. Utjecaj BDP-a na visinu profitabilnosti poduzeća bit će različit u različitim sektorima.

Sedma pomoćna hipoteza druge temeljne radne hipoteze prihvaća se. Rezultati su pokazali značajan utjecaj BDP-a na visinu profitabilnosti malih i srednjih poduzeća u samo jednom sektoru i različit utjecaj BDP-a na visinu profitabilnosti malih i srednjih poduzeća među sektorima čime se potvrdila sedma pomoćna hipoteza druge temeljne radne hipoteze.

Dobiven je značajan i negativan odnos u sektoru građevinarstvo, odnosno povećanje BDP-a utjecalo je na smanjenje visine profitabilnosti poduzeća. BDP je od 2010. do 2015. godine prosječno rastao 0,61 % što je značajno utjecalo na smanjenje visine profitabilnosti poduzeća promatranog sektora. Rezultati nisu pokazali značajan utjecaj BDP-a na visinu profitabilnosti malih i srednjih poduzeća u prerađivačkom sektoru, sektoru trgovina na malo i sektoru trgovina na veliko.

U skladu s gore navedenim rezultatima potvrđuje se druga temeljna radna hipoteza.

6.5.3. Politike upravljanja obrtnim kapitalom po sektorima

Poduzeće može provoditi konzervativnu ili agresivnu strategiju upravljanja obrtnim kapitalom. Konzervativnost ili agresivnost je prisutna, s jedne strane, u investicijskoj strategiji, a s druge strane, u financijskoj strategiji. Odnosom tekuće imovine i ukupne imovine donosi se zaključak kakvu strategiju investiranja poduzeće provodi, a odnosom tekućih obveza i ukupne imovine kakvu strategiju financiranja poduzeće provodi.

Konzervativna strategija investiranja podrazumijeva višu razinu ulaganja u tekuću imovinu dok agresivna strategija podrazumijeva minimalnu razinu ulaganja u tekuću imovinu. U nastavku je opisana politika investiranja obrtnog kapitala po sektorima. Pri mjerenju politike investiranja obrtnog kapitala koristi se omjer tekuće imovine i ukupne imovine.

Tablica 54. Udio tekuće imovine u ukupnoj imovini

	Udio tekuće u ukupnoj imovini	Pojedinačni udio tekuće u ukupnoj imovini – Prosjek (%)	Pojedinačni udio tekuće u ukupnoj imovini - Standardna devijacija (%)	Pojedinačni udio tekuće u ukupnoj imovini - Minimalna vrijednost (%)	Pojedinačni udio tekuće u ukupnoj imovini - Maksimalna vrijednost (%)
Građevinarstvo	60,20%	56,79%	20,39%	6,42%	100,00%
Prerađivački sektor	47,87%	52,89%	20,70%	10,87%	100,00%
Trgovina na malo	54,77%	61,01%	23,39%	8,12%	100,00%
Trgovina na veliko	68,55%	74,86%	20,15%	7,20%	100,00%
Svi sektori zajedno	58,44%	62,02%	22,82%	6,42%	100,00%

Izvor: Izrada autorice

Poduzeća u sektoru građevinarstvo imaju u prosjeku 56,79 % tekuće imovine u ukupnoj imovini. Taj iznos u prosjeku odstupa od prosjeka za 20,39 %. Najmanja vrijednost iznosi 6,42 %, a najveća 100,00 %. Udio ukupne tekuće imovine u sveukupnoj imovini iznosi 60,20 %.

Poduzeća u prerađivačkom sektoru imaju u prosjeku 52,89 % tekuće imovine u ukupnoj imovini. Taj iznos prosječno odstupa od prosjeka za 20,70 %. Najmanji udio tekuće imovine u ukupnoj imovini iznosi 10,87 %, a najveći 100,00 %. Udio cjelokupne

tekuće imovine ispitanih poduzeća iz prerađivačkog sektora u njihovoj ukupnoj imovini iznosi 47,87 %.

Poduzeća u sektoru trgovine na malo imaju u prosjeku 61,01 % tekuće imovine u ukupnoj imovini. Prosječno odstupanje od prosjeka iznosi 23,39 %. Najmanji udio tekuće imovine u ukupnoj imovini iznosi 8,12 %, a najveći 100,00 %. Udio ukupne tekuće imovine ispitanih poduzeća iz sektora trgovine na malo u njihovoj ukupnoj imovini iznosi 54,77 %.

Poduzeća u sektoru trgovine na veliko imaju u prosjeku 74,86 % tekuće imovine u ukupnoj imovini. Prosječno odstupanje od prosjeka iznosi 20,15 %. Najmanji udio tekuće imovine u ukupnoj imovini iznosi 7,20 %, a najveći 100,00 %. Udio ukupne tekuće imovine ispitanih poduzeća iz sektora trgovine na veliko u njihovoj ukupnoj imovini iznosi 68,55 %.

Svi sektori zajedno imaju prosječno odstupanje 62,02 % tekuće imovine u ukupnoj imovini. Taj iznos u prosjeku odstupa od prosjeka za 22,82 %. Najmanja vrijednost iznosi 6,42 %, a najveća 100,00 %. Udio ukupne tekuće imovine u sveukupnoj imovini iznosi 58,44 %.

Udjeli tekuće imovine u ukupnoj imovini pokazuju da hrvatska mala i srednja poduzeća iz sektora građevinarstva, trgovine na veliko, trgovine na malo i prerađivačkog sektora koriste konzervativniju strategiju investiranja što je karakteristično za poduzeća koja posluju u nesigurnom poslovnom okruženju, odnosno kada uvjeti poslovanja nisu lako procjenjivi i predvidivi pa samim time je i budući novčani tijek vrlo nesiguran. U takvim uvjetima poduzećima je prioritet što veća likvidnost kako bi uvijek bila spremna odgovoriti na različite zahtjeve tržišta.

U nastavku je opisana strategija financiranja obrtnog kapitala po sektorima. Pri mjerenju strategije financiranja obrtnog kapitala koristi se omjer tekućih obveza i ukupne imovine.

Tablica 55. Udio tekućih obveza u ukupnoj imovini

	Udio tekućih obveza u ukupnoj imovini (KO/UI)	Pojedinačni udio tekućih obveza u ukupnoj imovini – Prosjek (%)	Pojedinačni udio tekućih obveza u ukupnoj imovini - Standardna devijacija (%)	Pojedinačni udio tekućih obveza u ukupnoj imovini - Minimalna vrijednost (%)	Pojedinačni udio tekućih obveza u ukupnoj imovini - Maksimalna vrijednost (%)
Građevinarstvo	41,86%	36,19%	19,04%	5,88%	96,08%
Prerađivački sektor	31,22%	38,35%	21,62%	1,85%	100,00%
Trgovina na malo	41,80%	46,32%	22,97%	4,25%	99,16%
Trgovina na veliko	42,53%	47,51%	23,15%	0,35%	99,38%
Svi zajedno	39,38%	42,28%	22,35%	0,35%	100,00%

Izvor: Izrada autorice

Prosječni udio tekućih obveza u ukupnoj imovini u sektoru građevinarstvo iznosi 36,19 %. Taj iznos u prosjeku odstupa od prosjeka za 19,04 %, najmanja vrijednost iznosi 5,88 %, a najveća 96,08 %. Udio ukupnih tekućih obveza poduzeća iz sektora građevinarstvo u cjelokupnoj imovini iznosi 41,86 %.

Prosječni udio tekućih obveza u ukupnoj imovini u prerađivačkom sektoru iznosi 38,35 %. Prosječno odstupanje od prosjeka iznosi 21,62 %, a najmanja i najveća vrijednost iznose 1,85 % i 100,00 %. Udio ukupnih tekućih obveza u ukupnoj imovini iznosi 31,22 %.

Prosječni udio tekućih obveza u ukupnoj imovini u sektoru trgovina na malo iznosi 46,32 %. Taj iznos u prosjeku odstupa od prosjeka za 22,97 %, najmanja vrijednost iznosi 4,25 %, a najveća 99,16 %. Udio ukupnih tekućih obveza u ukupnoj imovini iznosi 41,80 %.

Prosječni udio tekućih obveza u ukupnoj imovini u sektoru trgovina na veliko iznosi 47,51 %. Taj iznos prosječno odstupa od prosjeka za 23,15 %, najmanja vrijednost udjela tekućih obveza u ukupnoj imovini iznosi 0,35 %, a najveća 99,38 %. Udio ukupnih tekućih obveza u ukupnoj imovini iznosi 42,53 %.

Svi sektori zajedno imaju prosječni udio 42,28 % tekućih obveza u ukupnoj imovini. Najmanja vrijednost udjela tekućih obveza u ukupnoj imovini iznosi 0,35 %, a najveća

100,00 %, dok je standardna devijacija 22,35 %. Udio ukupnih tekućih obveza svih sektora u ukupnoj imovini svih sektora iznosi 39,98 %.

Neto obrtni kapital može poprimiti pozitivnu vrijednost što znači da se dio tekuće imovine financira iz dugoročnih izvora. U priloženoj analizi neto obrtni kapital ima pozitivnu vrijednost što upućuje na konzervativnu politiku upravljanja obrtnim kapitalom. U svim sektorima udio tekuće imovine u ukupnoj imovini je veći od udjela tekućih obveza u ukupnoj imovini.

Neto obrtni kapital može poprimiti i negativnu vrijednost što znači da se dio dugotrajne imovine financira iz tekućih izvora, odnosno da je tekuća imovina manja od tekućih obveza. U tom se slučaju radi o agresivnoj strategiji upravljanja obrtnim kapitalom. Umjerena strategija upravljanja obrtnim kapitalom označava ujednačenost dugotrajne imovine i dugoročnih izvora, odnosno u tom slučaju permanentna se tekuća imovina financira iz kratkoročnih izvora.

Poduzeća sva četiri promatrana sektora vode konzervativnu strategiju upravljanja obrtnim kapitalom što je u skladu s očekivanjima za poduzeća post-tranzicijskih zemalja. Očekivano, najmanje konzervativnu strategiju vode poduzeća sektora trgovine na malo jer imaju najbržu naplatu potraživanja, dok poduzeća sektora trgovine na veliko, koja ujedno imaju i najdulje dane naplate potraživanja, vode najviše konzervativnu strategiju upravljanja obrtnim kapitalom.

Iako nema apsolutnih mjera o onome što se može smatrati agresivnom ili konzervativnom strategijom upravljanja obrtnim kapitalom, prethodno navedene karakteristike korisne su u razumijevanju na koji način poduzeća upravljaju obrtnim kapitalom. Utvrđivanje agresivnosti i konzervativnosti investicijske i financijske strategije upravljanja obrtnim kapitalom najviše je svrsishodno ako se uspoređuju poduzeća unutar istog sektora ili s drugim zemljama unutar istog sektora ili usporedba pojedinačnog poduzeća s prethodnim rezultatima.

Da bi odnos rizika i profitabilnosti bio umjeren konzervativna investicijska strategija bi se mogla kombinirati s agresivnom financijskom strategijom, a konzervativna financijska strategija s agresivnom investicijskom strategijom.

7. ZAKLJUČAK

U okviru grane financije i područja financijske analize, konkretno poslovnih financija, uže područje ovog doktorskog rada jest područje upravljanja obrtnim kapitalom. Potonje preciznije podrazumijeva upravljanje neto operativnim obrtnim kapitalom, odnosno upravljanje zalihama, potraživanjima od kupaca i obvezama prema dobavljačima. U središtu je zanimanja obrtnog kapitala način na koji poduzeća koriste i upravljaju obrtnim kapitalom. Način upravljanja obrtnim kapitalom, s jedne strane ima utjecaj na likvidnost i sigurnost poduzeća, a s druge strane na profitabilnost i rizik poduzeća (Shin i Soenen, 1998). Većina radova iz područja financijskog menadžmenta usmjerena je na proučavanje dugoročnih financijskih i investicijskih odluka, dok su kratkoročne odluke, odnosno odluke o upravljanju obrtnim kapitalom, manje zastupljene u literaturi i znanstvenim studijama.

Dobro upravljanje obrtnim kapitalom podrazumijeva donošenje ispravnih kratkoročnih odluka, odnosno odluka o upravljanju obrtnim kapitalom, koje će dovesti do maksimiziranja zarada poduzeća pri čemu se mora uvažiti čitava lepeza rizika. Učinkovito upravljanje obrtnim kapitalom podrazumijeva postizanje ravnoteže između profitabilnosti i likvidnosti i profitabilnosti i rizika. Problem lošeg upravljanja obrtnim kapitalom nosi za sobom niz negativnih učinaka na visinu profitabilnosti poduzeća, ali i na opće bogatstvo vlasnika. Ako poduzeća u svojoj strukturi imovine imaju višu razinu obrtnog kapitala, mogu očekivati nižu razinu poslovnog rizika, ali i nepovoljniji utjecaj na visinu profitabilnosti. Taj problem posebno je izražen kod poduzeća koja imaju visoki udio tekuće imovine u ukupnoj imovini i koja se najvećim dijelom financiraju iz kratkoročnih izvora. Obrtni kapital mora biti oblikovan da pridonosi stvaranju vrijednosti dioničara.

Razne su studije analizirale odnos upravljanja obrtnim kapitalom i profitabilnosti poduzeća različitih veličina na različitim tržištima. Dobiveni su rezultati dosta različiti jer su pod utjecajem tržišta na kojem poduzeće posluje kao i veličine poduzeća. Najveći dio istraživanja upravljanja obrtnim kapitalom, proveden je u najrazvijenijim zemljama dok je upravljanje obrtnim kapitalom nedovoljno istraženo u tranzicijskim i post-tranzicijskim zemljama. Hrvatska pripada skupini post-tranzicijskih zemalja za koje su karakteristična manje razvijena financijska tržišta i bankocentričan financijski sustav. Najveći broj istraživanja proveden je u SAD-u, Velikoj Britaniji, državama zapadne Europe i drugim razvijenim zemljama, dok je puno manje istraživanja

provedeno u zemljama u razvoju. Istraživanja vezana za zemlje u razvoju više su usmjerena na Indiju, Maleziju i druge Azijske zemlje. Od tranzicijskih zemalja istraživanja su prisutna uglavnom za Baltičke zemlje, koje posluju u specifičnom skandinavskom okruženju, pa samim time istraživanja nisu dovoljno transparentna da bi se mogla generalizirati na područje ostalih tranzicijskih i post-tranzicijskih zemalja, a posebno ne na područje regije, a samim time i na Hrvatsku.

Upravljanje obrtnim kapitalom u zemljama u razvoju i post-tranzicijskim zemljama razmatralo se u kontekstu preživljavanja poduzeća na tržištu bez razmišljanja o posljedicama i utjecaju na visinu profitabilnosti. Zadnjih 20-ak godina posebno se izučavaju utjecaji razine ključnih čimbenika upravljanja obrtnog kapitala na razini poduzeća koji značajno utječu na visinu profitabilnosti poduzeća i otvara se mogućnost razmišljanja o drugačijem utjecaju, a ne tradicionalnom prihvaćanju utjecaja. Otvara se mogućnost razmišljanja o optimalnim razinama, o različitim utjecajima među različitim sektorima, ali i među različitim zemljama kao i o različitim utjecajima među poduzećima različitih veličina. Uvažavajući navedene razlike, potrebno je kontinuirano praćenje svakog čimbenika posebno i kroz duže razdoblje, a onda i njegova usporedba s poduzećima istog sektora. Pritom se mora uzeti u obzir da upravljanje obrtnim kapitalom ne ovisi samo o odlukama unutar poduzeću, nego i o nizu nametnutih politika od strane kupaca, dobavljača, banaka, ali i o samom utjecaju države i tržišta što zahtijeva stalnu spremnost menadžmenta da bude podložan odgovorima na promjene istih.

Fokus ovog rada je na malim i srednjim poduzećima zbog njihove velike važnosti u gospodarskom napretku svake države. Odabrana su poduzeća iz četiri sektora koja čine najveći udio u strukturi malih i srednjih poduzeća i istovremeno imaju veliku razinu obrtnog kapitala u strukturi svoje imovine, a to su: sektor građevinarstvo, prerađivački sektor, sektor trgovine na malo i sektor trgovine na veliko. Mala i srednja poduzeća sudjeluju s oko 99 % u ukupnom broju poduzeća, 69 % u ukupnom broju zaposlenih, 54 % u ukupnim prihodima, 56 % u dobiti razdoblja te 50 % u ukupnom izvozu u Republici Hrvatskoj.

Predmet istraživanja ovog doktorskog rada je identifikacija zajedničkih čimbenika upravljanja obrtnim kapitalom na razini poduzeća, u funkciji povećavanja profitabilnosti malih i srednjih poduzeća te analiziranje utjecaja zajedničkih čimbenika upravljanja obrtnim kapitalom na razini poduzeća na profitabilnost malih i srednjih poduzeća, u

četiri sektora koji čine najveći udio u strukturi malih i srednjih poduzeća, i to: građevinarstvo, prerađivački sektor, trgovina na malo, trgovina na veliko.

Iz tako definiranog predmeta proizašao je glavni cilj ovog doktorskog rada koji se sastojao upravo u ispitivanju odnosa između upravljanja obrtnim kapitalom i profitabilnosti malih i srednjih poduzeća u Republici Hrvatskoj te pružanju empirijskih dokaze o učincima upravljanja obrtnim kapitalom na profitabilnost malih i srednjih poduzeća u Republici Hrvatskoj. Interes za proučavanjem hrvatskih poduzeća proizlazi iz činjenice da ona djeluju u bankocentričnom financijskom sustavu gdje su tržišta kapitala manje razvijena, pa samim time poduzeća imaju manje alternativa za dobivanje financijskih sredstava iz vanjskih izvora.

Kao rezultat postavljenih istraživačkih ciljeva i hipoteza, doktorski rad je, uz uvod i zaključak, strukturiran u pet poglavlja. Od drugog do petog poglavlja prikazan je teorijski okvir područja doktorskog rada, dok se u šestom poglavlju prezentira empirijski dio istraživanja fokusiran na testiranje hipoteza i ostvarivanje ciljeva istraživanja.

U drugom su poglavlju definirani kriteriji određenja malih i srednjih poduzeća te upotrebe različitih definicija malih i srednjih poduzeća u Hrvatskoj i svijetu. Često dolazi do problema kada međunarodne organizacije i vlade pojedinih država, koje surađuju prilikom dodjele sredstava u sklopu različitih programa, koriste različite kriterije prilikom definiranja malih i srednjih poduzeća. Berisha i Shiroka Pula (2015) navode da se definicije razlikuju između međunarodnih ustanova, nacionalnih zakona i sektora. Tako na primjer, unutar grupe Svjetske banke, postoje različite definicije. Zemlje Europske unije najčešće primjenjuju definiciju Europske komisije, pri čemu Europska komisija potiče članice na primjenu, ali ih ne obvezuje. Također, brojni znanstvenici i istraživači koriste različite definicije i to najčešće u ovisnosti o bazama podataka koje su koristili prilikom njihova istraživanja. Kriteriji razvrstavanja poduzeća na mikro, male i srednje u Hrvatskoj su definirani Zakonom o računovodstvu (NN 120/16) i Zakonom o poticanju razvoja malog gospodarstva (NN 121/16) koji je u skladu s Preporukom Komisije 2003/361/EC od 6. svibnja 2003. godine. U ovom doktorskom radu koristili su se kriteriji i definicija malih i srednjih poduzeća prema Zakonu o računovodstvu.

U istom poglavlju prikazana je struktura, veličina i sastav malih i srednjih poduzeća u Republici Hrvatskoj i odabranim zemljama Europske unije. U Hrvatskoj najveći broj poduzeća čine mikropoduzeća koja ujedno i zapošljavaju najviše osoba, a odmah iza

njih su velika poduzeća prema broju zaposlenih osoba. Najvišu dodanu vrijednost ostvaruju velika poduzeća. Sektor trgovina na veliko i na malo ima najveći broj poduzeća u ukupnom broju poduzeća svih veličina. Po broju zaposlenih osoba najvažniji je prerađivački sektor, zatim trgovina na veliko i na malo, te građevinarstvo. Po stvaranju dodane vrijednosti najvažniji je prerađivački sektor, zatim trgovina na veliko i na malo, prijevoz i skladištenje te građevinarstvo. Također, u državama Europske unije mikropoduzeća čine najveći broj poduzeća te u većini država zapošljavaju najviše osoba. Iznimke su Austrija, Češka, Rumunjska, Bosna i Hercegovina i Velika Britanija, gdje najveći broj zaposlenih imaju velika poduzeća. Najveću dodanu vrijednost u promatranim zemljama također imaju velika poduzeća. Na kraju poglavlja definirane su ključne razlike između malih i srednjih poduzeća i velikih poduzeća. Razlike između malih i velikih poduzeća ogledaju se sa stajališta potencijalnih investitora i sa stajališta financijskog upravljanja (Orsag, 2002).

U trećem poglavlju definiran je pojam tranzicije kojim se označavaju tranzicijske zemlje te glavne sastavnice tranzicijskog procesa. Dan je pregled tranzicijskih zemalja, uvažavajući kriterije načina pristupanja tranziciji te klasifikacija tranzicijskih zemalja prema Međunarodnom monetarnom fondu. Europska banka za obnovu i razvoj razvila je klasifikacijski sustav koji procjenjuje napredak zemalja u procesu tranzicije. Prema navedenim tranzicijskim pokazateljima analiziran je napredak Republike Hrvatske i odabranih zemalja u procesu tranzicije. U ovisnosti o napretku prema tranzicijskim pokazateljima neke zemlje više su napredovale, neke manje pa se prema tomu može zaključiti da su jedne zemlje još uvijek u tranziciji dok su druge u post-tranziciji. Prema nekim autorima, očekivao se znatno veći napredak Hrvatske u procesu tranzicije pa su pronašli uzroke zbog kojih se isti nije ostvario u skladu s očekivanjima. U istom poglavlju analizirali su se uvjeti poslovanja Republike Hrvatske i promatranih zemalja prema različitim tematskim područjima. Analizirali su se nalazi nekih od najpoznatijih međunarodnih istraživanja poput izvještaja Svjetske banke *Doing Business*, izvještaja Svjetskog ekonomskog foruma o globalnoj konkurentnosti, izvještaja Europske komisije SBA Fact Sheet i drugi. Poseban osvrt dan je na poduzetničke probleme malih i srednjih poduzeća u Republici Hrvatskoj te na institucionalnu potporu za mala i srednja poduzeća u Republici Hrvatskoj. Na kraju trećeg poglavlja analizirao se pristup financiranju i ispitivali su se različiti kriteriji koji određuju financiranje u pojedinoj zemlji.

Naveli su se najvažniji oblici financiranja malih i srednjih poduzeća u Republici Hrvatskoj i zemljama Europske unije te namjena korištenja vanjskih oblika financiranja.

U četvrto poglavlje daje se teorijski okvir upravljanja obrtnim kapitalom. Polazi se od definiranja koncepta obrtnog kapitala i to koncepta bruto obrtnog kapitala, koncepta neto obrtnog kapitala i koncepta neto operativnog obrtnog kapitala. Definiran je pojam obrtni kapital koji se najčešće poistovjećuje s tekućom imovinom i obrtnim sredstvima. Nastavno na potonje napravljena je jasna distinkcija između navedenih pojmova. Obrtni kapital jest dio imovine kojom se koristi poduzeće za potrebe svog poslovanja, ali i način financiranja te imovine. Ilustrirana je funkcija obrtnih sredstava kroz ciklus obrtnih sredstava. Definiran je bruto ili ukupni obrtni kapital kroz različite perspektive. Također, definiran je neto obrtni kapital kao dio tekuće imovine i način njezina financiranja (Orsag, 2015) te kako poduzeća financiraju svoju imovinu u slučaju pozitivnog i negativnog neto obrtnog kapitala. I na kraju, definiran je neto operativni obrtni kapital ili nenovčani obrtni kapital koji je u fokusu ovog doktorskog rada, a predstavlja razliku operativne tekuće imovine i operativnih tekućih obveza poduzeća.

Nakon toga, prema različitim autorima, objašnjena je svrha upravljanja obrtnim kapitalom te važnost upravljanja obrtnim kapitalom zbog njegova utjecaja na profitabilnost poduzeća, vrijednost poduzeća, likvidnost i solventnost poduzeća. U središtu upravljanja obrtnim kapitalom je učinkovito upravljanje obrtnim kapitalom, odnosno odnos između učinkovitosti upravljanja obrtnim kapitalom i profitabilnosti poduzeća. Ilustriran je ciklus konverzije novca kao najčešća mjera učinkovitosti upravljanja obrtnim kapitalom te utjecaj skraćivanja ciklusa konverzije novca na glavne komponente obrtnog kapitala. Nakon toga, definirano je utvrđivanje optimalne veličine i strukture obrtnog kapitala te problem njezina postizanja u praksi. Na kraju poglavlja dan je koncept upravljanja tekućom imovinom i tekućim obvezama. S obzirom na fokus ovog doktorskog rada, dan je osvrt na pojavne oblike obrtnih sredstava zalihe i potraživanja od kupaca te na trgovački kredit dobavljača kao najvažniji oblik financiranja obrtnog kapitala, odnosno tekuće imovine.

U petom poglavlju dan je pregled strategija upravljanja obrtnim kapitalom. Poduzeće može provoditi konzervativnu ili agresivnu strategiju upravljanja obrtnim kapitalom. Konzervativna strategija upravljanja obrtnim kapitalom daje prednost sigurnosti i likvidnosti poslovanja (Orsag, 2003) i karakteristična je za poduzeća koja posluju u zemljama u razvoju i post-tranzicijskim zemljama te za nestabilnija makroekonomska

okruženja. Agresivna strategija upravljanja obrtnim kapitalom favorizira profitabilnost naspram sigurnosti i likvidnosti (Orsag, 2003) i karakteristična je za poduzeća koja posluju u razvijenim i gospodarski naprednijim zemljama sa stabilnim makroekonomskim okruženjima. Postoji konzervativnost i agresivnost u investicijskoj i financijskoj strategiji upravljanja obrtnim kapitalom pa su tako opisane strategije investiranja u obrtnom kapitalu kao i strategije financiranja obrtnog kapitala. U istom poglavlju dan je pregled, kratka objašnjenja i izračuni pokazatelja obrtnog kapitala. Na kraju petog poglavlja analiziran je utjecaj sektora na upravljanje obrtnim kapitalom. Analizirani su dani naplate potraživanja po sektorima, dani vezivanja zaliha po sektorima, dani plaćanja dobavljača po sektorima, dani potrebni poduzeću da pretvori svoja obrtna sredstva u prihode od prodaje po sektorima te ciklus konverzije novca po sektorima.

U šestom poglavlju prezentiran je empirijski dio istraživanja fokusiran na testiranje hipoteza i ostvarivanje ciljeva istraživanja. Teorijskim razmatranjima i empirijskim potvrdama utvrdili su se i sistematizirali ključni čimbenici upravljanja obrtnim kapitalom na razini poduzeća koji značajno utječu na profitabilnost malih i srednjih poduzeća u svim sektorima, ali utjecaj svake od navedenih varijabli nije istog smjera i intenziteta u poduzećima različitih sektora. Zajednički čimbenici upravljanja obrtnim kapitalom na razini poduzeća koji utječu na profitabilnost poduzeća su: zalihe, potraživanja od kupaca, obveze prema dobavljačima, veličina poduzeća, rast prodaje, sektor (pripadnost industriji), inflacija i BDP. Prema tradicionalnom prihvaćanju utjecaja čimbenika upravljanja obrtnim kapitala na profitabilnost poduzeća izdvaja se negativan utjecaj potraživanja od kupaca i zaliha na visinu profitabilnosti poduzeća i pozitivan utjecaj obveza prema dobavljačima, veličine prodaje i rasta prodaje na visinu profitabilnosti poduzeća.

U radu su se koristile različite znanstvene metode. Polazeći od deduktivnog pristupa provela se analiza relevantne znanstvene i stručne literature gdje su se korištenjem metoda analize i sinteze, apstrakcije i konkretizacije, generalizacije i specifikacije i drugih potrebnih znanstveno istraživačkih metoda, deducirali zaključci o značaju ključnih čimbenika upravljanja obrtnim kapitalom na razini poduzeća koji utječu na profitabilnost poduzeća općenito te specifičnosti utjecaja tih čimbenika na mala i srednja poduzeća u različitim gospodarstvima. Nakon toga su se sistematizirali ključni čimbenici upravljanja obrtnim kapitalom koji su ušli u istraživački model.

Polazeći od induktivnog pristupa, provelo se je empirijsko istraživanje na odabranom uzorku. Varijable su se najprije analizirale deskriptivnom statistikom na prikupljenim podacima o izabranim varijablama u razdoblju od 2011. do 2015. godine. Ti su se isti podaci organizirali u obliku panela, pa se provela i njihova odgovarajuća analiza u ovisnosti o rezultatima Hausman testa. U odgovarajućem je panel-modelu zavisna varijabla bila profitabilnost, a nezavisne varijable potraživanja od kupaca, zalihe i obveze prema dobavljačima, dok su kontrolne varijable veličina poduzeća, rast prodaje, BDP, inflacija i sektor.

Panel analizom ispitao se utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća, rasta prodaje, rasta BDP-a, stope inflacije i sektora na profitabilnost malih i srednjih poduzeća. Panel-analizom podataka ispitao se utjecaj potraživanja od kupaca, zaliha, obveza prema dobavljačima, veličine poduzeća, rasta prodaje, rasta BDP-a i stope inflacije na profitabilnost malih i srednjih poduzeća pojedinačno u četiri sektora, i to u: građevinarstvu (24 % u ukupnom uzorku), prerađivačkom sektoru (24 % u ukupnom uzorku), trgovini na malo (23 % u ukupnom uzorku) i trgovini na veliko (29 % u ukupnom uzorku).

Hipoteza H1 djelomično je prihvaćena. Model je potvrdio utjecaj *zaliha*, *obveza prema dobavljačima* i *rasta prodaje* na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj, dok se utjecaj *potraživanja od kupaca* i *veličine poduzeća* na visinu profitabilnosti malih i srednjih poduzeća u Hrvatskoj nije potvrdio. Kontrolna varijabla *sektor* pokazala se statistički značajnom, dok se *BDP* i *inflacija* nisu pokazali statistički značajnim.

Hipoteza H2 djelomično je prihvaćena. Utjecaj *zaliha*, *obveza prema dobavljačima*, *veličine poduzeća*, *rasta prodaje* i *BDP-a* na visinu profitabilnosti poduzeća pokazao se značajnim u pojedinim sektorima i različit u različitim sektorima, i to u građevinarstvu, prerađivačkom sektoru, trgovini na malo i trgovini na veliko, dok se utjecaj *potraživanja od kupaca* i *inflacije* na visinu profitabilnosti malih i srednjih poduzeća nije pokazao značajnim niti u jednom sektoru.

Iz rezultata istraživanja ovoga rada može se zaključiti da je različita razina obrtnog kapitala od različitog značaja za promatrane sektore, odnosno, da je utjecaj obrtnog kapitala na visinu profitabilnosti poduzeća pod utjecajem sektora. To se je dokazalo uvođenjem varijable *sektor* koja se pokazala značajnom.

Poduzeća iz sektora građevinarstvo mogu utjecati na povećanje profitabilnosti svog poduzeća ako ne odugovlače s plaćanjem svojih obveza prema dobavljačima kako ne bi došlo do naprezanja odnosa s dobavljačima zbog kašnjenja u plaćanju, te povećanja troškova zbog plaćanja zateznih kamata, penala ili sudskih troškova. U skladu s očekivanjima, veličina poduzeća je utjecala na povećanje profitabilnosti poduzeća. Poduzeća iz sektora građevinarstvo jedina su poduzeća koja su pogođena rastom BDP-a i to negativno, odnosno, rast BDP-a je utjecao na smanjenje profitabilnosti poduzeća. U tim razdobljima poduzeća bi uvijek trebala biti spremna na kompenzaciju profitabilnosti putem drugih mjera i izvora. U odnosu na ostala promatrana tri sektora, poduzeća iz sektora građevinarstvo imaju najveću razinu dana naplate potraživanja, dok s druge strane imaju u prosjeku najveći broj dana plaćanja obveza prema dobavljačima. U skladu s ranije navedenim specifičnostima vođenja zaliha, sektor građevinarstvo imat će u prosjeku najmanje dane vezivanja zaliha. Poduzeća iz sektora građevinarstvo imat će najbrži ciklus konverzije novca. S jedne strane imaju najdulje dane naplate potraživanja od kupaca, a s druge strane najviše rastežu plaćanje obveza prema dobavljačima.

Poduzeća iz prerađivačkog sektora mogu utjecati na povećanje profitabilnosti svog poduzeća tako da ne odugovlače s plaćanjem svojih obveza prema dobavljačima kako bi s jedne strane izbjegla dodatne troškovi zbog neplaćanja na vrijeme, a s druge strane iskoristili ponuđeni popust od dobavljača. Također, poduzeća mogu povećati svoju profitabilnost većim obrtajem zaliha, odnosno da se zalihe što kraće vrijeme zadržavaju na skladištu kako bi se izbjegli dodatni troškovi skladištenja, troškovi kvarljivosti sirovina i materijala. U skladu s očekivanjima rast prodaje poduzeća utjecat će na povećanje profitabilnosti poduzeća.

Poduzeća iz sektora trgovina na malo mogu utjecati na povećanje profitabilnosti svog poduzeća tako da što prije plate svoje obveze prema dobavljačima kako bi se izbjegli dodatni troškovi zbog neplaćanja na vrijeme i iskoristili popusti od dobavljača za rane uplate. Također, poduzeća će povećati svoju profitabilnost većim obrtajem zaliha, odnosno pravovremenom narudžbom kako bi zalihe što kraće stajale na skladištu. Poduzeća iz sektora trgovina na malo, u odnosu na ostala tri sektora, imaju značajno najmanju razinu dana naplate potraživanja, a s druge strane, najveće dane vezivanja zaliha. Svoje obveze prema dobavljačima poduzeća iz ovog sektora plaćaju najbrže u

odnosu na ostala tri promatrana sektora. Sektor trgovine na malo po ciklusu konverzije novca nalazi se odmah nakon sektora građevinarstvo.

Kod poduzeća iz sektora trgovina na veliko pronašao se najmanji utjecaj obrtnog kapitala na visinu profitabilnosti poduzeća. Samo je skraćivanje dana zaliha na skladištu utjecalo na povećanje profitabilnosti poduzeća. Sve ostale varijable nisu imale značajan utjecaj.

Provedeno istraživanje unaprijedilo je spoznaju o upravljanju obrtnim kapitalom. Znanstveni doprinos istraživanja ogleda se već u pregledu i sistematizaciji dosadašnjih istraživanja na ovome području. Riječ je o području koje je još uvijek nedovoljno istraženo. Istraživanja su se uglavnom odnosila na velika gospodarstva i javna dionička društva. Usmjerenošću ovoga rada na mala i srednja poduzeća u uvjetima malih post-tranzicijskih gospodarstava, te analizom upravljanja obrtnim kapitalom u cjelini sektora malih i srednjih poduzeća i prema značajnijim sektorima, rad je značajno obogatio znanstvenu literaturu na ovom području.

Temeljni znanstveni doprinos ovoga rada i predmeta istraživanja sastoji se u istraživačkim spoznajama kojima su utvrđeni i sistematizirani ključni čimbenici upravljanja obrtnim kapitalom na razini poduzeća kao i koji ključni čimbenici upravljanja obrtnim kapitalom, na razini poduzeća, značajno djeluju na profitabilnost malih i srednjih poduzeća u post-tranzicijskom gospodarstvu. Provedenim istraživanjima utvrdilo se da će zalihe, obveze prema dobavljačima, rast prodaje i sektor iz kojeg poduzeće dolazi značajno utjecati na profitabilnost malih i srednjih hrvatskih poduzeća, dok potraživanja od kupaca, veličina poduzeća, inflacija i BDP neće imati značajan utjecaj na visinu profitabilnosti malih i srednjih hrvatskih poduzeća. Znanstveni doprinos očituje se u izradi modela analize utjecaja upravljanja obrtnim kapitalom na profitabilnost malih i srednjih poduzeća u specifičnom okruženju, karakterističnih post-tranzicijskih zemalja.

Za potrebe provedene analize i donošenje zaključaka izrađen je model analize utjecaja upravljanja obrtnim kapitalom na profitabilnost malih i srednjih poduzeća u specifičnom okruženju karakterističnih post-tranzicijskih zemalja.

Model za sva mala i srednja poduzeća je sljedeći:

$$\widehat{ROA}_{it} = -\frac{0,00011}{(0,00004)} \cdot DVZ_{it} - \frac{0,00028}{(0,00010)} \cdot DPOD_{it} + \frac{0,03610}{(0,01560)} \cdot RPR_{it} + \frac{0,03080}{(0,01780)} \cdot PRER + \frac{0,03500}{(0,01410)} \cdot TRGM + \frac{0,05390}{(0,01420)} \cdot TRGV$$

Iako je model testiran na malim i srednjim poduzećima u Republici Hrvatskoj, primjenjiv je i za provedbu istraživanja drugih sličnih tranzicijskih i post-tranzicijskih zemalja, napose onih iz bližeg okruženja.

Izrađeni model omogućio je i uključivanje u ispitivanje pripadnosti različitim sektorima. Time je ostvareno proširivanje spoznaja o upravljanju obrtnim kapitalom o različitosti utjecaja čimbenika upravljanja obrtnog kapitala na razini poduzeća u različitim sektorima. Provedenim istraživanjima potvrdio se različit utjecaj čimbenika upravljanja obrtnim kapitalom na razini poduzeća u različitim sektorima. Uz prikazani ostvareni doprinos na području raznolikosti sektora, sam izbor sektora omogućava daljnje deduciranje ostvarenih rezultata na usporedive tranzicijske i post-tranzicijske zemlje jer je riječ o sektorima značajno zastupljenim i u tim zemljama.

Znanstveni doprinos ostvaren je i rezultatima analize i ocjene ključnih čimbenika upravljanja obrtnog kapitala koji utječu na profitabilnost u hrvatskim poduzećima te njihova usporedba u različitim sektorima. Provedenim istraživanjima utvrdilo se da potraživanja od kupaca neće imati značajan utjecaj na visinu profitabilnosti malih i srednjih poduzeća niti u jednom sektoru. Zalihe će imati značajan utjecaj na visinu profitabilnosti malih i srednji poduzeća u prerađivačkom sektoru, trgovini na malo i trgovini na veliko, dok se u sektoru građevinarstvo nije pokazao utjecaj zaliha na visinu profitabilnosti poduzeća. Obveze prema dobavljačima imat će značajan utjecaj na visinu profitabilnosti malih i srednji poduzeća u sektoru građevinarstvo, prerađivačkom sektoru i trgovini na malo, dok se u sektoru trgovina na veliko nije pokazao utjecaj obveza prema dobavljačima na visinu profitabilnosti poduzeća. Provedenim istraživanjima, također, utvrdilo se da će veličina imati značajan utjecaj na visinu profitabilnosti poduzeća samo u sektoru građevinarstvo, dok će rast prodaje imati značajan utjecaj samo u prerađivačkom sektoru. Inflacija nije pokazala značajan utjecaj u niti jednom sektoru, dok je BDP imao značajan utjecaj na visinu profitabilnosti poduzeća samo u sektoru građevinarstvo.

Za prikazana znanstvena postignuća u istraživanju prikazani osnovni istraživački model razrađen je na modele za svaki sektor posebno.

Model za sektor građevinarstvo je sljedeći:

$$\widehat{ROA}_{it} = -\frac{0,00023}{(0,00011)} \cdot DPOD_{it} + \frac{0,04790}{(0,02210)} \cdot VEL_{it} - \frac{0,01240}{(0,00720)} \cdot BDP_{it}$$

Model za prerađivački sektor je sljedeći:

$$\widehat{ROA}_{it} = -\frac{0,00013}{(0,00006)} \cdot DVZ_{it} - \frac{0,00032}{(0,00016)} \cdot DPOD_{it} - \frac{0,09336}{(0,02707)} \cdot RPR_{it}$$

Model za sektor trgovine na malo je sljedeći:

$$\widehat{ROA}_{it} = -\frac{0,00014}{(0,00008)} \cdot DVZ_{it} - \frac{0,00057}{(0,00022)} \cdot DPOD_{it}$$

Model za sektor trgovine na veliko je sljedeći:

$$\widehat{ROA}_{it} = -\frac{0,00054}{(0,00025)} \cdot DVZ_{it}$$

Istraživanje se je provelo na hrvatskim poduzećima i isto će se deducirati i proširiti na zemlje regije, jer su se izolirale specifične okolnosti Hrvatske kao post-tranzicijskog gospodarstva u kojem su sadržane i posljedice nastale kroz vrijeme tranzicije. Istraživanja su dovoljno transparentna da se mogu primijeniti, odnosno generalizirati na područje ostalih post-tranzicijskih i tranzicijskih zemalja, a posebno na područje regije. Primjena rezultata istraživanja sastoji se i u informiranju svih aktera upravljanja obrtnim kapitalom post-tranzicijskih zemalja.

Osim u teorijskom smislu, rezultati znanstvenih istraživanja, koji su prezentirani u doktorskom radu, daju znanstveni doprinos ekonomskim znanostima u teorijskom i aplikativnom smislu. Znanstveni rezultati i saznanja imat će svoju aplikativnu stranu, jer će pomoći za unaprjeđenje upravljanja obrtnim kapitalom u malim i srednjim poduzećima. Očekuje se da će spoznaje ovog dokorskog rada probuditi svijest o postojećim problemima o upravljanju obrtnim kapitalom.

Primjena rezultata istraživanja ovoga dokorskog rada može biti od velike koristi financijskom menadžmentu poduzeća iz sva četiri sektora jer pružaju informacije o upravljanju obrtnim kapitalom. Rezultati sugeriraju poduzećima koju investicijsku i financijsku strategiju koristiti radi povećanja visine profitabilnosti poduzeća, a da pri tome ne ugroze kontinuitet poslovanja poduzeća. Također, pružaju informacije kojim se strategijama koriste poduzeća istog sektora te kako to utječe na visinu profitabilnosti poduzeća.

Rad je osigurao i aplikativni doprinos prema kojem se mogu istaknuti određene preporuke za unaprjeđenje upravljanja obrtnim kapitalom malih i srednjih poduzeća.

- Iako je većina istraživača u svojim studijama pronašla negativan i značajan odnos između dana naplate potraživanja od kupaca i visine profitabilnosti poduzeća, rezultati istraživanja u hrvatskim malim i srednjim poduzećima, promatranih sektora, pokazuju da nema značajnog odnosa između potraživanja od kupaca i profitabilnosti poduzeća. Pretpostavlja se da do značajnog odnosa nije došlo jer je naplata potraživanja od kupaca kasnila, a kada bi se potraživanja i naplatila, sredstva se nisu koristila za unaprjeđenje prodaje, nego za podmirivanje starih dugova koji su sa sobom nosili i visoke troškove. Preporuka je da se napravi oštrija politika naplate potraživanja od kupaca radi što brže naplate potraživanja od kupaca. S druge strane, prikupljena sredstva bi se trebala koristiti radi unaprjeđenja prodaje i podmirivanja svojih tekućih obveza na vrijeme. Unaprjeđenje prodaje isto će tako utjecati na kraće zadržavanje zaliha na skladištu i veći obrtaj zaliha, što će rezultirati većom profitabilnosti, pogotovo jer se odnos zaliha i profitabilnosti pokazao značajnim u svim sektorima, osim u sektoru građevinarstvo. Povećanje obrtaja zaliha te pravovremena narudžba zaliha rezultira manjim troškovima zadržavanja zaliha na skladištu. Također, preporuka je da se jasno napravi politika dobrih kupaca i loših kupaca te da se bude oprezan s lošim kupcima i da se ugovore svi instrumenti osiguranja plaćanja.
- Poduzeća koja posluju u nesigurnom okruženju moraju biti više orijentirane na sigurnost poslovanja jer u nesigurnim uvjetima nije moguće predvidjeti buduće kretanje cijena kao ni kratkoročne kamatne stope. Stoga je preporuka da se u takvim uvjetima više ulaže u tekuću imovinu, odnosno da se primjenjuje konzervativnija politika investiranja.
- Preporučuje se financiranje iz kratkoročnih sredstava iako tu treba biti oprezan kako se ne bi ugrozila likvidnost i sigurnost poslovanja. Generalno, brže prikupljanje novca, manje zadržavanje zaliha na skladištu, ali i brže podmirivanje kratkoročnih obveza prema dobavljačima, rezultirat će većom profitabilnosti malih i srednjih poduzeća u Hrvatskoj.

- Identificirati tržišno okruženje, odnosno prepoznati snage i slabosti, prilike i prijetnje tržišta na kojem se posluje te prilagoditi proces poslovanja tržišnim uvjetima.
- Pratiti proces obrtnog kapitala od početka do kraja i stvoriti uvjete za njegovom što većom efikasnošću.
- Iako pojedine varijable nisu pokazale utjecaj na visinu profitabilnosti u pojedinim sektorima, preporuka je da se upravljanje tim varijablama ne zanemaruju jer bi loše upravljanje moglo dovesti do neželjenih utjecaja na rezultate poslovanja.

Bez obzira na to što nema rezultata za usporedbu zbog sličnih osnova nastanka i sličnih tranzicijskih prilika te geopolitičkog položaja mogu se očekivati slični rezultati u post-tranzicijskim zemljama. S obzirom na nedostatak istraživanja o obrtnom kapitalu za mala i srednja poduzeća u zemljama post-tranzicijskog gospodarstva, rezultati ovog doktorskog rada mogu poslužiti za bolje razumijevanje upravljanja obrtnim kapitalom i njegovih odrednica u navedenim zemljama.

Ograničenja ove doktorske disertacije bila su prisutna u trenutku prikupljanja podataka. Podaci su se preuzimali iz financijskih izvještaja poduzeća, a za veliki broj poduzeća bili su dostupni samo skraćeni financijski izvještaji koji nisu imali sve podatke potrebne za analizu pa su se brojna poduzeća izostavila iz analize. Razlog tomu je što mala i srednja poduzeća nisu obveznici javne objave financijskih izvještaja.

Ovaj doktorski rad inicira daljnja istraživanja poput obuhvata većeg broja sektora, analize razlika s velikim poduzećima, istraživanja na sličnim gospodarstvima itd.

LITERATURA

- [1.] Akoto, R. K., Awunyo-Vitor, D., Angmor, P. L. (2013). Working capital management and profitability: Evidence from Ghanaian listed manufacturing firms. *Journal of Economics and International Finance*, vol. 5, no. 9, pp. 373-379.
- [2.] Almazari, A. A. (2014). The Relationship between Working Capital Management and Profitability: Evidence from Saudi Cement Companies. *British Journal of Economics, Management & Trade*, vol. 4, no. 1, pp. 146-157.
- [3.] Aljinović, Z., Marasović, B. (2012). *Matematički modeli u analizi razvoja hrvatskog financijskog tržišta*. Ekonomski fakultet u Splitu, Split.
- [4.] Archavli, E., Siriopoulos, K., Arvanitis, S. (2012). Determinants of working capital management. Technological Educational Institute (T.E.I.) of Crete, Dostupno: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2179907
- [5.] Arellano, M., Bond, S. (1991). Some tests of specifications for Panel Data, Monte Carlo Evidence and an Application to Employment Equations. *The Review of Economic Studies*, vol. 58, no. 2, pp. 277-297.
- [6.] Arnold, G. (2008). *Corporate Financial Management*. 4th edit. Prentice Hall.
- [7.] Atseye, F. A., Ugwu, J. I., Takon, S. M. (2015). Determinants of working capital management: Theoretical review. *International Journal of Economics, Commerce and Management*, vol. 3, no 2, pp.1-11.
- [8.] Bahovec, V., Erjavec, N. (2009). *Uvod u ekonometrijsku analizu*. Zagreb: Element.
- [9.] Banos-Caballero, S., Garcia-Teruel, P. J., Martinez-Solano, P. (2010). Working capital management in SMEs. *Accounting & Finance*, vol. 50, no. 3, pp. 511-527.
- [10.] Banos-Caballero, S., Garcia-Teruel, P. J., Martinez-Solano, P. (2012). How does working capital management affect the profitability of Spanish SMEs?. *Small Business Economics*, vol. 39, no. 2, pp. 517-529.
- [11.] Baum, C. F. (2001). Residual diagnostics for cross-section time series regression models. *The Stata Journal*, vol. 1, no. 1, pp. 101-104.
- [12.] Baveld, M. B. (2012). *Impact of Working Capital Management on the Profitability of Public Listed Firms in the Netherlands During the Financial Crisis*. Master Thesis, University of Twente, Dostupno: http://essay.utwente.nl/61524/1/MSc_M_Baveld.pdf
- [13.] Bellouma, M. (2010). Effects of capital investment on working capital management: Evidence on Tunisian export SMEs. *The International Journal of Finance*, vol. 22, no. 3, pp. 6497- 6509.
- [14.] Belsey, D. A., Kuh, E., Welsch, R. (2013). *Regression Diagnostics: Identifying Influential Data and Sources of Collinearity*. New York, Wiley.
- [15.] Bendeković, J., Bendeković, D., Brozović, T., Jančin, T., Lasić, V. (2007). *Priprema i ocjena investicijskih projekata*. Edited by J. Bendeković. Zagreb: FOIP 1974. d.o.o.

- [16.] Berisha, G., Shiroka Pula, J. (2015). Defining Small and Medium Enterprises: a critical review. *Academic Journal of Business. Administration, Law and Social Sciences*, vol. 1, no. 1, pp. 17-28.
- [17.] Bhattacharya, H. (2014). *Working Capital Management: Strategies and Techniques*. 3rd edn. Delhi: PHI Learning Private Limited.
- [18.] Binefeld, J., et al. (2004). Građenje i nekretnine u prometu. IV. izmjenjena i dopunjena naklada, Zagreb, RRI F Pus.
- [19.] Blundell, R., Bond, S. (1998). Initial conditions and moment restrictions in dynamic panel data models. *Journal of Econometrics*, 87(1), 115-143.
- [20.] Bošković, D. (2002). Temeljne postavke menadžmenta u graditeljstvu, Menadžment u graditeljstvu – nastavni materijali, Građevinski fakultet u Rijeci. Dostupno:
<https://helpdesk.uniri.hr/system/resources/docs/000/002/213/original/M1.ppt?>
- [21.] Bougheas, S., Mateut, S., Mizen, P. (2009). Corporate trade credit and inventories: New evidence of a trade-off from accounts payable and receivable. *Journal of Banking & Finance*, vol. 33, no. 2, pp. 300-307.
- [22.] Bradt, K. Louis (1965). *Business Finance – A Management Approach*. Prentice Hall, New Jersey.
- [23.] Brealey, R. A., Myers, S. C., Marcus, A. J. (2007). *Osnove korporativnih financija*. V edition, Zagreb: Mate.
- [24.] Brennan, M. J., Maksimovic, V., Zechner, J. (1988). Vendor financing. *The Journal of Finance*, vol. 43, no. 5, pp. 1127-1141.
- [25.] Breusch, T. S., Pagan, A. R. (1980). The Lagrange Multiplier Test and its Applications to Model Specification in Econometric. *The Review of Economics Studies*, vol. 47, no. 1, pp. 239-253.
- [26.] Brigham, E. F., Ehrhardt, M. C. (2005). *Financial Management: Theory and Practice*. 11th edn. Thomson South-Western.
- [27.] Brigham, E. F., Ehrhardt, M. C. (2011). *Financial Management: Theory and Practice*. 13th edn. Mason, OH: South-Western Cengage Learning.
- [28.] Chatterjee, S. (2010). The Impact of Working Capital Management on the Profitability of the Listed Companies in the London Stock Exchange. Working Paper Series, SSRN, Dostupno:
https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1587249
- [29.] Ching, H. Y., Novazzi, A., Gerab, F. (2011). Relationship between working capital management and profitability in Brazilian listed companies. *Journal of global business and economics*, vol. 3, no.1, pp. 74-86.
- [30.] Cvijanović, V., Marović, M., Sruk, B. (2008). *Financiranje malih i srednjih poduzeća*. Zagreb: Gipa d.o.o.
- [31.] Dadajan, V. S. (1966). *Optimum v ekonomike*. Znanje, Moskva.
- [32.] Deloof, M., Jegers, M. (1996). Trade Credit, Product Quality, and Intragroup Trade: Some European Evidence. *Financial Management*, vol. 25, no. 3, pp. 33-43.
- [33.] Damodaran, A. (2006). *Damodaran on Valuation: Security Analysis for Investment and Corporate Finance*. 2nd edn. John Wiley & Sons.

- [34.] Damodaran, A. (2010). *Applied Corporate Finance*. 3rd edn. John Wiley & Sons.
- [35.] Deloof, M. (2003). Does working capital management affect profitability of Belgian firms?. *Journal of business finance & Accounting*, vol. 30, no. 3-4, pp. 573–587.
- [36.] Dimitrić, M., Tomas Živković, I., Matejčić, V. (2018). Odrednice profitabilnosti hotelskih poduzeća – usporedna analiza Primorsko-goranske županije i Republike Hrvatske. *Financije – teorija i suvremena pitanja*, pp. 329-351.
- [37.] Emery, G. W. (1987). An Optimal Financial Response to Variable Demand. *Journal of Financial and Quantitative Analysis*, vol. 22, no. 2, pp. 209-225.
- [38.] Enqvist, J., Graham, M., Nikkinen, J. (2014). The impact of working capital management on firm profitability in different business cycles: Evidence from Finland. *Research in International Business and Finance*, vol. 32, issue C, pp. 36-49.
- [39.] Field, A. (2009). *Discovering Statistics Using SPSS, 3rd edition*. SAGE Publications LTD: London.
- [40.] Filbeck, G., Krueger, T. M. (2005). An Analysis of Working Capital Management Results Across Industries. *American Journal of Business*, vol. 20, no. 2, pp. 11-20.
- [41.] Gakure, R., Cheluget, J. K., Onyango, J. A., Keraro, V. (2012). Working capital management and profitability of manufacturing firms listed at the Nairobi stock exchange. *Prime Journal of Business Administration and Management*, vol. 2, no. 9, pp. 680-686.
- [42.] Ganesan, V. (2007). An Analysis of Working Capital Management Efficiency in Telecommunication Equipment Industry. *Rivier Academic Journal*, vol. 3, no. 2, pp. 1-10.
- [43.] Garcia-Teruel, P. J., Martinez-Solano, P. (2007). Effects of working capital management on SME profitability. *International Journal of managerial finance*, vol. 3, no. 2, pp. 164–177.
- [44.] Garcia-Teruel, P. J., Martinez-Solano, P. (2010). A Dynamic Approach to Accounts Receivable: a Study of Spanish SMEs. *European Financial Management*, vol. 16, no. 3, pp. 400-421.
- [45.] Gentry, J. A., Vaidyanathan, R., Lee, R., Wai, H. (1990). A weighted cash conversion cycle. *Financial Management*, vol. 19, no. 1, pp. 90-99.
- [46.] Gill, A., Biger, N., Mathur, N. (2010). The Relationship Between Working Capital Management And Profitability: Evidence From The United States', *Business and Economics Journal*, vol. 10, no. 1, pp. 1-9.
- [47.] Gitman, L. J., Zutter, C. J. (2011). *Principles of Managerial Finance*. 13th edn. New Jersey: Prentice Hall Inc.
- [48.] Grablowsky, B.J. (1984). Financial management of inventory. *Journal of Small Business Management*, vol. 22, pp. 59-65.

- [49.] Gul, S., Khan, M. B., Rehman, S. U., Kahn, M. T., Khan, M., Khan, W. (2013). Working Capital Management and Performance of SME sector. *European Journal of Business and management*, vol. 5, no. 1, pp. 60-68.
- [50.] Gupta, R. K., Gupta, H. (2015). *Working Capital Management and Finance: A Handbook for Bankers and Finance Managers*. 2nd revised and updated edition. Chennai: Notion Press.
- [51.] Haramija, P., Njavro, Đ. (2016). Tranzicija i njezini rezultati – zašto tranzicija iz komunističkog u demokratski sustav tržišnog gospodarstva nije ostvarila očekivanja. *Obnovljeni život: časopis za filozofiju i religijske znanosti*, vol. 71, no. 4, pp. 515-527.
- [52.] Hawawini, G., Viallet, C., Vora, A. (1986). Industry influence on corporate working capital decisions. *Sloan Management Review*, pp. 15-24.
- [53.] Hofmann, E., Belin, O. (2011). *Relevance of WCM and Its Weaknesses*. In Supply chain finance solutions. Springer-Velag Berlin Heidelberg.
- [54.] Kieschnick, R., Laplante, M., Moussawi, R. (2013). Working capital management and shareholders' wealth. *Review of Finance*, vol. 17, no. 5, pp. 1827-1852.
- [55.] Kordić, N. Tranzicija u međunaronoj ekonomiji. Dostupno: https://updoc.site/download/tranzicija_pdf, (pristupljeno: 28.08.2018.).
- [56.] Korent, D. (2018). Identifikacija odrednica upravljanja obrtnim kapitalom u funkciji povećanja profitabilnosti poduzeća u odabranim djelatnostima u Republici Hrvatskoj. Doktorska disertacija, Ekonomski fakultet u Zagrebu, Zagreb.
- [57.] Lamberg, S., Vålming, S. (2009). *Impact of Liquidity Management on Profitability: A study of the adaptation of liquidity strategies in a financial crisis*. Master thesis, Umeå University, Umeå School of Business.
- [58.] La Porta, R., Lopez-de-Silanes, F., Shleifer, A., Vishny, R.W. (1997). Legal Determinants of External Finance. *The Journal of Finance*, vol. 52, no. 3, pp. 1131-1150.
- [59.] Lazaridis, I., Tryfonidis, D. (2006). The relationship between working capital management and profitability of listed companies in the Athens Stock Exchange. *Journal of Financial Management and Analysis*, vol. 19, no. 1.
- [60.] Lee, Y. W., Stowe, J. D. (1993). Product Risk, Asymmetric Information, and Trade Credit. *Journal of Financial and Quantitative Analysis*, vol. 28, no. 2, pp. 285-300.
- [61.] Long, M. S., Malitz, L. B., Ravid, S. A. (1993). Trade Credit, Quality Guarantees, and Product Marketability. *Financial Management*, vol. 22, no. 4, pp. 117-127.
- [62.] Lukić, R. (2013). The Influence of Working Assets Efficiency Management on the Profitability of Trade in Serbia. *Review of International Comparative Management*, vol. 14, no. 5, pp. 731-745.

- [63.] Lyroudi, K., Lazaridis, Y. (2000). The Cash Conversion Cycle and Liquidity Analysis of the Food Industry in Greece. EFMA, Athens, Dostupno: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=236175
- [64.] Makori, D. M., Jagongo, A. (2013). Working Capital Management and Firm Profitability: Empirical Evidence from Manufacturing and Construction Firms Listed on Nairobi Securities Exchange, Kenya. *International Journal of Accounting and Taxation*, vol. 1, no. 1, pp.1-14.
- [65.] Mamić, H. (2015). *Panel analiza značaja visokog obrazovanja u zemljama Srednje i Istočne Europe*. Diplomski rad, Ekonomski fakultet, Split.
- [66.] Mathuva, D. M. (2010). The Influence of Working Capital Management Components on Corporate Profitability: A Survey on Kenyan Listed Firms. *Research Journal of Business Management*, vol. 4, no. 1.
- [67.] Mengesha, W. (2014). *Impact of Working Capital Management on Firms' Performance: The Case of Selected Metal Manufacturing Companies in Addis Ababa, Ethiopia*. Master Thesis. Jimma University, College of Business and Economics, Jimma, Ethiopia.
- [68.] Monto, S. (2013). *Towards inter-organizational working capital management*. PhD Thesis, Lappeenranta University of Technology, Faculty of Industrial Engineering and Management.
- [69.] Moyer, R. C., McGuigan, J. R., Kretlow, W. J. (2006). *Contemporary Financial Management*. 10th edn. Mason, OH: South-Western, Thomson Corporation.
- [70.] Nigatu, H. Y. (2015). Working Capital Management and Firms profitability: Evidence from Manufacturing SC in Addis Ababa, Ethiopia. PhD Thesis, ADDIS ABABA UNIVERSITY.
- [71.] Nobanee, H., Abdullatif, M., AlHajjar, M. (2011). Cash conversion cycle and firm's performance of Japanese firms. *Asian Review of Accounting*, vol. 19, no. 2, pp. 147-156.
- [72.] Orsag, S. (2002). *Budžetiranje kapitala: Procjena investicijskih projekata*. Masmedia, Zagreb.
- [73.] Orsag, S. (2003). *Vrijednosni papiri*. Revicon, Sarajevo.
- [74.] Orsag, S. (2015). *Poslovne financije*. Avantis: HUFA, Zagreb.
- [75.] Papić, M. (2014). *Primijenjena statistika u MS Excelu, 5. izdanje*. Naklada Zoro, Zagreb.
- [76.] Pepur, S., Šimić Šarić, M., Vidučić, Lj. (2015). *Financijski menadžment*. RRiF Plus, Zagreb.
- [77.] Petersen, M. A., Rajan, R. G. (1995). The effect of credit market competition on lending relationships. *The Quarterly Journal of Economics*, vol. 110, no. 2, pp. 407-443.
- [78.] Petersen, M. A., Rajan, R. G. (1997). Trade Credit: Theories and Evidence. *The Review of Financial Studies*, vol. 10, no. 3, pp. 661-691.
- [79.] Pogue, G. A., Sartoris, W. L., Hill, N. C. (1983). A Generalized Cash Flow Approach to Short-Term Financial Decisions. *The Journal of Finance*, vol. 38, no. 2, pp. 349-360.

- [80.] Potnik Galić, K. (2008). Optimalizacija strukture obrtnoga kapitala. *Računovodstvo, revizija i financije, RRIF*, Dostupno: http://www.rrif.hr/Optimalizacija_strukture_obrtnog_kapitala-11313C.pdf
- [81.] Raheman, A., Nasr, M. (2007). Working capital management and profitability – case of Pakistani firms. *International Review of Business Research Papers*, vol. 3, no.1, pp. 279-300.
- [82.] Raheman, A., Afza, T., Qayyum, A., Bodla, M. A. (2010). Working Capital Management and Corporate Performance of Manufacturing Sector in Pakistan. *International Research Journal of Finance and Economics*, vol. 47, no. 1 pp. 151-163.
- [83.] Ramachandran, A., Janakiraman, M. (2009). The relationship between working capital management efficiency and EBIT. *Managing Global Transitions*, vol. 7, no. 1, pp. 61-74.
- [84.] Ramljak, I. (2018). *Upravljanje obrtnim kapitalom u građevinskim poduzećima*. Poslijediplomski specijalistički rad, Ekonomski fakultet, Zagreb.
- [85.] Rehn, E. (2012). *Effects of Working Capital Management on Company Profitability. An industry-wise study of Finnish and Swedish public companies*. Master's Thesis. Hanken School of Economics.
- [86.] Ross, S. A., Westerfield, R. W., Jordan, B. D. (2008). Essentials of corporate finance. 6th edn. New York: McGraw-Hill/Irwin.
- [87.] Samiloglu, F., Demirgunes, K. (2008). The Effects of Working Capital Management on Firm Profitability: Evidence from Turkey. *The International Journal of Applied Economics and Finance*, vol. 2, no. 1, pp. 44-50.
- [88.] Scharf, A. D. (1984). Productivity and Problem Solving: Don't collect Data First. In *Proceedings, Annual Conference, Institute of Industrial Engineering*, Chicago, USA.
- [89.] Seidman, K. F. (2004). *Economic Development Finance*. 1st edn. London: SAGE Publications Ltd.
- [90.] Sen, M., Oruc, E. (2009). Relationship between Efficiency Level of Working Capital Management and Return on Total Assets in Ise. *International Journal of Business and Management*, vol. 4, no. 10, pp. 109-114.
- [91.] Seyoum, A., Tesfay, T., Kassahun, T. (2016). Working Capital Management and Its Impact on Profitability Evidence from Food Complex Manufacturing Firms in Adis Ababa. *International Journal of Scientific and Research Publications*, vol. 6, no. 6, pp. 815-833.
- [92.] Sharma, A. K., Kumar, S. (2011). Effect of Working Capital Management on Firm Profitability: Empirical Evidence from India. *Global Business Review*, vol. 12, no. 1, pp. 159-173.
- [93.] Shim, J. K., Siegel, J. G. (2007). *Upravljačke financije*. Zgombić & partneri-nakladništvo i informatika, Zagreb.
- [94.] Shin, H. H., Soenen, L. (1998). Efficiency of working capital and corporate profitability. *Financial Practise and Education*, vol. 8, no. 2, pp. 37–45.

- [95.] Smith, K. (1980). Profitability Versus Liquidity Tradeoffs in Working Capital Management. In K.V. Smith (Ed), Readings on the management of working capital, St. Paul, MN: West Publishing Company, pp. 549-562.
- [96.] Sruk, B. (2007). *Strateška fleksibilnost malih i srednjih hrvatskih poduzeća u kontekstu nastupa na tržištu Europske unije*. Magistarski rad, Ekonomski fakultet u Zagrebu, Zagreb.
- [97.] Stokes, D., Wilson, N., Wilson, N. (2010). *Small business management and entrepreneurship*. Cengage Learning EMEA.
- [98.] Škrabić Perić, B. (2012). *Utjecaj stranog vlasništva banke na njezin kreditni rizik u zemljama srednje i istočne Europe: dinamički panel modeli*. Doktorska disertacija, Ekonomski fakultet, Split.
- [99.] Šošić, I. (2006). *Primijenjena Statistika, 2. Izmijenjeno izdanje*. Školska knjiga, Zagreb.
- [100.] Talonpoika, A. M., Monto, S., Pirttilä, M., Kärri, T. (2014). Modifying the cash conversion cycle: revealing concealed advance payments. *International Journal of Productivity and Performance Management*, vol. 63, no. 3, pp. 341-353.
- [101.] Tauringana, V., Afrifa, G. A. (2013). The relative importance of working capital management and its components to SMEs profitability. *Journal of Small Business and Enterprise Development*, vol. 20, no. 3, pp. 453-469.
- [102.] Tepšić, R. (1985). *Obrtna sredstva*. Informator, Zagreb.
- [103.] Unković, M., Kordić, N. (2014). *Međunarodna ekonomija*. Univerzitet Singidunum, Beograd.
- [104.] Van Horne, J., Wachowicz, Jr., J. (2002). *Osnove financijskog menadžmenta*. Mate d.o.o., Zagreb.
- [105.] Van Horne, J., Wachowicz, Jr., J. (2014). *Osnove financijskog menadžmenta*. Mate d.o.o., Zagreb.
- [106.] Vater, H., Bail, E., Klepzig, H. J. (2016). *Upravljanje radnim kapitalom*. Kontroling Kognosko d.o.o., Zagreb.
- [107.] Vishnani, S., Shah, B. K. (2007). Impact of Working Capital Management Policies on Corporate Performance-An Empirical Study. *Global Business Review*, vol. 8, no. 2, pp. 267-281.
- [108.] Vidučić, L. (2002). *Financijski menadžment*. VII edition, RRif-plus.
- [109.] Wesley, O. N., Musiega, M. G., Douglas, M., Atika, M. G. (2013). Working Capital Management And Corporate Performance. Special Reference To Manufacturing Firms On Nairobi Securities Exchange. *International Journal of Innovative Research and Development*, vol. 2, no. 9, pp. 177-183.
- [110.] Wilner, B.S. (2000). The Exploitation of Relationship in Financial Distress: The Case of Trade Credit. *The Journal of Finance*, vol. 55, no. 1, pp. 153-178.
- [111.] Wooldridge, J., M. (2012). *Introductory Econometrics: A Modern Approach*. 5th Edition, Mason Ohio: South-Western Cengage Learning.
- [112.] Yamano, T. (2009). Advanced Econometrics, lecture notes, Advanced Econometrics (Ph,D, Course), National Graduate Institute for Policy Studies.

Dostupno:

http://www3.grips.ac.jp/~yamanota/Lecture_Note_9_Heteroskedasticity

(pristupljeno: 14.03.2018.).

- [113.] Yon, R., Evans, D. (2011). The role of small and medium enterprises in frontier capital markets. *Network Science Center at West Point*, 7.
- [114.] Zariyawati, M. A., Annuar, M. N., Taufiq, H., Rahim, A. A. (2009). Working capital management and corporate performance: Case of Malaysia. *Journal of Modern Accounting and Auditing*, vol. 5, no. 11, pp. 47-54.

POPIS DRUGIH KORIŠTENIH IZVORA

- [115.] CEPOR (2017) *Izvešće o malim i srednjim poduzećima u Hrvatskoj – 2016. uključujući rezultate GEM – Global Entrepreneurship Monitor istraživanja za Hrvatsku za 2015. godinu*. [pdf] Zagreb: Centar za politiku razvoja malih i srednjih poduzeća i poduzetništva. Dostupno: <http://www.cepor.hr/wp-content/uploads/2015/04/Cepor-izvjesce-2016-HR-web.pdf> (pristupljeno: 27.08.2017.).
- [116.] DZS (2015a) *Broj i struktura poslovnih subjekata u prosincu 2015.*; Državni zavod za statistiku, Zagreb, Dostupno: https://www.dzs.hr/Hrv_Eng/publication/2015/11-01-01_04_2015.htm, (pristupljeno: 26.08.2018.).
- [117.] DZS (2015b) *Strukturno-poslovni pokazatelji poduzeća u 2015.*; Državni zavod za statistiku, Zagreb, Dostupno: https://www.dzs.hr/Hrv_Eng/publication/2017/15-01-02_01_2017.htm (pristupljeno: 29.08.2017.).
- [118.] DZS *Kalkulator inflacije*, Dostupno: <https://www.dzs.hr/app/rss/stopa-inflacije.html>
- [119.] EBRD (1994) *Transition indicators methodology*, Corporate and Investor Information, European Bank for Reconstruction and Development, Dostupno: https://www.ebrd.com/cs/Satellite?c=Content&cid=1395237866249&d=&page_name=EBRD%2FContent%2FContentLayout (pristupljeno: 29.08.2018.).
- [120.] EBRD (2014) *Forecasts, macro data, transition indicators*, Corporate and Investor Information, European Bank for Reconstruction and Development, Dostupno: <https://www.ebrd.com/what-we-do/economic-research-and-data/data/forecasts-macro-data-transition-indicators.html> (pristupljeno: 29.08.2018.).
- [121.] EOS Grupa (2017) *European Payment Practices 2017*, nezavisni institut za istraživanje tržišta Kantar TNS, Dostupno: <https://www.eos-solutions.com/paymentpractices2017/economicdriver> (pristupljeno: 01.03.2018.).
- [122.] Europska komisija (2003a) *Commission communication – Model declaration on the information relating to the qualification of an enterprise as an SME*, Official Journal C 118, Dostupno: http://eur-lex.europa.eu/legal-content/EN/TXT/?uri=uriserv:OJ.C_.2003.118.01.0005.01.ENG&toc=OJ:C:2003:118:TOC (pristupljeno: 23.08.2017.).
- [123.] Europska komisija (2003b) *Commission Recommendation of 6 May 2003 concerning the definition of micro, small and medium-sized enterprises*, C (2003) 1422, Dostupno: <http://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32003H0361> (pristupljeno: 22.08.2017.).
- [124.] Europska komisija (2016) *Vodič za korisnike o definiciji malih i srednjih poduzeća*, Dostupno:

- <https://poduzetnistvo.gov.hr/UserDocsImages/slike/Vodi%C4%8D%20za%20kategorije%20-%20definicija%20MSP.pdf> (pristupljeno: 22.08.2017.).
- [125.] Europska komisija (2017a) *Bijela knjiga o budućnosti Europe*, COM (2017), Dostupno: https://ec.europa.eu/commission/sites/beta-political/files/bijela_knjiga_o_buducnosti_europe_hr.pdf (pristupljeno: 13.08.2017.).
- [126.] Europska komisija (2017b) *Izvešće za Hrvatsku 2017. s detaljnim preispitivanjem o sprečavanju i ispravljanju makroekonomskih neravnoteža*, SWD (2017) 76 final, Dostupno: <https://ec.europa.eu/info/sites/info/files/2017-european-semester-country-report-croatia-hr.pdf> (pristupljeno: 13.08.2017.).
- [127.] Europska komisija (2017c) *2017 SBA Fact Sheet Croatia*, Dostupno: [file:///C:/Users/Darija/Downloads/Croatia%20-%202017%20SBA%20Fact%20Sheet%20\(2\).pdf](file:///C:/Users/Darija/Downloads/Croatia%20-%202017%20SBA%20Fact%20Sheet%20(2).pdf) (pristupljeno: 09.09.2018.).
- [128.] Europska komisija (2017d) *SME access to finance conditions 2017 SAFE results – Croatia*, Dostupno: <https://ec.europa.eu/docsroom/documents/26627> (pristupljeno: 09.09.2018.).
- [129.] Europska komisija (2017e) *SME access to finance conditions 2017 SAFE results – EU*, Dostupno: <https://ec.europa.eu/docsroom/documents/26625> (pristupljeno: 10.09.2018.).
- [130.] Europska komisija (2017f) *Survey on the access to finance of enterprises (SAFE)*, Analytical Report 2017, Dostupno: <https://ec.europa.eu/docsroom/documents/26641> (pristupljeno: 10.09.2017.).
- [131.] EUROSTAT (2015a) *Number of enterprises in the non-financial business economy by size class of employment (tin00145)*; European Commission, Dostupno: <http://ec.europa.eu/eurostat>, (pristupljeno: 21.08.2018.).
- [132.] EUROSTAT (2015b) *Persones employed in the non-financial business economy by size class of employment (tin00148)*; European Commission, Dostupno: <http://ec.europa.eu/eurostat>, (pristupljeno: 21.08.2018.).
- [133.] EUROSTAT (2015c) *Value added of the non-financial business economy by size class of employment (tin00147)*; European Commission, Dostupno: <http://ec.europa.eu/eurostat>, (pristupljeno: 22.08.2018.).
- [134.] EXECUTIVE OFFICE of the PRESIDENT of the UNITED STATES (2017) *North American Industry Classification System*, Office of Management and Budget, United States, Dostupno: https://www.census.gov/eos/www/naics/2017NAICS/2017_NAICS_Manual.pdf (pristupljeno: 25.08.2018.).
- [135.] FINA *Registar godišnjih financijskih izvještaja*, Dostupno: <http://rgfi.fina.hr/JavnaObjava-web/jsp/prijavaKorisnika.jsp>
- [136.] FINA *Sudski registar*, Dostupno: <http://rgfi.fina.hr/JavnaObjava-web/jsp/prijavaKorisnika.jsp>
- [137.] HAVOR *Trajna obrtna sredstva: Kreditiranje trajnih obrtnih sredstava za osnaženje poslovanja*, Dostupno: <https://www.hbor.hr/wp->

[content/uploads/2016/10/Trajna-obrtna-sredstva-PK-trajnih-obrtnih-sredstava-za-osnazenje-poslovanja.pdf](#) (pristupljeno: 30.10.2017.).

- [138.] IEG.(2008) *Financing micro, small, and medium Enterprises: An Independent Evaluation of IFC's experience with Financial intermediaries in frontier Countries*. Independent Evaluation Group, the International Finance Corporation, World Bank Group, Dostupno: <https://openknowledge.worldbank.org/bitstream/handle/10986/6485/448160PUB0Box327413B01official0use0only1.pdf?sequence=1&isAllowed=y> (pristupljeno: 09.09.2017.).
- [139.] IEG. (2014) *The Big Business of Small Enterprises: Evaluation of the World Bank Group Experience with Targeted Support to SMEs, 2006-12*. Independent Evaluation Group, the International Finance Corporation, World Bank Group, Dostupno: [http://lnweb90.worldbank.org/oed/oeddoclib.nsf/DocUNIDViewForJavaSearch/A452BA16F516CC0585257D330006CCE9/\\$file/sme_eval_updated.pdf](http://lnweb90.worldbank.org/oed/oeddoclib.nsf/DocUNIDViewForJavaSearch/A452BA16F516CC0585257D330006CCE9/$file/sme_eval_updated.pdf) (pristupljeno: 09.09.2017.).
- [140.] IMF (2000) *Transition Economies: An IMF Perspective on Progress and Prospects* International Monetary Fund, Dostupno: <https://www.imf.org/external/np/exr/ib/2000/110300.htm> (pristupljeno: 29.08.2018.).
- [141.] IMF (2014) *25 Years of Transition Post-Communist Europe and the IMF Regional Economic Issues*, International Monetary Fund, Dostupno: http://www.imf.org/external/region/bal/rr/2014/25_years_of_transition.pdf (pristupljeno: 30.08.2018.).
- [142.] London Business School *Global Entrepreneurship Monitor 2016/17*.
- [143.] Ministarstvo poduzetništva i obrta (2013). *Izvešće opservatorija malog i srednjeg poduzetništva u Republici Hrvatskoj za 2013. godinu*. U sklopu projekta Poboljšanje administrativne učinkovitosti na nacionalnoj razini, IPA 2007/HR/16/IPO/001-020201, Dostupno: <http://www.efos.unios.hr/suvremene-poslovne-aktivnosti/wp-content/uploads/sites/137/2013/04/HR-Final.pdf> (pristupljeno: 29.08.2017.).
- [144.] Odluka o Nacionalnoj klasifikaciji djelatnosti 2007. – NKD 2007., Narodne novine, br. 98/94, Dostupno: https://narodne-novine.nn.hr/clanci/sluzbeni/2007_06_58_1870.html (pristupljeno: 13.07.2016.).
- [145.] OECD-UNIDO (2004) *Effective policies for small business*. Paris: OECD.
- [146.] pwc (2015) *Bridging the Gap 2015 Annual Global Working Capital Survey*, Dostupno: <https://www.pwc.com/gx/en/business-recovery-restructuring-services/working-capital-management/working-capital-survey/2015/assets/global-working-capital-survey-2015-report.pdf> (pristupljeno: 19.09.2017.).
- [147.] U.S. Small Business Administration (2018) *SBA'S Size Standards METHODOLOGY*, Dostupno: <https://www.sba.gov/sites/default/files/2018->

[04/SBA%27s%20Size%20Standards%20Methodology%20White%20Paper%20%28April%202018%29.pdf](#), (pristupljeno: 25.08.2018.).

- [148.] WEF (2017) *The Global Competitiveness Report 2017-2018*, World Economic Forum, Geneva, Dostupno: www.aik-invest.hr/wp-content/uploads/2018/01/TheGlobalCompetitivenessReport2017-2018.pdf, (pristupljeno: 05.09.2018.).
- [149.] World Bank Group, The International Bank for Reconstruction and Development (2017) *Doing Business 2017: Equal Opportunity for All*. Washington, DC: World Bank. DOI: 10.1596/978-1-4648-0948-4. License: Creative Commons Attribution CC BY 3.0 IGO. Dostupno: <http://www.doingbusiness.org/~media/WBG/DoingBusiness/Documents/Annual-Reports/English/DB17-Full-Report.pdf> (pristupljeno: 27.08.2017.).
- [150.] World Bank Group (2018) *Doing Business 2018: Reforming to Create Jobs*. Washington, DC: World Bank. 15th edition. Dostupno: <http://www.doingbusiness.org/~media/WBG/DoingBusiness/Documents/Annual-Reports/English/DB2018-Full-Report.pdf> (pristupljeno: 09.09.2018.).
- [151.] Zakon o faktoringu, Narodne novine, br. 99/14, 85/15, 41/16, Dostupno: <https://www.zakon.hr/z/742/Zakon-o-faktoringu> (pristupljeno: 25.02.2018.)
- [152.] Zakon o poticanju razvoja malog gospodarstva, Narodne novine, br. 29/02, 63/07, 53/12, 56/13, 121/16, Dostupno: <https://www.zakon.hr/z/527/Zakon-o-poticanju-razvoja-malog-gospodarstva> (pristupljeno: 26.08.2017.).
- [153.] Zakon o računovodstvu, Narodne novine, br. 78/15, 134/15, 120/16, Dostupno: <https://www.zakon.hr/z/118/Zakon-o-ra%C4%8Dunovodstvu> (pristupljeno: 09.08.2017.).
- [154.] Zakon o sudskom registru, Narodne novine, br. 1/95, 57/96, 1/98, 30/99, 45/99, 54/05, 40/07, 91/10, 90/11, 148/13, 93/14 i 110/15, Dostupno: <http://www.propisi.hr/print.php?id=1035> (pristupljeno: 27.08.2018.).
- [155.] Zakon o trgovačkim društvima, Narodne novine, br. 111/93, 34/99, 121/99, 52/00, 118/03, 107/07, 146/08, 137/09, 125/11, 152/11, 111/12, 68/13, 110/15, Dostupno: <https://www.zakon.hr/z/546/Zakon-o-trgova%C4%8Dkim-dru%C5%A1tvima>, (pristupljeno: 27.08.2018.).

POPIS TABLICA

Tablica 1. Trgovačka društva prema pravno ustrojbenim oblicima i aktivnosti, stanje 31. prosinca 2015.	25
Tablica 2. Ukupan broj poduzeća, ukupan broj zaposlenih osoba i dodana vrijednost prema veličini poduzeća u 2015. godini	26
Tablica 3. Broj poduzeća prema gospodarskoj djelatnosti i veličini poduzeća u 2015. godini	28
Tablica 4. Broj zaposlenih osoba prema gospodarskoj djelatnosti i veličini poduzeća u 2015. godini	30
Tablica 5. Ukupna dodana vrijednost i udjeli prema gospodarskoj djelatnosti i veličini poduzeća u 2015. godini.....	32
Tablica 6. Broj poduzeća u odabranim zemljama Europske unije prema veličini poduzeća u 2015. godini.....	33
Tablica 7. Broj zaposlenih u odabranim zemljama Europske unije prema veličini poduzeća u 2015. godini.....	34
Tablica 8. Dodana vrijednost u odabranim zemljama Europske unije prema veličini poduzeća u 2015. godini.....	35
Tablica 9. Kvalitativni kriteriji u malim i srednjim poduzećima i velikim poduzećima ..	38
Tablica 10. Tranzicijski pokazatelji po zemljama u 2014. godini	44
Tablica 11. „Doing Business“ pokazatelji za Hrvatsku za 2017. i 2018. godinu	47
Tablica 12. Rangiranje Hrvatske i odabranih zemalja Europske unije prema <i>Doing Business</i> pokazateljima za 2018. godinu	49
Tablica 13. Indeks globalne konkurentnosti i faktori konkurentnosti za Hrvatsku za 2017. – 2018. godinu	50
Tablica 14. Indeks globalne konkurentnosti 2017. – 2018.	52
Tablica 15. Varijacije od prosjeka Europske unije u području poduzetništva, mjereno standardnom devijacijom	53
Tablica 16. Najvažniji problemi u Hrvatskoj i odabranim zemljama u 2017. godini ...	55
Tablica 17. Najvažniji oblici financiranja malih i srednjih poduzeća u Hrvatskoj u 2017. godini	60
Tablica 18. Veličina kredita malih i srednjih poduzeća u promatranim zemljama u 2017. godini	61
Tablica 19. Vanjsko financiranje korišteno za ulaganja u fiksnu imovinu i zalihe i obrtni kapital malih i srednjih poduzeća u 2017. godini.....	62
Tablica 20. Varijable s punim nazivom, pokratama i objašnjenjem.....	120
Tablica 21. Deskriptivna statistika za sve sektore zajedno	134
Tablica 22. Razdioba vrijednosti Spearmanovog koeficijenta korelacije.....	136
Tablica 23. Spearmanov koeficijent korelacije – svi sektori zajedno	136
Tablica 24. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima	138
Tablica 25. Korelacijska matrica parova nezavisnih varijabli	140
Tablica 26. Deskriptivna statistika za građevinarstvo	143
Tablica 27. Spearmanov koeficijent korelacije – sektor građevinarstva.....	144
Tablica 28. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima	145
Tablica 29. Korelacijska matrica parova nezavisnih varijabli	146
Tablica 30. Deskriptivna statistika za prerađivački sektor.....	149
Tablica 31. Spearmanov koeficijent korelacije – prerađivački sektor	150

Tablica 32. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima.	151
Tablica 33. Korelacijska matrica parova nezavisnih varijabli	152
Tablica 34. Deskriptivna statistika za trgovinu na malo	155
Tablica 35. Spearmanov koeficijent korelacije – sektor trgovine na malo.....	156
Tablica 36. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima	157
Tablica 37. Koeficijenti i pripadajuće standardne pogreške u dinamičkim panel regresijskim modelima	158
Tablica 38. Korelacijska matrica parova nezavisnih varijabli	159
Tablica 39. Deskriptivna statistika za trgovinu na veliko	161
Tablica 40. Spearmanov koeficijent korelacije – sektor trgovine na veliko	162
Tablica 41. Koeficijenti i pripadajuće standardne pogreške u panel regresijskim modelima	164
Tablica 42. Korelacijska matrica parova nezavisnih varijabli	165
Tablica 43. Dani naplate potraživanja – deskriptivna statistika.....	166
Tablica 44. Kruskal-Wallis test.....	166
Tablica 45. Sve moguće kombinacije sektora.....	167
Tablica 46. Kruskal-Wallis test za sve moguće parove, pripadajuće p vrijednosti i korigirane p vrijednosti (dani naplate potraživanja).....	167
Tablica 47. Dani vezivanja zaliha – deskriptivna statistika.....	168
Tablica 48. Kruskal-Wallis test.....	168
Tablica 49. Kruskal-Wallis test za sve moguće parove, pripadajuće p vrijednosti i korigirane p vrijednosti (dani vezivanja zaliha)	169
Tablica 50. Dani plaćanja dobavljača – deskriptivna statistika	169
Tablica 51. Kruskal-Wallis test.....	169
Tablica 52. Kruskal-Wallis test za sve moguće parove, pripadajuće p vrijednosti i korigirane p vrijednosti (dani plaćanja dobavljača)	170
Tablica 53. Usporedni prikaz rezultata za sve sektore zajedno i za svaki sektor pojedinačno	170
Tablica 54. Udio tekuće imovine u ukupnoj imovini	181
Tablica 55. Udio tekućih obveza u ukupnoj imovini	183

POPIS SLIKA

Slika 1. Permanentna i privremena tekuća imovina	68
Slika 2. Položaj neto obrtnog kapitala u bilanci poduzeća	69
Slika 3. Konzervativna strategija upravljanja obrtnim kapitalom	102
Slika 4. Agresivna strategija upravljanja obrtnim kapitalom	103
Slika 5. Potrebe za financiranjem i imovinom tijekom vremena: umjerena strategija financiranja i usklađivanje dospijeća	104
Slika 6. Medijan dana potrebnih za pretvorbu obrtnih sredstava u prihode od prodaje	111
Slika 7. Kvartili potrebnih dana za pretvorbu obrtnih sredstava u prihode od prodaje	112
Slika 8. Medijan i kvartili dana naplate potraživanja po sektorima	113
Slika 9. Medijan i kvartili dana vezivanja zaliha po sektorima	114
Slika 10. Medijan i kvartili dana plaćanja dobavljača po sektorima	115
Slika 11. Ciklus konverzije novca po sektorima	116

LONG ABSTRACT

Within the scope of finance and the area of financial analysis, specifically business finance, the narrow field of this doctoral thesis is working capital management. The latter is more precisely the management of net operating capital, inventory management, customer claims and suppliers' obligations. At the core of the interest of working capital is the way companies use and manage working capital. The management of working capital, on the one hand, has an impact on the liquidity and safety of the company, and on the other hand, on the profitability and risk of the company (Shin and Soenen, 1998). Most financial management projects focus on studying long-term financial and investment decisions, while short-term decisions, or decisions on working capital management, are less represented in literature and scientific studies.

Good working capital management implies the adoption of correct short-term decisions, or decisions on the working capital management of working capital, which will maximize the profits of a company, considering a whole range of risks. Efficient working capital management means achieving a balance between profitability and liquidity, and profitability and risk. The problem of poor management of working capital carries several negative effects on the level of profitability of the company, but also on the general wealth of the owner. If companies in their property structure have a higher level of working capital, they may expect a lower level of business risk, but also a worse impact on the level of profitability. This problem is particularly pronounced in companies with a high share of short-term assets in total assets and largely financed from short-term sources. Working capital must be shaped to contribute to the creation of shareholder value.

Various studies have analyzed the relationship between the management of working capital and the profitability of companies of different sizes in different markets. The results obtained are quite different because they are influenced by the market on which the company operates and the size of the company. Most of the research on working capital management has been conducted in the most developed countries, while the management of working capital is insufficiently explored in the transition and post-transition countries. Croatia belongs to a post-transition group characterized by less developed financial markets and a bank-centric financial system. The largest number of studies were conducted in the United States, Great Britain, Western Europe and

other developed countries, while much less research was conducted in developing countries. Research related to developing countries is more focused on India, Malaysia and other Asian countries. From transitional countries research is largely present in the Baltic countries, which operate in a specific Scandinavian environment, so research is not sufficiently transparent to be generalized to other transitional and post-transition countries, especially not in Croatia or its region.

The working capital management in developing and post-transition countries has been considered in the context of market survival without thinking about the consequences and the impact on the level of profitability. Over the last 20 years, the impact of the key level of company-wide working capital management factors has been studied, which significantly influences the company's profitability level and opens the possibility of thinking about a different impact rather than the traditional acceptance of the impact. There is a possibility of thinking about optimal levels, different influences across different sectors, but also between different countries as well as different impacts between companies of different sizes. Given these differences, it is necessary to continuously monitor each factor over a longer period, and then compare it with companies in the same sector. It must be borne in mind that the management of working capital is not only dependent on decisions within the enterprise, but also on a series of imposed policies by customers, suppliers, banks, but also on the influence of the state and the market, which requires constant management's readiness to be responsive to changes in the same.

The subject of this PhD thesis is the identification of common factors of company-wide working capital management in order to increase the profitability of small and medium-sized enterprises and analyze the impact of common corporate capital stock management at the enterprise level on the profitability of small and medium-sized enterprises in four industry branches that make up the largest share in structure small and medium-sized enterprises, namely: civil engineering, processing, retail and wholesale.

The main goal of this thesis results from such a defined subject. The main goal is to examine the relationship between working capital management and profitability of SMEs in the Republic of Croatia and provide empirical evidence on the effects of working capital management on the level of profitability of small and medium-sized enterprises in the Republic of Croatia.

To reach the main goal, these specific goals are defined:

- establish and systematize key management factors of working capital at company level which significantly influence the level of profitability of small and medium-sized enterprises;
- develop a model for an impact analysis of working of capital management on the level of profitability of small and medium-sized enterprises in a specific environment, characterized by post-transition countries;
- include in the model of analysis the affiliation of different sectors;
- determine the diversity of the impact of corporate funded equity management factors across different sectors;
- analyze and evaluate the key factors of working capital management that affect the level of profitability in Croatian small and medium enterprises and compare them in different sectors;
- isolate the specific circumstances of Croatia as a post-transition economy;
- analyze the impact of accounts receivable on the level of profitability of small and medium-sized enterprises for all sectors together;
- analyze the impact of inventory management on the level of profitability of small and medium-sized enterprises for all sectors together;
- analyze the impact of accounts payable on the level of profitability of small and medium-sized enterprises for all sectors together;
- analyze the impact of enterprise size on the level of profitability of small and medium-sized enterprises for all sectors together;
- analyze the impact of sales growth on the level of profitability of small and medium-sized enterprises for all sectors together;
- analyze the impact of inflation on the level of profitability of small and medium-sized enterprises for all sectors together;
- analyze the impact of GDP on the level of profitability of small and medium-sized enterprises for all sectors together;

- analyze the sector's impact on the level of profitability of small and medium-sized enterprises;
- analyze the impact of accounts receivable on the level of profitability of small and medium-sized enterprises for each sector in particular;
- analyze the impact of inventory management on the level of profitability of small and medium-sized enterprises for each sector in particular;
- analyze the impact of accounts payable on the level of profitability of small and medium-sized enterprises for each sector in particular;
- analyze the impact of enterprise size on the level of profitability of small and medium-sized enterprises for each sector in particular;
- analyze the impact of the sales growth of the company on the level of profitability of small and medium-sized enterprises for each sector in particular;
- analyze the impact of inflation on the level of profitability of small and medium-sized enterprises for each sector in particular;
- - analyze the impact of GDP on the level of profitability of small and medium-sized enterprises for each sector in particular.

Following all this, the next first working hypothesis is set:

H1. Accounts receivable, accounts payable, stock inventory, company's size and sales growth on the company level have an impact on the profitability levels of small and medium-sized enterprises in Croatia.

Such a hypothesis implies several additional hypotheses:

H1.1. There is a significant and negative impact of accounts payable on the company's profitability.

H1.2. There is a significant and negative impact of the stock inventory of the company's profitability.

H1.3. There is a significant and positive impact of the accounts receivable on the level of profitability of the company.

H1.4. There is a significant and positive impact of the size of the company on the level of profitability of the company.

H1.5. There is a significant and positive impact of the company's sales growth on the company's profitability.

H1.6. There is a significant impact of the sector on the level of profitability of the company.

H1.7. There is a significant impact of inflation on the level of profitability of the company.

H1.8. There is a significant impact of GDP on the level of profitability of the company.

In continuation, the second working hypothesis is set:

H2. The impact of accounts payable, stocks, accounts receivable, company's size and sales growth on the profitability levels of small and medium-sized enterprises is different in different industry sectors.

Such a hypothesis implies several additional hypotheses:

H2.1. The impact of accounts payable on the company's profitability level will be different in different sectors

H2.2. The impact of stocks on the level of profitability of the company will be different in different sectors.

H2.3. The impact of accounts receivable on the level of profitability of the company will be different in different sectors.

H2.4. The impact of company size on the company's profitability level will be different in different sectors.

H2.5. The impact of sales growth on the level of profitability of the company will be different in different sectors.

H2.6. Influence of inflation on the level of profitability of the company will be different in different sectors.

H2.7. The impact of GDP on the level of profitability of the company will be different in different sectors.

As a result of thus set research goals and hypotheses, the doctoral thesis is, with an introduction and a conclusion, structured in five chapters. From the second to fifth chapters the theoretical framework of the doctoral field work is presented, while in the

sixth chapter the empirical part of the research focuses on testing the hypothesis and achievement of the research objectives.

The second chapter defines the criteria for determining small and medium-sized enterprises and the use of different definitions of small and medium-sized enterprises in Croatia and the world. There is often a problem when international organizations and governments of individual countries, which work together to allocate funds within different programs, use different criteria for defining small and medium-sized enterprises. Berisha and Shiroka Pula (2015) state that the definitions differ between international institutions, national laws and sectors. For example, within the World Bank group, there are different definitions. The European Union's countries most often apply the definition of the European Commission, but the European Commission only encourages members to apply its definitions, not committing them. Also, many scientists and researchers use different definitions, most often depending on the databases they used in their research. The criteria for classifying micro, small and medium sized companies in Croatia are defined by the Accounting Law (NN 120/16) and the Small Business Development Promotion Act (NN 121/16), in accordance with Commission Recommendation 2003/361 / EC of May 6th, 2003. In this PhD thesis the criteria and definition of small and medium enterprises were used according to the Accounting Law.

The same chapter presents the structure, size and composition of small and medium-sized enterprises in the Republic of Croatia and selected European Union countries. In Croatia, the largest number of companies are micro enterprises that also employ the highest number of people, and immediately behind them are large companies by the number of employees. The largest value added is made by large companies. The wholesale and retail trade sector have the largest number of companies in the total number of companies of all sizes. By the number of persons employed, the most important is the processing industry, then wholesale and retail, and civil engineering. Value creation is the most important activity of the processing industry, then wholesale and retail trade, transport and storage and construction. Also, in the EU, micro enterprises are the largest in number and employ most people in most countries. Exceptions are Austria, the Czech Republic, Romania, Bosnia and Herzegovina and the UK where large companies have the largest number of employees. The largest value added in the countries surveyed also have large companies. At the end of the

chapter, key differences between small and medium-sized enterprises and large enterprises are defined. Differences between small and large enterprises are reflected from the point of view of potential investors and from the standpoint of financial management (Orsag, 2002).

The third chapter defines the concept of transition in the so-called transition countries and the main constituents of the transition process. It is an overview of the transition countries, considering the criteria of the transition processes in different countries and the classification of transition countries of the International Monetary Fund. The European Bank for Reconstruction and Development has developed a classification system that assesses the progress of countries in the transition process. According to the mentioned transition indicators, the progress of the Republic of Croatia and selected countries in the transition process has been analyzed. Depending on progress towards the country's transition indicators, some countries have progressed more, some less, so it can be concluded that there are countries in transition and those in post-transition. According to some authors, Croatia was expected to make much more progress in the transition process, and they present the causes why it did not meet expectations. In the same chapter, the conditions of business of the Republic of Croatia and the observed countries were analyzed in different thematic areas. Some of the most well-known international researches such as World Bank *Doing Business Report*, Global Economic Forum Global Competitiveness Report, European Commission SBA Fact Sheet and others report have been analyzed. Special attention is given to the entrepreneurial problems of small and medium-sized enterprises in the Republic of Croatia and institutional support for small and medium-sized enterprises in the Republic of Croatia. At the end of the third chapter, access to finance was analyzed and different criteria were determined for funding in each country. The most important forms of SME financing in the Republic of Croatia and EU countries and the use of external forms of financing are presented as well.

The fourth chapter provides the theoretical framework for working capital management. It starts from defining the concept of working capital and the concept of gross working capital, the concept of net working capital and the concept of net operating working capital. The term "working capital" is often defined with current assets and capital. Next to the latter, a clear distinction is made between these terms. Working capital is part of the assets used by the company for its business purposes, but also the way it is

financed. The workflow function is illustrated through the workflow cycle. Gross or total working capital is defined through different perspectives. Also, net working capital is defined as part of the current assets and how it is financed (Orsag, 2015) and how companies finance their assets in the case of positive and negative net working capital. Finally, net operating capital or non-cash working capital is defined, which is the focus of this doctoral work, and is the difference between the operating current assets and the operating current liabilities of the company.

After that, according to various authors, the purpose of managing the working capital was explained and the importance of working capital management because of its impact on the company's profitability, the value of the company, liquidity and solvency of the company. At the core of working capital management is the effective management of working capital, the relationship between the efficiency of the working capital management and the profitability of the company. The cash conversion cycle is illustrated as the most common measure of the efficiency of working capital management and the effect of shortening the money conversion cycle on the main components of working capital. Definition of the optimal size and structure of working capital is detailed, as well as the problem of achieving the same in practice. At the end of the chapter, the concept of managing liquid assets and current liabilities is presented. Considering the focus of this PhD thesis, an overview is given of the emerging forms of stock inventories, accounts receivable and accounts payable, as well of the supplier's trade credit, the most important form of financing working capital or current assets.

The fifth chapter gives an overview of the working capital management strategy. The company may conduct a conservative or aggressive management strategy for working capital. The conservative management strategy of working capital gives priority to business security and liquidity (Orsag, 2003) and is characteristic for companies operating in developing and post-transition countries and for more unstable macroeconomic environments. Aggressive capital-working management strategy favors profitability versus security and liquidity (Orsag, 2003) and is characteristic for companies operating in more developed and economically advanced countries with stable macroeconomic environments. There is conservatism and aggressiveness in the investment and financial management strategy of working capital, and so are strategies of investment in working capital as well as the strategy of financing working

capital. In the same chapter there is an overview, brief explanations and calculations of working capital indicators. At the end of the fifth chapter, the industry's impact on working capital management was analyzed. An analysis is presented of the days of collection of claims by sector, the dates of stockpiling by sectors, the payment period of suppliers by sector, the days needed for the company to convert its working capital into sector revenue and the cash conversion cycle by sectors.

The sixth chapter presents an empirical part of the research focused on hypothesis testing and achievement of research goals. Theoretical considerations and empirical assertions have identified and systematized key management factors of working capital at company level which significantly affect the profitability of small and medium-sized enterprises in all industrial branches, but the impact of each of these variables is not of the same direction and intensity in companies in different sectors. Joint corporate equity management factors affecting the company's profitability include stocks, accounts receivables, accounts payables, business size, sales growth, sector (industry), inflation and GDP. According to the traditional acceptance of the influence of the working capital management factors on the profitability of the company, the negative impact of accounts receivable and stock payment on the company's profitability and the positive impact of the accounts payable, sales size and sales growth on the company's profitability level are outweighed.

Starting from the inductive approach, empirical research on a selected sample was performed. For the purpose of proving the main and ancillary hypothesis of a panel analysis, the impact of accounts receivable, inventories, accounts payable, company size, sales growth, GDP growth, inflation rate and sector on the level of profitability of small and medium-sized enterprises was examined. The data analysis panel analyzed the impact of accounts receivable, inventories, accounts payable, company size, sales growth, GDP growth and inflation rates on the level of profitability of small and medium-sized enterprises in four sectors: civil engineering (24% in the total sample), processing industry (24% in the total sample), retail trade (23% in the total sample) and wholesale trade (29% in the total sample). In the appropriate panel model, dependent variables were profitability, independent variables were accounts receivable, inventories and accounts payable, while control variables were the size of the enterprise, sales growth, GDP, inflation and industry (affiliation to the sector). The focus of this paper was on small and medium-sized enterprises that account for the largest share in the structure

of small and medium-sized enterprises and at the same time have a high level of working capital in the structure of total assets.

At the beginning of the analysis a descriptive statistical analysis of data was made. For all variables, the arithmetic mean, the standard deviation, the minimum and maximum value, and the number of observations of each variable were given. Then the basic model 1 was set for all sectors together, as well as additional models for all four sectors individually. For each of the 5 analyzes, three basic panel models have been set: a joint model, a fixed-effect model, and a random-effect model.

The results of the research partially confirm the first fundamental hypothesis of work. The model confirmed the impact of *stock inventories*, *accounts payable* and *sales growth* on the level of profitability of small and medium-sized enterprises in Croatia, while the impact of *accounts receivable* and *company size* on the level of profitability of small and medium enterprises in Croatia has not been confirmed. The control variable *sector* was statistically significant, while *GDP* and *inflation* were statistically significant.

The results of the research partially confirm the second fundamental working hypothesis. Influence of inventories, accounts payable, enterprise size, sales growth and GDP at the level of profitability of the company proved to be significant in certain sectors and different in different sectors, namely in civil engineering, processing industry, retail and wholesale, while the impact of accounts receivable and inflation on the level of profitability of small and medium-sized enterprises did not prove significant.

From the results of this paper it can be concluded that the different level of working capital is of different significance for the observed sectors, that is, that the influence of working capital on the level of profitability of the company is influenced by the sector. This has been proven by introducing a variable sector that has proved to be significant.

The first auxiliary hypothesis of the second main hypothesis is dismissed. The results did not show any significant impact of accounts receivable on the level of profitability of small and medium-sized enterprises, in any of the sector. No significance was gained anywhere. The results obtained are not consistent with the results of most researchers. In accordance with the above results, the second basic working hypothesis is rejected.

The second auxiliary hypothesis of the second basic working hypothesis is accepted. The results showed a significant impact of stock inventories on the level of profitability of small and medium-sized enterprises in individual sectors and the varying impact of stocks on the level of profitability of small and medium-sized enterprises among the sectors, thus confirming the second auxiliary hypothesis of the second basic hypothesis. Significant and negative relations were made in the processing industry, the retail trade and the wholesale trade sector. The results did not show a significant impact on the stock of the profitability of small and medium-sized enterprises in the civil engineering sector.

The third auxiliary hypothesis of the second basic working hypothesis is accepted. The results have shown a significant impact of accounts payable on the level of profitability of small and medium-sized enterprises in individual sectors and the different impact of accounts payable on the level of profitability of small and medium-sized enterprises across sectors, thus confirming the third auxiliary hypothesis of the second basic hypothesis. Significant and negative relations in the civil engineering, processing industry and the retail trade sector have been obtained. Contrary to expectations, the results did not show a significant impact on the payment of obligations to suppliers on the level of profitability of small and medium-sized enterprises in the wholesale trade.

The fourth auxiliary hypothesis of the second basic hypothesis is accepted. The results showed a significant impact of the size of the company on the level of profitability of small and medium-sized enterprises in only one sector and the different impact of enterprise size on the level of profitability of small and medium-sized enterprises across sectors thus confirming the fourth auxiliary hypothesis of the second basic hypothesis. Significant and positive relationship was reached in the civil engineering sector. The results did not show a significant impact of the size of the company on the level of profitability of small and medium-sized enterprises in the processing industry, the retail trade sector and the wholesale trade sector.

The fifth auxiliary hypothesis of the second basic working hypothesis is accepted. The results have shown a significant impact of the sales growth of the company on the level of profitability of small and medium-sized enterprises in only one sector and the different impact of sales growth on the level of profitability of small and medium-sized enterprises among the sectors, thus confirming the fifth auxiliary hypothesis of another basic hypothesis. A significant and positive relationship has been gained in the

processing industry, which means that the growth of sales affects the profitability of the company. The results did not show a significant impact of sales growth on the level of profitability of small and medium-sized enterprises in the civil engineering, the retail trade and the wholesale trade sectors.

The sixth auxiliary hypothesis of the second basic hypothesis is dismissed. The results did not show a significant impact of inflation on the level of profitability of small and medium-sized enterprises in any sector, which did not confirm the sixth auxiliary hypothesis of the second basic hypothesis. No significance was gained anywhere.

The seventh auxiliary hypothesis of the second basic hypothesis is accepted. The results showed a significant impact of GDP on the level of profitability of small and medium-sized enterprises in only one sector and the different impact of GDP on the level of profitability of small and medium-sized enterprises across sectors, thus confirming the seventh auxiliary hypothesis of the second basic hypothesis. Significant and negative relations were obtained in the civil engineering sector while the results did not show a significant impact of GDP on the level of profitability of small and medium-sized enterprises in the processing industry, the retail trade and the wholesale trade sector.

Civil engineering companies could have an impact on increasing their company's profitability if they are not delinquent in paying their obligations to suppliers so that there is no strain on supplier relationships due to delays in payment and increases in costs due to late interest, penalties or court costs. In line with expectations, the size of the company has influenced the company's profitability increase. Enterprises in the construction sector are the only companies affected by GDP growth and this is negative, as the GDP growth has affected the company's profitability decline. In the periods of GDP growth, companies should always be ready to compensate profitability through other measures and sources. Compared to the other observed three sectors, the sector of civil engineering has the highest level of collection of receivables while on the other hand they have on average the largest number of payment obligations to suppliers. In accordance with the above-mentioned inventory management features, the construction sector will have at least the minimum stockpiling time on average. Construction companies will have the fastest cash conversion cycle. On the one hand, they have the longest days of collecting receivables from customers, and on the other hand, the most striking is the payment of obligations towards suppliers.

Companies of the processing industry could have an impact on increasing their companies' profitability if they do not delay paying its obligations to suppliers in order to avoid additional costs and, on the other hand, make use of the discount offered by the supplier. Also, companies can increase their profitability through a larger turnover of stocks, that is to keep stocks as shortly as possible in the warehouse to avoid additional storage costs, raw material and material damage costs. In line with the expectations of sales growth, the company will leverage the profitability of the company.

Retail trade companies may have an impact on increasing company's profitability by paying off its obligations to suppliers as soon as possible to avoid extra costs and using rebates from early payment providers. Also, companies could increase their profitability through a larger turnaround, or timely order, to make stocks as shorter as possible in the warehouse. In retail trade, the biggest inventory expense is the perturbation of goods. Enterprises from the retail trade sector, compared to the other three sectors, have the lowest level of collection of receivables and, on the other hand, the largest stockholding dates. Its liabilities to suppliers of companies in this sector are payed the fastest in relation to the other three sectors surveyed. The retail trade section is, based on the money conversion cycle, located immediately after the civil engineering.

In the wholesale trade sector, the lowest impact of working capital was found on the company's profitability level. Only shortening inventory time has led to increased profitability of the company. All other variables did not have a significant impact.

The research has improved knowledge of the management of working capital. The scientific contribution of the research is already showed in the review and systematization of the current research in this area. It is an area that is still underrepresented. Up until now, the researches mainly focused on large corporations and public joint stock companies. The focus of this paper on small and medium-sized enterprises in the conditions of small post-transition economies, and the analysis of the management of working capital in the whole sector of small and medium-sized enterprises and by major industrial branches, has significantly enriched the scientific literature in this area.

The fundamental scientific contribution of this paper and the subject matter of the research consists of research findings that have identified and systematized the key factors of company-wide working capital management as well as how the key factors

of company-wide working capital management significantly affect the profitability of small and medium-sized enterprises in post-transition economies.

The scientific contribution is reflected in the development of a model for the analysis of the impact of the capital management on the profitability of small and medium-sized enterprises in a specific environment, characterized by post-transition countries. Although the model was tested for small and medium-sized companies in the Republic of Croatia, it is also applicable for the implementation of other similar transitional and post-transition countries, especially those from the immediate surroundings.

The model has also enabled inclusion in the examination of different industrial branches. This has led to the expansion of knowledge about the management of working capital on the diversity of the impact of company-wide working capital management factors in different industrial branches. The researches carried out confirmed the different impact of company-wide working capital management factors in different industrial branches.

The scientific contribution was also achieved through the results of the analysis and evaluation of key working capital management factors that affect profitability in Croatian companies and their comparison in different industrial branches.

The research was carried out on Croatian companies, but the same can be deduced and extended to the countries of the region, as the specific circumstances of Croatia as a post-transition economy were isolated, including the consequences of transition. Research is sufficiently transparent to be applied or generalized to the area of other post-transition and transition countries, especially in the region. The application of the results of the research also consists in informing all the actors of the management of working capital of post-transition countries.

Apart from theoretical considerations, the results of the scientific research presented in the doctoral dissertation has given scientific contribution to economic sciences in theoretical and applicative terms. Scientific results and findings will have their application side, as they will help improve the management of working capital in small and medium-sized enterprises. It is expected that the knowledge of this paper will awaken awareness of the existing problems of working capital management.

ŽIVOTOPIS AUTORICE I POPIS OBJAVLJENIH RADOVA

Darija Prša rođena je 9. svibnja 1982. godine u Požegi. Majka je jedne djevojčice. Osnovnu školu pohađala je u Pleternici, a srednju Opću gimnaziju u Požegi. Diplomirala je 2005. god. na Ekonomskom fakultetu Sveučilišta u Zagrebu, smjer Računovodstvo. Ima 14 godina radnog iskustva u području financija i računovodstva. Radila je u Hrvatskoj agenciji za nadzor financijskih usluga i u Raiffeisen mirovinskom društvu za upravljanje dobrovoljnim mirovinskim fondovima na mjestu voditelja Back Officea te u Privatnoj srednjoj ekonomskoj školi Katarina Zrinski na mjestu nastavnika ekonomske grupe predmeta i statistike. 2011. godine stekla je akademski stupanj magistra znanosti na Ekonomskom fakultetu Sveučilišta u Zagrebu, smjer Financije poduzeća. Od 2010. godine zaposlena je na Veleučilištu Vern' na katedri Financije, računovodstvo i pravo, gdje je nositeljica pet predmeta i izvođačica osam predmeta na preddiplomskim i diplomskim stručnim studijima. Objavila je niz znanstvenih i stručnih radova i aktivno sudjelovala na nekoliko međunarodnih konferencija. 2018. godine imenovana je zamjenicom predstojnika katedre Financija, računovodstva i prava. Doktorski studij upisala je 2012. godine na Ekonomskom fakultetu Sveučilišta u Rijeci.

OBJAVLJENI RADOVI:

Znanstveni radovi objavljeni u indeksiranim zbornicima radova:

- Prša Krunić, D., Dražić Lutilsky, I. (2011). Utvrđivanje cijena usluga u obrazovnim neprofitnim organizacijama pomoću ABC računovodstvenog modela, *Zbornik Ekonomskog fakulteta*, str. 243-263.
- Prša Krunić, D., Dražić Lutilsky, I. (2012). Implementation of the Balanced scorecard model in a non-profit organisation – a virtual secondary school model, *Sarajevo Business and Economics Review* 32/2012, str. 33-53.

Stručni radovi u domaćim časopisima važnim za struku:

- Prša Krunić, D. (2012). Implementacija ABC metode u srednjoškolsku ustanovu, *Računovodstvo i porezi u praksi*, str. 72-75.
- Prša Krunić, D., Žunić, M. (2013). Analiza vremenskog niza realnog prometa trgovine na malo u RH, *Suvremena trgovina*, str. 54-59.

- Prša Krunić, D., Dražić Lutilsky, I. (2013). Obilježja „Balanced Scorecard“ modela, *Računovodstvo i financije*, str. 16-18.
- Prša, D., Banić, M. (2018). Utjecaj trgovačkog kredita dobavljača na profitabilnost velikih poduzeća s područja djelatnosti trgovina na veliko i na malo u RH, *Suvremena trgovina*, str. 66–70.
- Prša, D., Banić, M. (2018). Analiza agresivne i konzervativne strategije upravljanja obrtnim kapitalom na primjeru malih poduzeća iz hotelijerske industrije, *Suvremena trgovina*, str. 24-27.

Konferencije:

- Prša Krunić, D., Dražić Lutilsky, I. (2012). Recognition of revenues and expenses in Croatian non-profit organizations, *An Enterprise Odyssey: Corporate governance and public policy – path to sustainable future*, 6th International Conference, University of Zagreb, Faculty of Economics and Business, Šibenik, Croatia, ISBN 978-953-6025-57-2, str. 567-581.
- Prša Krunić, D. (2012). Prednosti prelaska neprofitnih organizacija sa modificirane novčane osnove na potpunu obračunsku osnovu priznavanja poslovnih događaja, *Vallis Aurea – focus on: Regional Development*, 3rd International Conference, Veleučilište u Požegi i DAAAM International Vienna, Požega, Croatia, ISBN 978-3-901509-78-0, str. 0795-0799.

IZJAVA

kojom ja, Darija Prša, broj indeksa: 86/11 doktorandica Ekonomskog fakulteta Sveučilišta u Rijeci, kao autorica doktorske disertacije s naslovom: Utjecaj upravljanja obrtnim kapitalom na profitabilnost malih i srednjih poduzeća u post-tranzicijskom gospodarstvu.

1. Izjavljujem da sam doktorsku disertaciju izradila samostalno pod mentorstvom prof. dr. sc. Silvija Orsaga, a pri izradi doktorske disertacije rada pomagala mi je i komentorica: prof. dr. sc. Mira Dimitrić. U radu sam primijenila metodologiju znanstvenoistraživačkog rada i koristila literaturu koja je navedena na kraju rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući navela u radu citirala sam i povezala s korištenim bibliografskim jedinicama sukladno odredbama Pravilnika o izradi i opremanju doktorskih radova Sveučilišta u Rijeci, Ekonomskog fakulteta u Rijeci. Rad je pisan u duhu hrvatskog jezika.
2. Dajem odobrenje da se, bez naknade, trajno pohrani moj rad u javno dostupnom digitalnom repozitoriju ustanove i Sveučilišta te u javnoj internetskoj bazi radova Nacionalne i sveučilišne knjižnice u Zagrebu, sukladno obvezi iz odredbe članka 83. stavka 11. Zakona o znanstvenoj djelatnosti i visokom obrazovanju (NN 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).

Potvrđujem da je za pohranu dostavljena završna verzija obranjene i dovršene doktorske disertacije. Ovom izjavom, kao autorica dajem odobrenje i da se moj rad, bez naknade, trajno javno objavi i besplatno učini dostupnim studentima i djelatnicima ustanove.

Darija Prša

U Rijeci, 23.04.2019.