Utjecaj strukture kapitala na profitabilnost poduzeća

Mamut, Jelena

Master's thesis / Diplomski rad

2017

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:464865

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILISTE U SPLITU
EKONOMSKI FAKULTET

DIPLOMSKI RAD

UTJECAJ STRUKTURE KAPITALA NA PROFITABILNOSTI PODUZEĆA

Mentorica:
Doc. dr. sc. Sandra Pepur

Studentica:
Jelena Mamut

Split, rujan, 2017

SADRŽAJ:

1. UVOD 1
1.1 Definicija problema 1
1.2 Predmet istraživanja 4
1.3 Istraživačke hipoteze 5
1.4 Ciljevi istraživanja 6
1.5 Metode rada 6
1.6 Doprinos istraživanja 6
1.7 Struktura rada 7
2. TEORIJSKI ASPEKT STRUKTURE KAPITALA I PROFITABILNOSTI 8
2.1 Pregled teorija strukture kapitala 8
2.1.1 Teorija redoslijeda pakiranja 9
2.1.2 Trade-off teorija 13
2.2 Pojam profitabilnosti i njezino mjerenje 16
2.3 Dosadašnja istraživanja o odnosu strukture kapitala i profitabilnosti 17
2.4 Poduzeću specifične determinante profitabilnosti 22
2.5 Pokazatelji uspješnosti i zaduženosti poslovanja 26
3. EMPIRIJSKO ISTRAŽIVANJE 31
3.1 Kretanje zaduženosti i profitabilnosti poduzeća u Hrvatskoj 31
3.3 Definiranje uzorka i varijabli 42
3.3 Metodologija istraživanja 43
3.5 Rezultati istraživanja 44
3.5.1 Rezultati regresijskog modela s tradicionalnom mjerom profitabilnosti - ROA 44
3.5.2 Rezultati regresijskog modela s tržišnom mjerom profitabilnosti P/E (2016. g.) ... 49
3.6 Osvrt na istraživačke hipoteze 52
4. ZAKLJUČAK 54

5. LITERATURA.....57
6. POPIS TABLICA I SLIKA.....62
7. PRILOG.....63

1. UVOD

1.1 Definicija problema

Svako poduzeće želi uspješno poslovati. Pri tome se uspješnost može različito promatrati i definirati. Sve donedavno smatralo se da je maksimizacija profita osnovni i najsveobuhvatniji cilj poslovanja[1]. Iako je poslovati profitabilno (rentabilno) cilj kojeg teže ostvariti svi poslovni subjekti, cilj koji najbolje objašnjava prema čemu su usmjerene različite odluke koje se donose u poduzeću je cilj maksimalizacije bogatstva vlasnika (dioničara). Jedna od takvih važnih odluka koja može utjecati na profitabilnost poslovanja je i odluka o financiranju. Financiranje je iznimno važno u različitim fazama životnog ciklusa poduzeća – od osnivanja, tekućeg poslovanja, preko rasta i razvoja. Poduzeću su na raspolaganju dva osnovna izvora financiranja – vlastiti izvori (dionički kapital, rezerve i zadržana dobit) i tuđi izvor (zaduživanje odnosno dug, neovisno o ročnosti i plasmanu…). Struktura izvora financiranja poduzeća, koju prikazuje pasiva bilance, naziva se financijska odnosno kapitalna struktura. Razlika u terminologiji pretpostavlja razliku u obuhvatu duga[2]. Naime, za razliku od šireg obuhvata pojma financijske strukture, pojam kapitalne strukture je užeg obuhvata i podrazumijeva strukturu dugoročnih izvora financiranja, odnosno pokazuje odnos vlastitog (dioničkog) kapitala i dugoročnog duga unutar ukupnog dugoročnog kapitala poduzeća. Dakle, razlika pojma kapitalne strukture u odnosu na širi pojam financijske strukture je u (ne)obuhvatu kratkoročnog duga.

Na profitabilnost poduzeća utječe cijeli niz faktora, a kapitalna struktura je jedan od onih čimbenika koji intrigira znanstvenike i praktičare dugi niz godina. Prva teorija o strukturi kapitala, Millerova i Modiglianiova teorija o irelevantnosti strukture kapitala (prije-porezna verzija), seže iz 1958. godine. Prema ovoj teoriji, struktura kapitala nema utjecaja na vrijednost poduzeća, odnosno vrijednost zaduženog poduzeća je ista kao i vrijednost nezaduženog poduzeća. Navedeno je impliciralo da je svejedno hoće li se financijski menadžer za financiranje zadužiti ili koristiti vlastita sredstva. Tvrdili su da će čak i u situaciji jeftinijeg izvora financiranja putem duga struktura kapitala biti bez utjecaja na prosječni ponderirani trošak kapitala. Naime, ušteda dobivena dugom će se poništiti s

[1] Vidučić, L. (2012): Financijski menadžment, 8. nepromijenjeno izdanje, str. 13.
[2] Za potrebe ovoga rada, pojmovi financijska struktura, kapitalna struktura i zaduženost će se koristiti naizmjenično, kao sinonimi.

povećanjem stope povrata na vlastiti kapital zbog povećanog rizika poduzeća zbog korištenja poluge. Njihovo mišljenje se mijenja uvođenjem poreznih zakona koji su dug činili porezno priznatim troškom zbog čega je dug naposljetku mogao povećati vrijednost poduzeća više nego vlastiti kapital. Novim radom iz 1964. godine su objavili svoje *poslije-porezne postavke* prema kojima je vrijednost zaduženog poduzeća veća od vrijednosti nezaduženog poduzeća. Prema tome, vrijednost poduzeća raste s povećanjem količine duga ovisno o stopi korporativnog poreza odnosno poreza na dobit. Pri tome se za povećanje vrijednosti zaduženog poduzeća uzima u obzir diskontirana vrijednost porezne uštede zbog povoljnog poreznog tretmana kamata, odnosno takozvana porezna zaštita.

Slijedeća teorija o strukturi kapitala je nastala kao odgovor na teoriju o irelevantnosti strukture kapitala te proširuje njezin pogled na visinu duga. Naime, prema prvoj teoriji vrijednost poduzeća je maksimalna kada se struktura kapitala sastoji samo od duga, maksimizirajući pri tome efekt porezne zaštite. Međutim, pri tome nije uzeto u obzir povećanje rizika poduzeća koje koristi financijsku polugu zbog rizika stečaja pri nemogućnosti plaćanja dospjelih obveza. Zbog toga se pri *tradicionalnom gledištu na strukturu kapitala* u središte pozornosti stavlja prosječni ponderirani trošak kapitala (engl. WACC[3]). Prema toj teoriji vrijednost poduzeća se maksimizira kada se minimizira njezin WACC. Također, WACC će biti minimalan pri umjerenoj razini duga, prelaskom koje će vrijednost tvrtke padati zbog povećanog rizika, iako će WACC padati sve do umjerene razine duga jer je dug prema toj teoriji jeftiniji izvor financiranja. Stoga, financijski menadžer treba naći optimalnu razinu pokazatelja zaduženosti kako bi maksimalno iskoristio prednosti duga bez da ponovno smanjuje vrijednost poduzeća povećavajući traženu stopu povrata na vlastiti kapital uslijed rasta rizičnosti dionica zbog prekomjerne financijske poluge.

Dodatno proširenje prve teorije se nalazi u teoriji strukture kapitala koja na već navedene faktore dodaje i agencijski problem. *Teorija izbora (agencijski model)* nadovezuje se na linearnu vezu koja pokazuje povećanje vrijednosti zaduženog poduzeća u odnosu na nezaduženo poduzeće zbog porezne zaštite, dodajući na to i agencijske troškove i troškove financijskih neprilika koje smanjuju taj rast[4]. Agencijski problem se može tumačiti dvojako, putem boljih kontrola i veće transparentnosti može povećati vrijednost poduzeća. Međutim,

[3] WACC je akronim od engl. Weighted Average Cost of Capital.
[4] Vidučić, L. (2001): Teorijska i praktična motrišta strukture kapitala. Dostupno na: http://hrcak.srce.hr/28757, str. 790-793 [30.05.2017]

putem problema agenta i principala može smanjiti vrijednost poduzeća. Pod financijskim neprilikama (ili poteškoćama) se podrazumijevaju troškovi koji nastaju kada poduzeće više nije u mogućnosti u roku servisirati svoje dospjele dugove ili su to naposljetku troškovi stečaja poduzeća. Glavni cilj financijskog menadžera prema ovoj teoriji je izjednačiti korist od duga (agencijske koristi i porezna zaštita) i troškove od duga (agencijski problem i financijske neprilike).

Modeli temeljeni na asimetričnim informacijama podrazumijevaju posjedovanje privatnih informacija od strane zaposlenika poduzeća. Prema *teoriji signalizacije* se očekuje rast poduzeća nakon zaduživanja na financijskim tržištima (emisije obveznica). Glavna pretpostavka te teorije je da će se menadžer, kada pomoću privatnih informacija očekuje rast poduzeća radije zadužiti (izdati obveznice) nego emitirati dionice kako bi što veći dio profita zadržao. Prema *teoriji „postupka slaganja" („redoslijeda pakiranja")* postoje predefinirane preferencije menadžera o načinu financiranja. Taj redoslijed znači da se najprije koristi interno generirana gotovina, potom kreditni izvori, zatim emisija dužničkih i na kraju emisija vlasničkih vrijednosnica, koja je zbog većih informacijskih troškova najskuplja opcija relativno prema ostalim izvorima financiranja te stoga posljednji izbor. Prema tome, financijska struktura je posljedica investicijskih prilika poduzeća.

Hijerarhijska teorija bi mogla dijelom objasniti i ponašanje poduzeća u Hrvatskoj zbog relativno velikog stupnja tržišnih nesavršenosti i asimetričnih informacija koje se općenito javljaju u posttranzicijskim zemljama. Međutim, rezultati istraživanja koja su do sada provedena nisu dala jednoznačan odgovor. Primjerice, u istraživanju na uzorku hrvatskih poduzeća u proizvodnom sektoru potvrđena je snažna negativna veza između zaduženosti i profitabilnosti[5], što je u skladu s postavkama hijerarhijske teorije. Rezultati analize Učkara i Urtija[6] upućuju na sličan zaključak, međutim povezanost između financijske strukture i profitabilnost testirana je putem koeficijenta korelacije zbog čega treba rezultate interpretirati s oprezom te napraviti detaljniju analizu. Slični rezultati su dobiveni u istraživanju provedenome na velikim trgovačkim društvima četiriju odabranih post-tranzicijskih zemalja

[5] Škuflić, L., Mlinarić, D., Družić, M., (2016): Determinants of firm profitability in Croatia's manufacturing sector, International Conference on Economic and Social Studies. Dostupno na: http://eprints.ibu.edu.ba/3328/1/Lorena%20Skuflic%20Danijel%20Mlinaric%20and%20Marko%20Druzic.pdf [20.05.2017]

[6] Učkar, D., Urti, J., (2015): Utjecaj financijske strukture na profitabilnost hrvatskih poduzeća, Oeconomica Jadertina. Dostupno na: hrcak.srce.hr/file/225882 [20.05.2017]

na balkanskom poluotoku. Rezultati su potvrdili da menadžeri u ovim zemljama ne postavljaju ciljne omjere zaduženosti, već umjesto toga poštuju određeni red u odabiru izvora financiranja. Iz toga proizlazi da je potvrđena hijerarhijska teorija[7].

S druge strane, autori jednog istraživanja na uzorku zemalja s baltičkog područja došli su do zaključka o postojanju pozitivne veze između zaduženosti i profitabilnosti promatranih poduzeća, čime su potvrđene postavke Trade-off teorije, zbog mogućnosti korištenja poreznog štita i usporedno jeftinije cijene zaduživanja u odnosu na vlastiti kapital[8]. Razlog tome je veća cijena kapitala na netransparentnim tržištima. Međutim, autori naglašavaju da se pri tome treba uzeti u obzir značaj i visina poreza jer će to naposljetku odrediti i značaj korištenja poreznog štita.

Na temelju iznesenih teorijskih postavki i rezultata nekih od do sada provedenih istraživanja, može se zaključiti slijedeće: financijska struktura utječe na vrijednost poduzeća budući da su odluke o različitim izvorima financiranja i njihovim udjelima u ukupnim izvorima utječu na rizičnost poduzeća, troškove poslovanja a onda posljedično i na ostvareni financijski rezultat. Međutim, koji efekt dominira - porezna zaštita, troškovi financijskih neprilika, sklonost određenom izvoru financiranja i drugo, još uvijek nije jasno određeno.

1.2 Predmet istraživanja

Dosadašnja istraživanja uglavnom su se provodila u razvijenim zemljama, a posljednjih godina raste broj studija provedenih na uzorku razvijajućih (tranzicijskih) gospodarstava pa tako i u Hrvatskoj. Imajući na umu važnost financiranja kao i ostvarenje uspješnog poslovanja s jedne strane, te rezultate dosadašnjih istraživanja u različitim kontekstima koji nisu jednoznačni, s druge strane, javlja se potreba da se ova problematika kontinuirano ispituje i propituje.

S obzirom na sve ranije izneseno, predmet ovog rada je istraživanje utjecaja financijske (kapitalne) strukture odnosno zaduženosti poduzeća na njegovu profitabilnost. Kao što je već

[7] Arsov, S., Naumoski, A. (2016): Determinants of capital structure - an empirical study of companies from selected post-transition countries, Zbornik radova Ekonomski fakultet Rijeka, vol.34. Dostupno na: https://www.efri.uniri.hr/sites/efri.uniri.hr/files/cr-collections/2/04-arsov-naumoski-2016-1.pdf [25.04.2017]
[8] Berzkalne, I., Zelgalve, E. (2014): Trade-off theory vs. Pecking order theory – empirical evidence from the baltic countries, Journal of economic and social development, Vol 1, No 1. Dostupno na: http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=189801 [03.05.2017]

navedeno, struktura kapitala nije jedina odrednica profitabilnosti, ali će ona biti u fokusu ovoga rada na način da će se u analizi koristiti više različitih pokazatelja zaduženosti te će se njihov utjecaj ispitivati na različitim mjerama profitabilnosti. Ispitati će se i ostale determinante koje mogu imati utjecaj na profitabilnost poduzeća (tzv. kontrolne varijable) kao što su veličina poduzeća, udio materijalne imovine, likvidnost i drugo.

1.3 Istraživačke hipoteze

Iz definirane problematike i predmeta istraživanja proizlaze istraživačke hipoteze koje predstavljaju osnovu istraživanja.

H1: Zaduženost poduzeća negativno utječe na njegovu profitabilnost.

Ovakva hipoteza u skladu je s postavkama hijerarhijske teorije. Međutim, kao što je ranije navedeno, rezultati dosadašnjih istraživanja nisu jasni i nedvosmisleni, iako većina njih potvrđuje negativnu vezu, a manji broj pozitivnu koja je u skladu s teorijom izbora. Stoga će i ovaj rad doprinijeti jasnijoj slici o ovoj problematici u kontekstu poduzeća u Hrvatskoj.

Druga i treća hipoteza glase:

H2. Postoji razlika u zaduženosti poduzeća ovisno o sektoru.
H3. Veza između zaduženosti i profitabilnosti varira ovisno o pokazatelju zaduženosti.

Obje hipoteze oblikovane su na temelju proučene literature i dosadašnjih istraživanja koja upućuju na to da smjer utjecaja zaduženosti i profitabilnosti može ovisiti o korištenom pokazatelju zaduženosti, odnosno o strukturi obveza poduzeća (dugoročne, kratkoročne), a koja je pak dijelom opet uvjetovana okruženju u kojem poduzeće djeluje (sektorska pripadnost).

1.4 Ciljevi istraživanja

Cilj rada je utvrditi utjecaj strukture kapitala na profitabilnost odabranih poduzeća u Hrvatskoj. Također, cilj je analizirati kretanje obveza promatranih poduzeća u zadanom razdoblju u svrhu stvaranja slike o dominantnim izvorima financiranja. Također, dat će se pregled dosadašnjih istraživanja, posebno onih koja se odnose na Hrvatsku.

1.5 Metode rada

Kako bi se testirale postavljene hipoteze provest će se teorijski i empirijski dio rada. **Teorijski** dio rada će uključivati različite metode kao što su:

- metoda analize
- metoda sinteze
- metoda dokazivanja i opovrgavanja
- komparativna metoda
- metoda klasifikacije
- metoda deskripcije

Navedeno obuhvaća teorijsku analizu znanstvene literature koja će se sistematizirati, objasniti i analizirati. Različiti teorijski pojmovi će se razvrstati i usporediti kako bi se na temelju teorijskog dijela moglo stvoriti kvalitativno očekivanje o rezultatu istraživanja.

Empirijski dio rada će uključivati različite statističke i matematičke metode kojima će se analizirati prikupljeni podaci o poduzećima i kvantitativno dokazati istinitost postavljenih hipoteza. Za statistički dio rada će se koristiti softverski alati programa SPSS i Excel.

1.6 Doprinos istraživanja

Usprkos rastućem broju empirijskih istraživanja problematike strukture kapitala i utjecaja na profitabilnost, teško je odrediti koja teorijska saznanja najbolje objašnjavaju ponašanje u različitim zemljama. Pogotovo zemlje u razvoju često ostaju nedovoljno istražene. Doprinos ovog rada će se sagledati u popunjavanju uočenih praznina na primjeru poduzeća u Hrvatskoj.

1.7 Struktura rada

Diplomski rad će se sastojati od uvodnog, teorijskog i empirijskog dijela, koje će slijediti sažetak, zaključak, literatura te prilozi.

U **uvodnom dijelu** rada će se razraditi problem i predmet istraživanja. Pri tome će se dati općeniti uvid u tematiku strukture kapitala i navesti te objasniti istraživačke hipoteze, cilj rada, doprinos rada i metode korištene pri pisanju ovoga rada. Dati će se pregled dosadašnjih teorija strukture kapitala kao temelj razumijevanja teorijskog dijela rada.

U **teorijskom dijelu** će se sumirati i objasniti teorije strukture kapitala s posebnim naglaskom na teoriju redoslijeda pakiranja i teoriju izbora. Uz to, u ovome poglavlju dat će se pregled najvažnijih provedenih relevantnih istraživanja o vezi strukture kapitala i profitabilnosti i njihovih rezultata. Zatim će bit dan pregled osnovnih varijabli i pokazatelja koji se vežu uz profitabilnost i zaduženost. Objasnit će se njihova polazišta i očekivane implikacije na vrijednost poduzeća.

U **empirijskom dijelu** kako bi se bolje mogle analizirati rezultati regresijske analize na temelju uzorka hrvatskih poduzeća biti će dan pregled profitabilnosti i zaduživanja cjelokupnog gospodarstva na temelju službenih državnih publikacija. Potom će bit predstavljen uzorak koji je u ovom radu korišten. Grafičkim prikazom će se pokazati kretanja glavnih varijabli te će se objasniti i definirati korišteni uzorak podataka i varijable koje će ulaziti u model te njihov izračun. Bit će prikazani i analizirani regresijski modeli za različite godine s različitim pokazateljima za varijablu profitabilnost i strukturu kapitala. Naposljetku, bit će dan osvrt na postavljene hipoteze.

U **zaključku** rada će se ukratko sumirati dobiveni rezultati i staviti u kontekst prijašnjih istraživanja.

2. TEORIJSKI ASPEKT STRUKTURE KAPITALA I PROFITABILNOSTI

2.1 Pregled teorija strukture kapitala

Kako bi se mogao analizirati utjecaj strukture kapitala na profitabilnost prvo se treba definirati pojam strukture kapitala i njezin utjecaj na odluke financijskih menadžera i vrijednost poduzeća. U osnovi je struktura kapitala odnos između vlastitih izvora financiranja (vlastiti kapital, emisija dionica) i dugovnih izvora (emisija obveznica, kredit). Prvenstveno se misli na dugoročne izvore financiranja kojima se financiraju dugoročne investicije kojima poduzeće ne samo u financijskom smislu, već i u fizičkom smislu raste pri čemu onda i vrijednost poduzeća na tržištu raste.

S vremenom je pitanje načina financiranja poduzeća dobilo na sve većem značaju. Sve veći broj različitih rizika koji utječu na poduzeće su stvorila i sve veći pritisak na njihove gotovinske tokove i rezerviranja. Velika neizvjesnost i česte promjene u okolini poduzećima ostavljaju malen prostor za odluke o investiranju. Istovremeno se na financijskim tržištima pojavljuju različiti načini financiranja poduzeća koji postaju sve dostupniji. U takvim okolnostima je bitno razmatrati utjecaj odluka financijskih menadžera ne samo na strukturu kapitala, već cjelokupnu vrijednost poduzeća. Kako bi se taj utjecaj objasnio, su teoretičari postavili različite teorije.

Prema Millerovoj i Modiglianiovoj teoriji kapitala, odluke o strukturi kapitala su bile irelevantne za vrijednost poduzeća. Oni su smatrali da će se pozitivan utjecaj korištenja duga, zbog niže cijene zaduživanja, poništiti s većom traženom stopom povrata od dioničara zbog povećanog rizika uzrokovanog korištenjem financijske poluge. S uvođenjem poreznih zaklona zbog korištenja zaduživanja su naknadno priznali pozitivan utjecaj zaduživanja na vrijednost poduzeća.

Nakon što je priznat pozitivan utjecaj zaduživanja na trošak financiranja investicija, prosječan ponderiran trošak kapitala je stavljen u središte pozornosti u tradicionalnom gledištu na strukturu kapitala. Pridodan je trošak koji nastaje zbog rizika stečaja pri nemogućnosti plaćanja dospjelih obveza. Prema tome se pretpostavlja da financijski menadžeri pri

određivanju strukture kapitala traže optimalnu razinu duga koja će izjednačiti uštede od duga s troškovima zaduživanja zbog povećane tražene stope na vlastiti kapital.

Najnoviji modeli su temeljeni na asimetričnim informacijama, tj. na utjecaju koje same radnje financijskih menadžera imaju na mišljenje dioničara ili drugih osoba van poduzeća na vrijednost i budućnost poduzeća. Prema tome će odluka o načinu financiranja imati utjecaj na vrijednost poduzeća zbog utjecaja na očekivanja dioničara.

Druga teorija temeljena na asimetričnim informacijama, teorija redoslijeda pakiranja odnosno teorija postupka slaganja, ima slično polazište. U ovom radu ona će biti posebno razjašnjena u sljedećem poglavlju rada. Uz to će posebno biti objašnjena trade-off teorija koja je postavljena prije teorije redoslijeda pakiranja. Veliki broj radova je posvećen razlučivanju tih dviju teorija jer su neke njihove postavke veoma slične. Temeljna razlika između tih dvaju teorija je u očekivanom odnosu između zaduživanja i profitabilnosti. Prema tome će u ovome radu obje teorije biti suprotstavljene, a s obzirom na rezultate dosadašnjih istraživanja očekivat će se negativan utjecaj strukture kapitala na profitabilnost, kako je definirano hipotezom H1, odnosno očekivati će se potvrđivanje postavki teorije redoslijeda pakiranja.

2.1.1 Teorija redoslijeda pakiranja

Dosadašnja istraživanja, baveći se pitanjem kojom bi se teorijom strukture kapitala najbolje moglo objasniti ponašanja poduzeća, u fokus stavljaju dvije teorije. Na jednoj strani je teorija redoslijeda pakiranja, koja očekuje negativnu vezu između zaduživanja i profitabilnosti; a na drugoj strani Trade-off teorija, koja očekuje pozitivnu vezu između zaduženosti i profitabilnosti. Razlog tome je glavna pretpostavka trade-off teorije da će poduzeće povećati razinu duga sve dok se ne izjednače koristi i troškovi zaduživanja. Trošak zaduživanja uvećava vjerojatnost propasti poduzeća uslijed prevelike razine zaduživanja, koja direktno utječe i na troškove zatvaranja poduzeća. S druge strane se gleda korist od zaduživanja, odnosno koliko poreznih ušteda poduzeće može iskoristiti putem zaduživanja kako bi na taj način povećao svoju konačnu razinu profita. Međutim, pri tome je važno uzeti u obzir visinu porezne stope na dobit. Što je veća stopa, veći je učinak, što u protivnome znači da u poduzećima koja posluju u zemljama s niskom razinom poreza na dobit to ne mora biti značajan faktor za izbor načina financiranja.

Teorija redoslijeda pakiranja je jedna od najmlađih. Utemeljena je na postojanju asimetričnih informacija koje nastaju između različitih dionika poduzeća. U ovom se kontekstu radi o odnosima između menadžera i ostalih zaposlenika poduzeća te dioničara [9]. Osnovna pretpostavka ove teorije je da financijski menadžeri imaju preferirani redoslijed načina financiranja koji će koristiti kada im se ukaže prilika za investiciju.

U počecima razvoja teorija strukture kapitala mnogi utjecaji nisu uzeti u obzir pri istraživanjima. Koristila se pretpostavka o savršenom tržištu bez transakcijskih troškova, troškova financijskih neprilika i bez utjecaja asimetričnih informacija. Pri savršenim uvjetima poduzeće može slobodno birati način financiranja koji mu je najisplativiji. Međutim, na pravom tržištu različiti načini financiranja nisu svim poduzećima podjednako dostupni. Prema teorijama asimetričnih informacija dioničari prate svaki potez financijskog menadžera kako bi indirektno iščitali stvarno stanje poduzeća. Menadžeru će uvijek biti u interesu prikupiti što više kapitala po što manjoj cijeni kako bi bila što veća neto sadašnja vrijednost investicije. S druge strane, dioničar će uvijek pokušati iz informacija koje su mu dostupne odrediti rizičnost poduzeća, a i rizičnost investicija koje poduzeće planira. Prema tome, dioničar će prilagoditi svoju traženu stopu povrata koja direktno utječe na cijenu financiranja poduzeća. Uz to, financijski menadžer uvijek mora biti svjestan posljedica svojih radnji na cijenu dionica. Menadžeru će uvijek biti u interesu izdati nove emisije dionica kada očekuje da su precijenjene, a (budući) dioničari će uvijek pokušati kupiti dionice koje su trenutno podcijenjene, a za koje se očekuje rast cijene u budućnosti.

Dakle, odluka o načinu financiranja koju će financijski menadžer koristiti kao prvo ovisi o tome koji su mu načini financiranja dostupni. Postoje različiti načini, od

- financijskih institucija (banke, lizing društva…),
- fizičkih osoba (zajam, poslovni anđeli…) ili
- povezanih društva (zajam).

Važno je razlučiti porijeklo sredstava koje može bit:

- Unutarnji (interni izvori)
- Vanjski (eksterni izvori)

[9] Vidučić, L. (2001): Teorijska i praktična motrišta strukture kapitala, Ekonomski pregled, Vol.52 No.7-8, 784-800, str. 793. Dostupno na: http://hrcak.srce.hr/28757 [27.04.2017]

Uz privatne ugovore poduzeće također može prikupiti kapital putem javnih tržišta:

- tržišta kapitala (emisija dionica, emisija obveznica…) ili
- tržišta novca.

Uz to se financijski menadžer mora odlučiti hoće li investicije financirati

- kratkoročnim ili
- dugoročnim izvorima.

S obzirom da se radi o financiranju investicija koje su uobičajeno dugoročne naravi, pretpostavlja se da će se koristiti dugoročno financiranje. Međutim, često zbog nedostatka ili nemogućnosti pribavljanja dugoročnih izvora po adekvatnim uvjetima, poduzeća kratkoročno financiranje koriste za dugoročne investicije.

Prema teoriji redoslijeda pakiranja („postupka slaganja“) preferencije financijskog menadžera za izvor financiranja investicija su sljedeće[10]:

1. Interno generirana sredstva
2. Nisko rizični dugovni instrumenti (obveznice)
3. Hibridne vrijednosnice (konvertibilne obveznice)
4. Obične dionice

Ove su preferencije utemeljene na tome da menadžeri biraju liniju manjeg otpora pri financiranju koja će istovremeno imati i najmanji utjecaj na publicitet poduzeća. Naime, emisija dionica ima snažan efekt signalizacije na dioničare. Stoga, financijski menadžer mora biti oprezan u svojim odlukama kako ne bi nepovoljno utjecao na cijenu dionica pa tako i na cjelokupnu tržišnu vrijednost poduzeća. Prema izvornim postavkama S. C. Myersa i N. S. Majlufa [11] poduzeće bi u svakom slučaju trebalo preferirati dugovno prema vlastitom financiranju, jer se time bitno umanjuje rizik investiranja. Prema njima bi poduzeća, nakon što iskoriste cjelokupna interno generirana sredstva i više nemaju mogućnost financirati se putem nisko rizičnog zaduživanja, trebala odbiti nove prilike investiranja što nije u skladu s ciljem maksimiziranja bogatstva dioničara. Menadžeri bi, dakle, trebali staviti postojeće dioničare na prvo mjesto. Također, u svome istraživanju daju sugestije kako menadžeri mogu

[10] Vidučić, L. (2012): Financijski menadžment, str. 225,226, 8. nepromijenjeno izdanje, RRiF – plus, d.o.o. za nakladništvo i poslovne usluge, Zagreb

[11] Myers, C., S., Majluf, S., N., (1984): Corporate financing and investment decisions when firms have information that investors do not have, Journal of financial economics 13. Dostupno na: https://pdfs.semanticscholar.org/77de/0d5a47ff0ccbff22255155f1009265af270c.pdf [05.05.2017]

pomoću dividendnih politika otkriti tržištu informacije o poduzeću. Problem menadžera je što pri emisiji novih dionica, za financiranje novih investicija, cijene dionice padaju. Ukoliko se poduzeće financira putem ne rizičnog zaduživanja, ne dolazi do problema takve vrste.

Kada poduzeće investicije financira interno generiranim sredstvima, izostaju troškovi kamata, a poduzeće nije dužno isplaćivati dividende. Uz to nema brige o promjeni cijene dionica, jer pri korištenju vlastitih rezervi ima skoro potpunu diskreciju u svome djelovanju. Jedini trošak koji se javlja jest oportunitetni trošak koji nastaje jer poduzeće čuva visoko likvidna novčana sredstva za potencijalne investicije koje se ne moraju nužno dogoditi. Ona poduzeća koja su najsposobnija će uvijek imati dovoljno vlastitih sredstava kojima će moći financirati investicije. Takva sredstva se najlakše generiraju iz zadržane dobiti. Ona poduzeća koja nemaju takve rezerve okreću se zaduživanju. Pokušat će se koristiti oblik zaduživanja s najmanjom razinom rizika. Međutim, svako zaduživanje ima svoju cijenu koja direktno smanjuje dobit, pa i profit poduzeća. Uz to, svako zaduživanje povećava fiksne troškove poduzeća, što otežava opstanak u vremenima krize i povećava trošak financijskih neprilika. Naposljetku će se poduzeće okrenuti emisiji dionica, koji je najrizičniji način financiranja i najmanje diskretan. Ta vrsta financiranja zahtjeva dug proces, visoke troškove i ima dugoročne i snažne učinke na tržišnu kapitalizaciju poduzeća. Zbog toga se pretpostavlja da će poduzeća emisije dionica koristiti veoma rijetko.

Također, u obzir se treba uzeti razvijenost tržišta kapitala. Likvidnost i razvijenost na zagrebačkoj burzi će teško pratiti stanje i mogućnosti drugih burzi. Zbog toga će u Hrvatskoj troškovi asimetričnih informacija pri emisiji dionica bit naglašeniji. Tomu nadalje pridonosi rijetkost takvih emisija na zagrebačkoj burzi. Kada se uzima u obzir da se pod dugovni zaduživanjem u Hrvatskoj prvenstveno misli na zaduživanje putem različitih vrsta bankarskih kredita, još više dolazi do izražaja diskretnost koja se postiže financiranjem putem zaduživanjem. A u bankocentričnom financijskom sustavu, kao što ga Hrvatska ima, su poduzećima banke kao način financiranja mnogo bliže nego tržišta vrijednosnih papira. Dodatnu prednost imaju poduzeća koja imaju vrijednu dugotrajnu, materijalnu imovinu, koju mogu koristiti kao kolateral i s time sniziti trošak financiranja, te iskustvo koje će pomoć pri zaduživanjem putem kredita. S obzirom na izneseno, u ovome radu polazi se od pretpostavke negativne veze između profitabilnosti i zaduženosti.

Navedeno ide u prilog postavljenoj hipotezi da dug ima negativan utjecaj na profitabilnost. Očekuje se manja razina zaduženosti kod visoko profitabilnih poduzeća jer će takva poduzeća biti u mogućnosti investicije s pozitivnom neto sadašnjom vrijednošću financirati iz interno generiranih sredstava koja imaju najmanji trošak financiranja.

2.1.2 Trade-off teorija

Trade-off teorija odnosno teorija izbora (agencijski model) je proširena verzija tradicionalnog gledišta te u razmatranje uzima uz troškove financijskih neprilika i agencijske troškove. Prema toj teoriji financijski menadžeri razinu strukture kapitala mijenjaju kako bi postigli optimalnu razinu zaduženosti koja će izjednačiti troškove i koristi duga. Pri ovoj teoriji korist duga proizlazi iz poreznih ušteda i smanjenja agencijskog problema prvenstveno zbog nadzora financijskih institucija koja kreditiraju poduzeće. Troškovi zaduživanja su troškovi financijskih neprilika i agencijski troškovi koji prethodne teorije nisu uzele u obzir.

Financijske neprilike (poteškoće) su troškovi koji nastaju jer poduzeće s poteškoćama nije u mogućnosti u potpunosti servisirati dug što može i naposljetku voditi do troškova stečaja. Ti troškovi mogu biti direktni (administrativni i zakonski troškovi vezani uz likvidaciju i reorganizaciju) i indirektni (ugrožavanje odnosa s poslovnim partnerima)[12]. Kada je razina duga mala ocjenjuje se i vjerojatnost financijskih neprilika malom zbog čega je onda korist od zaduživanja veća od troškova zaduživanja. U tom slučaju će financijski menadžer povećati razinu duga u strukturi kapitala poduzeća. Međutim, što se poduzeće više zadužuje, raste rizik financijskih neprilika koji najviše ugrožava dioničare čije će dionice nakon stečaja poduzeća biti bezvrijedne. Iz tog razloga će dioničari u slučaju povećanja razine duga povećati svoju traženu stopu povrata na kapital što direktno povećava troškove zaduživanja.

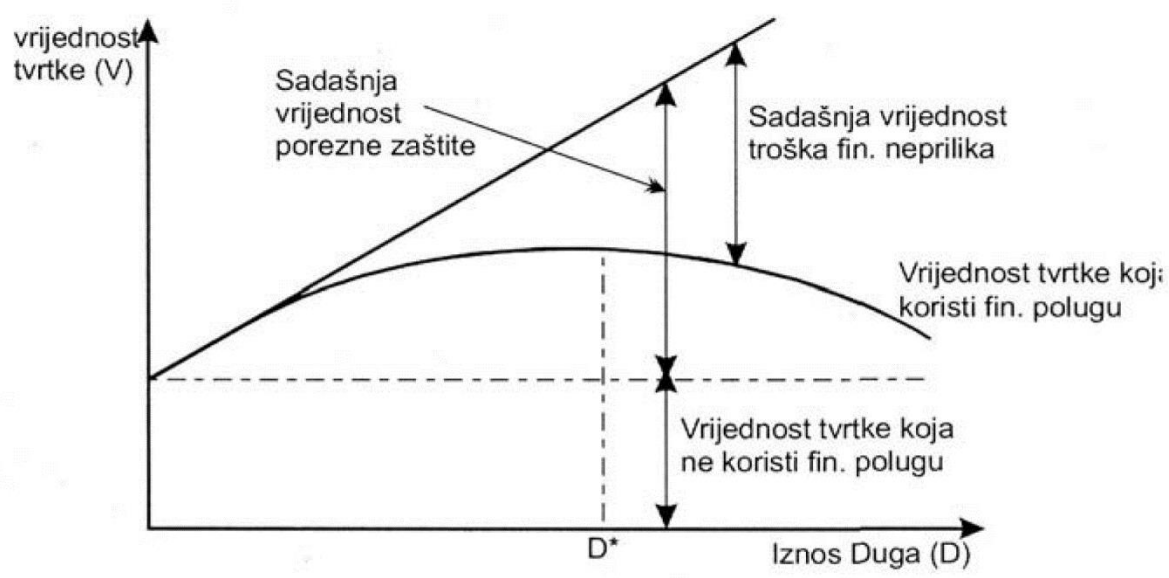
[12]Vidučić, L. (2001): Teorijska i praktična motrišta strukture kapitala, str. 792, Ekonomski pregled, Vol.52 No.7-8, 784-800. Dostupno na: http://hrcak.srce.hr/28757 [15.08.2017]

Vrijednost poduzeća prema Trade-off teoriji se može prikazati sljedećim izrazom:

Vrijednost tvrtke	=	vrijednost tvrtke koja se financira samo vlastitim kapitalom	+	sadašnja vrijednost porezne olakšice	-	sadašnja vrijednost troška financijskih neprilika

Izvor: Vidučić, L. (2001): Teorijska i praktična motrišta strukture kapitala, Ekonomski pregled, Vol.52 No.7-8, 784-800. Dostupno na: http://hrcak.srce.hr/28757 [15.08.2017]

Prema toj relaciji svako poduzeće ima svoju početnu vrijednost koja je neovisna o razini zaduživanja, a to je vrijednost poduzeća koje se financira samo vlastitim kapitalom. Nadalje se vrijednost poduzeća povećava za iznos sadašnje vrijednosti porezne zaštite odnosno diskontirane vrijednosti poreznih ušteda zbog zaduživanja, ali ne u njihovom cijelom iznosu. Korist od duga se smanjuje za iznos sadašnje vrijednosti troškova financijskih prilika, kako prikazuje i slika 1.



Slika 1: Grafički prikaz postavki Trade-off teorije

Izvor: Vidučić, L. (2001): Teorijska i praktična motrišta strukture kapitala, Ekonomski pregled, Vol.52 No.7-8, 784-800. Dostupno na: http://hrcak.srce.hr/28757 [15.08.2017]

Temeljna razlika trade-off teorije u odnosu na druge teorije je naglasak na agencijskim troškovima. Oni nastaju zbog konfliktnih interesa principala i agenata koji se javljaju na više razina. Može se razmatrati u kontekstu vlasnika (dioničara koji je principal) i menadžera (koji djeluje kao agent) ili dioničara (kao principala) i kreditora (koji je agent). Kada se radi o

zaduživanju poduzeća koje vodi menadžer u ime vlasnika, pretpostavlja se korist zaduživanja u obliku kontrole nad menadžerom. Dakle, jedna korist zaduživanja je smanjenje agencijskih troškova na način da se menadžeru daju određeni uvjeti i fiksne naknade koje mora ispuniti. S druge strane, dioničari su oni koji nose najveći dio rizika od financijskih neprilika. Kreditori će se osigurati vlastitim mjerama za slučaj stečaja i vlasnici obveznica će unaprijed ugraditi te rizike u svoje kamatne stope jer i dioničari mogu djelovati u vlastitim interesima. Tako će oni pogotovo uoči bankrota tražiti isplate ekstra dividendi ili poduzimanje vrlo rizičnih projekata.

Prema agencijskoj teoriji je financijska poluga pozitivno povezana s[13]:

- Vjerojatnošću financijskih neprilika
- Vrijednošću tvrtke
- Stupnjem regulacije
- Slobodnim gotovinskim tijekovima
- Likvidacijskom vrijednošću tvrtke
- Stupnjem u kojem je tvrtka predmet preuzimanja
- Važnošću reputacije menadžmenta

Istovremeno prema toj teoriji financijska poluga je negativno povezana s[14]:

- Stupnjem postojanja razvojnih mogućnosti
- Pokazateljem pokrića kamata
- Troškovima analize perspektive tvrtke
- Vjerojatnosti reorganizacije tvrtke koja nastupa nakon ulaska u financijske neprilike.

Također, agencijska teorija ne propisuje određenu razinu strukture kapitala jer se ta razina razlikuje između industrija te čak između poduzeća unutar iste industrije. Teorija sugerira da bi veću polugu morale imati tvrtke s velikim udjelom materijalne imovine, zrele kompanije s malo razvojnih mogućnosti i profitabilne tvrtke s velikim očekivanim poreznom dobitkom. Nasuprot tome, poduzeća iz područja visoke tehnologije s malim udjelom materijalne imovine, poduzećima s malim oporezivim dobitkom i visokom razinom duga bi trebala smanjiti svoju razinu duga prikupljanjem vanjskog kapitala, ograničenjem dividendi i prodajom imovine[15].

[13] Ibid, str 792
[14] Ibid.
[15] Ibid.

Iako se u ovom radu pretpostavlja negativna veza između strukture kapitala i profitabilnosti, ne može se isključiti mogućnost rezultata pozitivne veze koja bi potvrdila trade-off teoriju. U različitim zemljama su dobiveni različiti rezultati koji su osjetljivi na mnoge faktore. Usprkos velikom broju provedenih različitih istraživanja, i dalje nema jednoznačnog odgovora na pitanje o prirodi veze između strukture kapitala i profitabilnosti, odnosno odgovora koja teorija dominantno objašnjava ponašanje poduzeća pri odabiru strukture kapitala.

2.2 Pojam profitabilnosti i njezino mjerenje

Profitabilnost je jedan od najvažnijih pojmova u korporativnom izvještavanju. S njom se može mjeriti uspješnost i sposobnost poduzeća i njihova perspektiva u budućnosti. Koliko je profitabilnost važna za privatna poduzeća koja nastoje maksimizirati svoje profite, tako je za dionička društva važna vrijednost poduzeća. Zbog toga je osnovni cilj financijskog menadžera maksimiziranja vrijednosti dioničara odnosno poduzeća jer ona predstavlja bogatstvo dioničara na čijem kapitalu je poduzeće temeljeno. U tom kontekstu je važno uzeti u obzir da profit poduzeća nije istovremeno i profit dioničara. Iako su dioničari vlasnici poduzeća, profit pripada poduzeću kao pravnoj osobi, a dioničari svoj prihod ostvaruju pomoću koristi od dividendi i kapitalnih dobitaka prodajom dionica. Zbog toga financijski menadžeri trebaju, kako bi udovoljili dioničarima, osigurati rast vrijednosti poduzeća kako bi dionice poduzeća bile poželjnije. Istovremeno će poduzeće sa stabilnim rastom imati manju traženu stopu povrata na kapital od dioničara jer je i manje rizično. Prema tome, profitabilnost je dioničarima veoma važna kako bi se iz nje mogle isplatiti dividende ili financirale investicije za daljnji rast vrijednosti poduzeća i cijene njihovih dionica.

U računovodstvenom smislu razlikuju se pojmovi prihod i profit. Prihodi su stavka koja uzima u obzir sva potraživanja poduzeća. Najčešće se radi o potraživanju od kupaca za prodanu robu ili obavljene usluge. Nasuprot prihodima stoje rashodi koji uključuju sve troškove koji se javljaju pri poslovanju poduzeća. Oduzimanjem troškova od prihoda dobije se iznos dobiti. Od tog iznosa će se u ovisnosti dotičnih zakona i propisa oduzeti iznos poreza na dobit i slično. Tek tada se dolazi do iznosa neto dobiti nakon oporezivanja koja se može poistovjetiti s pojmom profit.

Kako bi se te iznose i stavke moglo analizirati i donijeti zaključke o poduzeću, koriste se financijski izvještaji. U njima se u različitim oblicima opisuje stanje poduzeća. Kako bi se iz tih izvještaja odredila kvaliteta poslovanja poduzeća i njegova perspektiva u konkurentnom okruženju, koriste se različite metode. One se dijele na analizu pokazatelja, komparativnu analizu i analizu trenda. Iako bi bilo najbolje koristiti sve tri metode zajedno, analiza pomoću pokazatelja je i dalje najkorištenija. Danas postoje razni pokazatelji profitabilnosti, svaki pokazatelj uzima druge stavke financijskih izvještaja u obzir. S njima se izražava uspješnost poduzeća, njegova snaga, utjecaj njegove razine likvidnosti i upravljanja dugom i imovinom. Pokazatelji profitabilnosti se u osnovi dijele na tradicionalne i suvremene pokazatelje. Tradicionalni se temelje na odnosu profita i imovine te cijene proizvoda ili usluga koje poduzeće nudi u odnosu na obujam prodaje. U suvremenim pokazateljima profitabilnosti u obzir se uzimaju tržišni podaci koji se ne moraju nužno nalaziti u financijskim izvještajima poduzeća. Ti podaci su objavljeni na burzama vrijednosnica.

Bez obzira na veličinu poduzeća, njegovu industriju i prisutnost na financijskim tržištima, profitabilnost je od izuzetne važnosti. Njeno mjerenje i analiza ne ograničava se samo na analizu kretanja profitabilnosti jednog poduzeća kroz vrijeme. Teoretičari i praktičari istražuju mnoge razloge i determinante koje utječu na profitabilnost. Pri tim istraživanjima, uključujući istraživanjima o strukturi kapitala, cilj je ustvrdit jačinu i vezu profitabilnosti s mnogo faktora koji na nj utječu kako bi se mogle donijeti što bolje odluke u korist poduzeća i njegovih dionika.

2.3 Dosadašnja istraživanja o odnosu strukture kapitala i profitabilnosti

Zbog izuzetne važnosti profitabilnosti poduzeća postoji mnoštvo radova čije je središnje pitanje utvrditi koji faktori utječu na profitabilnost poduzeća kako bi se moglo svjesno utjecati na njih. U praksi postoji mnoštvo potencijalnih determinanti profitabilnosti koji se mogu podijeliti na:

- Mikroekonomske ili
- Makroekonomske

ili

- Interne (unutar poduzeća) ili
- Eksterne (van poduzeća).

Makroekonomske varijable koje utječu na poduzeća su specifičnosti cjelokupnog gospodarstva ili države unutar kojeg poduzeće posluje. U skupinu tih pokazatelja ubraja se kamatna stopa u gospodarstvu, kretanje BDP-a, pokazatelji zaposlenosti i drugi. Mikroekonomske varijable utjelovljuju utjecaje specifične za posebne industrije ili zasebno poduzeće. Nadalje, razlikuju se vanjski utjecaji koji mogu biti konkurencija, cijene supstituta i slično ili efekti unutar poduzeća kao što je njegova produktivnost ili razina likvidnosti. U ovom radu promatrat će se prvenstveno utjecaj internih obilježja poduzeća na profitabilnost, odnosno strukture kapitala i ostalih obilježja.

U nastavku rada će se ukratko prikazati rezultati relevantnih istraživanja koji su ispitivali odnos između strukture kapitala i profitabilnosti te validnost postavki teorije redoslijeda pakiranja u odnosu na trade-off teoriju.

Upravo zbog nemogućnosti jasnog razlikovanja utjecaja teorije redoslijeda pakiranja i trade-off teorije su autori istraživanja iz 1999 godine[16] svoj rad posvetili pitanju koja teorija ima veću snagu testa te bolje objašnjava kretanje i ostavlja manji dio neobjašnjene varijance. Radi se o činjenici da će se teorija redoslijeda pakiranja odbaciti u svakom slučaju kada visoko profitabilna poduzeća, iako imaju mogućnost zadužiti se, izdaju emisiju dionica. Poteškoće se teško otklanjaju u pitanju razloga mijenjanja udjela duga u strukturi kapitala poduzeća. Zagovornici trade-off teorije će svako smanjenje udjela duga shvatiti kao kretanje prema optimalnoj strukturi kapitala. Međutim, visoko profitabilna poduzeća koja nemaju prilike za nove investicije će prirodno smanjiti svoju razinu duga kako bi rasteretili bilancu, što ne mora biti znak postojanja optimalne strukture kapitala. U suprotnom, poduzeća s mnogo prilika za investiranja će se morati više i više zaduživati ukoliko ne žele propustiti te prilike. Naglasak rada ovih autora je da je teorija redoslijeda pakiranja određena preferenciji internim izvorima financiranja naprema vanjskim i dugom prije nego dionicama, bez postojanja optimalne razine strukture kapitala. Prema njima, dug poduzeća je kumulativ rezultata izbora načina financiranja proteklih razdoblja, pri čemu su poduzeća bez zadržane dobiti skloniji zaduživanju jer imaju manji udio interno generiranih sredstava koja mogu koristiti za financiranje. Također ističu da teorija redoslijeda pakiranja u testovima ima veću snagu i objašnjava veći dio varijance. Otpornija je na promjene od trade-off teorije te će se odbaciti u

[16] Shyam-Sunder, L., Myers, C., S. (1999): Testing Static Trade-off against Pecking Order Models of Capital Structure, Journal of Financial Economics, Vol. 51, No. 2. Dostupno na: http://pages.stern.nyu.edu/~eofek/PhD/papers/FG_Testing_JFE.pdf [16.08.2017]

slučajevima u kojima nije točna. Prema njima je kod trade-off teorije problem što se neće nužno odbaciti u slučajevima kada nije točna, čak ni kada se radi o slučajno generiranim podacima. Sve to vodi do zaključka da je teorija redoslijeda pakiranja u ukupnosti superiornija teorija, ali da same postavke modela i kvalitativne pretpostavke mogu značajno utjecati na rezultat i zaključak istraživanja.

Istraživanje provedeno na uzorku američkih poduzeća uvrštenih na burzu u periodu od 1971-1998 godine[17] pokazuje rezultate suprotne pretpostavkama teorije redoslijeda pakiranja. Autori se slažu s pretpostavkom da će poduzeća preferirati dug naspram dionica zbog manjih troškova asimetrije informacija. Međutim, podaci iz njihovog uzorka pokazuju kako je u Americi iznos financiranja putem emisija dionica premašio iznose financiranja putem duga te kako trendovi emisije dionica bolje prate financiranje deficita poduzeća nego što to čini trend zaduživanja. Uz to će, prema njihovom shvaćanju, poduzeća s visokim stopama rasta imati visok udio duga. Razlog tomu je da će poduzeća, kada iskoriste sva raspoloživa interno generirana sredstva, ostale investicije financirati dugom.

Istraživanje provedeno na uzorku od 961 velikih poduzeća u Australiji od 1995-2005 godine prvenstveno je promatralo utjecaj produktivnosti na profitabilnost poduzeća[18]. Rezultat istraživanja je ukazao na pozitivan učinak zaduživanja na profitabilnost. Korišten je dinamičan panel model s varijablama veličina poduzeća, pokazatelj zaduženosti, starost poduzeća, financijski rizik te mjere produktivnosti. Prema njihovim rezultatima veličina poduzeća ima pozitivan utjecaj na profitabilnost poduzeća zbog učinka ekonomije obujma ili pristupu kapitalu s manjim troškovima. Dodatno, poduzeća koja su u proteklim razdobljima bila profitabilnija i produktivnija od drugih su i u sadašnjim razdobljima imala veći profit. Učinak financijskog rizika je bio negativan.

Istraživanje provedeno na temelju 208 poduzeća u Maleziji od 1994 do 2000 godine bavilo se vezom između profitabilnosti, strukture kapitala i tržišne strukture[19]. Koristeći se panel

[17] Murray, Z., F., Goyal, K. V. (2003): Testing the pecking order theory of capital structure, Journal of Financial Economics, Vol. 67., No. 2. Dostupno na: http://www.sciencedirect.com/science/article/pii/S0304405X02002520 [16.08.2017]

[18] Stierwald, A., (2009): Determinants of Firm Profitability – The effect of Productivity and its Persistence, Melbourne Institute of Applied Economic and Social Research, Dostupno na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.361.1327&rep=rep1&type=pdf [02.08.2017]

[19] Pandey, I., M. (2004): Capital Structure, Profitability and Market Structure: Evidence from Malaysia, The Asia Pacific journal of economics and business, Vol. 8, 78-91. Dostupno na: https://www.researchgate.net/publication/265273461 [16.08.2017]

podacima, autor je došao do konačnog rezultata značajne negativne veze između zaduženosti mjerene Tobinovim koeficijentom Q i profitabilnosti. Autor u svom radu razmatra kako oligopolska tržišna struktura utječe na ponašanje pri financiranju poduzeća. Prema njegovim zaključcima će poduzeća u takvim situacijama koristiti veću razinu duga kada im se ukažu prilika za višim iznosom profita. Pri takvoj postavci, struktura kapitala bi imala pozitivan učinak na profitabilnost poduzeća. Naglašava kako i za kreditne institucije mogu postojati poteškoće u smanjenju agencijskih problema usprkos postojanju specifičnih odredbi kreditnih ugovora. Usprkos tome, zbog povećanja troškova financijskih neprilika pri zaduživanju, poduzeća s mnogo interno generiranih sredstava imaju mogućnost „guranja" visokozaduženih poduzeća u stečaj. Takve mogućnosti dovode do agresivnih predatorskih strategija.

Prema istraživanju[20] provedenome SAD-u (2011) koje se bavilo uslužnim i manufakturnim sektorom od 2005-2007 godine, proizašao je zaključak o pozitivnoj vezi između zaduženosti i profitabilnosti. Kod tog istraživanja je naglasak stavljen na trade-off između koristi od porezno odbitnih kamata na dug i troškova povišenog rizika bankrota. S obzirom na veliki porezni namet poduzećima u SAD, autori su očekivali se da će u uzorku 272 američka poduzeća teorija redoslijeda pakiranja imati manju objašnjavajuću snagu. Pri tom istraživanju su kao varijable uzete veličina poduzeća, rast, profitabilnost mjerena pokazateljem ROE, pokazatelji kratkoročnog duga naprema ukupnoj imovini, pokazatelji dugoročnog duga naprema ukupnoj imovini i ukupni dug naprema ukupnoj imovini. Korištenjem korelacije i regresijske analize je dobivena pozitivna veza između kratkoročnog duga, dugoročnog te ukupnog duga i profitabilnosti.

Zaseban rad su autori posvetili utjecaju strukture kapitala na profitabilnost u informatičkim poduzećima u Indiji tijekom perioda 1999-2000 i 2006-2007[21]. U radu je korištena deskriptivna statistika i regresijska analiza. Utvrđena je snažna negativna veza između strukture kapitala, odnosno povećanja zaduženosti, i profitabilnosti. U ovom radu je profitabilnost mjerena pomoću pokazatelja ROA (povrat na imovinu) i ROCE (povrat na kapital koji je raspoloživ za generiranje dodatnog profita), a aproksimirana vrijednost

[20] Gill, A., Biger, N., Mathur, N. (2011): The Effect of Capital Structure on Profitability: Evidence from the United States, International Journal of Management, Vol. 28, No. 4. Dostupno na: https://www.researchgate.net/publication/281004540_The_effects_of_capital_structure_on_profitability_Evidence_from_United_States [15.08.2017]

[21] Azhagaiah, R., Gavoury, C. (2011): The Impact of Capital Structure on Profitability with Special Reference to IT Industry in India, Managing Global Transitions: International Research Journal, Vol. 9, No. 4, 371-392. Dostupno na: http://www.fm-kp.si/zalozba/ISSN/1581-6311/9_371-392.pdf [22.08.2017]

strukture kapitala je dobivena pokazateljem ukupnog duga naprema ukupnoj imovini te odnosa duga i dioničke glavnice .

U istraživanju temeljenome na uzorku hrvatskih poduzeća s prehrambenog sektora 1999-2009 pomoću dinamične panel analize ispitivale su se determinante profitabilnosti poduzeća u tom sektoru[22]. Rezultati istraživanja ukazuju na značajan negativan utjecaj zaduženosti poduzeća. Zaduženost je mjerena putem odnosa ukupnih obveza naprema ukupnoj imovini. Značajan pozitivan utjecaj su imale varijable veličina poduzeća (mjerena prirodnim logaritmom iznosa ukupne imovine poduzeća), koncentracije u industriji mjerena indeksom koncentracije (CR) i Herfindahl-Hirschmanovim indeksom (HHI) te razina profitabilnosti u proteklom razdoblju.

Detaljniju analizu utjecaja zaduženosti na profitabilnost može se pronaći u istraživanju provedenom na temelju poduzeća uvrštenih na burzi u Gani u periodu 2005-2009[23]. Rezultati tog istraživanja pokazuju značajnu pozitivnu vezu između profitabilnosti i kratkoročnog duga. Veza između profitabilnosti, dugoročnog duga i ukupnog duga je značajna i negativna. Kao mjera profitabilnosti je korišten pokazatelj ROE, kao odnos dobiti prije kamata i poreza te dioničke glavnice i rezervi. Za pokazatelje zaduženosti je korišten odnosi duga i kapitala.

Istraživanje provedeno na uzorku od 75 poduzeća s baltičke burze (Baltic stock exchange)[24] u periodu od 1998 do 2011, koristeći se panel podacima i regresijskom analizom, pokazalo je kako se u tim poduzećima odnos između zaduženosti i profitabilnosti može bolje objasniti trade-off teorijom odnosno da je veza između strukture kapitala i profitabilnosti pozitivna. Bitno je naglasiti kako teorija redoslijeda pakiranja ne niječe utjecaj poreza i troškova financijskih neprilika, već pretpostavlja da preferencije financijskog menadžera imaju veći utjecaj na izbor načina financiranja. Ovim istraživanjem se pokazalo da poduzeća prate slična ponašanja u kretanju strukture kapitala. Iako ovo istraživanje zaključuje da u Latviji,

[22] Pervan, M., Mlikota, M. (2013): What determines the profitability of companies: Case of Croatian food and beverage industry, Ekonomska istraživanja – Economic research, Vol. 26, 277-286. Dostupno na: https://hrcak.srce.hr/104021 [16.08.2017]

[23] Addae, A., A., Nyarko-Baasi, M., Hughes, D. (2013): The Effects of Capital Structure on Profitability of Listed Firms in Ghana, European Journal of Business and Management, Vol. 5, No. 31, 215-226. Dostupno na: http://www.iiste.org/Journals/index.php/EJBM/article/view/9490/9684 [16.08.2017]

[24] Berzkalne, I., Zelgalve, E. (2014): Trade-off theory vs. Pecking order theory – empirical evidence from the baltic countries, Journal of economic and social development, Vol 1, No 1. Dostupno na: http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=189801 [03.05.2017]

Estoniji i Litvi dominiraju postavke trade-off teorije, priznaju kako je teško isključiti utjecaj i jedne i druge teorije u ovom slučaju.

Još jedno istraživanje na primjeru hrvatskih poduzeća ispitivalo je relevantne faktore od utjecaja na visinu profita poduzeća u hrvatskoj prerađivačkoj industriji od 2003-2013 godine[25]. Rezultati pokazuju očekivanu negativnu vezu između zaduženosti i profitabilnosti, tekuće likvidnosti i rasta troškova osoblja. Taj rad naglašava neoklasični pristup maksimiziranja profita. Visoke izdatke za istraživanje i razvoj će bolje podnijeti velika poduzeća koja imaju zadržanu dobit iz proteklih razdoblja. Najznačajnije varijable u njihovom istraživanju su produktivnost, tržišni udio, veličina imovine, likvidnost i izdaci za istraživanje i razvoj.

Zaključno se može reći da se istraživači koji su se bavili tematikom strukture kapitala i njezine veze s profitabilnosti nisu uspjeli ujednačeno složiti koja bi teorija najbolje objasnila odluke financijskih menadžera o izboru strukturi kapitala. Teorija redoslijeda pakiranja i trade-off teorija imaju svoje potvrde u raznim istraživanjima. Međutim, makrookruženje poduzeća i specifičnosti dotične zemlje u kojoj posluje imaju značajan utjecaj na poduzeće, njegovu strukturu kapitala te smjer i jačinu veze između strukture kapitala i profitabilnosti.

2.4 Poduzeću specifične determinante profitabilnosti

Kao što je prethodno navedeno, postoji mnoštvo čimbenika koji imaju utjecaj na profitabilnost poduzeća. Mogu se izraziti pomoću kvalitativnih ili kvantitativnih utjecaja. Kako je ovo rad kvantitativne prirode, koristiti će se knjigovodstvene vrijednosti koje se mogu naći u financijskim izvještajima poduzeća i tržišnih vrijednosti s izvorom u Zagrebačkoj burzi. U ovom dijelu rada će se razmotriti varijable koje su najčešće korištene u istraživanjima provedenima na temu determinanti profitabilnosti.

Struktura kapitala

Pod pojmom strukture kapitala podrazumijeva se odnos dugovnog i vlasničkog financiranja poduzeća. Uobičajeno, razina zaduženosti premašuje razinu financiranja poduzeća emisijom dionica. Prema teoriji redoslijeda pakiranja očekuje se negativna veza između zaduženosti

[25] Škuflić, L., Mlinarić, D., Družić, M. (2016): Relevantni faktori utjecaja na visinu profita poduzeća u prerađivačkoj industriji Hrvatske, Ekonomski fakultet, Zagreb. Dostupno na: http://hrcak.srce.hr/file/252978

poduzeća i njegove razine profitabilnosti jer će sposobnije (i prema tome profitabilnije) poduzeće u većini slučaja koristiti interno generirana sredstva, a ne dug za financiranje investicija, također bez korištenja dionica koje nose visoke troškove. Povremene nedostatke sredstava će financirati dugom. Kritičari te teorije zagovaraju pozitivnu vezu između zaduženosti i profitabilnosti kao rezultat poreznih ušteda zbog porezno odbitnih stavki[26]. U Hrvatskoj je bio vidljiv trend razduživanja i korištenja interno generiranih sredstava za investiranje kada je profitabilnost ukupnog sektora nefinancijskih poduzeća porasla. Prema navedenom će se očekivati negativna veza između zaduženosti i profitabilnosti u Hrvatskim poduzećima.

Ukupna imovina

Poduzeća na raspolaganju imaju različite vrste imovine, što uključuje dugotrajnu i kratkotrajnu imovinu kojom raspolaže tijekom svoga poslovanja. S jedne strane, na veliki udio materijalne imovine poduzeća može se gledati kao na sigurnosni jastuk pri zaduživanju jer će se ta imovina koristiti kao kolateral za kredit i time povećati dostupnost kredita za to poduzeće te sniziti cijena zaduživanja. S druge strane, poduzeća s velikim udjelom materijalne imovine mogu biti nefleksibilna zbog poteškoća pretvaranja takve imovine u likvidna sredstva. Korištenje materijalne imovine za dobivanje likvidnosti tijekom krize je mnogo teže za ostvariti. Međutim, kako je prema teoriji redoslijeda pakiranja zaduživanje nakon internih sredstva najznačajniji izvor financiranja investicija, očekivan je pozitivan utjecaj ukupne imovine. Treba uzeti u obzir kako se dug prvenstveno odnosi na kredite, a banke u Hrvatskoj traže visoku kolateriziranost kredita.

Veličina

Kao jedna od najčešće korištenih varijabli, veličina zauzima posebnu pažnju u analizi profitabilnosti poduzeća. Ona može imati različite učinke na profitabilnost. S jedne strane se očekuje pojava ekonomije obujma, pogotovo kod proizvodnih poduzeća, koja će omogućiti efikasniju proizvodnju pri višim razinama proizvodnje. S druge strane, veća se poduzeća mogu ponašati tromo i nefleksibilno zbog prevelike kompleksnosti. Međutim, prednosti velikih poduzeća se mogu ogledati u boljoj dostupnosti načina financiranja. Također, veliko poduzeće će imati manje problema s asimetričnim informacijama pa će se moći lakše

[26] Gill, A., Biger, N., Mathur, N. (2011): The Effect of Capital Structure on Profitability: Evidence from the United States, International Journal of Management, Vol. 28, No. 4. Dostupno na: https://www.researchgate.net/publication/281004540_The_effects_of_capital_structure_on_profitability_Evidence_from_United_States [15.08.2017]

financirati putem dionica. Veličina se može mjeriti raznim pokazateljima, uključujući prihode, imovinu i broj zaposlenika. Sve od navedenog upućuje na veliku imovinu, ne samo u materijalnom smislu, već znanju i iskustvu zaposlenika i povezanih sudionika poduzeća. Zbog toga, očekuje se pozitivna veza između imovine i profitabilnosti poduzeća.

Likvidnost

U širem smislu likvidnost poduzeća označava je li poduzeće u mogućnosti podmiriti svoje kratkoročne obveze bez značajnog gubitka vrijednosti imovine ili pak problema sa solventnošću. U praksi to za poduzeća znači da uvijek moraju imati dovoljno likvidnih sredstava na raspolaganju kako bi udovoljile svim neočekivanim događajima. Međutim, što je veća likvidnost poduzeća to je manji udio uloženih sredstava koja će generirati profit, a bez profita nema opstanka za poduzeće. Uz to, već samo pitanje o tome koliko bi likvidnih sredstava poduzeće trebalo čuvati sa strane teško će se moći odgovoriti. Iz tih razloga velika likvidnost, usprkos sigurnosti koju pruža, najčešće negativno utječe na profitabilnost poduzeća. Očekuje se prema teoriji redoslijeda pakiranja, da će poduzeće svojim likvidnim sredstvima financirati investicije. Prema tome bi poduzeća, umjesto da drže velik iznos likvidnih sredstava, trebala imati dobro uspostavljene načine financiranja kojima će zamijeniti potrebu za držanjem likvidnih sredstava. Načini financiranja za takve slučajeve mogu biti kratkoročni krediti, kreditne linije i slično. Prema navedenome, profitabilno poduzeće svoja likvidna sredstva koristi za generiranje dodatnih profita, što pretpostavlja negativnu vezu između likvidnosti poduzeća i njegove profitabilnosti.

Efikasnost

Jedna od determinanti profitabilnosti jest produktivnost poduzeća. Ona se može shvatiti kao sposobnost generiranja što viših prihoda sa što manje troškova. Efikasnije poslovanje treba imati pozitivan učinak na profitabilnost poduzeća. Iz tog razloga je važno pratiti kako poduzeće troši svoje resurse. Prema nekim autorima produktivnost ima velik utjecaj na formiranje tržišne strukture koja će pridonijeti raspodjeli profita na produktivnija i veća poduzeća[27].

[27] Stierwald, A., (2009): Determinants of Firm Profitability – The effect of Productivity and its Persistence, Melbourne Institute of Applied Economic and Social Research, Dostupno na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.361.1327&rep=rep1&type=pdf [02.08.2017]

Rast poduzeća

Kao i kod država kod kojih je cilj rast BDP-a, tako je i kod poduzeća važan rast. S tim rastom će u budućim razdobljima olakšati teret financiranja duga i uspostaviti preduvjete za prihvaćanje sve većeg broja investicija. To s druge strane može stvoriti i lakše uvjete financiranja, a očekuje se pozitivna veza između rasta poduzeća i njegove profitabilnosti jer rast poduzeća označava i povećanje imovine te rast interno generiranih sredstava zbog kojih će poduzeće bit manje ovisno o vanjskom financiranju.

Zadržana dobit

Istraživanja upućuju na to da će poduzeća koja su u prijašnjim razdobljima bila profitabilna vrlo vjerojatno i u sljedećem razdobljima biti profitabilna. S jedne strane, postojanje zadržane dobiti može se shvatiti kao sigurnosni sloj poduzeća, ali i kao znak dobrog poslovanja.

U tablici 1 prikazani su očekivani utjecaji razmatranih obilježja poduzeća:

Tablica 1: Očekivani učinci determinanti na profitabilnosti

Determinanta	**Očekivani učinak**
Zaduženost	Negativan/Pozitivan
Ukupna imovina	Pozitivan/Negativan
Veličina	Pozitivan/Negativan
Likvidnost	Negativan/Pozitivan
Zadržana dobit	Pozitivan/Negativan
Rast poduzeća	Pozitivan/Negativan
Produktivnost	Pozitivan/Negativan

Izvor: Izrada studentice

2.5 Pokazatelji uspješnosti i zaduženosti poslovanja

U središtu analize poduzeća je analiza financijskih izvještaja poduzeća[28]. Financijski izvještaji sadržavaju veliki skup podataka o poduzećima razdijeljen na 5 temeljnih financijskih izvještaja:

1. Bilanca
2. Račun dobiti i gubitka
3. Izvještaj o novčanom toku
4. Izvještaj o promjeni glavnice
5. Bilješke uz financijske izvještaje.

Kako bi se iz tih izvještaja dobila slika o stanju poduzeća i njegovoj budućnosti, koriste se različite metode analize financijskih izvještaja, koje se međusobno nadopunjuju:

1. Analiza putem pokazatelja
2. Komparativna analiza
3. Analiza trenda.

Najkvalitetniji pristup jest korištenje svih triju metoda. Pomoću pokazatelja u odnos se stavljaju podaci koji će se lakše moći analizirati i komparativnom analizom usporediti s povijesnim podacima, pokazateljima industrije i planiranim veličinama. Također, može se analizom trenda dobiti uvid u kretanje stanja poduzeća kroz vrijeme.

Postoji mnoštvo različitih pokazatelja koji se mogu koristiti u analizi, čak i za isti pokazatelj različiti autori koriste različite formule, ovisno o predmetu i kontekstu rada. Prema tome se pokazatelji i mogu različito klasificirati. Jedna uobičajena klasifikacija je[29]:

1. Pokazatelji likvidnosti
2. Pokazatelji menadžmenta imovine (efikasnost, aktivnost)
3. Pokazatelji menadžmenta duga (zaduženosti)
4. Pokazatelji uspješnosti (rentabilnosti)
5. Pokazatelji financijskih tržišta (tržišne vrijednosti)

[28] Vidučić, L. (2012): Financijski menadžment, 8. nepromijenjeno izdanje, RRiF – plus, d.o.o. za nakladništvo i poslovne usluge, Zagreb, poglavlje 11.
[29] Ibid, str. 392

Značajne razlike koje se javljaju kad se poduzeće financira pomoću zaduživanja u odnosu na vlastito financiranje jesu da[30]:

1. Vlasnici uz manja ulaganja zadržavaju kontrolu nad tvrtkom.
2. Kreditori su svjesni da je njihova sigurnost veća što je veći udio sredstava koji su osigurali vlasnici.
3. Dobit na vlastiti kapital tvrtke raste ako je stopa povrata ostvarena ulaganjem pozajmljenih sredstava veća od (fiksne) naknade za ta sredstva.

Pokazatelji profitabilnosti pokazuju ukupnu uspješnost poduzeća koja obuhvaća i informacije o snazi poduzeća, efektu likvidnosti i upravljanja dugom i imovine. Također, kod analize profitabilnosti poduzeća mogu se koristiti tržišni pokazatelji za poduzeća čije su dionice uvrštene na burzi vrijednosnica. Razlikuju se tradicionalni i suvremeni pokazatelji profitabilnosti. U tradicionalne pokazatelje profitabilnosti ubrajaju se:

- Povrat na ukupnu imovinu (ROA)
- Povrat na vlastiti kapital/dioničku glavnicu (ROE)
- Bruto profitna marža
- Neto profitna marža
- Temeljna snaga zarade

ROA je najrasprostranjeniji pokazatelj profitabilnosti koji se koristi. Taj pokazatelj uspoređuje dobit koju je poduzeće u toj godini ostvarilo u odnosu na ukupnu imovinu[31]. Također, pokazuje koliko efikasno menadžment koristi imovinu poduzeća za generiranje profita. Zbog toga predstavlja i snagu zarade tvrtke[32]. Umjesto neto dobiti nakon oporezivanja moguće je u brojnik ovog pokazatelja staviti neto dobit s pribrojenim troškom kamata, ako se želi uzeti u obzir operativna imovina koja se koristi bez troška nabave te imovine. Od neto dobiti se oduzme iznos dividendi za povlaštene dionice, ali se ostavlja dio neto dobiti za dividende redovnih dionica. ROA se među poduzećima može veoma razlikovati. Čak među industrijama u pravilu vladaju različite očekivane razine tog pokazatelja. Neki autori ovaj pokazatelj nazivaju i ROI, odnosno povrat na investiranje.

$$\text{ROA} = \frac{\text{neto dobit nakon oporezivanja}}{\text{ukupna imovina}} \quad (1)$$

[30] Ibid, str. 399
[31] http://www.investopedia.com/terms/r/returnonassets.asp
[32] Vidučić, L.(2012), op.cit., str. 404.

ROE uspoređuje neto dobit nakon oporezivanja s iznosom trajnog kapitala (vlastiti kapital ili dionička glavnica). To je pokazatelj povrata na vlastiti kapital koji pokazuje snagu zarade u odnosu na ulaganje dioničara, dok je ta zarada izražena prema knjigovodstvenoj vrijednosti[33]. Ovaj pokazatelj najbolje pokazuje koliko je poduzeće uspješno u cilju povećanja vrijednosti za dioničare.

$$\text{ROE} = \frac{\text{neto dobit nakon oporezivanja}}{\text{trajni kapital}} \quad (2)$$

Bruto profitna marža računa se dijeljenjem prihoda od prodaje umanjenih za trošak prodane robe s prihodima od prodaje[34]. Prema tome, ovaj pokazatelj je veoma podložan promjenama cijene proizvoda poduzeća koje prodaje, ali istovremeno i odražava efikasnost proizvodnje i kontrolu troškova. Kod ovog pokazatelja bilo bi dobro usporediti ga s obujmom prodaje. Naime, poduzeće može postati profitabilnije ukoliko na malen obujam prodaje stavlja veliku maržu ili uz malu maržu ostvaruje veliki obujam prodaje.

$$\text{Bruto profitna marža} = \frac{\text{Prodaja - troškovi za prodano}}{\text{Prodaja}} \quad (3)$$

Neto profitna marža pokazuje kako menadžment kontrolira troškove, rashode i prihode, pa se koristi kao pokazatelj efikasnosti menadžmenta[35]. Taj pokazatelj određuje kolika se neto dobit po jednoj kuni prodaje generira za dioničare. Nizak pokazatelj javlja se zbog niskih cijena proizvoda koja poduzeće prodaje, ili zbog visokih troškova koja terete tu prodaju.

$$\text{Neto profitna marža} = \frac{\text{neto dobit nakon oporezivanja}}{\text{Prodaja}} \quad (4)$$

Temeljna snaga tvrtke se koristi kada se uspoređuju poduzeća s različitim stupnjevima financijske poluge.

$$\text{Temeljna snaga tvrtke} = \frac{\text{dobit prije kamata i oporezivanja}}{\text{ukupna imovina}} \quad (5)$$

[33] Ibid, str. 404
[34] Ibid, str. 402.
[35] Ibid, str. 402-403.

Pod **tržišnim pokazateljima profitabilnosti** se podrazumijevaju:

- Dobit po dionici (EPS)
- Pokazatelj cijena/zarada (P/E)
- Pokazatelj tržišna/knjigovodstvena vrijednost (M/B)
- Stopa isplate dividendi
- Povrat od dividendi

EPS je jedan od najčešćih pokazatelja (uz stope isplate dividendi i povrat od dividendi) koji dioničari i druge osobe mogu koristiti kako bi uzevši u obzir tržišne podatke o poduzeću ocijenili njegovu vrijednost [36]. Ovaj pokazatelj se također naziva neto dobitak nakon prioritetnih dividendi po običnoj dionici (EPS).

$$\text{EPS} = \frac{\text{neto dobitak nakon prioritetnih dividendi}}{\text{broj običnih dionica u prometu}} \qquad (6)$$

Pokazatelj cijena i zarada (P/E) pokazuje koliko su investitori voljni platiti za 1 kunu zarade poduzeća. Za izračun ovog pokazatelja koristi se pokazatelj EPS.

$$\text{Pokazatelj } \frac{\text{P}}{\text{E}} = \frac{\text{tržišna cijena dionice}}{\text{neto dobitak nakon prioritetnih dividendi po običnoj dionici}} \qquad (7)$$

Uz navedene tržišne pokazatelje profitabilnosti, mogu se koristiti pokazatelji M/B i knjigovodstvena vrijednost po dionici. M/B označava kako investitori procjenjuju tvrtku jer uzima u obzir tržišnu cijenu dionica poduzeća naprema njegovoj knjigovodstvenoj vrijednosti.

[36] Ibid, str. 405.

Pokazatelji zaduženosti daju uvid u razinu duga u financiranju poduzeća. Može pokazati odnos između ročnosti financiranja ili pak između dugovnog i vlastitog financiranja.

Pokazatelj zaduženosti (D/A) pokazuje koliki udio sredstava su osigurali vjerovnici (kreditori)[37]. Pri ovom pokazatelju se uzimaju u obzir ukupni dugovni izvori financiranja poduzeća, dugoročni i kratkoročni.

$$\frac{D}{A} = \frac{\text{ukupni dug}}{\text{ukupna imovina}} \qquad (8)$$

Pokazatelj financiranja (D/E) pokazuje omjer između duga i vlastitog kapitala, pri čemu veći pokazatelj označava da će tvrtka imati i veći trošak trajnog kapitala i manju sposobnost zadržavanja financijske stabilnosti u razdobljima recesije[38].

$$\frac{D}{E} = \frac{\text{ukupni dug}}{\text{vlastiti kapital}} \qquad (9)$$

[37] Ibid, str. 400.
[38] Ibid.

3. EMPIRIJSKO ISTRAŽIVANJE

3.1 Kretanje zaduženosti i profitabilnosti poduzeća u Hrvatskoj

Hrvatski sektor poduzeća obilježen je velikom razinom duga kod domaćih, ali i inozemnih kreditnih institucija, što se vidi u visokim razinama vanjskog duga. Takvo stanje nije samo nezgodno za poduzeća, već se i smatra čimbenikom kočenja oporavka cjelokupnog gospodarstva[39]. Kao što se vidi na slici 2, nekonsolidirani dug poduzeća u 2016. godini kreće se oko 100% BDP-a što čini hrvatski sektor nefinancijskih poduzeća jednom od najzaduženiji u središnjoj i istočnoj Europi. Jedan od najvećih problema prezaduženih poduzeća je njihov manjak prostora djelovanja kada im se ukaže prilika za investiranje. Dodatno, velika ukupna zaduženost poremećuje alokaciju sredstava od neproduktivnih prema produktivnim, rastućim poduzećima te predstavlja rizik za stabilnost cjelokupnog financijskog sustava zbog negativnih učinaka slabog vraćanja kredita i većoj osjetljivost na šokove pri kamatnim stopama. Tako je zaduženost najviše porasla u razdoblju između 2005. i 2014. godine, ponajviše u sektoru nekretnina, građevinarstva, prijevoza i zaliha.



Slika 2: Zaduženost sektora poduzeća

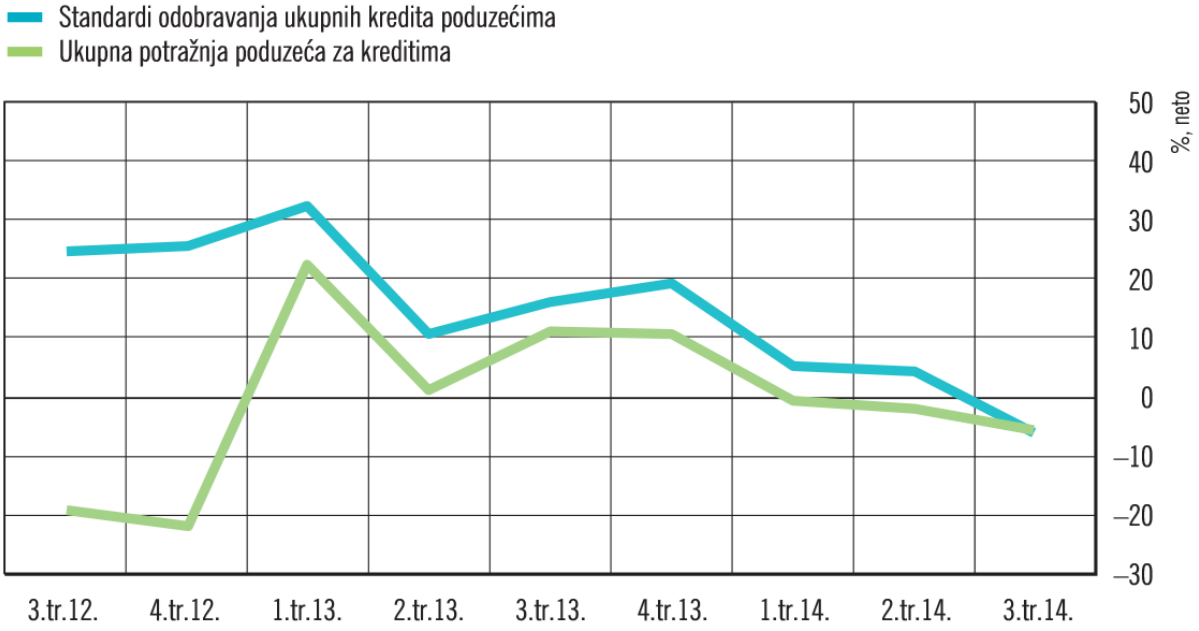
Izvor: HNB, Financijska stabilnost 18

U razdoblju krize je uzlet zaduženosti stao, ali je razina samo opala u sektorima u kojima je i početno bila niža. Također, autori posebno ističu kako je sektor malih poduzeća manje

[39] Martinis, A., Ljubaj, I. (2016): Corporate Debt Overhang in Croatia: Micro Assessment and Macro Implications, The Twenty-Second Dubrovnik Economic Conference, Dostupno na: https://www.hnb.hr/documents/20182/783865/22-dec-martinis-ljubaj.pdf [16.08.2017]

zadužen od ostalih poduzeća što upućuje na nedostupnost tog načina financiranja za njih. Rezultat istraživanja upućuje na to da je trećina iznosa duga neumjeren i koncentriran kod velikih poduzeća koja nemaju izvoznu stranu. Neumjerena zaduženost koči investicijske aktivnosti poduzeća.

Obzirom što uzorak podataka ovog rada obuhvaća razdoblje od 2014. do 2016. godine, nadalje će se detaljnije razmotriti kretanje zaduženosti poduzeća u hrvatskoj u tim godinama. Prema publikaciji Hrvatske Narodne Banke[40] 2014. godini je prethodio proces razduživanja nefinancijskih poduzeća u inozemstvu zbog zamjene duga s vlasničkim udjelima. Također se na slici 3 može vidjeti pad ukupne potražnje poduzeća za kreditima uz istovremeni pad standarda odobravanja kredita što kredite čini dostupnijim poduzećima.



Slika 3: Promjena potražnje i standarda odobravanja kredita poduzećima

Izvor: HNB, Financijska stabilnost 14

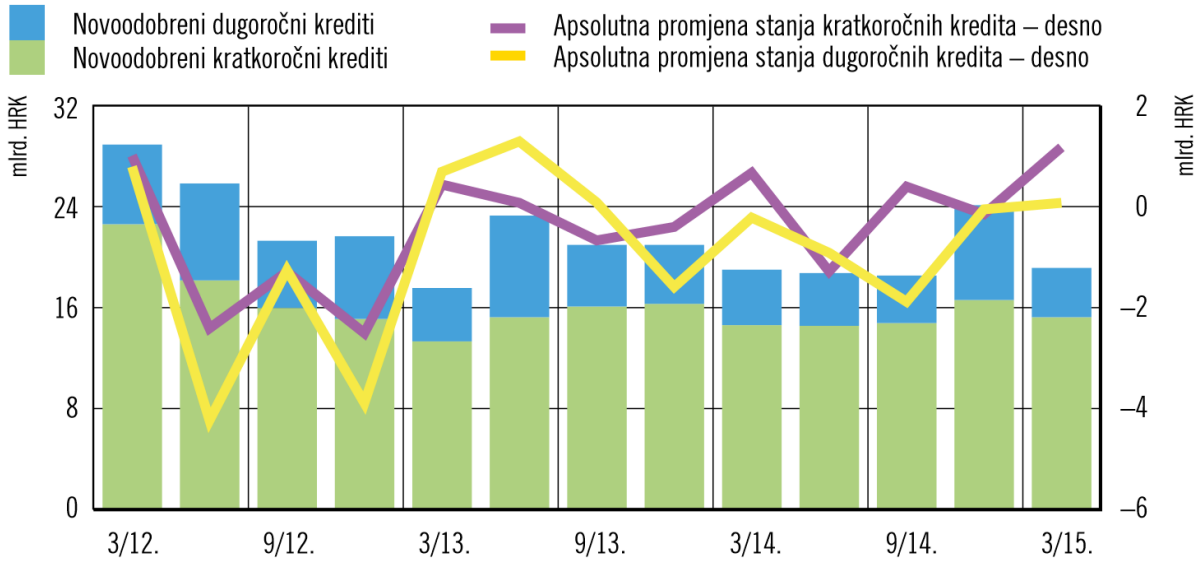
Zatim je, početkom 2014. godine opet zabilježen rast vanjskog duga dok dug prema domaćim bankama stagnira. Poseban je naglasak na povećani rizik kamatnih stopa koji bi se trebao kompenzirati s padom prosječne kamatne stope. Problem je što je razduživanje u mnogo slučaja uzrokovano refinanciranjem, korištenjem drugih metodologija ili prebacivanje s inozemnog na tuzemno zaduživanje. Prema HNB-ovim rezultatima anketiranja banaka,

[40] Hrvatska narodna banka (2014): Financijska stabilnost, broj 13, Zagreb. Dostupno na: http://old.hnb.hr/publikac/financijska%20stabilnost/h-fs-13-2014.pdf [30.08.2017]

potražnja za kreditima u 2013. godini je porasla, međutim stagnirala je ulaskom u 2014. godinu. Istovremeno, udio kratkoročnih kredita u novoodobrenim kreditima je porastao, što upućuje na negativne trendove investiranja uzevši pretpostavku da poduzeća investicije financiraju dugoročnim izvorima. Nadalje, poduzeća se u nastavku 2014. godine razdužuju prema inozemnim izvorima, ali se zato zadužuju tuzemno, što u ukupnosti rezultira u većem teretu zaduženosti na nefinancijski sektor poduzeća[41]. Inozemni dug se tako najviše povećavao u djelatnostima trgovine, građevinarstva, djelatnosti pružanja smještaja i pripreme hrane. Najveći porast inozemnog duga se javlja kod prehrambene, farmaceutske, metaloprerađivačke i elektroindustrije. Neke djelatnosti imaju smanjenu potražnju za kreditima, što ukazuje na razduživanje kod domaćih banaka. Djelatnosti građevinarstva i hotelijerstva su se dalje zaduživale, a kod prehrambene industrije je izraženo refinanciranje domaćeg duga inozemnim. Sve navedeno ukazuje na visoku razinu rizičnosti u sektoru nefinancijskih poduzeća koji se nakon 2013. godine nastavlja u 2014. godini.

Početkom 2015. godine primjećuje se proces razduživanja poduzeća kod domaćih izvora i intenzivnog inozemnog zaduživanja prema čemu u ukupnosti razina duga raste, makar po niskim stopama, i to u ožujku 2015. na 81,3% BDP-a[42]. Poboljšani financijski rezultati su rezultirali u smanjenoj ranjivosti sektora poduzeća. Prema podacima FINE je tako ROE za 2014. godinu za poduzetnike obveznike poreza na dobit (uključujući obrtnike, javna poduzeća i fizičke osobe) porastao na 3,7%. U drugoj polovici 2015 godine se nastavio oporavak gospodarske aktivnosti koji je dodatno smanjio teret sektora poduzeća zbog poboljšanih financijskih rezultata poduzeća. Iz istog razloga je i ukupni rizik sektora pao. Nadalje, poduzeća su smanjila svoju razinu zaduženosti kod domaćih banaka. Usprkos daljnjem povećanju inozemnog zaduživanja, ukupan efekt je smanjenje ukupne zaduženosti. Također se početkom 2015. godine vidi ublažavanje kreditnih standarda. Kamatni rizik je početkom 2015. godine blago rastao uz istovremeno snižavanje kamatnih stopa. Cijene kratkotrajnog zaduživanja su primjetno više pale od cijene dugoročnog financiranja poduzeća u Hrvatskoj. Čak su razine kamatnih stopa na kratkoročni dug bile niže od razine kamatnih stopa na dugoročni dug u tom razdoblju. Navedeno upućuje na stanje u kojem je bila mala potražnja za dugoročnim izvorima financiranja zbog niske razine investicijskih aktivnosti.

[41] Hrvatska narodna banka (2015): Financijska stabilnost, broj 14, Zagreb. Dostupno na: http://old.hnb.hr/publikac/financijska%20stabilnost/h-fs-14-2015.pdf [30.08.2017]
[42] Hrvatska narodna banka (2015): Financijska stabilnost, broj 15, Zagreb. Dostupno na: http://old.hnb.hr/publikac/financijska%20stabilnost/h-fs-15-2015.pdf [30.08.2017]



Slika 4: Novoodobreni krediti banaka i apsolutna promjena stanja bruto kredita

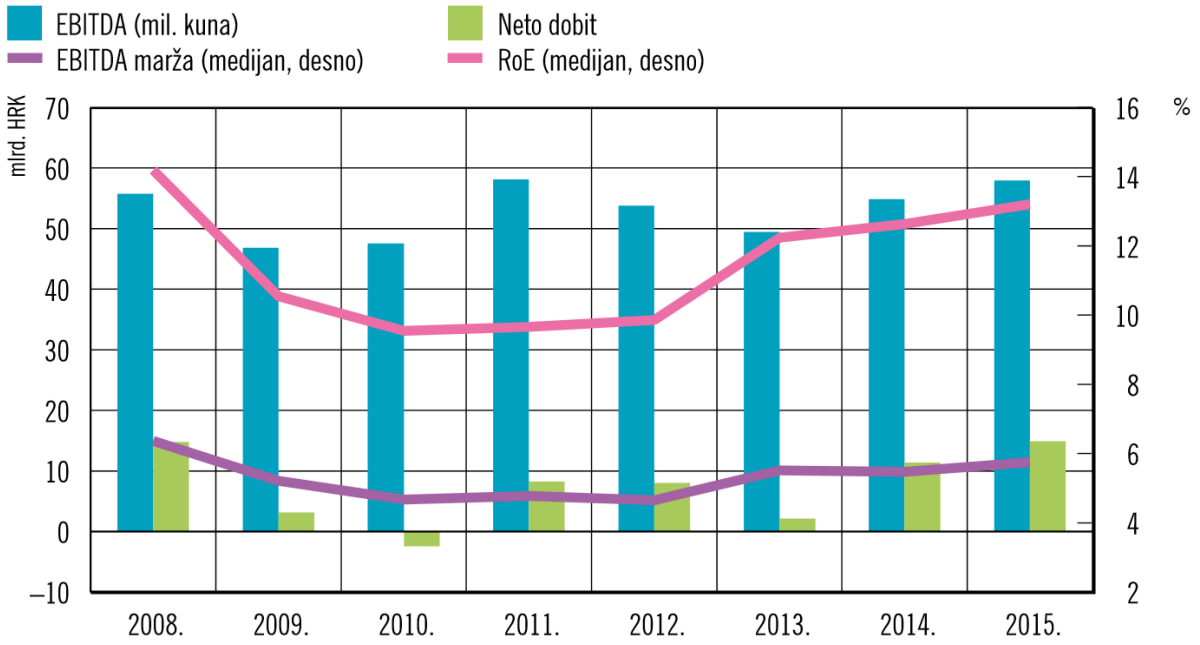
Izvor: HNB, Financijska stabilnost 15

Vrlo dobri poslovni rezultati iz 2014. godine su poduzećima omogućila nastavak trenda razduživanja i korištenja interno generiranih sredstava za financiranje. Činjenica smanjena broja kratkoročnih kredita upućuje na veću sposobnost da poduzeća sama financiraju svoj radni i obrtni kapital. Istovremeno je povećan broj novoodobrenih dugoročnih kredita poduzećima kao što se može vidjeti na slici 4. Prema zaključku HNB-a, poduzeća su u tom razdoblju dio zadržane dobiti pretvarala u kapital i rezerve za buduće potrebe financiranja.

Početkom 2016. godine nastavljen je pad ukupne zaduženosti iako se kreditiranje intenziviralo[43]. Razlog tomu je snažno razduživanje u inozemstvu omogućeno dobrim poslovnim rezultatima u 2015. godini. Takva kretanja omogućuju poduzećima postupno restrukturiranje njihovih bilanci i financiranje iz vlastitih izvora. Također, rezultati ankete banaka o kreditnoj aktivnosti poduzeća pokazuju istovremeni rast potražnje za kreditima i ublažavanje uvjeta kreditiranja za sve segmente poduzeća i skupine kredita. Tomu su pridonijele investicije u fiksni kapital i restrukturiranje duga u poduzećima. Međutim, u tom razdoblju povećala se izloženost poduzeća kamatnom riziku odnosno riziku zbog mogućeg povećanja kamatne stope. Jedan od razloga rasta u značaju tog rizika je povećana potražnja za kratkoročnim financiranjem. Dugoročne kamatne stope domaćih banaka su stagnirale i bile relativno stabilne. Sektor nefinancijskih poduzeća u prvom tromjesečju 2016. godine je bio

[43] Hrvatska narodna banka (2016): Financijska stabilnost, broj 17, Zagreb. Dostupno na: https://www.hnb.hr/documents/20182/521139/h-fs-17-2016.pdf [30.08.2017]

manje ranjiv zbog pada rizika likvidnosti i pada rizika solventnosti zbog čega su poduzeća imala mogućnost povećanja svog kapitala i rezervi. Zbog pozitivnih kretanja u drugoj polovici 2016 godine, očekivanja za 2017 godinu su optimistična[44].



Slika 5: Oporavak agregatnoga poslovnog rezultata nefinancijskih poduzeća u razdoblju 2008.-2015. g.

Izvor: HNB, Financijska stabilnost 17

Kao što se može vidjeti na slici 5, financijski rezultat nefinancijskih poduzeća od 2012. godine stabilno raste. Nadalje, može se uočiti blagi pad ukupne zaduženosti. Navedeno rezultira u smanjenju pokazatelja ranjivosti nefinancijskih poduzeća i očekivanim nastavkom takvog trenda što su važni preduvjeti za zadovoljavanje kreditnih uvjeta i omogućavanje pozitivne investicijske klime za poduzeća.

Kada je riječ o kretanju profitabilnosti poduzeća u Hrvatskoj, može se primijetiti da se nakon nepovoljnih gospodarskih kretanja i krize Hrvatsko gospodarstvo polagano oporavlja. Takva kretanja imaju velik utjecaj na glavne makroekonomske agregate koje posredno i neposredno utječu i na cjelokupno poslovanje poduzeća te financijski rezultat na kraju godine. Usprkos pozitivnog financijskog rezultata u 2013. godini, druga polovica 2014. godine upućuje na

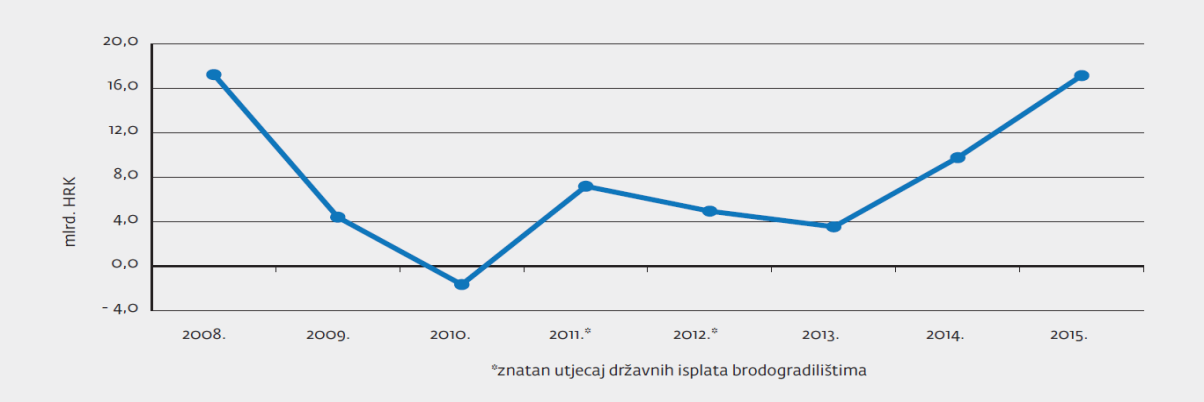
[44] Hrvatska narodna banka (2017): Financijska stabilnost, broj 18, Zagreb. Dostupno na: https://www.hnb.hr/documents/20182/1972383/h-fs-18-2017.pdf [30.08.2017]

nastavak nepovoljnih gospodarskih kretanja. Prema podacima Zagrebačke burze, veći broj izvještaja tvrtki čije su dionice uvrštene na burzu pokazuje pad poslovnih i ukupnih prihoda[45].

Krajem 2014. godine je na zagrebačkoj burzi zabilježena veća dinamika trgovanja, povećani promet uz povoljnije kretanje cijena dionica zbog smanjenja političke neizvjesnosti i uobičajenih prilagodbi portfelja koju investitori obavljaju krajem godine kako bi optimizirali svoje poslovne rezultate. Kao dodatni čimbenik povećanog prometa krajem 2014. godine poslužila je odluka o uvođenju oporezivanja kapitalnih dobitaka. Investicije su smanjene u promatranom razdoblju. Većina djelatnosti je poslovala s dobiti. Najveći rast u ukupnim prihodima je ostvaren u trgovini na malo i veliko te u prijevozu i skladištenju. Najveća dobit je ostvarena u prerađivačkoj industriji te trgovini na malo i veliko, a najveći gubitak je bilježen u građevinarskoj industriji[46].

Visoka neizvjesnost i rizik te iznenađujuća politička kretanja uzrokovala su kratkoročne trzavice na tržištu kapitala. Nakon toga je ubrzan rast cijena i vraćen optimizam investitora. Krajem 2015. godine su bilježeni osjetno bolji financijski rezultati poslovanja poduzetnika. Prema strukturi veličine, veliki su poduzetnici svoj financijski rezultat blago pogoršali u odnosu na prethodnu godinu. Gledajući prema djelatnostima, najbolji rezultat ostvaren je kod trgovine na malo i veliko, prijevozu i skladištenju te u poslovanju nekretninama. U 2015. godini su samo 3 područja prema NKD-a[47] ostvarile gubitak na kraju godine: rudarstvo i vađenje, građevinarstvo, te poslovanje nekretninama [48] . Slika 6 prikazuje ukupnog konsolidiranog financijskog rezultata poslovanja poduzetnika.

[45] Zubak, D., Hanzl, Ž., Pađen, Ž., Pipp, P. (2016): Gospodarska kretanja 2016. 11/12, Hrvatska gospodarska komora. Dostupno na: https://www.hgk.hr/documents/gospodarskakretanja111258860da55f948.pdf [30.08.2017]
[46] Zubak, D., Hanzl, Ž., Pađen, Ž., Pipp, P. (2016): Gospodarska kretanja 2015. 11/12, Hrvatska gospodarska komora. Dostupno na: http://www.hgk.hr/documents/gospodarskakretanja111257b6f893727ba.pdf [30.08.2017]
[47] Skraćen naziv za: nacionalna klasifikacija djelatnosti.
[48] Zubak, D., Hanzl, Ž., Pađen, Ž., Pipp, P. (2015): Gospodarska kretanja 2014. 12, Hrvatska gospodarska komora. Dostupno na: https://www.hgk.hr/documents/gospodarskakretanja12-201457d29d5a9b724.pdf [30.08.2017]



Slika 6: Konsolidirani financijski rezultat poslovanja poduzetnika

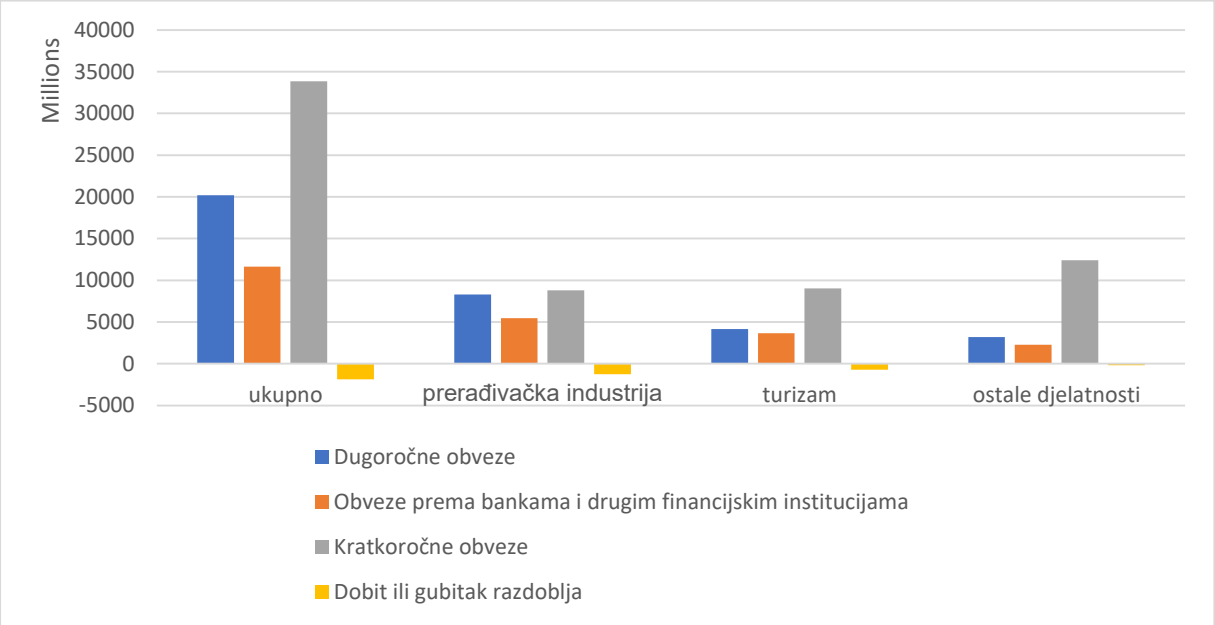
Izvor: HGK, gospodarska kretanja 2016. 11/12.

U ovom radu će se koristiti podaci iz objavljenih financijskih izvještaja poduzeća koja su uvrštena na Zagrebačku burzu. Uzorak je sastavljen od ukupno 84 poduzeća za koja su u razdoblju 2014. do 2016. godine neprekidno bili dostupni cjeloviti financijski izvještaji kako bi se mogla napraviti usporedba kroz te tri godine. Od tih podataka je sastavljena baza podataka za sve tri godine. Za godinu 2016. podaci su dodatno dopunjeni za podatke o iznosu dividendi za redovne dionice, broju redovnih dionica, pokazatelju P/E i pokazatelju EPS, sa internetske stranice mojedionice.com kako bi se također mogla izračunati regresijska analiza s tržišnim pokazateljima profitabilnosti. Pokazatelj ROE nije uzet u obzir u analizi jer je i za 2016. godinu značajan dio podataka bio nepotpun što bi uvelike smanjilo uzorak. Pomoću podataka su izračunati različiti pokazatelji koji predstavljaju različite varijable za koje se ispituje statistički značajan utjecaj na profitabilnost poduzeća. Utjecaj varijabli će se ispitati pomoću različitih statističkih testova. Rezultati tih analiza će se prikazati i analizirati u daljnjem tekstu.

U ovom dijelu rada će se prvo razmotriti druga hipoteza koja glasi: **Postoji razlika u zaduženosti poduzeća ovisno o sektoru.** Prema već iznesenome, odnosno prema HGK-u i HNB-u, postoji razlika u razini profitabilnosti i u razini zaduženosti prema sektorima. Razlika postoji ne samo u pogledu razine, već i u kretanju financijskih rezultata i kretanja zaduživanja. Unutar nekih sektora može se u promatranom razdoblju uočiti proces razduživanja, stagnacije duga ili porasta zaduživanja. Međutim, u ovom dijelu rada će se razmotriti te varijable na podacima iz baze podataka promatranih 84 poduzeća uvrštenih na redovno tržište Zagrebačke burze. Kako bi se mogla napraviti usporedba, uzorak će se podijeliti na sektore kako bi se bolje moglo uočiti razlike. Podjela je temeljena na nacionalnoj

klasifikaciji sektora, međutim je ta klasifikacija za korištenje u ovom radu prekomjerno detaljna. S obzirom što se radi o relativno malom uzorku je ta klasifikacija agregirana na 3 sektora. S obzirom na hrvatsko gospodarstvo će se smatrati prihvatljivim podijeliti sva poduzeća na 3 sektora kako ne bi bio premali broj industrija u pojedinom sektoru. Kako bi se ravnomjerno podijelilo poduzeća u sektore bez da se poremeti njihova industrijska pripadnost će se koristiti dva glavna sektora ovog gospodarstva: turizam i industrija. Ostala poduzeća koja ne upadaju u spomenuta dva sektora će se zajedno spojiti u sektor ostalo jer su previše specifična kako bi se uvrstila u industriju ili turizam, ali premalobrojni da i tvorili zasebnu podjelu.

Konačan izbor sektora glasi: prerađivačka industrija[49] (u kojoj su ubrajana poduzeća s prehrambene, kemijske, proizvodne, naftne industrije i sl.), turizam (u kojemu su spojeni hoteli, hotelske grupe i poduzeća koja se bave poslovima turističkih agencija) i ostale djelatnosti (u koje su uključene telekomunikacije, trgovina, prijevoz i sl.) Tablica koja pokazuje koje je poduzeće klasificirano u koji sektor nalazi se u prilogu rada.

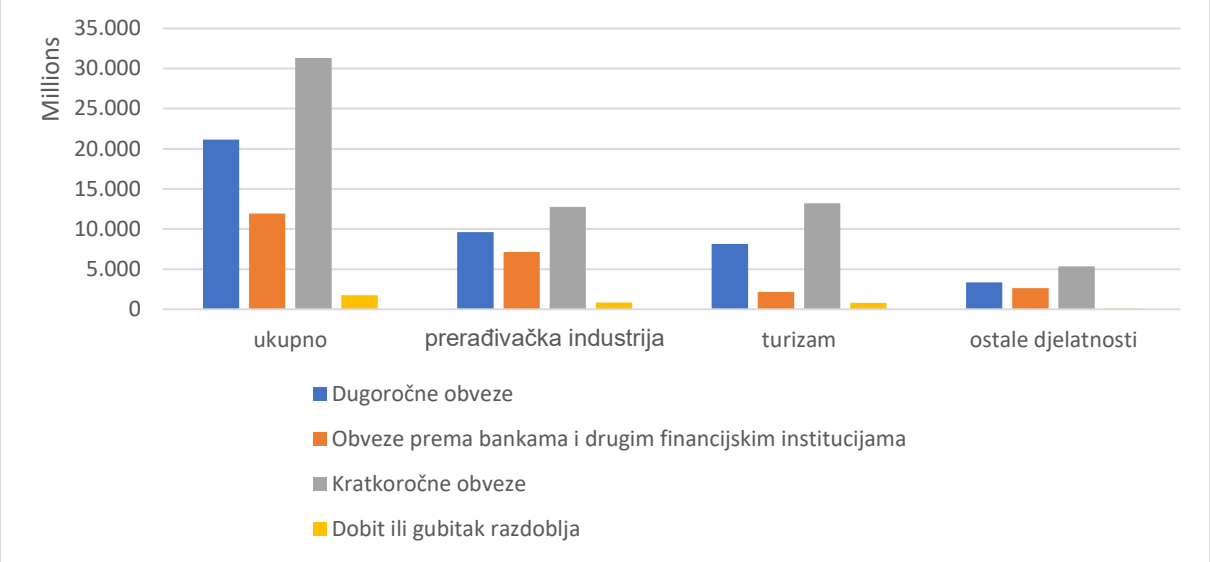


Grafikon 1: Zaduženost i profitabilnost poduzeća prema odabranim sektorima u 2014. godini

Izvor: Izrada studentice prema podacima iz financijskih izvještaja poduzeća sa Zagrebačke burze

[49] http://www.enciklopedija.hr/natuknica.aspx?id=50198

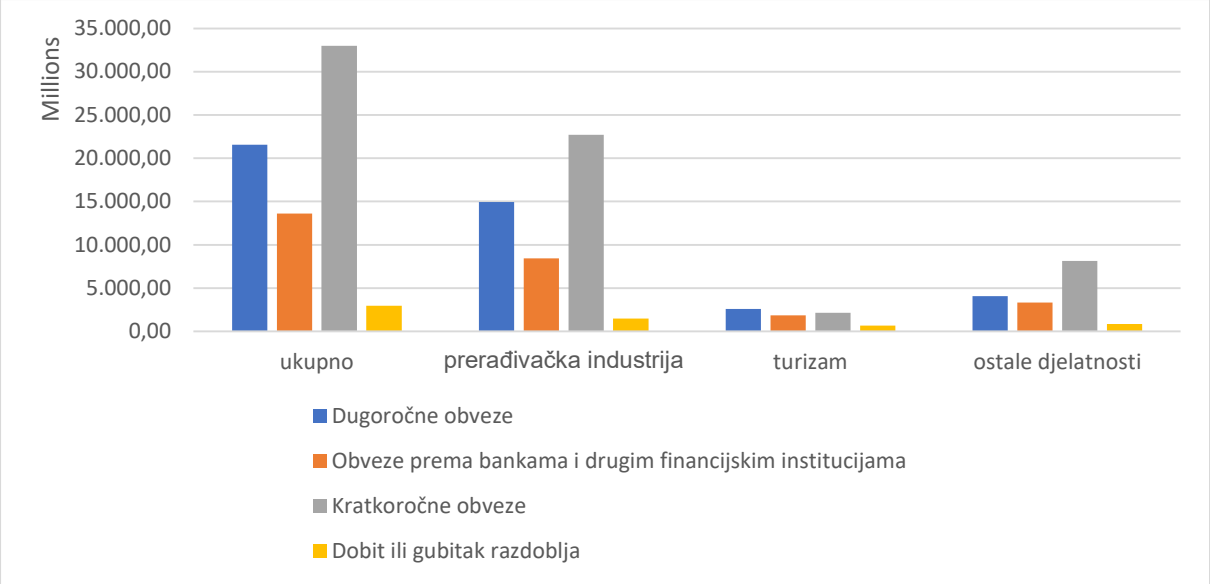
Na grafikonu 1 koji prikazuje podatke iz 2014. godine se jasno vide posljedice krize kojom je hrvatsko gospodarstvo do nedavno bilo zahvaćeno. Naime, uzorak kao cjelina je bilježila gubitak u svojim financijskim izvještajima. Također, može se primijetiti velika razina zaduženosti u odnosu na financijski rezultat, u svim sektorima. Što se tiče strukture zaduženosti, ona je u ovim grafičkim prikazima podijeljena na dugoročne obveze, obveze prema bankama i drugim financijskim institucijama i kratkoročne obveze. Pretpostavit će se u ovom dijelu rada da se obveze prema bankama i drugim financijskim institucijama prvenstveno odnose na kredite odobrenih kod kreditnih institucija bilo tuzemnog ili inozemnog porijekla. Takvo očekivanje se temelji na bankocentričnosti hrvatskog financijskog sustava na kojem je mali udio obveznica na tržištu kapitala. U objavljenim financijskim izvještajima nema izdvojenih podataka o iznosima uzetih kredita. Dodatno, ističe se kako je udio obveza prema bankama i drugim financijskim institucijama u dugoročnom financiranju poduzeća u cijelom uzorku veći od polovice iznosa ukupnog dugoročnog financiranja. Pri prerađivačkoj industriji ono iznosi i dvije trećine ukupnog dugoročnog zaduživanja, a kod turizma zauzima gotovo cjelokupno dugoročno zaduživanje. Dodatno, važno je uočiti odnos između kratkoročnih i dugoročnih obveza poduzeća. Naime, kratkoročne obveze u svim sektorima premašuju dugoročne, ponajviše u ostalim djelatnostima. Pri prerađivačkoj industriji je kratkoročno zaduživanje gotovo jednakog iznosa kao dugoročno financiranje, a kod sektora turizam je iznos kratkoročnih obveza otprilike dvostruke visine iznosa dugoročnih obveza. U svemu tome se vidi smanjena gospodarska aktivnost uz veliku zaduženost i slab okvir za investicijske aktivnosti koje se uobičajeno financiraju dugoročnim izvorima.



Grafikon 2: Zaduženost i profitabilnost poduzeća prema odabranim sektorima u 2015. godini

Izvor: Izrada studentice prema podacima iz financijskih izvještaja poduzeća sa Zagrebačke burze

U odnosu na 2014. godinu, u 2015. godini može se primijetiti porast svih prikazanih stavki kada se pogleda dio grafikona 2 koji prikazuje podatke za cijeli uzorak. Uz to može se vidjeti pomak financijskog rezultata iz negativnog u pozitivno područje. Ukupno gledano, kratkoročne obveze su se više, a dugoročne obveze manje, smanjile. U prerađivačkoj industriji se može primijetiti porast svih vrsti obaveza što upućuje na porast aktivnosti u poduzećima. Dugoročne obveze se gledaju kao izvor financiranja investicija, a kratkoročne obveze često služe za financiranje obrtnog kapitala za kojim postoji veća potreba pri rastu gospodarske aktivnosti. Pogotovo kada se uzme u obzir da poduzeća još nemaju dovoljne zalihe zadržane dobiti i slobodnih likvidnih sredstava kao posljedice nedavne krize. Kod sektora turizma se vidi povećanje kratkoročnog financiranja, uz istovremeni pad iznosa dugoročnog financiranja od financijskih institucija. Kod ostalih djelatnosti se može uz porast profitabilnosti primijetiti i drastično smanjenje kratkoročnog zaduživanja poduzeća.



Grafikon 3: Zaduženost i profitabilnost poduzeća prema odabranim sektorima u 2016. godini

Izvor: Izrada studentice prema podacima iz financijskih izvještaja poduzeća sa Zagrebačke burze

Uzimajući u obzir podatke iz 2016. godine, prikazanih na grafikonu 3, može se primijetiti daljnji porast profitabilnosti poduzeća iz uzorka, izuzev sektora turizma koji je na malo nižoj razini u odnosu na prethodnu godinu. Ukupno gledano, rasla je razina kratkoročne zaduženosti. Dugoročne obveze su ostale na istoj razini, međutim se udio obveza prema bankama i drugim financijskim institucijama u ukupnom dugovnom financiranju povećao. Posebno se ističe pad razine zaduženosti u sektoru turizma, uz istu razinu obveza prema bankama i drugim financijskim institucijama. U ostalim djelatnostima se razina svih vrsta zaduženosti povećala.

3.3 Definiranje uzorka i varijabli

Konačni izbor varijabli korištenih u regresijskoj analizi i formule korištene za njihov izračun prikazane su u tablici 2. Rezultati regresijske analize detaljnije prikazati u nastavku rada. Očekivani učinci i značenje varijabli su prethodno opisani u poglavlju 2.4. Rast poduzeća je izuzet pri regresijskoj analizi jer bi se za dobivanje te varijable trebala uzeti u obzir delta prihoda što bi s korištenom bazom podataka uzrokovalo smanjenje odabranog vremenskog razdoblja s tri na dvije godine. Također, varijabla zadržana dobit se ne nalazi u konačnom modelu jer je bila neznačajna i nije povećala snagu modela. Takav rezultat je vjerojatno povezan s razdobljem gubitka potom lagano rastuće dobiti poduzeća pri čemu nije bilo prilike stvoriti zadržanu dobit do sada.

Kako bi se dobili bolji rezultati u regresijskoj analizi, za različite varijable postavljeni su i analizirani različiti izračuni za iste varijable. Za pokazatelj P/E je upisana formula iz stručne literature, a podaci su bez izračuna direktno preuzeti s internetske stranice mojedionice.com. Ostale varijable su ili direktne vrijednosti iz napravljene baze podataka ili izračunati iz tih podataka. Pri modelima su korištene sljedeće varijable odnosno pokazatelji s prikazanim izračunom:

Tablica 2: Prikaz zavisnih i nezavisnih varijabli korištenim u analizi

Varijabla	Naziv u SPSS-u	Izračun
Profitabilnost (tradicionalni pokazatelj)	ROA	ROA = neto dobit /u kupna imovina
Profitabilnost (suvremeni pokazatelj)	P/E	P/E = tržišna cijena dionice / neto dobitak nakon prioritetnih dividendi po običnoj dionici
Zaduženost	koefZad	Koeficijent zaduženosti = ukupni dug (tj. obveze) / ukupna imovina
Likvidnost	tekLik	Tekuća likvidnost = kratkotrajna imovina / kratkotrajne obveze
Veličina	matIm	Logaritam na bazi 10 od materijalne imovine
Efikasnost	obrZal	Koeficijent obrta ukupne imovine = ukupni prihodi / ukupna imovina
Profitabilnost prijašnjih razdoblja	zadDob	Zadržana dobit

Izvor: Rezultat istraživanja studentice

3.3 Metodologija istraživanja

Kako bi se potvrdile ili opovrgnule hipoteze koje su postavljene u teoretskom dijelu rada će se koristiti kvantitativne metode u statističkom programu SPSS. Koristit će se regresijska analiza za svaku od promatranih godina zasebno te usporediti rezultati. Podaci nemaju vremensku komponentu i prostorno se odnose na poduzeća na području Hrvatske. Usporedbom različitih modela će se odabrati onaj koji je najoptimalniji, mjeren koeficijentom determinacije. Metodom ENTER[50] će se uvesti varijable u model kako bi imao što veću snagu. Ta metoda odabira varijabli pretpostavlja da sve odabrane varijable odjednom ulaze u model višestruke regresije što se naziva forsiranim ulazom svih varijabli. Pri tome u model mogu ući i varijable koje same po sebi nisu statistički značajne, ukoliko one povećaju snagu testa.

Općenito, model višestruke regresije može se zapisati kao:

$y = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \beta_3 \cdot x_3 ... \beta_k \cdot x_k + e$

Modeli koji će se u nastavku rada međusobno uspoređivati se mogu zapisati na sljedeći način:

1. $ROA = \beta_0 + \beta_1 \cdot koefZad + \beta_2 \cdot tekLik + \beta_3 \cdot matIm + \beta_4 \cdot obrZal + \beta_5 zadDob \cdot + e$
2. $P/E = \beta_0 + \beta_1 \cdot koefZad + \beta_2 \cdot tekLik + \beta_3 \cdot matIm + \beta_4 \cdot obrZal + \beta_5 zadDob \cdot + e$

Pri čemu je:

β_0 – konstanta

β_i – procijenjeni parametri

e – slučajna greška

[50] Detaljnije o regresijskoj analizi i korelaciji te korištenim testovima u ovom istraživanju pogledati u: Rozga, A. (2009): Statistika za ekonomiste, V. izdavanje, str. 197. Sveučilište u Splitu, Ekonomski fakultet, Split.

3.5 Rezultati istraživanja

3.5.1 Rezultati regresijskog modela s tradicionalnom mjerom profitabilnosti - ROA

Pomoću višestruke linearne regresije testirani su različiti modela kako bi se testirale postavljene hipoteze. U svrhu izračuna je korišten statistički program SPSS. U prvom modelu je uzet pokazatelj ROA kao mjera profitabilnosti. Ona predstavlja zavisnu varijablu u modelu. Nezavisne varijable su struktura kapitala izražena koeficijentom zaduživanje (koefZad), tekuća likvidnost (tekLid), prirodni logaritam materijalne imovine (matIm), pokazatelj efikasnosti izražen obrtajem zaliha (obrZal) i zadržana dobit. U ovom dijelu rada će se pokazati i analizirati rezultati modela te će se komentirati razlike u odnosu na isti model proveden s podacima za 2015. i 2014. godinu kako bi se usporedili rezultati kroz vrijeme. Kako bi se mogao dovesti zaključak o hipotezi da različiti pokazatelji zaduženosti imaju utjecaj na vezu između strukture kapitala i profitabilnosti će se tijekom analize također razmatrati razlike u korištenju drugog pokazatelja strukture kapitala. Tablice u kojima se prikazuju konkretni rezultati regresijske analize za 2015. i 2014. godinu nalaze se u prilogu rada.

Kao prvo će se prikazati deskriptivna statistika svih varijabli uključujući minimalne, maksimalne i srednje vrijednosti svih korištenih varijabli uz njihovih standardnih devijacija.

Tablica 3: Deskriptivna statistika varijabli s ROA kao zavisnom varijablom (2016.g.)

	N	Minimum	Maximum	Mean	Std. Deviation
ROA	84	,00000	,91973	,03794	,10496
koefZad	84	,01684	5,83352	,60832	,70808
tekLik	84	,06561	15,90110	1,71553	2,40315
matIm	84	,00000	23,25783	19,00963	3,27944
obrZal	84	,00000	3852,95499	110,08331	437,08940
zadDob	84	,00000	1180769619	75457871,347	191627717,5751
Valid N (listwise)	84				

Izvor: Rezultati istraživanja studentice

Kao sljedeće će se prikazati korelacijska matrica varijabli:

Tablica 4: Korelacijska matrica varijabli s ROA kao zavisnom varijablom (2016.g.)

		ROA	koefZad	tekLik	matIm	obrZal	zadDob
ROA	Pearson Correlation	1	,231*	,086	-,568**	,004	,032
	Sig. (2-tailed)		,034	,438	,000	,973	,776
	N	84	84	84	84	84	84
koefZad	Pearson Correlation	,231*	1	-,285**	-,772**	-,021	-,144
	Sig. (2-tailed)	,034		,009	,000	,848	,192
	N	84	84	84	84	84	84
tekLik	Pearson Correlation	,086	-,285**	1	,077	-,025	,162
	Sig. (2-tailed)	,438	,009		,484	,824	,142
	N	84	84	84	84	84	84
matIm	Pearson Correlation	-,568**	-,772**	,077	1	,045	,225*
	Sig. (2-tailed)	,000	,000	,484		,686	,039
	N	84	84	84	84	84	84
obrZal	Pearson Correlation	,004	-,021	-,025	,045	1	-,044
	Sig. (2-tailed)	,973	,848	,824	,686		,690
	N	84	84	84	84	84	84
zadDob	Pearson Correlation	,032	-,144	,162	,225*	-,044	1
	Sig. (2-tailed)	,776	,192	,142	,039	,690	
	N	84	84	84	84	84	84

*. Correlation is significant at the 0.05 level (2-tailed).

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

Izvor: Rezultati istraživanja studentice

U korelacijskoj matrici se može vidjeti stupanj i smjer korelacije među korištenim varijablama. Može se primijetiti da materijalna imovina ima značajnu koreliranost s pokazateljem ROA. Pri tome se treba uzeti u obzir da se pokazatelj ROA u računa pomoću iznosa ukupne imovine. Kako bi se smanjio utjecaj korelacije je zato korišten podatak logaritma materijalne imovine umjesto originalnog iznosa. Uz to u modelu postoji značajna korelacija između zaduženosti i tekuće likvidnosti, koja nije jaka i upućuje na financiranje obrtnog kapitala i drugih izvora likvidnosti sa zaduživanjem, te postoji značajna, jaka korelacija između zaduženosti i materijalne imovine što upućuje na zaključak da poduzeća svoju imovinu financiraju kreditnim ili sličnim izvorima koje nude financijske institucije. Za razliku od 2016. godine, u 2015. godini se javlja značajna korelacija zadržane dobiti i zaduživanja s tekućom likvidnosti. U tom razdoblju je bio na snazi proces razduživanja za

većinu poduzeća. U 2014. godini je bila značajna i snažna korelacija između profitabilnosti i zaduživanja te između zadržane dobiti i materijalne imovine.

Tablica 5 pokazuje koje su varijable ušle u model primjenom ENTER metode. Za 2015. i 2014. godinu su korištene iste varijable kao za 2016. godinu.

Tablica 5: Varijable koje su uvrštene s ROA kao zavisnom varijablom (2016.g.)

Model	Variables Entered	Variables Removed	Method
1	obrZal, koefZad, zadDob, tekLik, matIm[b]	.	Enter

a. Dependent Variable: ROA

b. All requested variables entered.

Izvor: Rezultati istraživanja studentice

Snaga modela je određena koeficijentom determinacije, pri malim uzorcima se preporučuje korištenje prilagođenog koeficijenta determinacije. U tablici su ti pokazatelji prikazani vrijednošću R square, a u ovom slučaju iznosi 68% odnosno prilagođeni iznosi 46,3%. Taj podatak nam pokazuje da model objašnjava samo mali dio odstupanja. Odnosno, koeficijent determinacije ili reprezentativnosti regresije pokazuje koliki udio varijance možemo objasniti našim varijablama. U suprotnom smislu, koeficijent determinacije od 68% znači da se 32% varijacija između profitabilnosti poduzeća ne može objasniti varijablama koje se nalaze unutar modela, nego ovise o drugim faktorima. U ovom kontekstu se pod drugim faktorima mogu podrazumijevati i markoekonomski faktori, drugi interni faktori koji nisu uzeti u obzir u ovom modelu ili drugi kvalitativni faktori koje nije bilo moguće kvantificirati.

Dodatno se u ovoj tablici nalazi rezultat Durbin-Watsonovog testa. Pomoću tog testa se utvrđuje postoji li problem autokorelacije. Pod problemom autokorelacijom se podrazumijeva situacija kada su slučajne greške u modelu međusobno korelirane. Zbog toga će ocjene parametra biti nepristrane i neefikasne, ocjena varijance će biti podcijenjena i standardna greška će se činiti mala, te će pouzdanost testa biti neopravdano visoka. S obzirom što je rezultat Durbin-Watsonovog testa 2,161 ćemo zaključiti kako u modelu ne postoji problem autokorelacije. Modeli za 2015. i 2014. godinu također prolaze Drubin-Watsonov test s vrijednostima 2,107 za 2015. godinu i 2,049 za 2014. godinu.

Tablica 6: Osnovni podaci o ocijenjenom regresijskom modelu s ROA kao zavisnom varijablom (2016.g.)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,680[a]	,463	,429	,07934	2,161

a. Predictors: (Constant), obrZal, koefZad, zadDob, tekLik, matIm

b. Dependent Variable: ROA

Izvor: Rezultati istraživanja studentice

Sljedeća tablica pokazuje rezultate testa varijance. U ovoj tablici se vide suma kvadrata protumačenih, neprotumačenih i ukupnih odstupanja koja određuju koeficijent determinacije. Uz to se u ovoj tablici nalazi F-test pomoću kojeg se testira značajnost modela kao cjeline. Može se primijetiti kako je ovaj model značajan pri razini signifikantnosti od 5%. Model s podacima iz 2015. godine je također značajan kao cjelina, međutim model za 2014. godinu nije značajan prema F-testu. Dotične tablice se nalaze u prilogu rada.

Tablica 7: Tablica ANOVA ocijenjenog regresijskog modela s ROA kao zavisnom varijablom (2016.g.)

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,423	5	,085	13,451	,000[b]
	Residual	,491	78	,006		
	Total	,914	83			

a. Dependent Variable: ROA

b. Predictors: (Constant), obrZal, koefZad, zadDob, tekLik, matIm

Izvor: Rezultati istraživanja studentice

Tablica 8 pokazuje koeficijente varijabli u modelu. Istovremeno predznakom pokazuje smjer učinka nezavisne varijable na zavisnu i iznos učinka. T-test pokazuje značajnost svake nezavisne varijable zasebno uključujući konstantu. Uz to se ističe koeficijent varijable zaduženosti koji je značajan i negativan. Time se potvrđuje negativna veza između zaduženosti i profitabilnosti kako ju i pretpostavlja teorija redoslijeda pakiranja.

Zadržana dobit ima očekivan pozitivan utjecaj što upućuje na to da jeftinije financiranje iz vlastitih izvora pozitivno utječe na profitabilnost. Moguće je da svoju zadržanu dobit koriste kao dodatan izvor financiranja kao što to pretpostavlja teorija redoslijeda pakiranja te poduzeća pomoću zadržane dobiti suzbijaju negativan efekt zaduživanja na profitabilnost. Materijalna imovina ima značajan negativan utjecaj na profitabilnost. Kao što je isčitano iz korelacijske matrice je materijalna imovina kod poduzeća iz ovog uzorka usko vezana uz zaduživanje jer je velikom vjerojatnošću ta materijalna imovina kupljena putem zaduživanja te predstavlja u tom smislu teret poduzeću i njegovoj profitabilnosti. U 2016. godini likvidnost i efikasnost nisu imale značajnog utjecaja na profitabilnost.

Nadalje, kada bi se pokazatelj zaduženosti promijenio na pokazatelj vlastitog financiranja, predznak postaje pozitivan, a kada se koristi samo kratkotrajno zaduživanje je i dalje negativan predznak. S obzirom da je vlastito financiranje suprotno od dugovnog, pozitivan bi se predznak također mogao tumačiti kao potvrde postavki teorije redoslijeda pakiranja. Tablice s rezultatima tog modela se nalaze u prilogu rada.

Tablica 8: Ocijenjeni regresijski model s ROA kao zavisnom varijablom (2016.g.)

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	,704	,096		7,338	,000		
	koefZad	-,080	,021	-,538	-3,830	,000	,348	2,871
	zadDob	1,044	,000	,190	2,195	,031	,914	1,094
	matIm	-,033	,004	-1,027	-7,451	,000	,362	2,760
	tekLik	-,001	,004	-,018	-,199	,843	,841	1,189
	obrZal	1,110	,000	,046	,556	,580	,994	1,006

a. Dependent Variable: ROA

Izvor: Rezultati istraživanja studentice

Kod prezentiranog modela, prikazanog u tablici 8, ne postoji problem multikolinearnosti. Taj problem ne postoji ukoliko je tolerancija veća od 0,2, a VIF manji od 5 što je u oba modela zadovoljeno. U slučaju postojanja problema multikolinearnosti to bi značilo da nezavisne

varijable nisu uistinu međusobno nezavisne što vodi do precijenjenih učinaka varijabli u modelu.

3.5.2 Rezultati regresijskog modela s tržišnom mjerom profitabilnosti P/E (2016. g.)

U nastavku rada će se prikazati rezultati modela na temelju podataka iz 2016. godine sa zavisnom varijablom koja je tržišni pokazatelj odnosno odnos P/E. Izračun je proveden samo s podacima iz 2016. godine zbog nedostatka podataka za ostale godine. Zbog toga će se rezultati ove regresije usporediti s rezultatima regresije za 2016. godinu s tradicionalnim pokazateljem profitabilnosti.

Tablica 9: Deskriptivna statistika varijabli u modelu s P/E kao zavisnom varijablom (2016. g.)

	N	Minimum	Maximum	Mean	Std. Deviation
PE	84	-849	985	32,23	161,197
tekLik	84	,06561	15,90110	1,71554	2,40315
zadDob	84	,00000	1180769619,00	75457871,34767	191627717,57519
obrZal	84	,00000	3852,95499	110,08331	437,08940
matIm	84	,00000	23,25783	19,00963	3,27944
koefZad	84	,01685	5,83353	,60832	,70808
Valid N (listwise)	84				

Izvor: Rezultati istraživanja studentice

Slijedi prikaz deskriptivne statistike:

Tablica 10: Korelacijska matrica varijabli u modelu s P/E kao zavisnom varijablom (2016. g.)

		PE	koefZad	tekLik	matIm	obrZal	zadDob
PE	Pearson Correlation	1	-,267*	-,003	,375**	-,018	-,033
	Sig. (2-tailed)		,014	,975	,000	,869	,765
	N	84	84	84	84	84	84
koefZad	Pearson Correlation	-,267*	1	-,285**	-,772**	-,021	-,144
	Sig. (2-tailed)	,014		,009	,000	,848	,192
	N	84	84	84	84	84	84
tekLik	Pearson Correlation	-,003	-,285**	1	,077	-,025	,162
	Sig. (2-tailed)	,975	,009		,484	,824	,142
	N	84	84	84	84	84	84
matIm	Pearson Correlation	,375**	-,772**	,077	1	,045	,225*
	Sig. (2-tailed)	,000	,000	,484		,686	,039
	N	84	84	84	84	84	84
obrZal	Pearson Correlation	-,018	-,021	-,025	,045	1	-,044
	Sig. (2-tailed)	,869	,848	,824	,686		,690
	N	84	84	84	84	84	84
zadDob	Pearson Correlation	-,033	-,144	,162	,225*	-,044	1
	Sig. (2-tailed)	,765	,192	,142	,039	,690	
	N	84	84	84	84	84	84

*. Correlation is significant at the 0.05 level (2-tailed).

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

Izvor: Rezultati istraživanja studentice

Korelacijska matrica u odnosu na prijašnju pokazuje značajnu ali slabu korelaciju između odnosa P/E i varijabli zaduženost i materijalne imovine. Može se pretpostaviti da dioničari imaju pozitivan stav prema poduzeću koje ima mnogo materijalne imovine koja može poslužiti kao sigurnosni sloj za poduzeće i njih, a negativan stav prema zaduženosti poduzeća.

Tablica 11: Varijable koje su uvrštene u modelu s P/E kao zavisnom varijablom (2016. g.)

Model	Variables Entered	Variables Removed	Method
1	zadDob, obrZal, koefZad, tekLik, matIm[b]	.	Enter

a. Dependent Variable: PE

b. All requested variables entered.

Izvor: Rezultati istraživanja studentice

Kako bi modeli bili direktno usporedivi su također ponovno uzete iste varijable koje su metodom ENTER obavezno ušle u model.

Tablica 12: Osnovni podaci o ocijenjenom regresijskom modelu s P/E kao zavisnom varijablom (2016. g.)

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,399[a]	,159	,105	152,493	2,091

a. Predictors: (Constant), zadDob, obrZal, koefZad, tekLik, matIm

b. Dependent Variable: PE

Izvor: Rezultati istraživanja studentice

U tablici 12 vidimo da je snaga testa manja nego s pokazateljem ROA. Durbin-Watsonov test je pozitivan.

Tablica 13: Tablica ANOVA ocijenjenog modela s P/E kao zavisnom varijablom (2016. g.)

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	342884,579	5	68576,916	2,949	,017[b]
	Residual	1813816,220	78	23254,054		
	Total	2156700,798	83			

a. Dependent Variable: PE

b. Predictors: (Constant), zadDob, obrZal, koefZad, tekLik, matIm

Izvor: Rezultati istraživanja studentice

U rezultatima testa varijance se vidi da je model u ukupnosti statistički značajan prema F-testu.

Tablica 14: Ocijenjeni regresijski model s P/E kao zavisnom varijablom (2016. g.)

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	-396,000	184,283		-2,149	,035		
	koefZad	15,531	40,051	,068	,388	,699	,348	2,871
	tekLik	,016	7,596	,000	,002	,998	,841	1,189
	matIm	22,550	8,479	,459	2,660	,009	,362	2,760
	obrZal	-,016	,038	-,043	-,414	,680	,994	1,006
	zadDob	-1,082E-007	,000	-,129	-1,185	,240	,914	1,094

a. Dependent Variable: PE

Izvor: Rezultati istraživanja studentice

U tablici 14 se vidi da zaduženost ima pozitivan predznak, ali da prema t-testu nije značajna. Kada se umjesto ukupnog zaduživanja uzme samo kratkoročno zaduživanje predznak uz zaduženost postane pozitivan. Moguć razlog za to je oporavak poduzeća i veći obujam korištenja kratkoročnog duga za obrtni kapital. Poduzeća tek prikupljaju zadržanu dobit iz nedavnih pozitivnih financijskih rezultata iz koje bi mogli financirati povećanje obujma posla uslijed oporavljanja gospodarstva nakon krize. Kada se kao pokazatelj profitabilnosti uzme pokazatelj EPS cijeli model postane statistički neznačajan.

3.6 Osvrt na istraživačke hipoteze

U ovom dijelu rada će se sumirati rezultati istraživanja u kontekstu hipoteza koje su postavljene u uvodnom dijelu prema predmetu i problemu rada.

Hipoteza 1: Zaduženost poduzeća negativno utječe na njegovu profitabilnost

Temeljem postavljenih teorijskih postavki očekivala se negativna veza između zaduženosti i profitabilnosti poduzeća u Hrvatskoj. Provedena regresijska analiza to potvrđuje u slučaju mjerenja profitabilnosti pokazateljem ROA za podatke iz 2016. godine. Isti model s podacima iz 2015. i 2014. godine nije statistički značajan.

Kada se profitabilnost izražava pomoću pokazatelja vlastitog dobije se statistički značajna pozitivna veza. Također, potvrđena je negativna veza regresijskom analizom na temelju podataka 2014 i 2015 godine. Time je do neke mjere potvrđena teorija redoslijeda pakiranja na uzorku analiziranih kotiranih poduzeća u Hrvatskoj prema kojoj će poduzeća nove prilike za investiranje financirati najprije interno generiranim sredstvima, a tek onda dugom.

Hipoteza 2: Postoji razlika u zaduženosti poduzeća ovisno o sektoru.

Temeljem rezultata istraživanja u ovome radu prihvatiti će se druga hipoteza. Već u dijelu rada koji opisuje Hrvatsku kao cjelinu je bilo vidljivo kako određeni sektori u Hrvatskoj prate slične trendove zaduživanja zbog specifičnosti s kojima se ti sektori susreću, a i načina na koji gospodarstvo i njegovo stanje utječe na dotične sektore. Isto tako, podjelom poduzeća iz analiziranog uzorka grafičkom se metodom moglo utvrditi kako postoje značajne razlike u razinama zaduženosti među sektorima. Iako se radi o kratkom razdoblju promatranja od 3 godine, jasno se može uočiti kako su trendovi kretanja razine zaduženosti različiti za sva tri analizirana sektora. Uz to se može i primijetiti razlika između odnosa kratkotrajnog i dugoročnog financiranja i udjela obveza prema bankama i drugim financijskim institucijama u ukupnim dugoročnim obvezama.

Hipoteza 3: Veza između zaduženosti i profitabilnosti varira ovisno o pokazatelju zaduženosti

Kao što je pokazano u regresijskoj analizi kod koje su uzete u obzir tržišni pokazatelji profitabilnosti, veza između zaduženosti varira ovisno o korištenom pokazatelju. Zbog toga je veoma važno odrediti kojim će se pokazateljem izraziti zaduženost. Naime, korišten dugoročnog ili kratkoročnog koeficijenta zaduženosti ili korištenje koeficijenta vlastitog financiranja umjesto koeficijenta zaduživanja može bitno utjecati rezultate istraživanja.

4. ZAKLJUČAK

Odnos strukture kapitala i profitabilnosti je područje financija kojim se bavi veliki broj istraživača. Usprkos tome, način na koji struktura kapitala odnosno zaduženost utječe na profitabilnost poduzeća i dalje nije jednoznačno određena. Različite teorije pokušavaju objasniti utjecaj različitih varijabli na odluke o financiranju poduzeća. Međutim, zaduženost nije jedina varijabla koja utječe na profitabilnost. Trebaju se uzeti u obzir i interni i eksterni faktori utjecaja. Pri tome, teorija redoslijeda pakiranja pretpostavlja nepostojanje određene optimalne razine strukture kapitala, već pretpostavlja da financijski menadžeri imaju određene preferencije naspram nekim izvorima financiranja.

U ovom radu se analizira uzorak od 84 velikih poduzeća uvrštenih na redovno tržište Zagrebačke burze u razdoblju od 2014 do 2016 godine. Regresijskom analizom je utvrđena negativna veza između zaduženosti mjerena odnosom ukupnog duga i ukupne imovine te profitabilnosti mjerene pokazateljem ROA u 2016. godini. Nezavisne varijable u modelima su bile: koeficijent ukupne zaduženosti, logaritamska vrijednost materijalne imovine, obrtaj zaliha, tekuća likvidnost i zadržana dobit. U modelu sa zavisnom varijablom ROA i pokazateljem zaduženosti kao nezavisna varijabla, utvrđena je statistički značajna negativna veza između profitabilnosti i zaduženosti što je u skladu s postavkama teorije redoslijeda pakiranja. Isti model s podacima iz 2015. i 2014. godine nije statistički značajan.

Kada se kao mjera strukture kapitala koristi vlastito financiranje, rezultat je statistički značajna pozitivna veza između strukture kapitala i profitabilnosti. Ako se kao nezavisna varijabla koristi koeficijent kratkoročne zaduženosti, dobije se statistički značajna negativna veza. Kada se kao zavisna varijabla koristi P/E u kombinaciji s koeficientom zaduženosti, odnos je pozitivan, ali statistički neznačajan. Također je neznačajna kada se kao nezavisna varijabla koristi koeficijent kratkoročne zaduženosti.

Na temelju svega navedenoga, može se zaključiti da struktura kapitala negativno i statistički značajno utječe na profitabilnost čime se potvrđuju postavke teorije redoslijeda pakiranja. Međutim, treba biti oprezan jer su rezultati pokazali da smjer i intenzitet veze ovise o korištenom pokazatelju zaduženosti i mjeri profitabilnosti. Također, trebaju se uvažavati ograničavajući faktori ovog rada. Svako korištenje uzoraka smanjuje preciznost rezultata istraživanje. Shodno tome, trebalo bi se ubuduće provesti detaljnija analiza koja će potpunije

dopustiti da razlike u sektorima i vrstama zaduživanja dođu do izražaja kako bi se mogli istražiti razlozi razlika rezultata.

SAŽETAK

Među mnogim faktorima, odnos profitabilnosti i strukture kapitala je srž mnogih znanstvenih radova te temelj raznovrsnih teorija strukture kapitala. Prema teoriji redoslijeda pakiranja, financijski menadžer ima određene preferencije prema različitim načinima financiranja. Prema tome, nove investicijske prilike će ponajprije financirati interno generiranim sredstvima, potom nisko rizičnim dugom, konvertibilijama pa emisijom dionica. U ovom radu korišten je uzorak od 84 velikih poduzeća uvrštenih na redovno tržište Zagrebačke burze u razdoblju od 2014-2016 godine. Pri regresijskoj analizi je za zavisnu varijablu odabrana profitabilnost poduzeća izražena pokazateljem ROA odnosno pokazateljem P/E. U nezavisne varijable uključene su: koeficijent zaduženosti, logaritamska vrijednost materijalne imovine, obrtaj zaliha, tekuća likvidnost i zadržana dobit. Rezultati regresijske analize pokazuju negativnu vezu između zaduženosti i profitabilnosti čime se potvrđuje teorija redoslijeda pakiranja.

Ključne riječi: profitabilnost, struktura kapitala, zaduženosti

SUMMARY

Between many factors, the relationship between profitability and capital structure is at the core of many scientific researches and the foundation of several capital structure theories. According to the pecking order theory, a financial manager has specific preferences towards different ways of financing investments. Thus, new investment opportunities will be financed preferably via internally generated funds at first, then with low-risk debt, convertibles and finally, issuing new shares. In this research, the sample includes 84 large companies listed on the Zagreb stock exchange in the time period form 2014-2016. While using the regression analysis, the company's profitability has been chosen as the dependent variable. Profitability was expressed with ROA or the P/E ratio. The independent variables include: company efficiency, the log value of material assets, liquidity, lagged profitability and, as the most important variable, indebtedness. The results of the regression analysis show a negative relationship between indebtedness and profitability, which confirms the pecking order theory.

Key words: profitability, capital structure, indebtedness

5. LITERATURA

Članci:

1. Addae, A., A., Nyarko-Baasi, M., Hughes, D. (2013): The Effects of Capital Structure on Profitability of Listed Firms in Ghana, European Journal of Business and Management, Vol. 5, No. 31, 215-226. Dostupno na: http://www.iiste.org/Journals/index.php/EJBM/article/view/9490/9684 [16.08.2017]
2. Arsov, S., Naumoski, A. (2016): Determinants of capital structure - an empirical study of companies from selected post-transition countries, Zb. rad. Ekon. fak. Rij., vol.34. Dostupno na: https://www.efri.uniri.hr/sites/efri.uniri.hr/files/cr-collections/2/04-arsov-naumoski-2016-1.pdf [25.04.2017]
3. Azhagaiah, R., Gavoury, C. (2011): The Impact of Capital Structure on Profitability with Special Reference to IT Industry in India, Managing Global Transitions: International Research Journal, Vol. 9, No. 4, 371-392. Dostupno na: http://www.fm-kp.si/zalozba/ISSN/1581-6311/9_371-392.pdf [22.08.2017]
4. Berzkalne, I., Zelgalve, E. (2014): Trade-off theory vs. Pecking order theory – empirical evidence from the baltic countries, Journal of economic and social development, Vol 1, No 1. Dostupno na: http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=189801 [03.05.2017]
5. Booth, L., Aivazian, V., Demirguc-Kunt, A., Maksimovic, V. (2001): Capital structures in developing countries, The journal of Finance, Vol. 56, No. 1, 87-130. Dostupno na: https://www.researchgate.net/publication/227715364_Capital_Structure_in_Developing_Countries [26.04.2017]
6. Gill, A., Biger, N., Mathur, N. (2011): The Effect of Capital Structure on Profitability: Evidence from the United States, International Journal of Management, Vol. 28, No. 4. Dostupno na: https://www.researchgate.net/publication/281004540_The_effects_of_capital_structure_on_profitability_Evidence_from_United_States [15.08.2017]
7. Klapper, L., Tzioumis, K. (2008): Taxation and Capital Structure: evidence from a transition economy, GreeSE: Hellenic Observatory Papers on Greece and Southeast Europe, No. 16. Dostupno na: http://www.lse.ac.uk/europeanInstitute/research/hellenicObservatory/pdf/GreeSE/GreeSE16.pdf [15.08.2017]

8. Martinis, A., Ljubaj, I. (2016): Corporate Debt Overhang in Croatia: Micro Assessment and Macro Implications, The Twenty-Second Dubrovnik Economic Conference, Dostupno na: https://www.hnb.hr/documents/20182/783865/22-dec-martinis-ljubaj.pdf [16.08.2017]
9. Mörec, B., Rašković, M. (2011): Overview and estimation of the 2008 financial and economic crisis "effect size" on SME capital structures: case of Slovenia, Ekonomska istraživanja, Vol. 24, No.4 (107-125). Dostupno na: hrcak.srce.hr/file/115221 [27.04.2017]
10. Murray, Z., F., Goyal, K. V. (2003): Testing the pecking order theory of capital structure, Journal of Financial Economics, Vol. 67., No. 2. Dostupno na: http://www.sciencedirect.com/science/article/pii/S0304405X02002520 [16.08.2017]
11. Myers, C., S., Majluf, S., N., (1984): Corporate financing and investment decisions when firms have information that investors do not have, Journal of financial economics 13. Dostupno na: https://pdfs.semanticscholar.org/77de/0d5a47ff0ccbff22255155f1009265af270c.pdf [05.05.2017]
12. Pandey, I., M. (2004): Capital Structure, Profitability and Market Structure: Evidence from Malaysia, The Asia Pacific journal of economics and business, Vol. 8, 78-91. Dostupno na: https://www.researchgate.net/publication/265273461 [16.08.2017]
13. Penavin S., Šarilija, N. (2010): Pojave u kretanju strukture kapitala hrvatskih poduzeća u predrecesijskom razdoblju (2002.-2007.), Ekonomski vjesnik, Vol.XXIII No.2. Dostupno na: http://hrcak.srce.hr/63246 [27.04.2017]
14. Pervan, M., Mlikota, M. (2013): What determines the profitability of companies: Case of Croatian food and beverage industry, Ekonomska istraživanja – Economic research, Vol. 26, 277-286. Dostupno na: https://hrcak.srce.hr/104021 [16.08.2017]
15. Pervan, M., Pervan, I., Ćurak, M. (2017): The Influence of Age on Firm Performance: Evidence from the Croatian Food Industry, Journal of Eastern Europe Research in Business and Economics, Vol. 2017. Dostupno na: http://ibimapublishing.com/articles/JEERBE/2017/618681/618681.pdf [16.08.2017]
16. Shubita, F., M., Maroof alsawalhah, J. (2012): The Relationship between Capital Structure and Profitability, International Journal of Business and Social Science, Vol. 13, No. 16, 104-109. Dostupno na: https://pdfs.semanticscholar.org/a2a3/ed9d84b6dbd39ccc618f318e20847db55f1e.pdf [16.08.2017]

17. Shyam-Sunder, L., Myers, C., S. (1999): Testing Static Trade-off against Pecking Order Models of Capital Structure, Journal of Financial Economics, Vol. 51, No. 2. Dostupno na: http://pages.stern.nyu.edu/~eofek/PhD/papers/FG_Testing_JFE.pdf [16.08.2017]
18. Slade, E., M. (2003): Competing Models of Firm Profitability, Department of Economics, International Journal of Industrial Organization, Vol. 22. Dostupno na: http://isiarticles.com/bundles/Article/pre/pdf/13970.pdf [16.08.2017]
19. Stavropoulos, S., Burger, J., M., (2015): Data Sparseness and Variance in Accounting Profitability, Tinbergen Institute Discussion Paper, Dostupno na: https://papers.tinbergen.nl/15014.pdf [16.08.2017]
20. Stierwald, A., (2009): Determinants of Firm Profitability – The effect of Productivity and its Persistence, Melbourne Institute of Applied Economic and Social Research, Dostupno na: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.361.1327&rep=rep1&type=pdf [02.08.2017]
21. Šarlija, N., Harc, M. (2016): Capital Structure Determinants of Small and Medium Enterprises in Croatia, Managing Global Transitions: International Research Journal, Vol. 14, No. 3. Dostupno na: http://www.fm-kp.si/zalozba/ISSN/1581-6311/14_251-266.pdf [16.08.2017]
22. Škuflić, L., Mlinarić, D., Družić, M. (2016): Relevantni faktori utjecaja na visinu profita poduzeća u prerađivačkoj industriji Hrvatske, Ekonomski fakultet, Zagreb. Dostupno na: http://hrcak.srce.hr/file/252978
23. Škuflić, L., Mlinarić, D., Družić, M., (2016): Determinants of firm profitability in Croatia's manufacturing sector, International Conference on Economic and Social Studies. Dostupno na: http://eprints.ibu.edu.ba/3328/1/Lorena%20Skuflic%20Danijel%20Mlinaric%20and%20Marko%20Druzic.pdf [20.05.2017]
24. Učkar, D., Urti, J., (2015): Utjecaj financijske strukture na profitabilnost hrvatskih poduzeća, Oeconomica Jadertina. Dostupno na: hrcak.srce.hr/file/225882 [20.05.2017]
25. Vidučić, L. (2001): Teorijska i praktična motrišta strukture kapitala, Ekonomski pregled, Vol.52 No.7-8, 784-800. Dostupno na: http://hrcak.srce.hr/28757 [15.08.2017]

26. Vidučić, L. (2001): Teorijska i praktična motrišta strukture kapitala. Dostupno na: http://hrcak.srce.hr/28757 [27.04.2017]
27. Weiss, L., W. (1979): The structure-conduct-performance paradigm and antitrust, University of Pennsylvania, law preview, Vol. 127, Iss.4. Dostupno na: http://scholarship.law.upenn.edu/cgi/viewcontent.cgi?article=4870&context=penn_law_review [27.08.2017]

Knjige:

1. Vidučić, L. (2012): Financijski menadžment, 8. nepromijenjeno izdanje, RRiF – plus, d.o.o. za nakladništvo i poslovne usluge, Zagreb
2. Žager, K., Žager, L. (1999): Analiza financijskih izvještaja, Masmedia, Zagreb.
3. Rozga, A. (2009): Statistika za ekonomiste, V. izdavanje, Sveučilište u Splitu, Ekonomski fakultet, Split
4. Reić, Z., Kosor, M., M. (2011): Ekonomija, 3. Izmijenjeno izdanje, Sveučilište u Splitu, Split.

Internet stranice:

1. www.mojedionice.com
2. www.zse.hr
3. www.aztn.hr
4. www.investopedia.com
5. www.enciklopedija.hr
6. www.limun.hr

Nastavni materijali:

1. Kumar, R.: Structure – conduct – performance paradigm, College of Vocational Studies, Delhi University. Dostupno na: http://rajkumar2850.weebly.com/uploads/1/4/9/8/14980396/unit_1-_scp_model.pdf [16.08.2017]

Publikacije:

1. Zubak, D., Hanzl, Ž., Pađen, Ž., Pipp, P. (2016): Gospodarska kretanja 2016. 11/12, Hrvatska gospodarska komora. Dostupno na:

https://www.hgk.hr/documents/gospodarskakretanja111258860da55f948.pdf [30.08.2017]

2. Zubak, D., Hanzl, Ž., Pađen, Ž., Pipp, P. (2016): Gospodarska kretanja 2015. 11/12, Hrvatska gospodarska komora. Dostupno na: http://www.hgk.hr/documents/gospodarskakretanja111257b6f893727ba.pdf [30.08.2017]
3. Zubak, D., Hanzl, Ž., Pađen, Ž., Pipp, P. (2015): Gospodarska kretanja 2014. 12, Hrvatska gospodarska komora. Dostupno na: https://www.hgk.hr/documents/gospodarskakretanja12-201457d29d5a9b724.pdf [30.08.2017]
4. Hrvatska narodna banka (2014): Financijska stabilnost, broj 13, Zagreb. Dostupno na: http://old.hnb.hr/publikac/financijska%20stabilnost/h-fs-13-2014.pdf [30.08.2017]
5. Hrvatska narodna banka (2015): Financijska stabilnost, broj 14, Zagreb. Dostupno na: http://old.hnb.hr/publikac/financijska%20stabilnost/h-fs-14-2015.pdf [30.08.2017]
6. Hrvatska narodna banka (2015): Financijska stabilnost, broj 15, Zagreb. Dostupno na: http://old.hnb.hr/publikac/financijska%20stabilnost/h-fs-15-2015.pdf [30.08.2017]
7. Hrvatska narodna banka (2016): Financijska stabilnost, broj 17, Zagreb. Dostupno na: https://www.hnb.hr/documents/20182/521139/h-fs-17-2016.pdf [30.08.2017]
8. Hrvatska narodna banka (2017): Financijska stabilnost, broj 18, Zagreb. Dostupno na: https://www.hnb.hr/documents/20182/1972383/h-fs-18-2017.pdf [30.08.2017]

6. POPIS TABLICA I SLIKA

Slike:

Slika 1: Grafički prikaz postavki Trade-off teorije 14
Slika 2: Zaduženost sektora poduzeća 31
Slika 3: Promjena potražnje i standarda odobravanja kredita poduzećima 32
Slika 4: Novoodobreni krediti banaka i apsolutna promjena stanja bruto kredita 34
Slika 5: Oporavak agregatnoga poslovnog rezultata nefinancijskih poduzeća u razdoblju 2008.-2015. g. 35
Slika 6: Konsolidirani financijski rezultat poslovanja poduzetnika 37
Tablica 6: Osnovni podaci o ocijenjenom regresijskom modelu s ROA kao zavisnom varijablom (2016.g.) 47
Tablica 7: Tablica ANOVA ocijenjenog regresijskog modela s ROA kao zavisnom varijablom (2016.g.) 47
Tablica 8: Ocijenjeni regresijski model s ROA kao zavisnom varijablom (2016.g.) 48

Grafikoni:

Grafikon 1: Zaduženost i profitabilnost poduzeća prema odabranim sektorima u 2014. godini 38
Grafikon 2: Zaduženost i profitabilnost poduzeća prema odabranim sektorima u 2015. godini 40
Grafikon 3: Zaduženost i profitabilnost poduzeća prema odabranim sektorima u 2016. godini 41

Tablice:

Tablica 1: Očekivani učinci determinanti na profitabilnosti 25
Tablica 2: Prikaz zavisnih i nezavisnih varijabli korištenim u analizi 42
Tablica 3: Deskriptivna statistika varijabli s ROA kao zavisnom varijablom (2016.g.) 44
Tablica 4: Korelacijska matrica varijabli s ROA kao zavisnom varijablom (2016.g.) 45
Tablica 5: Varijable koje su uvrštene s ROA kao zavisnom varijablom (2016.g.) 46
Tablica 9: Deskriptivna statistika varijabli u modelu s P/E kao zavisnom varijablom (2016. g.) 49
Tablica 10: Korelacijska matrica varijabli u modelu s P/E kao zavisnom varijablom (2016. g.) 50
Tablica 11: Varijable koje su uvrštene u modelu s P/E kao zavisnom varijablom (2016. g.) 51
Tablica 12: Osnovni podaci o ocijenjenom regresijskom modelu s P/E kao zavisnom varijablom (2016. g.) 51
Tablica 13: Tablica ANOVA ocijenjenog modela s P/E kao zavisnom varijablom (2016. g.) 51
Tablica 14: Ocijenjeni regresijski model s P/E kao zavisnom varijablom (2016. g.) 52

7. PRILOG

Prilog 1: Popis poduzeća u sektoru prerađivačke industrije

3.maj brodogradilište d.d.
Adris grupa d.d.
Ad plastik d.d.
Agromeđimurje d.d.
Atlantic grupa d.d.
Badel 1862 d.d.
Ina d.d.
Ingra d.d.
Jadranski naftovod d.d.
Kamensko d.d.
Končar d&st d.d.
Končar - elektroindustrija d.d.
Koestlin d.d.
Končar sklopna postrojenja d.d.
Kraš d.d. Zagreb
Kutjevo d.d.
Dukat d.d.
Miv d.d.
Maraska d.d.
Prehrambeno industrijski kombinat d.d.
Podravka d.d.
Valamar riviera d.d.
Riz odašiljači d.d.
Solaris d.d.
Drvna industrija spačva d.d.
Uljanik plovidba d.d.
Uljanik d.d.
Viadukt d.d.
Viro tvornica šećera d.d.
Vjesnik d.d.
Viktor lenac d.d.
Zagrebačke pekarne klara d.d.
Petrokemija d.d.
Saponia d.d.

Prilog 2: Popis poduzeća u sektoru turizam

Adriatic croatia international club d.d.
Apartmani medena d.d. Seget donji
Hoteli brela d.d.
Hoteli baška voda d.d.
Hoteli haludovo malinska d.d.
Imperial d.d.
Hoteli jadran d.d.
Hotel medena d.d.
Hoteli maestral d.d.
Hoteli tučepi d.d.
Htp korčula d.d.
Htp orebić d.d.
Hup-zagreb d.d.
Hoteli vodice d.d.
Hoteli zlatni rat d.d.
Hoteli "živogošće" d.d.
Jelsa d.d.
Lošinjska plovidba holding d.d.
Liburnia rivijera d.d.
Maistra d.d.
Plava laguna d.d.
Palace hotel zagreb d.d.
Tankerkomerc d.d.
Turisthotel dd

Prilog 3: Popis poduzeća u sektoru ostalih djelatnosti

Excelsa nekretnine d.d.
Atlantska plovidba d.d.
Auto hrvatska-grupa
Brodomerkur trgovina i usluge dd
Croatia airlines d.d.
Čateks d.d.
Đuro đaković holding d.d.
Dalekovod d.d.
Elektrometal d.d.bjelovar
Ericsson nikola tesla d.d. Zagreb
Finvest corp d.d. Čabar
Hidroelektra niskogradnja d.d.
Hrvatski telekom d.d.
Institut igh d.d.
Termes grupa d.d.

Jadroagent d.d.
Jadroplov d.d.
Jadran tvornica čarapa d.d.
Koteks d.d.
Luka ploče d.d.
Luka rijeka d.d.
Medika d.d.
Magma d.d.
Ot-optima telekom d.d.
Tehnika d.d.
Varteks d.d.

Prilog 4: Deskriptivna statistika varijabli s ROA kao zavisnom varijablom (2015.g.)

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
ROA	86	,00000	,16932	,02681	,03867
koefZad	86	,02875	35,92585	,96061	3,84317
tekLik	86	,05289	12,45248	1,61276	2,08798
matIm	85	15,68835	23,26856	19,36476	1,44940
obrZal	85	,02235	4040,72039	94,51396	438,43819
zadDob	86	,00000	1114730594	62840567,67	173900847,6
Valid N (listwise)	84				

Prilog 5: Korelacijska matrica varijabli s ROA kao zavisnom varijablom (2015.g.)

Correlations

		ROA	koefZad	tekLik	matIm	obrZal	zadDob
ROA	Pearson Correlation	1	-,106	,476**	,062	,030	,075
	Sig. (2-tailed)		,329	,000	,574	,786	,492
	N	86	86	86	85	85	86
koefZad	Pearson Correlation	-,106	1	-,121	-,286**	-,019	-,056

	Sig. (2-tailed)	,329		,268	,008	,866	,611
	N	86	86	86	85	85	86
tekLik	Pearson Correlation	,476**	-,121	1	,025	-,010	,088
	Sig. (2-tailed)	,000	,268		,824	,929	,423
	N	86	86	86	85	85	86
matIm	Pearson Correlation	,062	-,286**	,025	1	,046	,428**
	Sig. (2-tailed)	,574	,008	,824		,675	,000
	N	85	85	85	85	84	85
obrZal	Pearson Correlation	,030	-,019	-,010	,046	1	-,055
	Sig. (2-tailed)	,786	,866	,929	,675		,619
	N	85	85	85	84	85	85
zadDob	Pearson Correlation	,075	-,056	,088	,428**	-,055	1
	Sig. (2-tailed)	,492	,611	,423	,000	,619	
	N	86	86	86	85	85	86

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

Prilog 6: Tablica varijabli koje su korištene u regresijskoj analizi za 2015. godinu

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	zadDob, koefZad, obrZal, tekLik, matIm[b]	.	Enter

a. Dependent Variable: ROA

b. All requested variables entered.

Prilog 7: Tablica koja prikazuje snagu modela i test autokorelacije u regresijskoj analizi u tradicionalnom modelu za 2015. godinu

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,475[a]	,226	,176	,035019789835424	2,107

a. Predictors: (Constant), zadDob, koefZad, obrZal, tekLik, matIm

b. Dependent Variable: ROA

Prilog 8: Tablica ANOVA ocijenjenog regresijskog modela s ROA kao zavisnom varijablom (2015.g.)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,028	5	,006	4,547	,001[b]
	Residual	,096	78	,001		
	Total	,124	83			

a. Dependent Variable: ROA

b. Predictors: (Constant), zadDob, koefZad, obrZal, tekLik, matIm

Prilog 9: Ocijenjeni regresijski model s ROA kao zavisnom varijablom (2015.g.)

Coefficients[a]

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
	B	Std. Error	Beta			Tolerance	VIF
(Constant)	-,015	,060		-,250	,803		
koefZad	,000	,001	-,029	-,277	,782	,896	1,116
tekLik	,008	,002	,462	4,584	,000	,979	1,022
matIm	,001	,003	,053	,460	,647	,739	1,354
obrZal	2,740E-006	,000	,031	,313	,755	,991	1,009
zadDob	3,378E-012	,000	,015	,134	,894	,799	1,252

a. Dependent Variable: ROA

Prilog 10: Deskriptivna statistika varijabli s ROA kao zavisnom varijablom (2014.g.)

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
ROA	86	,0000000000000000	1,560707758225413000	,046817104412970	,191108482117408
koefZad	86	,030997580361755500	8,217876271307233000	,612301662006205	,886510604508989
tekLik	86	,040208981970160600	14,540308812779092000	1,643199929759442	2,392465407077066
matIm	85	16,322108410044720	23,366884177889332	19,397923523635967	1,391543232155229
obrZal	86	,006652257323940100	127974,765957446810000000	1541,786712982154800	13794,601582145113000
zadDob	86	,000000000000000000	1586000000,000000000000000000	92532583,091564980000000	247516076,062355640000000
Valid N (listwise)	85				

Prilog 11: Korelacijska matrica varijabli s ROA kao zavisnom varijablom (2014.g.)

Correlations

		ROA	koefZad	tekLik	matIm	obrZal	zadDob
ROA	Pearson Correlation	1	,791**	-,010	-,026	,052	-,044
	Sig. (2-tailed)		,000	,925	,813	,632	,686
	N	86	86	86	85	86	86
koefZad	Pearson Correlation	,791**	1	-,205	-,151	-,045	-,081
	Sig. (2-tailed)	,000		,058	,169	,683	,460
	N	86	86	86	85	86	86

tekLik	Pearson Correlation	-,010	-,205	1	,040	,052	,027
	Sig. (2-tailed)	,925	,058		,715	,636	,803
	N	86	86	86	85	86	86
matIm	Pearson Correlation	-,026	-,151	,040	1	-,159	,520**
	Sig. (2-tailed)	,813	,169	,715		,147	,000
	N	85	85	85	85	85	85
obrZal	Pearson Correlation	,052	-,045	,052	-,159	1	-,039
	Sig. (2-tailed)	,632	,683	,636	,147		,724
	N	86	86	86	85	86	86
zadDob	Pearson Correlation	-,044	-,081	,027	,520**	-,039	1
	Sig. (2-tailed)	,686	,460	,803	,000	,724	
	N	86	86	86	85	86	86

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

Prilog 12: Varijable koje su uvrštene s ROA kao zavisnom varijablom (2014.g.)

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	zadDob, tekLik, obrZal, koefZad, matIm[b]	.	Enter

a. Dependent Variable: ROA

b. All requested variables entered.

Prilog 13: Tablica koja prikazuje snagu modela i test autokorelacije u regresijskoj analizi za 2014. godinu

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,167[a]	,028	-,034	,098314960959792	2,049

a. Predictors: (Constant), zadDob, tekLik, obrZal, koefZad, matIm

b. Dependent Variable: ROA

Prilog 14: Tablica ANOVA ocijenjenog regresijskog modela s ROA kao zavisnom varijablom (2014.g.)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,022	5	,004	,455	,809[b]
	Residual	,764	79	,010		
	Total	,786	84			

a. Dependent Variable: ROA

b. Predictors: (Constant), zadDob, tekLik, obrZal, koefZad, matIm

Tablica 15: Ocijenjeni regresijski model s ROA kao zavisnom varijablom (2014.g.)

Coefficients[a]

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
	B	Std. Error	Beta			Tolerance	VIF
(Constant)	,052	,181		,287	,775		
koefZad	-,021	,038	-,069	-,557	,579	,809	1,236
tekLik	,003	,005	,065	,536	,594	,838	1,193
matIm	-,001	,009	-,012	-,094	,926	,700	1,428
obrZal	7,842E-007	,000	,113	,993	,324	,958	1,043
zadDob	-6,610E-012	,000	-,017	-,129	,898	,726	1,377

a. Dependent Variable: ROA

Tablica 16: Deskriptivna statistika varijabli s ROA kao zavisnom varijablom i pokazateljem vlastitog financiranja kao nezavisnom varijablom (2014.g.)

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
tekLik	84	,0656150984481774	15,9011006817019890	1,715536511786031	2,403152772355910
zadDob	84	,0000000000000000	1180769619,0000000000000	75457871,34767054000000	191627717,575187980000000
obrZal	84	,0000000000000000	3852,954990561586000	110,0833149162549 00	437,0894037793574440
matIm	84	,0000000000000000	23,257835285920248	19,009637088900190	3,279443501781367
ROA	84	,0000000000000000	,9197363859625349	,037943554848394	,104960724242733
vlFin	84	-4,833527184172150 0	,9421838848074493	,3584323344679688	,7058739002716977
Valid N (listwise)	84				

Tablica 17: Korelacijska matrica varijabli s ROA kao zavisnom varijablom i pokazateljem vlastitog financiranja kao nezavisnom varijablom (2016.g.)

Correlations

		ROA	vlFin	tekLik	matIm	obrZal	zadDob
ROA	Pearson Correlation	1	-,233*	,086	-,568**	,004	,032
	Sig. (2-tailed)		,033	,438	,000	,973	,776
	N	84	84	84	84	84	84
vlFin	Pearson Correlation	-,233*	1	,285**	,768**	,016	,145
	Sig. (2-tailed)	,033		,009	,000	,883	,187
	N	84	84	84	84	84	84
tekLik	Pearson Correlation	,086	,285**	1	,077	-,025	,162
	Sig. (2-tailed)	,438	,009		,484	,824	,142
	N	84	84	84	84	84	84
matIm	Pearson Correlation	-,568**	,768**	,077	1	,045	,225*
	Sig. (2-tailed)	,000	,000	,484		,686	,039
	N	84	84	84	84	84	84
obrZal	Pearson Correlation	,004	,016	-,025	,045	1	-,044
	Sig. (2-tailed)	,973	,883	,824	,686		,690

	N	84	84	84	84	84	84
	Pearson Correlation	,032	,145	,162	,225*	-,044	1
zadDob	Sig. (2-tailed)	,776	,187	,142	,039	,690	
	N	84	84	84	84	84	84

*. Correlation is significant at the 0.05 level (2-tailed).

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

Tablica 18: Varijable koje su uvrštene s ROA kao zavisnom varijablom i pokazateljem vlastitog financiranja kao nezavisnom varijablom (2016.g.)

Variables Entered/Removed[a]

Model	Variables Entered	Variables Removed	Method
1	zadDob, obrZal, vlFin, tekLik, matIm[b]	.	Enter

a. Dependent Variable: ROA

b. All requested variables entered.

Tablica 19: Osnovni podaci o ocijenjenom regresijskom modelu s ROA kao zavisnom varijablom i pokazateljem vlastitog financiranja kao nezavisnom varijablom (2016.g.)

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,676[a]	,456	,422	,079830834965867	2,180

a. Predictors: (Constant), zadDob, obrZal, vlFin, tekLik, matIm

b. Dependent Variable: ROA

Tablica 20: Tablica ANOVA ocijenjenog regresijskog modela s ROA kao zavisnom varijablom i pokazateljem vlastitog financiranja kao nezavisnom varijablom (2016.g.)

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,417	5	,083	13,096	,000[b]
	Residual	,497	78	,006		
	Total	,914	83			

a. Dependent Variable: ROA

b. Predictors: (Constant), zadDob, obrZal, vlFin, tekLik, matIm

Tablica 21: Ocijenjeni regresijski model s ROA kao zavisnom varijablom varijablom i pokazateljem vlastitog financiranja kao nezavisnom varijablom (2016.g.)

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	,615	,079		7,740	,000		
	vlFin	,077	,021	,516	3,679	,000	,355	2,819
	tekLik	-,001	,004	-,013	-,138	,890	,843	1,186
	matIm	-,032	,004	-1,007	-7,329	,000	,369	2,709
	obrZal	1,162E-005	,000	,048	,578	,565	,994	1,006
	zadDob	1,029E-010	,000	,188	2,151	,035	,915	1,092

a. Dependent Variable: ROA