Raffaella Ljevar, mag. oec.

Doktorandica
Ekonomski fakultet Sveučilišta u Rijeci
E-mail: raffaella.ljevar@gmail.com
Orcid: https://orcid.org/0009-0003-4371-4679

Dr. sc. Ivana Tomas Žiković

Izvanredna profesorica
Ekonomski fakultet Sveučilišta u Rijeci
Katedra za financije
E-mail: ivana.tomas.zikovic@efri.uniri.hr
Orcid: https://orcid.org/0000-0002-9156-3479

Dr. sc. Sandra Pepur

Izvanredna profesorica
Ekonomski fakultet Sveučilišta u Splitu
Katedra za financije
E-mail: sandra.pepur@efst.hr
Orcid: https://orcid.org/0000-0003-3468-9072

ULOGA VELIČINE PODUZEĆA U OBLIKOVANJU STRUKTURE KAPITALA: ANALIZA PODUZEĆA IZ SREDNJE I ISTOČNE EUROPE

UDK / UDC: 330.32:005.71-022.5:658.15](4-11)(4-191.2)
JEL klasifikacija / JEL classification: G32, C33, L25, O16, P34
DOI: 10.17818/EMIP/2025/47
Izvorni znanstveni rad / Original scientific paper
Primljeno / Received: 25. lipnja 2025. / June 25, 2025
Prihvaćeno / Accepted: 14. listopada 2025. / October 14, 2025

Sažetak

Istraživanje analizira utjecaj poduzeću specifičnih, makroekonomskih i institucionalnih čimbenika na strukturu kapitala poduzeća različite veličine u odabranim zemljama srednje i istočne Europe. Empirijska analiza provedena je metodom generaliziranih procjena jednadžbi (GEE) na panelu od 8695 poduzeća iz sektora trgovine na veliko i malo u razdoblju 2016. – 2023. Rezultati pokazuju da profitabilnost smanjuje zaduženost u svim skupinama poduzeća, dok rast i veličina povećavaju sklonost korištenju dugom. Struktura imovine važna je samo za mala poduzeća, gdje materijalna imovina služi kao ključan kolateral, dok nedugovna porezna zaštita smanjuje razinu zaduženosti. Makroekonomski i institucionalni čimbenici pokazuju selektivne učinke: rast BDP-a i koncentracija bankarskog sektora značajno utječu na odluke malih i srednjih poduzeća, dok pri

velikima nisu statistički značajni. Rezultati također upućuju na razlike među državama: poduzeća u Mađarskoj i Sloveniji pokazuju nižu razinu zaduženosti u odnosu na Hrvatsku, dok su poduzeća u Slovačkoj zaduženija. Nalazi potvrđuju da kombinacija poduzeću specifičnih, makroekonomskih i institucionalnih čimbenika oblikuje strukturu kapitala, uz razlike po veličini poduzeća. Istraživanje naglašava potrebu prilagođenih financijskih politika za mala i srednja poduzeća te pruža smjernice za menadžere, kreditne institucije i kreatore politika.

Ključne riječi: struktura kapitala, poduzeću specifični čimbenici, makroekonomski čimbenici, institucionalno okruženje, metoda generaliziranih jednadžbi procjene.

1. UVOD

Pri odlučivanju o financiranju tekućeg poslovanja i investicijskih projekata poduzeća trebaju razmotriti dostupne izvore kapitala. Odabir optimalne strukture kapitala ključan je za unaprjeđenje financijskog položaja poduzeća i očuvanje dugoročne održivosti poslovanja. Stoga područje strukture kapitala i dalje zauzima važno mjesto u suvremenim istraživanjima financijske problematike jer proces donošenja odluka o financiranju još uvijek nije u potpunosti razjašnjen. Unatoč postojanju brojnih teorijskih pristupa koji nastoje objasniti sklonost poduzeća prema korištenju dugom ili vlasničkim kapitalom, empirijska praksa nerijetko odstupa od teorijskih pretpostavki. Na složenost ovih odluka utječu različiti čimbenici, uključujući asimetriju informacija, agencijske probleme, uvjete na tržištu, regulatorne okvire te specifične karakteristike pojedinog poduzeća. Upravo zbog te kompleksnosti razvijaju se novi modeli i provode empirijske analize s ciljem dubljeg razumijevanja procesa donošenja financijskih odluka. Takav znanstveni angažman ne doprinosi samo teorijskom napretku već i osigurava relevantne smjernice za menadžere koji nastoje optimizirati strukturu kapitala u uvjetima stvarnog tržišnog okruženja.

Istraživanje analizira važnost i utjecaj internih (poduzeću specifičnih) i eksternih (makroekonomskih i institucionalnih) čimbenika na strukturu kapitala poduzeća, pri čemu se posebna pozornost posvećuje veličini poduzeća. Među poduzeću specifičnim varijablama, u analizi su obuhvaćene: profitabilnost, struktura imovine, mogućnost rasta, nedugovna porezna zaštita te veličina poduzeća. Ovi čimbenici prepoznati su u prethodnoj literaturi kao ključni za oblikovanje odluka o strukturi kapitala. Promatra se utjecaj makroekonomskog te institucionalnog okruženja na temelju kretanja BDP-a, odnosno razvijenosti financijskog sustava u promatranim zemljama. Empirijska analiza temelji se na uzorku od 8695 poduzeća različitih veličina – malih, srednjih i velikih – iz četiriju država članica Europske unije: Hrvatske, Slovenije, Slovačke i Mađarske, u razdoblju od 2016. do 2023. godine. Odabrane države pripadaju srednjoj i istočnoj Europi te dijele slične povijesne i tranzicijske okolnosti, kao i usporediv institucionalni okvir. Zbog tih zajedničkih obilježja omogućena je relevantna usporedba i analiza financijskih performansi poduzeća u državi. Osim toga, države su odabrane jer je za njih dostupna pouzdana i usporediva baza podataka o

poduzećima, što je ključan preduvjet za provedbu kvantitativne analize. Poduzeća obuhvaćena istraživanjem djeluju unutar djelatnosti trgovine na veliko i malo. Trgovina je izrazito dinamična djelatnost, osjetljiva na promjene u potrošačkim navikama, makroekonomskim kretanjima i regulatornim okvirom. Upravo zbog toga pruža zanimljiv kontekst za istraživanje financijske stabilnosti poduzeća. Poseban naglasak stavlja se na uključivanje malih poduzeća, koja su u sličnim studijama često zanemarena unatoč njihovoj važnoj ulozi u gospodarskom rastu i zapošljavanju.

U kontekstu dinamičnog poslovnog okruženja, struktura kapitala predstavlja jedan od ključnih elemenata koji oblikuju financijsku stabilnost, potencijal rasta i konkurentsku poziciju poduzeća. Dosadašnja literatura obuhvaća brojne studije koje se oslanjaju na tradicionalne teorije strukture kapitala (Nivorozkin & Kireu, 2019; Salawu, 2008), kao i radove koji analiziraju utjecaj specifičnih karakteristika poduzeća i makroekonomskih čimbenika na odluke o financiranju (Nehrebecka & Dzik-Walczak, 2018; Haas & Peeters, 2006). Ipak, relativno je malo istraživanja koja detaljno razmatraju kako navedeni čimbenici utječu na strukturu kapitala s obzirom na veličinu poduzeća. Većina prethodnih radova fokusirala se na cjelokupni uzorak poduzeća, ne razdvajajući ih po veličini ili zanemarujući specifične karakteristike malih, srednjih i velikih poduzeća. Stoga postoji prostor za empirijsko istraživanje koje sustavno ispituje heterogenost utjecaja čimbenika strukture kapitala u različitim skupinama poduzeća. Poduzeća iz posttranzicijskih država, uključujući Hrvatsku, i dalje su nedovoljno istražena. Ova praznina u literaturi upućuje na istraživački problem – nedostatak suvremenih analiza zaduženosti koje uzimaju u obzir varijacije među poduzećima različitih veličina. Svrha je istraživanja ispitati utjecaj poduzeću specifičnih čimbenika, makroekonomskog okruženja te institucionalnih karakteristika na strukturu kapitala poduzeća, dok je cilj istraživanja analiza varijacija u determinantama strukture kapitala s obzirom na veličinu poduzeća.

Postoji niz teorija strukture kapitala, međutim dvije su koje dominiraju među studijama, a to su teorija kompromisa (engl. *trade off theory*) i teorija hijerarhije financijskih izbora (engl. *pecking order theory*). Postojeće teorije strukture kapitala imaju različita predviđanja o strukturi kapitala. Kraus i Litzenberger 973. godine iznose statičnu teoriju kompromisa. Prema teoriji, optimalna struktura kapitala postiže se u točki u kojoj se koristi i troškovi zaduživanja izjednačuju, s ciljem maksimizacije vrijednosti poduzeća. Porezna zaštita predstavlja korist zaduživanja, dok troškovi financijskih neprilika i stečaja predstavljaju troškove zaduživanja. Dinamična teorija kompromisa (Kane, Marcus, McDonald, Brennan & Schwartz, 1984) nastaje uvođenjem troškova pojedinih oblika financiranja te uvažavanjem vremenske komponente donošenja odluka o financiranju poduzeća. Dinamični pristup oblikovanju strukture kapitala uključuje mogućnost da poduzeća svoju financijsku polugu prilagođavaju prema ciljanoj razini tijekom određenog vremena. Teorija hijerarhije financijskih izbora (Myers & Majluf, 1984) ne predviđa optimalnu strukturu kapitala, nego se asimetrija informacija između menadžmenta i investitora gleda kao temeljna odrednica izbora financiranja. Prema navedenoj teoriji, menadžeri preferiraju financiranje

investicijskih projekata unutarnjim sredstvima kao što su zadržana dobit ili likvidna imovina radije nego vanjskim izvorima financiranja (Popescu & Visinescu, 2009). Asimetrija informacija povećava troškove financiranja jer potencijalni vjerovnici ili budući dioničari nemaju potpune informacije o poslovanju poduzeća. Iz toga razloga, čak i ako se koriste vanjski izvori financiranja, menadžeri će odabrati način na koji se minimiziraju troškovi asimetričnih informacija. Prema teoriji postoji hijerarhija financiranja investicijskih projekata: prvo financiranje iz zadržane dobiti, zatim financiranje dugom te se posljednje izdaju dionice.

Pregled dostupne literature ukazuje na nedostatak istraživanja koja integriraju analizu strukture kapitala, uz istovremeno promatranje veličine poduzeća. Navedeno je područje i dalje ostalo nedovoljno istraženo, posebno u poduzećima srednje i istočne Europe. Istovremeno, rezultati postojećih istraživanja koja se bave analizom veličine poduzeća i dalje pokazuju nekonzistentnost, što dodatno naglašava potrebu za empirijskim testiranjem na velikim uzorcima, kao što je to predviđeno ovim istraživanjem. Istraživanje obuhvaća, osim velikih, srednja i mala poduzeća koja su izuzetno važna za gospodarski razvoj s obzirom na činjenicu da ovaj segment nefinancijskih poslovnih subjekata predstavlja 99% poduzeća Europske unije te zapošljava oko 100 milijuna ljudi. Predlaže se i primjenjuje metodološki pristup kako bi se razumio utjecaj čimbenika te njihova važnost i implikacije na strukturu kapitala. Navedeno je izuzetno važno jer menadžeri donose odluke o strukturi kapitala na temelju dostupnih informacija, a te odluke izravno ili neizravno utječu na vrijednost poduzeća. Također, kreditne institucije mogu imati koristi od rezultata ovog istraživanja jer pružaju empirijski utemeljene informacije o tome kako se čimbenici strukture kapitala razlikuju ovisno o veličini poduzeća. Takvi podaci omogućuju bankama i drugim financijskim institucijama da bolje prilagode svoje modele kreditne procjene, razvijajući mehanizme koji uzimaju u obzir specifične karakteristike malih, srednjih, velikih i jako velikih poduzeća. Tako institucije mogu preciznije procijeniti rizik zajmova, optimizirati uvjete kreditiranja i smanjiti vjerojatnost neplaćanja, čime se povećava učinkovitost i sigurnost kreditnog portfelja. Rad se sastoji od pet poglavlja. Nakon uvoda, slijedi pregled literature i hipoteze istraživanja. U idućem poglavlju objašnjava se prikupljanje podataka i opisuje metodološki pristup analizi uzorka, odabira varijabli te ekonometrijski model istraživanja. Na kraju slijede rezultati te zaključna razmatranja.

2. PREGLED LITERATURE I HIPOTEZE ISTRAŽIVANJA

U posljednje vrijeme velik broj studija posvećen je ispitivanju utjecaja internih čimbenika na strukturu kapitala poduzeća. Među najčešće istraživanim čimbenicima na razini poduzeća ističu se profitabilnost, veličina poduzeća, mogućnost rasta, nedugovna porezna zaštita te struktura imovine, koje literatura prepoznaje kao ključne odrednice strukture kapitala (Alves & Francisco, 2014; Matemilola, Bany-Ariffin, Azman-Saini & Annuar Md Nassir, 2017; Demirguc-

Kunt, Peria & Tressel, 2020; Chua, Razak, Nazir & Yahya, 2021; Daskalakis, Kakavas & Missiakoulis, 2022; Casino-Martinez, Lopez-Gracia & Maestre-Barbera, 2023). Teorijski okvir koji podupire ove analize obuhvaća nekoliko dominantnih teorija, među kojima se posebno ističu teorija kompromisa i teorija hijerarhije financijskih izbora.

Prema teoriji kompromisa, profitabilna poduzeća zahvaljujući boljim financijskim rezultatima imaju povoljnije uvjete za zaduživanje te će, posljedično, biti sklonija višim razinama duga. Suprotno tome, teorija hijerarhije financijskih izbora sugerira da se takva poduzeća, zbog viška zadržane dobiti, radije koriste vlastitim sredstvima nego vanjskim izvorima financiranja (Frank & Goyal, 2009; Kontuš & Šarlija, 2019; He, Hu, Mi & Yu, 2021). Kada je riječ o mogućnosti rasta, teorija hijerarhije financijskih izbora predviđa veću sklonost zaduživanju zbog potrebe za financiranjem budućih investicija. Međutim, teorija kompromisa ističe da poduzeća s visokim potencijalom rasta, često mlađa i s manje kolaterala, imaju otežan pristup kreditima, što dovodi do nižih razina zaduženosti (Frank & Goyal, 2009). Veličina poduzeća i struktura imovine usko su vezane jer je pretpostavka da veća poduzeća imaju više dugotrajne imovine koja im može služiti kao kolateral prilikom zaduživanja, što će dovesti do većeg zaduživanja prema teoriji kompromisa. Rijetko koje poduzeće ima dovoljno vlastitih sredstava za financiranje ulaganja, stoga posežu za vanjskim izvorima (Lemma & Negash, 2014; Loof, 2004; Ankamah-Yeboah, Nielsen & Llorente, 2021). Poduzeća koja imaju veći udio nematerijalne imovine koristit će se manje vanjskim izvorima zbog većih troškova stečaja i umanjenja vrijednosti poduzeća (teorija hijerarhije financijskih izbora). Dodatno, nedugovna porezna zaštita, najčešće mjerena udjelom amortizacije u ukupnoj imovini, također smanjuje potrebu za zaduživanjem jer amortizacija osigurava poreznu olakšicu bez povećanja financijskog rizika, ali u slučaju kada je nedugovna porezna zaštita generirana troškovima povezanima nematerijalnom imovinom, što je u skladu s teorijom kompromisa (Chua et al., 2021; Matemilola et al., 2017). Međutim, u slučaju kada se nedugovna porezna zaštita sastoji od troškova koji su povezanih s materijalnom imovinom, poduzeća će se više zaduživati jer se ona gleda kao zamjenski pokazatelj materijalne imovine. Unatoč postojanju više teorijskih pristupa, prema Myersu (2001: 81), ne postoji jedna univerzalna, općeprihvaćena teorija kojom bi se objasnile odluke o strukturi kapitala. Umjesto toga, poduzeća u praksi donose financijske odluke na temelju kombinacije različitih teorijskih pretpostavki. Slični zaključci proizlaze iz brojnih empirijskih istraživanja, koja potvrđuju da poduzeća ne slijede strogo jednu teoriju, već se njihova struktura kapitala oblikuje pod utjecajem različitih čimbenika i teorijskih smjernica (Frank & Goyal, 2009; Touil & Mamoghli, 2019). U skladu s time postavljena je prva hipoteza:

H1: Interni čimbenici imaju značajan utjecaj na strukturu kapitala poduzeća, pri čemu dolazi do izraženije primjene različitih teorijskih pristupa, ovisno o veličini poduzeća.

Utjecaji makroekonomskog i institucionalnog okruženja različitih država na strukturu kapitala otvorili su daljnji smjer istraživanja u kojem su mnogi

istraživači nastojali ispitati vezu između karakteristika države i strukture kapitala. Tako su 2021. godine Memon, Md-Rus i Ghazali ispitali i dokazali značajan utjecaj stope rasta BDP-a i razvoja tržišta kapitala na strukturu kapitala. Botta i Colombo (2022) ističu da različita poduzeća različito reagiraju na promjene u makroekonomskim i institucionalnim uvjetima zbog interakcija između agregatnih čimbenika i karakteristika pojedinog poduzeća. Mol-Gomez-Vázquez i sur. (2019) sugeriraju da bi vjerovnici bili skloniji financirati poduzeća s ograničenim pristupom kapitalu (najčešće mala poduzeća) u koncentriranom kreditnom tržištu, što im omogućuje da u budućnosti dijele višak vrijednosti koji ta poduzeća generiraju. La Porta, Lopez de Silanes i Shleifer (1998) te Demirguc Kunt, Maksimović i Beck (2005) zaključuju da pravno, regulatorno i institucionalno okruženje zemlje, promatrano na temelju učinkovitosti države, političke stabilnosti, razine korupcije i učinkovitosti provedbe zakona, utječe na odnose između dionika poduzeća, a time i na proces korporativnog upravljanja. Isto tako zabilježen je i značajan utjecaj veličine i aktivnosti financijskog sustava (Bontempi et al., 2019). Financijske institucije imaju bolju mogućnost nadzora, stoga tržišna moć banaka izravno utječe na odluke o financiranju. Taj nadzor omogućen je zahvaljujući široj dostupnosti informacija, koja proizlazi iz veće koncentracije na bankarskom tržištu. Tako banke mogu iskoristiti prednosti ekonomije razmjera te smanjiti troškove povezane s problemima zastupanja (Diamond, 1984). Nadalje, istraživanje Casino-Martineza, Lopez Garcie i Mestre Barbere (2023: 10) pokazuje da makroekonomsko i institucionalno okruženje imaju snažniji utjecaj na manja poduzeća, što ukazuje na njihovu veću osjetljivost na vanjske uvjete u odnosu na veća poduzeća. U odnosu na navedeno postavljena je druga hipoteza:

H2: Makroekonomsko i institucionalno okruženje imaju značajnu ulogu u određivanju strukture kapitala poduzeća, pri čemu je utjecaj izraženiji pri malim i srednjim poduzećima u odnosu na velika poduzeća.

Brojna istraživanja ukazuju na to da utjecaj čimbenika koji određuju strukturu kapitala može značajno varirati ovisno o veličini poduzeća. Demirguc-Kunt, Martinez Peria i Tressel (2020: 16) zaključuju da učinak pojedinih odrednica strukture kapitala nije jednak za sva poduzeća, već se razlikuje s obzirom na njihovu veličinu. Sličan zaključak donose Arsov i Naumoski (2016: 136), ističući kako isti čimbenici različito djeluju na mala i velika poduzeća. Stegovec i Črnigoj (2020: 282) dodatno naglašavaju da je veličina poduzeća znatno važniji faktor u određivanju dinamike strukture kapitala od statusa poduzeća (javno ili privatno). U skladu s time postavljena je treća hipoteza:

H3: Utjecaj internih i eksternih čimbenika na zaduženost razlikuje se ovisno o veličini poduzeća.

3. OPIS UZORKA, PODACI I METODOLOŠKI PRISTUP

U nastavku se prikazuje uzorak istraživanja, definiraju varijable te opisuje ekonometrijski model koji je korišten u provedenom empirijskom istraživanju.

3.1. Uzorak istraživanja

Financijski podaci, koji odražavaju poduzeću specifične čimbenike, prikupljeni su iz baze podataka Orbis Europe, kojom upravlja Moody's. Baza Orbis obuhvaća informacije za više od 100 milijuna poduzeća diljem Europe. Uzorak istraživanja obuhvaća 8695 poduzeća (67 958 opažanja) društava kapitala (dionička društva i društva s ograničenom odgovornošću) koja prema Orbis Europe bazi spadaju u kategorije engl. *private limited companies* i engl. *public limited companies*. Preuzeta poduzeća obuhvaćaju sve kategorije poduzeća po veličini: mala, srednja i velika poduzeća. Uključivanje malih i srednjih poduzeća u uzorak od iznimne je važnosti jer ona čine 99% ukupnog broja poduzeća u Europskoj uniji. Analiza malih poduzeća ključna je jer su pokretač gospodarskog razvoja i zemlje koje se usmjereno bave razvojem malog i srednjeg poduzetništva bilježe veće ekonomske stope rasta. Unatoč brojnim studijama o strukturi kapitala koje su uglavnom provedene na razvijenim tržištima, poput Sjedinjenih Američkih Država i Velike Britanije, uključivanje zemalja srednje i istočne Europe započelo je nešto kasnije, što rezultira manjim brojem istraživanja posttranzicijskih država. Uzorak uključuje poduzeća iz država članica Europske unije, odnosno Hrvatske, Slovenije, Slovačke i Mađarske. Odabrane države pripadaju srednjoj i istočnoj Europi te dijele slične povijesne i tranzicijske okolnosti, kao i usporediv institucionalni okvir. Zbog tih zajedničkih obilježja omogućena je relevantna usporedba i analiza financijskih performansi poduzeća u državi. Osim toga, države su odabrane jer je za njih dostupna pouzdana i usporediva baza podataka o poduzećima, što je ključan preduvjet za provedbu kvantitativne analize. Vremenski okvir istraživanja pokriva razdoblje od 2016. do 2023. godine. Nakon globalne financijske krize gospodarstva su se stabilizirala, ali u promatranom razdoblju analize dolazi do značajnih izazova poput pandemije virusa COVID-19 (2020. – 2021.) koje su snažno utjecale na maloprodaju i potrošačke navike. Upravo u ovom razdoblju ubrzano raste e-trgovina i digitalizacija maloprodajnog sektora. Dodatno, za odabrane zemlje financijski su podaci sustavno dostupni i pouzdani za navedeno razdoblje, što osigurava konzistentnost analize. Iz uzorka izuzete su banke, financijska i osiguravajuća poduzeća, istraživački instituti te razni fondovi jer imaju specifičan model poslovanja te im financijski izvještaji nisu usporedivi s poduzećima iz realnog sektora. Ukupna populacija čini poduzeća koja zadovoljavaju specifične kriterije, uključujući kontinuirano poslovanje najmanje pet godina, potpunost financijskih izvještaja potrebnih za izračun varijabli te organizacijski oblik kao dioničko društvo ili društvo s ograničenom odgovornošću. Dodatno, izuzeta su poduzeća koja imaju dug veći od imovine jer takva poduzeća ne predstavljaju tipična aktivna društva te njihovi pokazatelji mogu imati negativne i nelogične vrijednosti koje otežavaju statističku analizu i interpretaciju rezultata. Dodatno, mogu iskriviti rezultate analiziranih poduzeća. Uzorak obuhvaća poduzeća koja posluju u djelatnosti trgovine na veliko i malo. Trgovina na veliko i malo pokazuje rastući trend i predstavlja jednu od unosnih djelatnosti, omogućujući učinkovitu distribuciju industrijskih proizvoda te doprinosi zapošljavanju i ekonomskom razvoju. Osim toga, trgovina je izrazito dinamična djelatnost, osjetljiva na promjene u potrošačkim navikama, makroekonomskim kretanjima i regulatornim

okvirom. Upravo zbog toga pruža zanimljiv kontekst za istraživanje financijske stabilnosti poduzeća. *Tablica 1. Distribucija uzorka po državama* pruža detaljan pregled raspodjele poduzeća prema državama, što omogućuje bolje razumijevanje kompozicije uzorka u kontekstu geografske raznolikosti. Važno je napomenuti da se Orbis Europe baza koristi drukčijom klasifikacijom poduzeća u odnosu na onu kojom se koristi Europska komisija. Prema Orbis Europe bazi, jako velika poduzeća imaju najmanje 1000 zaposlenih, ukupnu imovinu od najmanje 200 milijuna eura te godišnji poslovni prihod od najmanje 100 milijuna eura. Velika poduzeća zapošljavaju najmanje 150 osoba, imaju imovinu od najmanje 20 milijuna eura i godišnje prihode od najmanje 10 milijuna eura. Srednja poduzeća imaju najmanje 15 zaposlenih, imovinu od najmanje 2 milijuna eura i prihode od najmanje 1 milijun eura godišnje. Mala poduzeća zapošljavaju manje od 15 osoba, s imovinom manjom od 2 milijuna eura i godišnjim prihodom manjim od 1 milijun eura. U okviru ovog istraživanja, kategorija jako velikih poduzeća pripojena je kategoriji velikih poduzeća. Razlog za ovu odluku jest izuzetno mali broj jako velikih poduzeća u uzorku, što bi onemogućilo provođenje statistički relevantnih analiza unutar te skupine. Spajanjem dviju kategorija osigurana je veća robusnost i pouzdanost rezultata te omogućena usporedivost između različitih grupa veličine.

Tablica 1. Distribucija uzorka po državama

Država	**Broj poduzeća**	**Jako velika i velika poduzeća**	**Srednja poduzeća**	**Mala poduzeća**
Slovenija (SI)	1696	141	839	716
Slovačka (SK)	1382	199	740	443
Hrvatska (HR)	2091	280	869	942
Mađarska (HU)	3726	328	1316	1882
Ukupno	**8695**	**948**	**3764**	**3983**

Izvor: Autorice prema podacima preuzetim iz Orbis Europe baze

3.2. Definicija varijabli

3.2.1. Zavisna varijabla

Kao zavisna varijabla u ovom istraživanju koristi se zaduženost poduzeća ($Y_{i,j,t}$). U literaturi o strukturi kapitala često se kao zavisna varijabla koristi financijska poluga (engl. *leverage*), međutim, izračun financijske poluge razlikuje se među autorima. Pojmovi zaduženost i financijska poluga često se u literaturi koriste kao sinonimi za strukturu kapitala pa će se u tom značenju koristiti i u ovom istraživanju. Touil i Mamoghli (2019), Nivorozhkin i Kireu (2019), Canarella i Miller (2019), Marinšek, Pahor i Mramor (2016), Cerović, Zaninović i Dukić (2011), Wanzenried (2006) financijsku polugu izračunavaju kao omjer sume dugoročnog i kratkoročnog duga (ukupnog duga) i ukupne imovine. Omjerom dugoročnog duga i ukupne imovine koriste se Stegovec i Črnigoj (2020), Salim (2019), Fama i French (2002), dok se omjerom kratkoročnog duga i ukupne

imovine koriste Lemma i Negash (2014) i Salawu (2008). Budući da je u literaturi najčešće korišten omjer ukupnog duga i ukupne imovine, u ovom se radu za izračun financijske poluge također koristi omjer ukupnog duga i ukupne imovine. Dodatno, navedeni je omjer najprikladnija mjera zaduženosti poduzeća u analiziranim europskim državama jer pruža cjelovitu sliku financijske strukture poduzeća. Korištenje samo kratkoročnimg ili dugoročnim dugom može dovesti do iskrivljenih zaključaka jer različite veličine poduzeća imaju specifične obrasce financiranja. Mala poduzeća često nemaju pristup dugoročnim izvorima financiranja i stoga se u većoj mjeri oslanjaju na kratkoročne obveze (npr. kratkoročne kredite, obrtna sredstva, dobavljače). Suprotno tome**,** velika poduzeća češće se koriste dugoročnim izvorima financiranja, što znači da bi korištenje samo jednom vrstom duga dovelo do pristranosti u analizi. Omjer ukupnog duga i ukupne imovine neutralizira te razlike omogućujući usporedivost između analiziranih poduzeća. Time se izbjegava potencijalno pogrešno tumačenje zaduženosti temeljeno samo na jednoj vrsti duga, a osigurava se realnija procjena financijske stabilnosti i rizika poduzeća.

3.2.2. Poduzeću specifični čimbenici (interni čimbenici)

Uzimajući u obzir prethodna empirijska istraživanja, u model su kao nezavisne varijable uključeni čimbenici specifični za poduzeće kako bi se kontrolirao njihov relevantan učinak (Fama & French, 2002; Leary & Roberts, 2005; Flannery & Rangan, 2006; Frank & Goyal, 2009; Oztekin, 2015). Poduzeću specifični čimbenici uključuju strukturu imovine, profitabilnost, mogućnost rasta, nedugovnu poreznu zaštitu i veličinu poduzeća. Za obuhvat informacija potrebnih za izračun navedenih čimbenika koriste se sekundarni izvori podataka iz baze Orbis Europe (Moody's).

Profitabilnost (ROA) je mjerena s pomoću pokazatelja stope povrata na imovinu (Touil & Mamoghli, 2019; Drobetz et al., 2007). Struktura imovine (TANG) izražava se kao udio dugotrajne materijalne imovine u ukupnoj imovini (Rajan & Zingales, 1995; Lemma & Negash, 2014; Nivorozkin & Kireu, 2019). Mogućnost rasta (GROWTH) mjeri se kao postotna promjena ukupne imovine (Fama & French, 2002). Nedugovna porezna zaštita (NDTS) mjeri se kao omjer amortizacije i ukupne imovine (Demirguc-Kunt, Beck & Maksimović, 2005). Na kraju, razmatra se i veličina (SIZE) koja označava veličinu poduzeća mjerenu logaritmom ukupne prodaje (Dang, Kim & Shin, 2012; Frank & Goyal, 2009). Poduzeću specifične varijable – profitabilnost (ROA), struktura imovine (TANG), nedugovna porezna zaštita (NDTS), mogućnost rasta (GROWTH) ograničene su na 1 i 99 percentil, dok je varijabla veličina poduzeća (SIZE) logaritmirana varijabla.

3.2.3. Makroekonomsko i institucionalno okruženje (eksterni čimbenici)

U analizu eksternih čimbenika, kao nezavisne varijable uključene su jedna makroekonomska varijabla i jedna institucionalna varijabla kako bi se kontrolirali

opći gospodarski i institucionalni utjecaj. Varijable variraju tijekom vremena i među zemljama, iako su iste za sva poduzeća unutar iste godine i zemlje. Rast bruto domaćeg proizvoda (*GDPg*) jest varijabla koja opisuje makroekonomsko okruženje, a mjeri se kao godišnja stopa rasta realnog BDP-a (Demirguc-Kunt, Beck & Maksimović, 2005). Druga varijabla odnosi se na koncentraciju bankarskog sektora (BANK) te je definirana kao udio imovine triju najvećih banaka u ukupnoj imovini komercijalnih banaka (Bontempi et al., 2019; Casino-Martinez et al., 2023). Ova varijabla odražava institucionalne karakteristike, odnosno razinu razvijenosti financijskog sustava u pojedinoj zemlji. Obje varijable preuzete su iz baze podataka Svjetske banke. Tablica 2. daje prikaz opisa varijabli korištenih u ovom istraživanju.

Tablica 2. Definicija i opis varijabli

Varijabla	**Mjerenje**	**Literatura**
Profitabilnost	Povrat na imovinu (ROA)	Touil & Mamoghli, 2019; Drobetz & Wanzenried, 2007
Struktura imovine	Dugotrajna materijalna imovna/Ukupna imovina	Nivorozkin, 2019; Lemma & Negash, 2014; Rajan & Zingales, 1995;
Mogućnost rasta	Promjena imovine u odnosu na prethodnu godinu	Fama & French, 2002
Nedugovna porezna zaštita	Amortizacija/Ukupna imovina	Lemma &Negash, 2014; Dang et al, 2012; Mahakud & Mukherjee, 2011; Fama & French, 2002
Veličina	Logaritam od prihoda od prodaje	Dang et al., 2012; Frank & Goyal, 2009
Rast BDP-a	Godišnja postotna stopa rasta (World Bank database)	Demirguc-Kunt, Beck & Maksimović, 2005
Koncentracija banaka	Imovina tri najveće banke u udjelu ukupne imovine komercijalnog bankarstva (World Bank database)	Casino-Martinez A. et al., 2023; Bontempi et al., 2019

Izvor: Autorice

3.3. Ekonometrijski model

Istraživanje se provodi na panel podacima, što omogućuje uvažavanje heterogenosti poduzeća. To je ključno za istraživanje jer je glavni cilj ispitati postojanje učinaka specifičnih za poduzeće u kontekstu strukture kapitala među različitim veličinama poduzeća. Metoda generaliziranih jednadžbi procjene (GEE – engl. *Generalized Estimating Equations*) koristi se za analizu longitudinalnih ili klasteriranih podataka, gdje postoji korelacija između opažanja unutar iste grupe (Hardin & Hilbe, 2018). *Generalized Estimating Equations* (GEE) jest metoda za modeliranje zavisnosti među promatranjima u panelima, s naglaskom na ispravnu specifikaciju varijance i korelacije unutar jedinica. Međutim, GEE nije dizajniran za rješavanje endogenosti, što je njegova najveća metodološka slabost. GEE pretpostavlja da su regresori egzogeni, ne koristi se instrumentalnim varijablama te se fokusira na korelacijsku strukturu pogrešaka, a ne na problem simultanosti ili

uzročnosti. GEE je koristan kada postoji problem heteroskedastičnosti i serijska korelacija, kada se analizira prosječni efekt na populaciji i kada su regresori opravdano egzogeni. Potencijalni izvori endogenosti mogu uključivati simultanost, čime se može uzrokovati pristranost procjena. Drugi izvor mogu predstavljati izostavljene varijable koje utječu na zaduženost i regresore, ali nisu uključene u model, poput unutarnje politike poduzeća, kvalitete menadžmenta ili strateških odluka specifičnih za djelatnost. Unatoč potencijalnim izvorima, u ovom radu pretpostavlja se da regresori imaju egzogeni karakter u odnosu na zaduženost jer su promatrane varijable definirane na temelju financijskih izvještaja i makroekonomskih podataka. Osim toga, model se koristi panel podacima s višegodišnjim promatranjima, što smanjuje učinak slučajnih kratkoročnih fluktuacija koje bi mogle izazvati simultanost. Zbog navedenog, iako endogenost ne može biti potpuno isključena, smatra se da neće značajno narušiti konzistenciju i pouzdanost procjena GEE modela u okviru ovog istraživanja. Robusne standardne pogreške korištene su za dodatno ispravljanje heteroskedastičnosti i serijske korelacije, čime se osigurava da su procjene parametara konzistentne i statistički pouzdane.

Na temelju navedenih pretpostavki i metodoloških rješenja, u nastavku se specificira ekonometrijski model koji će poslužiti za empirijsku analizu. Procjenjuju se tri zasebna, ali ista modela za svaku kategoriju veličine poduzeća s uključenom kategorijskom varijablom koja se odnosi na državu. Ekonometrijski model glasi:

$$y_{ijt} = \beta_0 + \beta_1 X_{ijt} + \beta_2 Z_{jt} + \beta_3 W_{jt} + \gamma_1 Country_i + \varepsilon_{it}$$

gdje je y_{ijt} zavisna varijabla, odnosno financijska poluga (DEBT – engl. *Total debt ratio*, omjer ukupnih obveza i ukupne imovine) za poduzeće *i* u državi *j* tijekom godine *t*. X_{ijt} su poduzeću specifični čimbenici (engl. firm-specific), Z_{jt} je makroekonomska varijabla (engl. *macroeconomic variable*) koja se mijenja po zemljama *j* i godinama *t*, dok je W_{jt} institucionalna varijabla (engl. institutional variable) koja se također mijenja po zemljama i godinama. Kategorijska varijabla $Country_i$ = 1 ako poduzeće pripada Hrvatskoj (referentna kategorija). Parametri $\beta_1, \beta_2, \beta_3$ procijenjeni su korištenjem *Generalized Estimating Equations* (GEE – engl. *Generalized Estimating Equations for panel data*) za panel podatke (Demirguc-Kunt et al., 2020), što omogućuje uzimanje u obzir korelacija unutar poduzeća. U odnosu na strukturu korelacije, u analizi prvog i drugog modela, koji obuhvaćaju mala i srednja poduzeća, primijenjena je *exchangeable* (izmjenjiva ili jednolika) struktura korelacije. Ova struktura pretpostavlja da su sve međusobne korelacije unutar skupine jednake, što omogućuje jednostavnije modeliranje i stabilnije procjene. Takav pristup posebno je prikladan za manje i srednje poduzetničke subjekte, gdje varijacije među jedinicama unutar iste kategorije nisu pretjerano izražene. S druge strane, u trećem modelu, koji se odnosi na velika i jako velika poduzeća, korištena je AR(1) struktura korelacije (autoregresivna struktura korelacije prvog reda). Ova struktura pretpostavlja da je korelacija između opažanja postupno opadajuća s udaljenošću između njih, što omogućuje modelu da bolje uhvati dinamičke i vremenske obrasce koji su češći u većim organizacijama.

ε it ~ N(0,σε2) predstavlja odstupanje na razini poduzeća, pri čemu je njegova međuzavisnost modelirana prema odabranoj strukturi korelacije za svaki model.

4. EMPIRIJSKA ANALIZA

Tablica 3. u nastavku prikazuje deskriptivnu statistiku korištenih varijabli, uključujući broj opažanja (N), aritmetičku sredinu (Mean), standardnu devijaciju (Std. Dev.) te minimalne (Min) i maksimalne (Max) vrijednosti. Ovi pokazatelji omogućuju uvid u osnovne karakteristike podataka i raspon varijacija unutar uzorka.

Tablica 3. Deskriptivna statistika varijabli

Varijable	Opažanja (Obs)	Medijan (Mean)	Standardna devijacija (Std. Dev.)	Minimum (Min)	Maksimum (Max)
DEBT	69796	.479	.255	.026	.97
ROA	69796	9.842	12.714	-24.051	57.264
TANG	69796	.232	.217	0	.866
NDTS	69796	.037	.036	.001	.198
GROWTH	69796	.089	.318	-.628	1.64
Size	69796	.013	1.696	-9.244	7.915
GDPg	69796	2.935	3.946	-8.312	12.632
BANK	69796	64.199	6.628	48.568	78.923

Izvor: Autorice

Struktura kapitala poduzeća analizira se na temelju njegove zaduženosti, pri čemu se u radu detaljno istražuju trendovi zaduženosti po godinama i veličini poduzeća. U razdoblju od 2016. do 2023. godine proučavano je kretanje zaduženosti koristeći se omjerom ukupnih obveza i ukupne imovine. Ova analiza omogućuje dublje razumijevanje strukture kapitala promatranih poduzeća država članica Europske unije. Na Grafikonu 1 vidljivo je kretanje prosječne zaduženosti prema kategoriji veličine poduzeća. Može se uočiti da se prosječna zaduženost postupno smanjuje od 2016. do 2023. godine po svim kategorijama veličine poduzeća. Blag porast zaduženosti poduzeća zabilježen je u 2022. godini, što se može povezati s postupnim oporavkom od pandemije. Na kretanje zaduženosti poduzeća utjecali su razni makroekonomski uvjeti poput inflacije koja je povećala kamatne stope te smanjila atraktivnost zaduživanja. Osim toga, geopolitički utjecaji, kao rat u Ukrajini i poremećaji u lancima opskrbe, povećali su troškove sirovina, što je također utjecalo na poslovanje u okviru djelatnosti trgovine. U nastavku je grafikonom prikazano kretanje zaduženosti prema veličini poduzeća.

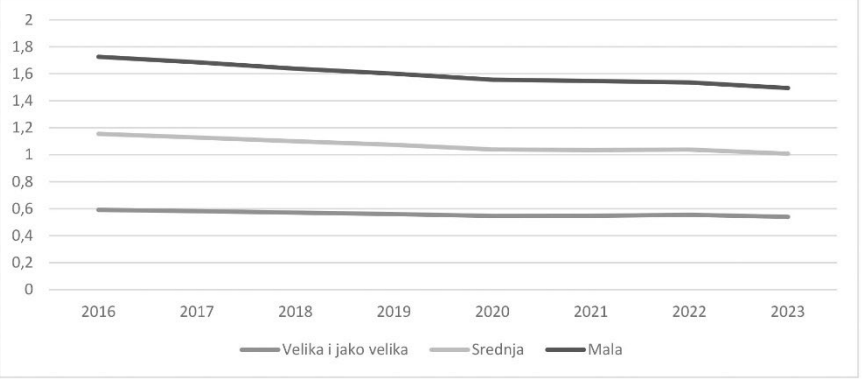

Grafikon 1. Kretanje zaduženosti prema veličini poduzeća

Izvor: Autorice

Analiza je pokazala da ne postoji visoka korelacija među parovima nezavisnih varijabli, čime je isključena mogućnost značajnije multikolinearnosti.

Tablica 4. Korelacijska matrica

Varijable	(1)	(2)	(3)	(4)	(5)	(6)	(7)
ROA	1.000						
TANG	-0.163	1.000					
NDTS	-0.066	0.336	1.000				
GROWTH	0.230	-0.032	-0.011	1.000			
Size	0.158	-0.124	-0.125	0.099	1.000		
GDPg	0.035	-0.012	-0.015	0.163	0.003	1.000	
BANK	-0.047	-0.021	0.058	0.024	0.099	0.090	1.000

Izvor: Autorice

U Tablici 5. prikazani su rezultati provedene analize koji prikazuju razlike u utjecaju odabranih odrednica na zaduženost poduzeća u promatranim državama, ovisno o njihovoj veličini (velika, srednja i mala poduzeća). Svi procijenjeni modeli statistički su značajni prema Wald testu, što ukazuje da su uključene varijable kao cjelina statistički značajne u objašnjavanju varijacije zavisne varijable. Provedena je analiza reziduala kako bi se dodatno procijenila prikladnost specifikacija modela. Konkretno, za svaki od triju procijenjenih GEE modela (jako velika i velika, srednja poduzeća te mala poduzeća) izračunati su Pearsonovi reziduali te grafički provjerena njihova raspodjela. Dobiveni grafikoni upućuju na to da reziduali u svim modelima pokazuju zadovoljavajuću simetričnost i ne odstupaju značajno od normalne raspodjele[1].

[1] Rezultati analize reziduala dostupni na zahtjev.

Tablica 5. Čimbenici strukture kapitala

VARIJABLA	Mala poduzeća	Srednja poduzeća	Jako velika i velika poduzeća
ROA	-0.0041***	-0.0054***	-0.0059***
	[-34.9291]	[-39.8229]	[-23.0060]
	(0.0001)	(0.0001)	(0.0003)
TANG	0.1026***	0.0174	-0.0646
	[8.6137]	[1.4141]	[-1.5748]
	(0.0119)	(0.0123)	(0.0410)
NDTS	-0.2786***	-0.1834***	-0.3406***
	[-6.1454]	[-3.8626]	[-4.0266]
	(0.0453)	(0.0475)	(0.0846)
GROWTH	0.0525***	0.0610***	0.0461***
	[16.4487]	[20.4767]	[7.9615]
	(0.0032)	(0.0030)	(0.0058)
Size	0.0204***	0.0203***	0.0295***
	[6.5124]	[5.6681]	[3.7753]
	(0.0031)	(0.0036)	(0.0078)
GDPg	-0.0021***	-0.0010**	0.0001
	[-4.2354]	[-2.5000]	[0.2846]
	(0.0005)	(0.0004)	(0.0004)
BANK	-0.0017***	-0.0022***	-0.0000
	[-7.2431]	[-10.1935]	[-0.0770]
	(0.0002)	(0.0002)	(0.0003)
Mađarska	-0.0805***	-0.0402***	-0.0200
	[-8.5736]	[-4.3274]	[-1.2965]
	(0.0094)	(0.0093)	(0.0155)
Slovenija	-0.0342***	-0.0337***	0.0061
	[-2.8977]	[-3.2802]	[0.3087]
	(0.0118)	(0.0103)	(0.0196)
Slovačka	0.0771***	0.0836***	0.0672***
	[5.5517]	[7.6635]	[3.9330]
	(0.0139)	(0.0109)	(0.0171)
Konstanta	0.7075***	0.7348***	0.5614***
	[37.3671]	[44.0771]	[15.8300]
	(0.0189)	(0.0167)	(0.0355)
Broj opažanja	30,036	30,543	7,379
Broj poduzeća	3,893	3,870	932
Wald chi2(17)	2792.65	3767.79	798.04
Prob > chi2	0.0000	0.0000	0.0000

Robusne standardne pogreške u zagradama.

*** p < 0.01, ** p < 0.05, * p < 0.1

Izvor: Autorice

Profitabilnost poduzeća pokazuje statistički značajan negativan utjecaj na zaduženost u svim skupinama poduzeća (Basto et al., 2009; Mukherjee & Mahakud, 2010; Daskalakis & Tsota, 2022). Rezultat je u skladu s teorijom hijerarhije financijskih izbora prema kojoj profitabilnija poduzeća imaju tendenciju oslanjati se na interne izvore financiranja poput zadržane dobiti umjesto na vanjsko financiranje putem duga. Struktura imovine (TANG) na zaduženost varira ovisno o veličini poduzeća. Pri velikim i srednjim poduzećima utjecaj nije statistički značajan. Za mala poduzeća, s druge strane, struktura imovine ima pozitivan i značajan utjecaj, što sugerira da je dostupnost kolaterala ključna za njihovo pristupanje vanjskom financiranju na temelju duga (Zabri, 2012; Ab Wahab & Ramli, 2014; Salim, 2019; Daskalakis & Tsota, 2022). Navedeno je u skladu s teorijom kompromisa, prema kojoj se poduzeća s više dugotrajne imovine, koja može poslužiti kao kolateral, lakše zadužuju. Razmatranje poreznih čimbenika obično nije prioritet za mala i srednja poduzeća (Pettit & Singer, 1985) jer se očekuje da takva poduzeća neće ostvarivati visoke profite te se stoga manje koriste dugom ili drugim poreznim olakšicama povezanima s dugom. Ipak, s obzirom na poteškoće malih poduzeća u pristupu financiranju putem duga, korištenje poreznim olakšicama koje nisu povezane s dugom (NDTS) može predstavljati glavnu alternativu za smanjenje poreznih obveza. Stoga se očekuje da će postojati negativan odnos između duga i poreznih olakšica koje nisu povezane s dugom (Chang, Chen & Guanmin, 2014; Daskalakis, Balios & Dalla, 2017; Touil & Mamoghli, 2019; Daskalakis & Tsota, 2022). Poduzeća koja imaju veću mogućnost porezne zaštite imaju manju potrebu za vanjskim financiranjem jer porezna zaštita može smanjiti ukupne porezne obveze i osigurati veću likvidnost poduzeća. Rezultati pokazuju negativnu i statistički značajnu vezu u svim skupinama, što je u skladu s teorijom kompromisa, a to je da nedugovna porezna zaštita (NDTS) smanjuje potrebu za zaduživanjem. Mogućnost rasta (GROWTH), kao mjera rasta poduzeća, ima pozitivan i statistički značajan utjecaj na zaduženost u svim trima skupinama poduzeća (De Miguel & Pindado, 2001; Aybar, Casino Martinez & Garcia Lopez, 2012; Chipeta & Mbululu, 2013; Arsov & Naumoski, 2016; Salim, 2019). Ovaj rezultat podržava pretpostavku da poduzeća s višim stopama rasta traže dodatno dugovno financiranje za realizaciju investicijskih prilika, što je također u skladu s teorijom hijerarhije financijskih izbora. Veličina poduzeća (SIZE) pokazuje pozitivnu i statistički značajnu povezanost sa zaduženošću u svim skupinama poduzeća. Veća poduzeća percipiraju se kao manje rizična od strane vjerovnika, što im omogućuje lakši pristup kreditima i veću razinu duga (Drobetz & Wanzenried, 2006; Salim, 2019), a to je u skladu s teorijom kompromisa. Poduzeću specifični čimbenici razmatrani u istraživanju utvrđeni su kao ključne odrednice strukture kapitala. Vidljiv je različit smjer utjecaja odrednica na strukturu kapitala, pri čemu se prihvaća prva hipoteza da značajan utjecaj internih čimbenika na strukturu kapitala rezultira primjenom različitih teorijskih pristupa strukture kapitala. Rast BDP-a (GDPg) koji predstavlja makroekonomsko okruženje statistički je značajan pri malim i srednjim poduzećima te pokazuje negativan utjecaj na zaduženost, što nije u skladu s očekivanim. Međutim, kada gospodarstvo raste (tj. raste BDP), potrošnja se povećava, što često znači i veće

prihode za poduzeća. S boljim poslovnim rezultatima, ta poduzeća imaju više vlastitih sredstava (interno financiranje) i manju potrebu za vanjskim zaduživanjem (Graham et al., 2014; Salim, 2019). Koncentracija bankarskog sektora (BANK) pokazuje negativan i značajan učinak pri srednjim i malim poduzećima (Touil & Mamoghli, 2019), dok pri velikim nije statistički značajna. Veća koncentracija na bankarskom tržištu smanjuje konkurenciju među bankama, otežavajući pristup financiranju posebno za manja poduzeća koja nemaju razvijene odnose s financijskim institucijama. U skladu s time, prihvaća se druga hipoteza da su mala i srednja poduzeća osjetljivija na makroekonomske i institucionalne čimbenike u donošenju odluka o strukturi kapitala u usporedbi s velikim poduzećima. Dodatno, rezultati ukazuju na značajne razlike među zemljama. Poduzeća u Mađarskoj i Sloveniji su u prosjeku manje zadužena u odnosu na Hrvatsku, posebno u kategoriji manjih i srednjih poduzeća. S druge strane, Slovačka pokazuje pozitivnu i značajnu povezanost sa zaduženošću u svim kategorijama veličine, što može upućivati na povoljnije uvjete financiranja ili specifičnosti lokalnog financijskog tržišta. Nalazi istraživanja potvrđuju značajan utjecaj poduzeću specifičnih čimbenika, makroekonomskog i institucionalnog okruženja na odluke o zaduženosti, uz značajne razlike među različitim veličinama poduzeća, stoga se prihvaća treća hipoteza.

5. ZAKLJUČAK

Istraživanje ispituje učinke poduzeću specifičnih čimbenika, makroekonomskog i institucionalnog okruženja na strukturu kapitala poduzeća ovisno o veličini poduzeća. Koriste se podaci poduzeća koji posluju u djelatnosti trgovine na veliko i malo iz država članica Europske unije (Hrvatska, Mađarska, Slovenija i Slovačka) u razdoblju od 2016. do 2023. godine.

Rezultati istraživanja potvrđuju postojanje značajnih razlika u utjecaju internih i institucionalnih čimbenika na zaduženost poduzeća, ovisno o njihovoj veličini. U skladu s teorijom hijerarhije financiranja, profitabilnija poduzeća, neovisno o veličini, pokazuju niže razine zaduženosti, što upućuje na njihovu sklonost oslanjanju na interno financiranje. Struktura imovine pokazala se značajnim čimbenikom samo za mala poduzeća, pri čemu materijalna imovina djeluje kao važan kolateral pri manjim poduzećima. Nedugovna porezna zaštita negativno utječe na zaduženost poduzeća, sugerirajući da poduzeća koja imaju veću mogućnost porezne zaštite imaju manju potrebu za vanjskim financiranjem jer porezna zaštita može smanjiti ukupne porezne obveze i osigurati veću likvidnost poduzeća. Dodatno, rast poduzeća povećava sklonost zaduživanju u svim trima skupinama. Veličina poduzeća pozitivno je povezana sa zaduženošću, u svim skupinama poduzeća, potvrđujući prednost veličine poduzeća u pristupu financijskim tržištima zbog percepcije manjeg rizika. S makroekonomskog aspekta, rast BDP-a utječe na zaduženost poduzeća malih i srednjih poduzeća, dok viša koncentracija u bankarskom sektoru negativno djeluje na dostupnost financiranja za mala i srednja poduzeća, ali ne i za velika, što dodatno potvrđuje

njihovu veću izloženost institucionalnim ograničenjima. Zemljopisne razlike među državama ukazuju na važnost lokalnog financijskog okruženja, pri čemu poduzeća iz Mađarske i Slovenije iskazuju niže razine zaduženosti u odnosu na Hrvatsku, dok poduzeća iz Slovačke bilježe višu zaduženost, što može ukazivati na povoljnije uvjete financiranja ili specifične karakteristike nacionalnog tržišta. S obzirom na navedeno, sve tri postavljene hipoteze u istraživanju su potvrđene. Interni čimbenici značajno oblikuju strukturu kapitala poduzeća i ne slijede pretpostavke jedne teorije, već se u praksi potvrđuje kombinacija postavki više teorija. Mala i srednja poduzeća osjetljivija su na institucionalne i makroekonomske uvjete u donošenju odluka o financiranju. Istraživanje time doprinosi boljem razumijevanju složenosti procesa odlučivanja o strukturi kapitala i ukazuje na potrebu diferenciranog pristupa u oblikovanju financijskih politika, osobito u kontekstu poticanja pristupa financiranju za mala i srednja poduzeća. Rezultati imaju nekoliko zanimljivih implikacija. S aspekta oblikovanja politika, nalazi mogu doprinijeti boljem razumijevanju poteškoća s kojima se mala poduzeća susreću prilikom pristupa vanjskom financiranju, osobito vlasničkom kapitalu. S obzirom na važnost ovog sektora u gospodarstvu, ima smisla da europske institucije razmotre provedbu reformi kako bi poboljšale zakonsko okruženje i smanjile nejednakosti među državama, čime bi se omogućili bolji uvjeti kreditiranja. Jednako tako, empirijski dokazi ističu važnost razmatranja varijabli na razini poduzeća, makroekonomskih i institucionalnih čimbenika kao odrednica strukture kapitala poduzeća. Doprinos ovog rada očituje se i u primjeni GEE metode, koja je još uvijek relativno rijetko korištena u relevantnoj znanstvenoj literaturi unatoč svojoj prikladnosti za analizu koreliranih podataka. Iako istraživanje pruža vrijedne uvide, važno je istaknuti određena ograničenja. Prije svega, analiza je provedena isključivo unutar djelatnosti trgovine na veliko i malo, što može ograničiti mogućnost generalizacije rezultata na druge gospodarske djelatnosti. Osim toga, zemljopisni fokus istraživanja obuhvaća samo četiri države, što također može utjecati na širinu primjenjivosti zaključaka. U budućim istraživanjima preporučuje se proširenje analize na druge djelatnosti te uključivanje većeg broja zemalja kako bi se dobio sveobuhvatniji uvid u promatrane pojave.

Doprinosi autora: Konceptualizacija R. LJ., I. T. Ž., S. P.; metodologija: R. LJ., I. T. Ž., S. P.; software: R. LJ.; validacija: I. T. Ž., S. P.; formalna analiza: R. LJ., I. T. Ž., S. P.; istraživanje: R. LJ.; resursi: R. LJ., I. T. Ž., S. P.; čuvanje podataka: R. LJ.; pisanje – priprema izvorne radne verzije: R. LJ., pisanje – pregled i priređivanje: I. T. Ž, S. P.; vizualizacija: R. LJ, I. T. Ž., S. P.; nadzor: I. T. Ž., S. P.

Financiranje: Istraživanje prikazano u rukopisu nije dobilo nikakva sredstva iz vanjskih izvora financiranja.

Sukob interesa: Nema.

Priznanje korištenja umjetne inteligencije (UI) ili alata temeljenih na umjetnoj inteligenciji: Nismo koristili UI ili alate temeljene na umjetnoj inteligenciji pri izradi ovog rada.

LITERATURA

Ab Wahab, S. N. A., & Ramli, N. A. (2014). The determinants of capital structure: an empirical investigation of Malaysian listed government linked companies. *International Journal of Economics and Financial Issues*, *4* (4), 930-945. https://doi.org/10.2139/ssrn.2364238

Alves, P., & Francisco, P. (2014). The Impact of Institutional Environment on the Capital Structure of Firms during Recent Financial Crises. *Quarterly Review of Economics and Finance*, *57* (C), 129-146. https://doi.org/10.1016/j.qref.2014.12.001

Ankamah-Yeboah I., Nielsen R., & Llorente I. (2021). Capital structure and firm performance: Agency theory application to Mediterranean aquaculture firms. *Aquaculture Economics & Management, 25* (4), 367-387. https://doi.org/10.1080/13657305.2021.1976884

Arsov, S., & Naumoski, A. (2016). Determinants of capital structure: An empirical study of companies from selected post-transition economies. *Zbornik radova Ekonomskog fakulteta Rijeka*, *34* (1), 119-146. https://doi.org/10.18045/zbefri.2016.1.119

Aybar Arias, C., Casino Martinez, A., & Gracia Lopez, J. (2012). On the adjustment speed ofSMEs to their optimal capital structure. *Small Business Economics*, *39* (4), 977-996. https://doi.org/10.1007/s11187-011-9327-6

Bontempi, M. E., & Pietro, F. (2019). Capital Structure across Italian Regions: The Role of Financial and Economic Differences. *Sustainability*, *11* (16), 4474. https://doi.org/ 10.3390/su11164474

Botta, M., & Colombo, L. V. A. (2022). Non-linear capital structure dynamics. *Journal of Business Finance & Accounting, 49* (9-10), 1897-1928. https://doi.org/10.1111/jbfa.12596

Casino-Martínez, A., Lopez-Gracia, J., & Mestre-Barbera, R. (2023). The regulatory environment and financial constraints of private firms in the European Union. *Global Finance Journal*, *55* (C). https://doi.org/10.1016/j.gfj.2022.100798

Chua, M., Razak, N. H., Nassir, A., & Yahya, M.H. (2021). Speed of adjustment towards targetleverage in the asean countries. *International Journal of Business and Society*, *22* (1), 313-331. https://doi.org/10.33736/ijbs.3177.2021

Canarella, G., & Miller, S. M. (2019). Determinants of Optimal Capital Structure and Speed of Adjustment: Evidence From the U.S. ICT Sector. *Working Papers 2019-06*. https://doi.org/10.2139/ssrn.3354975

Cerović, Lj., Zaninović, V., & Dukić, N. (2011). Utjecaj vlasničke i kapitalne strukture na kretanje agencijskih troškova: Studija slučaja vlasnički nisko koncentriranih poduzeća Republike Hrvatske. *Ekonomska misao i praksa*, *20* (2), 419-442.

Chang, C., Chen, X., & Guanmin, L. (2014). What are the Reliably Important DeterminantsofCapital Structure in China?. *Pacific-Basin Finance Journal*, *30* (C), 87-113. https://doi.org/10.1016/j.pacfin.2014.06.001

Chipeta, C., & Mbululu, D. (2013). Firm heterogeneity, macroeconomic conditions and capital structure adjustment speeds: Evidence from the JSE. *Investment Analysts Journal*, *42* (77), 69-80. https://doi.org/10.1080/10293523.2013.11082557

Dang, V. A., Kim, M., & Shin, Y. (2012). Asymmetric Adjustment toward Optimal Capital Structure: Evidence from A Crisis. *International Review of Financial Analysis*, *33* (C), 226-242. https://doi.org/10.1016/j.irfa.2014.02.013

Daskalakis, N., Balios, D., & Dalla, V. (2017). The behaviour of SMEs' capital structure determinants in different macroeconomic states. *Journal of Corporate Finance*, *46* (C), 248-260. https://doi.org/10.1016/j.jcorpfin.2017.07.005

Daskalakis, N., Kakavas, A., & Missiakoulis, S. (2022). Do industry differences affect firm-specific capital structure determinants?. *The European Journal of Finance*, *29* (15), 1705-1715. https://doi.org/10.1080/1351847X.2022.2145230

Daskalakis, N., & Tsota, E. (2022). Reintroducing industry effects in capital structure determination of SMEs. *Business and Entrepreneurship Journal*, *12* (2), 1-4. https://doi.org/10.21203/rs.3.rs-2324863/v1

De Miguel, A., & Pindado, J. (2001). Determinants of capital structure: New evidence from Spanish panel dana. *Journal of Corporate Finance*, *7* (1), 77-99. https://doi.org/10.1016/S0929-1199(00)00020-1

Demirguc-Kunt, A., Beck, T., & Maksimović, V. (2005). Financial and Legal Constraints to Growth: Does Firm Size Matter?. *The Journal of Finance*, *9* (1), 137-177. https://doi.org/10.1111/j.1540-6261.2005.00727.x

Demirguc-Kunt, A., Peria, M., & Tressel, T. (2020). The global financial crisis and the capital structure of firms: Was the impact more severe among SMEs and non listed firms?. *Journal of Corporate Finance*, *60* (C). https://doi.org/10.1016/j.jcorpfin.2019.101514

Diamond, D. W. (1984). Financial Intermediation and Delegated Monitoring. *The Review of Economic Studies*, *51* (C), 393-414. https://doi.org/10.2307/2297430

Dias, B., Wilson Toshiro, D., & Cruz Basso, L. (2009). Determinants of Capital Structure of Publicly-Traded Companies in Latin America: The Role of Institutional and Macroeconomics Factors. *International Journal of Economics and Finance*, *12* (6), 18-37.

Drobetz, W. & Wanzenried, G. (2006). What determines the speed of adjustment to the target capital structure?. *Applied Financial Economics*, *16* (13), 941-958. https://doi.org/10.1080/09603100500426358

Fama, E., & French, K. (2002). Testing trade-off and pecking order predictions about dividends and debt. *Review of Financial Studies*, *15* (1), 1-33. https://doi.org/10.1093/rfs/15.1.1

Flannery, M., & Rangan, K. (2006). Partial adjustment toward target capitalstructures. *Journal of Financial Economics*, *79* (3), 469-506. https://doi.org/10.1016/j.jfineco.2005.03.004

Frank, M. Z., & Goyal, V. K. (2009). Capital structure decisions: Which factors are reliably important?. *Financial Management*, *38* (1), 1-37. https://doi.org/10.1111/j.1755-053X.2009.01026.x

Graham, J. R., Leary, M. T., & Roberts, M. R. (2014). A century of capital structure: The leveraging of corporate America. *Journal of Financial Economics*. http://dx.doi.org/10.1016/j.jfineco.2014.08.005

Hall, G., Hutchinson, P. J., & Michaelas, N. (2004). Determinants of the Capital Structures of European SMEs. *Journal of Business Finance & Accounting*, *31* (5-6), 711-728. https://doi.org/10.1111/j.0306-686X.2004.00554.x

Hardin, J. W., & Hilbe, J. M. (2018). Generalized Linear Models and Extensions. *Stata Press*. Texas.

Haas, R., & Peeters, M. (2006). The dynamic adjustment towards target capital structures of firmsin transition economies. *Economics of Transition*, *14* (1), 133-169. https://doi.org/10.1111/j.1468-0351.2006.00237.x

He, W., Hu, M. R., Mi, L., & Yu, J. (2021). How stable are corporate capital structures? International evidence. *Journal of Banking and Finance*, 126. https://doi.org/10.1016/j.jbankfin.2021.106103

Kane, A., Marcus, A. J., & McDonald, R. (1984). How big is the tax advantage to debt?. *The Journal of Finance*, *9* (3), 841-853. https://doi.org/10.2307/2327948; https://doi.org/10.1111/j.1540-6261.1984.tb03678.x

Kontuš, E., & Šarlija, N. (2019). The impact of capital structure and pecking order theory on corporate liquidity. *Ekonomska misao i praksa*, *28* (2), 655-679.

La Porta, R., Lopez de Silanes, F., & Shleifer, A., (1998). Corporate ownership around the world. *The Journal of Finance*, *54* (1), 471-517. https://doi.org/10.3386/w6625; https://doi.org/10.2139/ssrn.103130

Leary, M. T., & Roberts, M. R. (2005). Do firms rebalance their capital structures. *Journal ofFinance*, *55* (6), 2575-2619. https://doi.org/10.1111/j.1540-6261.2005.00811.x

Lemma, T. T., & Negash, M. (2014). Determinants of the adjustment speed of capital structure. *Journal of Applied Accounting Research*, *15* (1), 64-99. https://doi.org/10.1108/JAAR-03-2012-0023

Loof, H. (2004). Dynamic optimal capital structure and technical change. *Structural change and economic dynamics*, *15* (C), 449-468. https://doi.org/10.1016/j.strueco.2003.05.001

Marinšek, D., Pahor, M., Mramor, D., & Luštrik, R. (2016). Do European Firms Behave as if they Converge toward a Target Capital Structure?. *Journal of International Financial Management & Accounting*, *27* (2), 97-125. https://doi.org/10.1111/jifm.12046

Matemilola, B. T., Bany-Ariffin, A. N., Azman-Saini, W. N. W., & Annuar Md Nassir, A.(2017). Does top managers' experience affect firms' capital structure?. *Research in International Business and Finance*, *45* (6), 488-498. https://doi.org/10.1016/j.ribaf.2017.07.184

Memon, P. A., Md-Rus, R., & Ghazali, Z. B. (2021). Adjustment speed towards target capital structure and its determinants. *Economic research – Ekonomska istraživanja*, *34* (1), 1966-1984. https://doi.org/10.1080/1331677X.2020.1860792

Mol-Gomez-Vazquez, A., Hernandez-Canovas, G., & Koeter-Kant, J. (2022). Banking stability and borrower discouragement: a multilevel analysis for SMEs in the EU-28. *Small Business Economics*, *58* (3), 1579-1593. https://doi.org/10.1007/s11187-021-00457-w

Mukherjee, S., & Mahakud, J. (2010). Dynamic adjustment towards target capital structure: evidence from Indian companies. *Journal of Advances in Management Research*, *7* (2), 250-266. https://doi.org/10.1108/09727981011085020

Myers, S., & Majluf, N. (1984). Corporate Financing and Investment Decisions When Firms Have Information that Investors Do Not Have. *Journal of Financial Economics*, *13* (2), 187-221. https://doi.org/10.1016/0304-405X(84)90023-0

Myers, S. (2001). Capital Structure. *Journal of Economic Perspectives*, *15* (2), 81-102. https://doi.org/10.1257/jep.15.2.81

Nehrebecka, N., & Dzik-Walczak, A. (2018). The dynamic model od partial adjustment of the capital structure: Meta analysis and a case of Polish enterprises. *Zbornik radova Ekonomskog fakulteta Rijeka*, *36* (1), 55-81. https://doi.org/10.18045/zbefri.2018.1.55

Nivorozkin, E., & Kireu, E. (2019). Analysis of Determinants of the Speed of Adjustment to Target Capital Structure of Companies in Developing Economies. *Journal of Corporate Finance Research*, *13* (3), 111-136. https://doi.org/10.17323/j.jcfr.2073-0438.13.3.2019.111-136

Oztekin, O. (2015). Capital Structure Decisions around the World: Which Factors Are Reliably Important. *Journal of Financial and Quantitative analysis*, *50* (3), 301-323. https://doi.org/10.1017/S0022109014000660

Pettit, R., & Singer, R. (1985). Small business finance: A research agenda. *Financial Management*, *14* (3), 47-60. https://doi.org/10.2307/3665059

Popescu, L., & Visinescu, S. (2009). A review of the capital structure theories. *Annals of Faculty of Economics*, *3* (1), 315-320.

Rajan, R. G., & Zingales, L. (1995). What Do We Know About Capital Structure? Some Evidence from International Data. *Journal of Finance*, *50* (5), 1421-1460. https://doi.org/10.1111/j.1540-6261.1995.tb05184.x

Salawu, R. O. (2008). The determinants of capital structure of large non-financial listed firms in Nigeria. *The International Journal of Business and Finance Research*, *2* (2), 75-84.

Salim, K. C. (2019). The Speed of Adjustment towards Optimal Capital Structure: A Testof Dynamic Trade-off Model. *Jurnal Ekonomi Malaysia*, *53* (3), 91-102. https://doi.org/10.17576/JEM-2019-5303-7

Sogorb-Mira, F. (2005). How SME Uniqueness Affects Capital Structure: Evidence From A 1994–1998 Spanish Data Panel. *Small Business Economics*, *25* (5), 447-457. https://doi.org/10.1007/s11187-004-6486-8

Stegovec, K., & Črnigoj, M. (2020). Optimal Capital Structure and Leverage Adjustment Speed of European Public and Private Firms. *Economic and Business Review*, *22* (2), 261-288. https://doi.org/10.15458/ebr103

Touil, M., & Mamoghli, C. (2019). Institutional environment and determinants of adjustment speed tothe target capital structure in the MENA region. *Borsa Istanbul Review*, *20* (2), 121-143. https://doi.org/10.1016/j.bir.2019.12.003

Wanzenried, G. (2006). What determines the speed of adjustment to the target capital structure?. *Applied Financial Economics*, *16* (13), 941-958. https://doi.org/10.1080/09603100500426358

Zabri, S. M. (2012). The Determinants of Capital Structure among SMES in Malaysia. *Proceedings International Conference of Technology Management, Business and Entrepreneurship (ICTMBE2012).*

Raffaella Ljevar, mag. oec.
PhD student
University of Rijeka
Faculty of Economics and Business
E-mail: raffaella.ljevar@gmail.com
Orcid: https://orcid.org/0009-0003-4371-4679

Ivana Tomas Žiković, PhD
Associate Professor
University of Rijeka
Faculty of Economics and Business
Department of Finance
E-mail: ivana.tomas.zikovic@efri.uniri.hr
Orcid: https://orcid.org/0000-0002-9156-3479

Sandra Pepur, PhD
Associate Professor
University of Split
Faculty of economics, Business and Tourism
Department of Finance
E-mail: sandra.pepur@efst.hr
Orcid: https://orcid.org/0000-0003-3468-9072

THE ROLE OF FIRM SIZE IN SHAPING CAPITAL STRUCTURE: AN ANALYSIS OF FIRMS FROM CENTRAL AND EASTERN EUROPE

Abstract

This study examines the impact of firm-specific, macroeconomic, and institutional factors on the capital structure of firms of different sizes in selected Central and Eastern European countries. The empirical analysis applies the generalized estimating equations (GEE) method to a panel of 8,695 firms in the wholesale and retail trade sector over the period 2016–2023. The results show that profitability reduces leverage across all groups of firms, while growth and size increase the propensity to use debt. Asset structure is significant only for small firms, where tangible assets serve as key collateral, while non-debt tax shields reduce leverage. Macroeconomic and institutional factors exhibit selective effects: GDP growth and banking sector concentration significantly influence borrowing decisions of small and medium-sized firms, but are not statistically significant for large firms. The findings also highlight cross-country differences: firms in Hungary and Slovenia show lower leverage compared to Croatia, while firms in Slovakia are more indebted. Overall, the results confirm that a combination of firm-specific, macroeconomic, and institutional factors shapes capital structure, with heterogeneous effects depending on firm size. The study underscores the need for

tailored financial policies for small and medium-sized firms and provides guidance for managers, financial institutions, and policymakers.

Keywords: capital structure, firm-specific factors, macroeconomic factors, institutional environment, generalized estimating equations method

JEL classification: G32, C33, L25, O16, P34