Utjecaj veličine poduzeća na modeliranje poslovnog neuspjeha

Raković, Goran

Professional thesis / Završni specijalistički

2018

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:124:544994

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

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

GORAN RAKOVIĆ

UTJECAJ VELIČINE PODUZEĆA NA MODELIRANJE POSLOVNOG NEUSPJEHA

ZAVRŠNI RAD

Split, 2018.

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

POSLIJEDIPLOMSKI SPECIJALISTIČKI STUDIJ
POSLOVNA EKONOMIJA

Goran Raković

UTJECAJ VELIČINE PODUZEĆA NA MODELIRANJE POSLOVNOG NEUSPJEHA

ZAVRŠNI RAD

Mentor: prof.dr.sc.Ivica Pervan

Split, 2018.

SADRŽAJ:

1. UVOD

1.1. Problem istraživanja…….……..5

1.2. Svrha i cilj istraživanja…….……..7

1.3. Sadržaj istraživanja…….…...…7

2. FINANCIJSKE INFORMACIJE U KONTEKSTU PROCJENE BONITETA

2.1. Važnost procjene boniteta……...9

2.2. Temeljni financijski izvještaji……10

2.2.1. Bilanca……..….12

2.2.2. Račun dobiti i gubitka/sveobuhvatna dobit…….…..14

2.2.3. Izvještaj o novčanim tokovima…….……16

2.2.4. Izvještaj o promjenama kapitala…….……...18

2.2.5. Bilješke uz financijska izvješća……...….……19

2.3. Financijski pokazatelji……..……20

2.3.1. Pokazatelji likvidnosti……..……20

2.3.2. Pokazatelji zaduženosti…….……...22

2.3.3. Pokazatelji aktivnosti…….…..….24

2.3.4. Pokazatelji ekonomičnosti…….……..25

2.3.5. Pokazatelji profitabilnosti…….……...26

2.3.6. Pokazatelji investiranja…….……...28

3. MODELI ZA PREDVIĐANJE POSLOVNOG NEUSPJEHA

3.1. Altmanovi modeli……..…….…….30

3.2. Kralicekovi modeli…….…….33

3.3. Springate model……..……..34

3.4. Zmijewski model……..……...35

3.5. Ohlson model……..……..36

3.6. Ostali modeli……..……...37

3.7. Modeli iz Hrvatske…….……39
3.7.1. FP Rating……...…..……..…..39
3.7.2. Pervan i Kuvek model……..…...40
3.7.3. Ivičić i Cerovac model……...…….….42
3.7.4. Zenzerović model……....…43
3.7.5. Šarlija i ostali model…….…..……..46
3.7.6. Ocjena financijskog rejtinga-Bonplus…….…...….48

4. OBLIKOVANJE MODELA ZA PREDVIĐANJE POSLOVNOG NEUSPJEHA
4.1. Opis uzorka……...……...50
4.2. Opis metodologije…….……...……..……...52
4.3. Opis varijabli……...…….…...52
4.4. Rezultati istraživanja……...……...58

5. ZAKLJUČAK…….……79
LITERATURA…….……80
SAŽETAK……...……..83
SUMMARY…….…..……84

1. UVOD

1.1 PROBLEM ISTRAŽIVANJA

Početkom 1930-ih zabilježena su u literaturi zanimanja znanstvenika za predviđanje poslovnog neuspjeha poduzeća prema financijskim informacijama, ali je znanstveni pristup financijskoj nestabilnosti sa korištenjem statističkih metoda započeo u drugoj polovini dvadesetog stoljeća. Na temelju empirijskih istraživanja i korištenjem statističkih metoda na određenim uzorcima znanstvenici su razvijali modele koje bi sa popriličnom točnosti mogli predvidjeti financijsku nestabilnost poduzeća. I neki od najpoznatijih modela predviđanja neuspjeha su dorađivani tijekom vremena dodavanjem novih varijabli tj. financijskih pokazatelja kako bi generirali preciznije rezultate i samim tim prepoznali poduzeća sa poteškoćama. Takvi modeli korišteni su za predviđanje financijske nestabilnosti poduzeća koja ponekad može čak i rezultirati i stečajem.

S obzirom da postoje mnogi modeli predviđanja poslovne neuspješnosti i financijske nestabilnosti poduzeća koji se temelje na financijskim pokazateljima dobivenima iz temeljnih financijskih izvješća dolazi i do razlika u preciznosti rezultata određenih modela kod razmatranja u različitim gospodarskim uvjetima te vrstama poduzeća. Ovakvi modeli predviđanja uspješnosti poduzeća najčešće su se temeljili na financijskoj komponenti (podacima iz temeljnih financijskih izvješća), ali na uspješnost poduzeća imaju određen utjecaj i neki drugi faktori koji nisu dio financijskih izvješća kao što su ovisnost o ključnim kupcima, kvaliteta financijskih informacija, kompetentnost i kvaliteta menadžmenta itd. Znanstvenici su naknadno dodavali i nefinancijske komponente u svoje modele kako bi pokušali povećati točnost predviđanja neuspjeha.

Pretpostavka je da korištenje određenog modela predviđanja poslovnog neuspjeha može donijeti rezultate koji imaju veći ili manji značaj kod primjene u različitim veličinama poduzeća (u ovom slučaju uzimajući u obzir iznos ukupnog kapitala poduzeća). U početku je veći broj istraživanja bio usmjeren na veća poduzeća i ona koja kotiraju na tržištu kapitala, ali su se s vremenom razvijali i posebni modeli za primjenu na malim i srednjim poduzećima.

Očekivanja da će doći do povećanja točnosti predviđanja poslovnog neuspjeha ako se poduzeća grupiraju po veličini kapitala proizlaze iz prethodnih istraživanja koja su potvrdila kako posebno prilagođeni modeli za mala i srednja poduzeća mogu ostvariti veću točnost predviđanja nego generički korporacijski modeli. S obzirom na važnost i zastupljenost malih i srednjih poduzeća u gospodarstvu (koji u zemljama OECD iznosi više od 90% od ukupnog broja poduzeća) Altman I. i Sabato G. 2007. godine su napravili slično istraživanje na primjeru američkog gospodarstva te izmjenom varijabli povećali točnost predviđanja za 30% u odnosu na generički korporacijski model. Također postoje mnoga istraživanja o modelima predviđanja uspješnosti prilagođena za uporabu na malim i srednjim poduzećima (SME – small medium enterprises) jer zbog svojih specifičnosti zahtijevaju posebne modele.

Predmet istraživanja u ovom radu je istražiti i ustvrditi koji **model će s najvećim stupnjem pouzdanosti predvidjeti poslovnu neuspješnost poduzeća kategoriziranih u nekoliko grupa s obzirom na njihovu veličinu uzimajući pri tom iznos kapitala poduzeća kao kriterij za razvrstavanje u pojedine grupe poduzeća. Istraživanje će također prikazati koje su varijable imale najveći utjecaj u određenoj kategoriji poduzeća grupirane prema iznosu kapitala.**

Kao izvor podataka u ovom radu koristit će se računovodstveni podaci i financijski pokazatelji iz financijskih izvješća više od 2.000 trgovačkih društva Republike Hrvatske u proizvodnom sektoru (podaci dostupni za posljednje obračunsko razdoblje te prethodne četiri godine). Na temelju opisanog problema i navedenog predmeta istraživanja postavljena je **temeljna radna hipoteza**:

H1: Točnost modela za predviđanje poslovnog neuspjeha se povećava ako se poduzeća grupiraju u više skupina, ovisno o veličini

Kako bi se dokazala hipoteza primijenit će se jedan model na sva poduzeća u uzorku, a zatim definirati modeli za svaku skupinu poduzeća zasebno, ovisno o veličini tj. visini ukupne imovine. Očekuje se da bi točnost takvih modela odabranih u ovisnosti o veličini poduzeća trebala biti veća nego kod primjene jedinstvenog modela za sva poduzeća. To ujedno navodi i na zaključak kako određene varijable tj. financijski pokazatelji imaju različit utjecaj i važnost u predviđanju poslovnog neuspjeha kod primjene na različitim skupinama poduzeća (ovisno o njihovoj veličini tj. visini kapitala).

1.2 SVRHA I CILJ ISTRAŽIVANJA

Cilj ovoga rada je analizirati utjecaj veličine poduzeća pri oblikovanju modela za procjenu neuspješnosti poduzeća na temelju dostupnih financijskih podataka poduzeća u Republici Hrvatskoj kategorizirajući ih u nekoliko grupe prema veličini njihove ukupne imovine.

Nakon primjene logističke regresije i definiranja grupa te zasebnih modela vršit će se usporedba osnovnog modela logističke regresije sa modelima izvedenih za pojedine skupine poduzeća razlikujući ih pritom po veličine poduzeća te uz to prikazati koje su varijable tj. financijski pokazatelji bili najutjecajniji u odabranom uzorku.

Rezultati istraživanja će pokazati da li se dodatnim grupiranjem poduzeća u nekoliko kategorija te primjenom prilagođenih modela posebno za tu grupu poduzeća može postići veća točnost predviđanja poslovnog neuspjeha nego kod korištenja jednog osnovnog modela.

1.3 SADRŽAJ ISTRAŽIVANJA

Na temelju definicije problema i ciljeva istraživanja određena je struktura rada koja sa uvodom i zaključkom sadrži pet poglavalja. Prvo poglavlje, kao uvodni dio rada opisuje problem istraživanja, definira svrhu i cilj istraživanja te predmet istraživanja. U prvom poglavlju je također prikazan i sadržaj istraživanja.

U drugom poglavlju obrazlaže se teorijski dio financijskih informacija u kontekstu procjene boniteta kroz objašnjavanje važnosti procjene boniteta te računovodstvenih izvještaja i financijskih pokazatelja kao izvor informacija.

Treće poglavlje prikazuje neke od poznatijih modela za mjerenje poslovne neuspješnosti, kao što su Altmanov, Kralicekov i Zmijewski modeli te uključuje i modele iz Hrvatske. Ovo poglavlje također prikazuje sličnosti i razlike između pojedinih modela.

U četvrtom poglavlju se definira uzorak, primijenjena metodologija i varijable koje su predmet razmatranja kod oblikovanja modela za predviđanje poslovnog neuspjeha u odnosu na različite veličine poduzeća. Ovo poglavlje uključuje testiranje preciznosti različitih

modela na temelju financijskih podataka uspješnih poduzeća i poduzeća sa poteškoćama u poslovanju. Rezultat istraživanja trebao bi prikazati koji od modela se pokazao najprecizniji u odnosu na velika, srednja i mala poduzeća u Hrvatskoj te uz to ustvrditi i usporediti koja od varijabla tj. financijskih pokazatelja je imala značajan utjecaj u predviđanju poslovnog neuspjeha razmatrajući različite veličine poduzeća.

U petom poglavlju se obrazlaže zaključak donesen na temelju postojećih teorijskih modela i empirijske analize provedene na stvarnim podacima hrvatskih uspješnih poduzeća i onih s poteškoćama.

2. FINANCIJSKE INFORMACIJE U KONTEKSTU PROCJENE BONITETA

2.1.Važnost procjene boniteta

Bonitet je jedan od vrlo značajnih pokazatelja koji se koristi kao dokaz gospodarske i financijske sposobnosti. Bonitetne informacije se koriste prilikom ulaska u poslovne odnose s nepoznatim poduzetnikom, postupcima javne nabave i općenito u postupcima nadmetanja, tj. uvijek kada se procjenjuje i bira novi poslovni partner.[1] Korisnici bonitetnih informacija su najčešće banke, osiguravajuća društva, investicijski fondovi, poslovni partneri, konkurenti, sami vlasnici poduzeća, itd. Važnost procjene boniteta i kreditne sposobnosti posebno dolazi do izražaja u uvjetima poslovne krize i nelikvidnosti.

Bonitet potiče od latinske riječi ”bonus”, koja znači dobar i predstavlja skup osobina jednog subjekta koji ga čine dobrim i sigurnim dužnikom. Pod ocjenom boniteta u užem smislu misli se na vjerojatnost nastupanja insolventnosti trgovačkog društva u budućnosti, odnosno na ocjenu likvidnosti i kreditne sposobnosti. U tom smislu smatra se da poduzeće ima dobar bonitet ukoliko pravodobno podmiruje dospjele obveze. U najširem smislu na ocjenu boniteta odnosi se i ocjena ekonomskih pojava i situacija u poduzeću, nekih oznaka neopipljivih sigurnosti s obzirom na brend tvrtke, unutarnja vrijednost tvrtke te specifične oznake koje u sebi sadrže i ocjenu likvidnosti i kreditne sposobnosti poduzeća[2]. Kako bi se došlo do kvalitetnih podataka prilikom istraživanja boniteta tvrtke, pregledavaju se poslovne knjige, planovi u kraćoj i dužoj budućnosti i slično.

Kao tri glavna razloga obavljanja procjene boniteta navode se:[3]

1. Kontinuirano praćenje vlastite financijske situacije, analiziranje ostvarenih financijskih pokazatelja, planiranje financijskih instrumenata i provođenje financijskog nadzora.

[1] Kavur, V. (2013): Bonitetne informacije za procjenu rizika poslovnog odnosa RRiF br. 5, str. 91. – 92.

[2] Bahtijarević-Šiber, F. (2001.): Leksikon menadžmenta, Masmedia, Zagreb, str. 357.

[3] Leko, V.(1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb, str.10.

2. Izračun i analiza financijskih pokazatelja poslovnih partnera s kojima trgovačko društvo ostvaruje razne poslovne odnose.
3. Provođenje detaljne provjere boniteta emitenta dugoročnih vrijednosnih papira kod ulaganja u dugoročne vrijednosne papire, tj. da se potencijalnim ulagačima pruže sve potrebne informacije za donošenje odluke o ulaganju kapitala.

Ukoliko bonitetna informacija sadrži i ocjenu financijskog rejtinga onda je njena vrijednost i kvaliteta veća jer ocjena financijskog rejtinga daje informaciju o tome kolika je vjerojatnost da će u određenom razdoblju kod određenog poduzetnika doći do zastoja u plaćanju.

2.2.Temeljni financijski izvještaji

Temeljni financijski izvještaji su glavni izvor informacija o poslovanju poduzeću jer sadrže informacije o prošlim aktivnostima poduzeća i njihovim rezultatima. Financijski izvještaji su dakle rezultat računovodstvenog praćenja poslovanja i knjigovodstvenog evidentiranja nastalih poslovnih promjena. Cilj financijskog izvještavanja je informiranje zainteresiranih korisnika o financijskom položaju kao i uspješnosti poslovanja.

U Republici Hrvatskoj za financijsko izvještavanje nadležan je Zakon o računovodstvu te se njime određuje računovodstvo poduzetnika, primjena standarda financijskog izvještavanja, primjena knjigovodstvenih isprava i poslovnih knjiga, izrada godišnjih financijskih izvještaja i konsolidacija, javna objava godišnjih financijskih izvještaja, razvrstavanje poduzetnika, revizija i sadržaj godišnjih financijskih izvještaja.

Izvještaji se moraju sastavljati i prezentirati prema Hrvatskim standardima financijskog izvještavanja, ukoliko se radi o mikro, malim i srednjim poduzetnicima. Ukoliko se radi o velikim poduzetnicima, oni imaju obvezu sastavljanja i prezentiranja financijskih izvještaja prema Međunarodnim računovodstvenim standardima (MRS), te prema Međunarodnim standardima financijskog izvještavanja (MSFI). Pokazatelji za razvrstavanje poduzeća prema Zakonu o računovodstvu su prikazani u tablici 2.1.

Tablica 2.1. Pokazatelji za razvrstavanje poduzeća prema Zakonu o računovodstvu

	Mikro poduzetnici	Mali poduzetnici	Srednji poduzetnici	Veliki poduzetnici
Uvjet	Ne prelaze 2 od 3 navedena uvjeta	Prelaze 2 od 3 prethodna, a ne prelaze 2 od 3 navedena uvjeta:	Prelaze 2 od 3 prethodna, a ne prelaze 2 od 3 navedena uvjeta:	Prelaze 2 od 3 navedena uvjeta
Iznos aktive	2.600.000 kuna	30.000.000 kuna	150.000.000 kuna	150.000.000 kuna
Iznos prihoda	5.200.000 kuna	60.000.000 kuna	300.000.000 kuna	300.000.000 kuna
Prosječan broj zaposlenih tijekom godine	10	50	250	250

Izvor: Prilagođeno od: Narodne Novine (2016): Zakon o računovodstvu, Narodne novine d.d., broj 120, čl.5.

Cilj upotrebe računovodstvenih standarda je da se računovodstvo harmonizira ili ujednači u različitim zemljama, te da na taj način računovodstvene informacije postanu usporedive. To ujedno bi ujedno omogućava olakšanje investiranje u kompanije drugih država i smanjuje rizike takvih ulaganja.

Korisnici temeljnih financijskih izvještaja su vanjski (eksterni) korisnici i unutarnji (interni) korisnici. Kao vanjske korisnike možemo navesti: vlasnike (dioničari), investitore, kreditore, poslovne partnere, vladu i njezine agencije i tijela, revizore, javnost, znanstvenike. Unutrašnji korisnici informacija iz izvještaja su menadžeri, članovi uprave, članovi nadzornog odbora, zaposlenici.

Prema zakonu o računovodstvu temeljni financijski izvještaji moraju pružiti istinit, fer, pouzdan i nepristran pregled imovine. obveza. kapitala, promjene financijskog položaja i dobiti ili gubitka.[4] Fer prezentacija zahtjeva vjerno predočavanje učinaka transakcija i drugih događaja, a u skladu kriterijima priznavanja imovine, obveza, kapitala, prihoda i rashoda.[5] ZOR propisuje i izradu financijskih podataka za statističke i druge potrebe, te godišnjeg izvješća s izvješćem poslovodstva koje uključuje i izjavu o primjeni kodeksa korporativnog upravljanja, izvještaj o plaćanjima u javnom sektoru, te nefinancijsko izvješće.

[4] Narodne Novine d.d., (2015), Zakon o računovodstvu, broj NN 78/15., članak 19.

[5] Žager, K., Žager, L. (1999): Analiza financijskih izvještaja, Masmedia, Zagreb, str. 33.

Zakon o računovodstvu u Republici Hrvatskoj definira sljedeće temeljne financijske izvještaje:[6]

1. Bilanca,
2. Račun dobiti i gubitka,
3. Izvještaj o ostaloj sveobuhvatnoj dobiti,
4. Izvještaj o novčanim tokovima,
5. Izvještaj o promjenama kapitala,
6. Bilješke uz financijske izvještaje.

2.2.1. Bilanca

Bilanca je jedan od temeljnih financijskih izvještaja. Ona predstavlja sustavni pregled imovine, kapitala i obveza gospodarskog subjekta na određeni datum[7], najčešće na datum završetka fiskalne godine.
Bilanca obuhvaća sva sredstva i izvore koji se u toku poslovne aktivnosti mijenjaju i to kvalitativno i kvantitativno, kod čega knjigovodstvo bilježi i poslovne promjene, a bilanca je prikaz stanja rezultirajućih iz poslovnih promjena.[8]

Pojednostavljeni prikaz bilance prikazan je u tablici 2.2. te se iz nje vidi kako se bilanca sastoji od dva dijela, aktive i pasive. Aktiva prikazuje imovinu s kojom poduzeće raspolaže, dok pasiva prikazuje izvore imovine. Suma aktive uvijek mora biti jednaka sumi pasive. Aktivu bilance dijelimo na dvije osnovne skupine imovine: dugotrajnu (stalna imovina) i kratkotrajnu imovinu (tekuća ili obrtna imovina).

[6] Narodne Novine d.d., (2015), Zakon o računovodstvu, broj NN 78/15., članak 19.

[7] Vidučić, Lj. (2006): Financijski menadžment, RRIF-plus d.o.o. za nakladništvo i poslovne usluge, Zagreb, str. 366.

[8] Habek, M. (1984).: Računovodstvo, Narodne novine, Zagreb, str. 184.

Tablica 2.2. Prikaz skraćene bilance (na određeni datum)

AKTIVA	PASIVA
A. Potraživanja za upisani a neuplaćeni kapital	**A. Kapital i rezerve**
B. Dugotrajna imovina	I. Upisani kapital
I. Nematerijalna imovina	II. Premija na emitirane dionice
II. Materijalna imovina	III. Revalorizacijska rezerva
III. Financijska imovina	IV. Rezerve
IV. Potraživanja	V. Zadržani dobitak ili preneseni gubitak
C. Kratkotrajna imovina	VI. Dobitak ili gubitak tekuće godine
I. Zalihe	**B. Dugoročna rezerviranja**
II. Potraživanja	**C. Dugoročne rezerve**
III. Financijska imovina	**D. Kratkoročne obveze**
IV. Novac u banci i blagajni	**E. Odgođeno plaćanje troškova i prihod budućeg razdoblja**
D. Plaćeni troškovi budućeg razdoblja i nedospjela naplata prihoda	**F. Ukupno pasiva**
E. Gubitak iznad visine kapitala	G. **Izvanbilančni zapisi**
F. Ukupna aktiva	
G. **Izvanbilančni zapisi**	

Izvor: Vidučić Lj. (2006): Financijski menadžment, RRIF-plus d.o.o. za nakladništvo i poslovne usluge, Zagreb, str. 367.

Dugotrajna imovina je onaj dio ukupne imovine poduzeća koji duže ostaje vezan u postojećem obliku i koji se postepeno pretvara u novac u toku više obračunskih razdoblja tj. u razdoblju dužem od godine dana.[9]

Dugotrajna imovina može biti:

1. Materijalna (zemljišta, zgrade, postrojenja i oprema, alati, uredski inventar)
2. Nematerijalna (patenti, licencije, koncesije, goodwill, istraživanje i razvoj)
3. Financijska (dani krediti, depoziti i kaucije, vrijednosni papiri)
4. Potraživanja (prodaja na kredit, ostala potraživanja).

[9] Žager K., Žager, L. (2008): Analiza financijskih izvještaja, Masmedia, Zagreb, str. 57.

Kratkotrajna imovina je onaj dio ukupne imovine za koji se očekuje da će se pretvoriti u novčani oblik u razdoblju kraćem od jedne godine. Kratkotrajna imovina se sastoji od:[10]

1. Novac (u banci i u blagajni)

2. Potraživanja (od kupaca, od zaposlenih, ostala potraživanja)

3. Financijska imovina (dani kratkoročni krediti, kupljeni vrijednosni papiri, ostala kratkotrajna ulaganja)

4. Zalihe (sirovina i materijala, proizvodnje, gotovih proizvoda, trgovačke robe).

2.2.2. Račun dobiti i gubitka

Račun dobitka i gubitka je prikaz prihoda, rashoda i financijskog rezultata u određenom vremenskom razdoblju. Za razliku od bilance koja prikazuje stanje imovine i kapitala na određeni datum račun dobiti i gubitka prikazuje ostvareni poslovni rezultat kroz određeno razdoblje.

Na temelju usporedbe ostvarenih prihoda i rashoda dobiva se financijski rezultat poslovanja obračunskog razdoblja. Pozitivan financijski rezultat tj. dobit ostvaruje se kada su ukupni prihodi veći od ukupnih rashoda dok u obrnutom slučaju kad su ukupni rashodi veći od ukupnih prihoda ostvaruje se negativan financijski rezultat tj. gubitak. Pojednostavljeni prikaz računa dobiti i gubitka prikazan je u tablici 2.3.

Tablica 2.3. Pojednostavljen prikaz računa dobiti i gubitka

I. POSLOVNI PRIHODI
II. POSLOVNI RASHODI 1. Promjene vrijednosti zaliha proizvodnje u tijeku i gotovih proizvoda 2. Materijalni troškovi 3. Troškovi osoblja

[10] Žager, K., Žager, L. (2008): Analiza financijskih izvještaja, Masmedia, Zagreb, str. 56.

4. Amortizacija 5. Ostali troškovi 6. Vrijednosna usklađenja 7. Rezerviranja 8. Ostali poslovni rashodi
III. FINANCIJSKI PRIHODI
IV. FINANCIJSKI RASHODI
V. UDIO U DOBITI OD DRUŠTAVA POVEZANIH SUDJELUJUĆIM INTERESOM
VI. UDIO U DOBITI OD ZAJEDNIČKIH POTHVATA
VII. UDIO U GUBITKU OD DRUŠTAVA POVEZANIH SUDJELUJUĆIM INTERESOM
VIII. UDIO U GUBITKU OD ZAJEDNIČKIH POTHVATA
IX. UKUPNI PRIHODI
X. UKUPNI RASHODI
XI. DOBIT ILI GUBITAK PRIJE OPOREZIVANJA
XII. POREZ NA DOBIT
XIII. DOBIT ILI GUBITAK RAZDOBLJA

Izvor: Pojednostavljen i prilagođen prikaz računa dobiti i gubitka sa http://www.rrif.hr/

U 2009. godini dolazi do izmjena MRS-a 1 (prezentiranje financijskih izvještaja) u kojima se mijenjaju nazivi financijskih izvješća te se ujedno određuje da su obveznici primjene MRS i MSFI-a dužni uz račun dobiti i gubitka iskazivati i izvještaj o sveobuhvatnoj dobiti razdoblja kao jedinstven izvještaj ili kao dva odvojena izvještaja. Na subjektu je da odabere iskazivanje u jedinstvenom izvještaju o sveobuhvatnoj dobiti ili u dvama izvještajima, jedan kao zaseban račun dobiti i gubitka i drugi koji započinje dobiti ili gubitkom i prikazuje ostale stavke sveobuhvatne dobiti.

Elementi ostale sveobuhvatne dobiti su tečajne razlike iz preračuna inozemnog poslovanja, promjene revalorizacijskih rezervi dugotrajne materijalne i nematerijalne imovine, dobit ili gubitak s osnove ponovnog vrednovanja financijske imovine raspoložive za prodaju, dobit ili gubitak s osnove učinkovite zaštite novčanog toka, dobit ili gubitak s učinkovite zaštite neto ulaganja u inozemstvu, udio u ostaloj sveobuhvatnoj dobiti/gubitku pridruženih poduzetnika i aktuarski dobici/gubici po planovima definiranih primanja.

Tablica 2.4. Pojednostavljen i prilagođen prikaz sveobuhvatne dobiti

I. DOBIT ILI GUBITAK RAZDOBLJA
II. OSTALA SVEOBUHVATNA DOBIT/GUBITAK PRIJE POREZA (1. do 7.) 1. Tečajne razlike iz preračuna inozemnog poslovanja 2. Promjene revalorizacijskih rezervi dugotrajne materijalne i nematerijalne imovine 3. Dobit ili gubitak s osnove ponovnog vrednovanja financijske imovine raspoložive za prodaju 4. Dobit ili gubitak s osnove učinkovite zaštite novčanog toka 5. Dobit ili gubitak s osnove učinkovite zaštite neto ulaganja u inozemstvu 6. Udio u ostaloj sveobuhvatnoj dobiti/gubitku pridruženih poduzetnika 7. Aktuarski dobici/gubici po planovima definiranih primanja
III. POREZ NA OSTALU SVEOBUHVATNU DOBIT RAZDOBLJA
IV. NETO OSTALA SVEOBUHVATNA DOBIT ILI GUBITAK RAZDOBLJA (II. – III.)
V. SVEOBUHVATNA DOBIT ILI GUBITAK RAZDOBLJA (I. – IV.)

Izvor: Pojednostavljen i prilagođen prikaz sveobuhvatne dobiti preuzet sa http://www.rrif.hr/

2.2.3. Izvještaj o novčanim tokovima

Izvještaj o novčanim tokovima je jedan od temeljnih financijskih izvješća koji prikazuje priljeve i odljeve novca i novčanih ekvivalenata u određenom obračunskom razdoblju. Za razliku od bilance koja prikazuje stanje novca i novčanih ekvivalenata na određen datum izvještaj o novčanom toku je puno informativniji jer prikazuje dinamiku odnosno tok transakcija.

Obveznici izrade izvještaja o novčanim tokovima su veliki i srednji poduzetnici dok mali obveznici nemaju obvezu izrade istog.

Primici i izdaci novca razvrstavaju se u tri vrste aktivnosti[11]:

[11] Vidučić, Lj. (2006): Financijski menadžment, RRIF-plus d.o.o. za nakladništvo i poslovne usluge, Zagreb, str. 371.

- poslovne aktivnosti
- investicijske aktivnosti
- financijske aktivnosti.

Poslovne aktivnosti predstavljaju glavne aktivnosti subjekta koje su rezultat njegove glavne djelatnosti (proizvodnja, prodaja robe ili pružanje usluga) te ujedno predstavljaju i najznačajniji utjecaj na financijski rezultat poduzeća.
Prema MRS-u 7 (točka 14.) pod novčane tokove poslovnih aktivnosti spadaju:

- novčani primici od prodaje roba i pružanja usluga
- novčani primici od tantijema, naknada, provizija i drugih prihoda
- novčane isplate dobavljačima proizvoda i usluga
- novčane isplate zaposlenima i za račun zaposlenih
- novčani primici i novčane isplate od osiguravajućeg subjekta za premije i odštetne zahtjeve, anuitete i druge koristi od police osiguranja
- novčane isplate ili povrati poreza na dobit, osim ako se ne mogu posebno povezati s financijskim i investicijskim aktivnostima
- novčani primici i isplate temeljem ugovora koji služe za svrhe dilanja ili trgovanja.

Investicijske aktivnosti predstavljaju ulagačke aktivnosti stjecanja i otuđenja dugotrajne imovine i uloga. Prema MRS-u 7 primjeri investicijskih aktivnosti su:

- novčane isplate za stjecanje i novčani primici od prodaje nekretnina, postrojenja i opreme, nematerijalne imovine i druge dugotrajne imovine. Navedene isplate obuhvaćaju one koje se odnose na kapitalizaciju troškova razvoja i izgradnju nekretnina, postrojenja i opreme u vlastitoj izvedbi;
- novčani izdaci za stjecanje i novčani primici od prodaje glavničkih ili dužničkih instrumenata drugih subjekata i udjela u zajedničkim pothvatima (osim isplata temeljem instrumenata koji se smatraju novčanim ekvivalentima ili se drže za svrhe dilanja ili trgovanja);
- novčani predujmovi i zajmovi dani drugim osobama (osim predujmova i zajmova koje je dala financijska institucija);

- novčani primici od otplata predujmova i zajmova danih drugim osobama (osim predujmova i zajmova financijske institucije);
- novčane isplate i novčani primici temeljem ugovora za futures-e, forward-e, opcije i swapove, osim kada se ti ugovori drže za svrhe dilanja ili trgovanja, ili su plaćanja klasificirana kao financijske aktivnosti.

Financijske aktivnosti predstavljaju aktivnosti koje utječu na promijene u sastavu i veličini glavnice te zaduživanje subjekta.
Primjeri financijskih aktivnosti prema MRS 7 su:

- novčani primici od izdavanja dionica ili drugih glavničkih instrumenata
- novčane isplate vlasnicima za stjecanje ili iskup dionica subjekta
- novčani primici od izdavanja zadužnica, zajmova, pozajmica, obveznica, hipoteka i drugih kratkoročnih ili dugoročnih posudbi
- novčane otplate posuđenih iznosa
- novčane otplate najmoprimca za smanjenje nepodmirene obveze koja se odnosi na financijski najam.

2.2.4. Izvještaj o promjenama kapitala

Izvještaj o promjenama kapitala prikazuje sve promjene na kapitalu koje su se dogodile između dva datuma bilance.[12] Subjekt je dužan u izvještaju o promjenama glavnice iskazati:

1. Ukupnu sveobuhvatnu dobit razdoblja, iskazujući odvojeno ukupne iznose raspodjeljive vlasnicima matice i vlasnicima nekontrolirajućih interesa
2. Učinke retroaktivne primjene promjene računovodstvenih politika ili retroaktivnog prepravljanja iznosa priznatih u skladu s MRS-om 8 i
3. Uskladu između knjigovodstvenog iznosa svake komponente glavnice na početku i na kraju razdoblja uz odvojeno prikazivanje svake promjene proizašle iz:
a) dobiti ili gubitka
b) svake stavke ostale sveobuhvatne dobiti
c) transakcija s vlasnicima u njihovom svojstvu vlasnika, uz odvojen prikaz uplata

[12] Prema HSFI, točka 1.9

vlasnika i isplata vlasnicima po osnovi glavnice te promjena vlasničkih udjela u ovisnim društvima koje nemaju za posljedicu gubitak kontrole.

Izvještaj o promjena kapitala su obvezni sastavljati srednji i veliki poduzetnici. Nije propisan standardiziran obrazac za sastavljanje izvještaja o promjenama kapitala, ali se obveznici pri sastavljanju izvještaja moraju koristi odredbama Pravilnika o strukturi i sadržaju godišnjih financijskih izvještaja.

2.2.5. Bilješke uz financijska izvješća

Bilješke uz financijska izvješća predstavljaju detaljniju dopunu i razradu podataka iz bilance, računa dobiti i gubitka i izvješća o novčanim tokovima. Bilješke se svode na dvije osnovne grupe bilješki: one koje objašnjavaju računovodstvene politike koje su primijenjene u izradi izvješća te ostale podatke koji su važni za razumijevanje izvješća.[13]
Za bilješke nije propisana formalna struktura, već se poduzetnici pri sastavljanju koriste Pravilnikom o strukturi i sadržaju godišnjih financijskih izvještaja.

Prema MRS-u 1 bilješke se uobičajeno prezentiraju po sljedećem redoslijedu:

1. Izjava o sukladnosti s MSFI-ima
2. Sažetak primijenjenih važnih računovodstvenih politika
3. Informacije koje potkrepljuju stavke prikazane u izvještaju o financijskom položaju te izvještaju o sveobuhvatnoj dobiti, u odvojenom računu dobiti i gubitka (ako je prezentiran), izvještaju o promjenama kapitala i izvještaju o novčanim tokovima, po redoslijedu prema kojemu su ti izvještaji i stavke prikazani i
4. Druga objavljivanja, uključujući:
    a) nepredviđene obveze i nepriznate ugovorno preuzete obveze
    b) nefinancijske informacije, primjerice, ciljeve i politike subjekta koji se odnose na upravljanje financijskim rizikom.[14]

[13] Vidučić, Lj. (2006): Financijski menadžment, RRIF-plus d.o.o. za nakladništvo i poslovne usluge, Zagreb, str. 375.

[14] TEB-poslovno savjetovanje (2011): Međunarodni standardi financijskog izvještavanja, prijevod s engleskog jezika, Tiskara Zelina d.d., Zagreb, str. 28.

2.3.Financijski pokazatelji

Financijski pokazatelj predstavlja racionalan broj koji se dobije stavljanjem u odnos jedne ekonomske veličine s drugom ekonomskom veličinom na temelju informacija iz financijskih izvješća. Svrha financijskog pokazatelja je pružiti dodatnu informacije koja se koristi radi jednostavnijeg pregleda poslovanja poduzeća te pomoći kod donošenja određenih poslovnih odluka.

Ne postoji standardiziran popis financijskih pokazatelja, ali se ipak kao najčešća klasifikacija financijskih pokazatelja u literaturi navodi sljedeća[15]:

- Pokazatelji likvidnosti
- Pokazatelji zaduženosti (menadžmenta duga)
- Pokazatelji aktivnosti (menadžmenta imovine)
- Pokazatelji ekonomičnosti
- Pokazatelji profitabilnosti (rentabilnosti)
- Pokazatelji investiranja.

2.3.1. Pokazatelji likvidnosti

Pokazatelji likvidnosti se koriste za procjenu sposobnosti tvrtke da udovolji kratkoročnim obvezama kratkotrajnom imovinom tj. gotovinom ili imovinom koja se može na kratak rok konvertirati u gotovinu[16].

Najčešće korišteni pokazatelji likvidnosti su[17] :

[15] Žager, K., Sačer, I., Sever, S., Žager, L., (2008.), Analiza financijskih izvještaja, Masmedia, Zagreb, str. 243.

[16] Vidučić, Lj. (2006): Financijski menadžment, RRIF-plus d.o.o. za nakladništvo i poslovne usluge, Zagreb, str. 383.

[17] Žager, K., Sačer, I., Sever, S., Žager, L., (2008.), Analiza financijskih izvještaja, Masmedia, Zagreb, str. 248.

- Koeficijent (pokazatelj) tekuće likvidnosti
- Koeficijent (pokazatelj) ubrzane likvidnosti
- Koeficijent (pokazatelj) trenutne likvidnosti
- Koeficijent (pokazatelj) financijske stabilnosti.

Upravo ova kategorija financijskih pokazatelja koja prikazuje likvidnost poduzeća je vrlo interesantna za dobavljače proizvoda i usluga poduzeću te vjerovnicima koji odobravaju kratkoročne kredite

Koeficijent (pokazatelj) tekuće likvidnosti je pokazatelj koji u odnos dovodi pokriće i potrebe za kapitalom u roku od godine dana. Pokazatelj tekuće likvidnosti računa se po formuli:

$$koeficijent\ tekuće\ likvidnosti = \frac{kratkotrajna\ imovina}{kratkoročne\ \text{obveze}}$$

Kako bi se ocijenila vrijednost pokazatelja tekuće likvidnosti potrebno je izračunatu vrijednost pokazatelja usporediti s drugim poduzećima u istoj grani industrije. Velike vrijednosti pokazatelja mogu upućivati na slabo upravljanje kratkotrajnom imovinom dok niža vrijednost pokazatelja u odnosu na industrijski prosjek ukazuje na moguće probleme kod likvidnosti. Smatra se da pokazatelj tekuće likvidnosti ne bi trebao biti manji od 2,0 jer postoji mogućnost da poduzeće ostane bez sredstava za podmirenje kratkoročnih obveza. U literaturi se također kao granična vrijednost tekuće likvidnosti navodi i koeficijent 1,5 koji se može koristiti za usporedbu ukoliko nisu dostupni podaci o industrijskom prosjeku.

Koeficijent ubrzane likvidnosti pokazuje sposobnost plaćanja kratkoročnih obveza svojom najlikvidnijom imovinom. S obzirom da su zalihe najlikvidniji dio kratkotrajne imovine za izračun ovog pokazatelja potrebno je od kratkotrajne imovine oduzeti zalihe i podijeliti sa kratkoročnim obvezama.

Pokazatelj se izračunava prema formuli:

$$koeficijent\ ubrzane\ likvidnosti = \frac{tekuća\ imovina - zalihe}{kratkoročne\ obveze}$$

Kao poželjna vrijednost ovog pokazatelja se uzima 1,0 i više, ali postoje i izuzetci u određenim industrijama.

Koeficijent (pokazatelj) trenutne likvidnosti pokazuje kolika je pokrivenost kratkoročnih obveza likvidnom kratkotrajnom imovinom, odnosno novčanim sredstvima.

Pokazatelj trenutne likvidnosti se računa prema formuli:

$$koeficijent\ trenutne\ likvidnosti = \frac{novac}{kratkoročne\ obveze}$$

Koeficijent (pokazatelj) financijske stabilnosti stavlja u odnos dugotrajnu imovinu s kapitalom uvećanog za dugotrajne obveze;

$$koeficijent\ financijske\ stabilnosti = \frac{dugotrajna\ imovina}{kapital + dugoročne\ obveze}$$

Ovaj pokazatelje bi trebao biti manji od 1,0 jer se iz dijela dugoročnih izvora treba financirati ne samo dugotrajna već i kratkotrajna imovina. Smanjenje ovoga koeficijenta je pozitivna tendencija, jer ako dugotrajna imovina angažira likvidnu kratkoročnu imovinu može doći do smanjenja mogućnosti podmirenja tekućih obveza.

2.3.2. Pokazatelji zaduženosti

Pokazatelji zaduženosti prikazuju strukturu kapitala i načine na koje poduzeće financira svoju imovinu te koriste za procjenu financijskog rizika poduzeća.

Trgovačka društva sa vrlo visokim stupnjem zaduženosti gube financijsku fleksibilnost što može utjecati na poteškoće u pronalaženju novih investitora te povećani rizik od stečaja.

Ipak, Zaduženost nije nužno loša te može rezultirati porastom povrata na investirano ukoliko je stupanj zaduženosti pod kontrolom, a posuđena sredstva se koriste na pravi način.

Najčešće korišteni pokazatelji zaduženosti su[18]:

5. koeficijent zaduženosti
6. koeficijent vlastitog financiranja
7. odnos duga i glavnice (koeficijent financiranja)
8. stupanj pokrića I.
9. stupanj pokrića II.

Koeficijent (pokazatelj) zaduženosti pokazuje koliki udio imovine je nabavljen zaduživanjem. Računa se dijeljenim ukupnih obveza (dugoročni dug i kratkoročne obveze) s ukupnom imovinom.

$$pokazatelj\ zaduženosti = \frac{ukupni\ dug}{ukupna\ imovina}$$

Koeficijent (pokazatelj) vlastitog financiranja prikazuje koliko je imovine financirano iz vlastitog kapitala (glavnice) a izračun se radi prema sljedećoj formuli:

$$pokazatelj\ vlastitog\ financiranja = \frac{glavnica}{ukupna\ imovina}$$

Koeficijent financiranja tj. odnos duga i glavnice se računa prema sljedećoj formuli:

$$koeficijent\ financiranja = \frac{ukupne\ obveze}{glavnica}$$

Stupanj pokrića I. i II. prikazuju informaciju o pokriću dugotrajne imovine glavnicom (stupanj

pokrića I.), tj. glavnicom uvećanom za dugoročne obveze (stupanj pokrića II.).

$$Stupanj\ pokrića\ I. = \frac{glavnica}{dugotrajna\ imovina}$$

[18] Žager, K., Sačer, I., Sever, S., Žager, L., (2008.), Analiza financijskih izvještaja, Masmedia, Zagreb, str. 250.

$$Stupanj\ pokrića\ II. = \frac{glavnica + dugoročne\ obveze}{dugotrajna\ imovina}$$

2.3.3. Pokazatelji aktivnosti

Pokazatelji aktivnosti poznati još i pod nazivom koeficijenti obrta upućuju na brzinu cirkulacije imovine u poslovnom procesu, a računaju se na temelju odnosa prometa i prosječnog stanja. Najčešće korišteni pokazatelji aktivnosti su[19]:

1. koeficijent obrta ukupne imovine
2. koeficijent obrta kratkotrajne imovine
3. koeficijent obrta potraživanja
4. trajanje naplate potraživanja u danima

Izračun svih navedenih pokazatelja dobiva se na temelju podataka iz bilance i računa dobiti i gubitka. Kod prva tri navedena pokazatelja je općenito pravilo da je bolje kada je koeficijent obrta što veći broj, odnosno da je vrijeme vezivanja ukupne i pojedinih vrsta imovine što kraće.

Koeficijent (pokazatelj) obrta ukupne imovine stavlja u omjer ukupni prihod i ukupnu imovinu te na taj način prikazuje koliko se puta ukupna imovina obrne u tijeku jedne godine tj. prikazuje koliko uspješno tvrtka koristi imovinu s ciljem stvaranja prihoda.

$$koeficijent\ obrta\ ukupne\ imovine = \frac{ukupan\ prihod}{ukupna\ imovina}$$

Koeficijent (pokazatelj) obrta kratkotrajne imovine prikazuje koliko puta se kratkotrajna imovina tvrtke obrne u tijeku jedne godine,

$$koeficijent\ obrta\ kratkotrajne\ imovine = \frac{ukupan\ prihod}{kratkotrajna\ imovina}$$

[19] Žager, K., Sačer, I., Sever, S., Žager, L., (2008.), Analiza financijskih izvještaja, Masmedia, Zagreb, str. 252

Koeficijent (pokazatelj) obrta potraživanja stavlja u omjer prihod od prodaje i stanje na kontu potraživanja te na taj način prikazuje koliko se novčanih jedinica podaje može ostvariti s jednom kunom uloženom u potraživanja.

$$koeficijent\ obrta\ potraživanja = \frac{prodaja}{potraživanja}$$

Ovaj pokazatelj se ujedno koristi i za dobivanje pokazatelja **trajanja naplate potraživanja u danima** za kojeg formula za izračun glasi:

$$trajanje\ naplate\ potraživanja\ u\ danima = \frac{broj\ dana\ u\ godini\ (365)}{koeficijent\ pbrtaja\ potraživanja}$$

2.3.4. Pokazatelji ekonomičnosti

Pokazateljima ekonomičnosti se utvrđuje stupanj ostvarenih prihoda društva po jedinici rashoda tj. koliko se prihoda ostvari po jedinici rashoda. Utvrđuje se ekonomičnost ukupnog poslovanja ili pojedine skupine prihoda i rashoda. Za uspješno poslovanje vrijednost pokazatelja mora biti veća od 1,0. Pokazatelji ekonomičnosti izračunavaju se na temelju računa dobiti i gubitka.

U literaturi se najčešće navode sljedeći pokazatelji ekonomičnosti[20]:

- ekonomičnost ukupnog poslovanja
- ekonomičnost poslovanja (prodaje)
- ekonomičnost financiranja
- ekonomičnost izvanrednih aktivnosti.

Ekonomičnost ukupnog poslovanja je pokazatelj koji stavlja u odnos ukupne prihode i ukupne rashode. Kako bi tvrtka poslovala ekonomično potrebno je da ostvaruje više prihoda nego je utrošeno za njihovo postizanje.

$$ekonomičnost\ ukupnog\ poslovanja = \frac{ukupni\ prihodi}{ukupni\ rashodi}$$

Ekonomičnost poslovanja (prodaje) stavlja u odnos prihode od prodaje i rashode prodaje. Ukoliko su prihodi od prodaje veći od rashoda prodaje ekonomičnost poslovanja je pozitivna.

[20] Žager, K., Sačer, I., Sever, S., Žager, L., (2008.), Analiza financijskih izvještaja, Masmedia, Zagreb, str. 252.

$$ekonomičnost\ poslovanja\ (prodaje) = \frac{prihodi\ od\ prodaje}{rashodi\ prodaje}$$

Ekonomičnost financiranja je omjer financijskog prihoda i financijskog rashoda.

$$ekonomičnost\ financiranja = \frac{financijski\ prihodi}{financijski\ rashod}$$

Ekonomičnost izvanrednih aktivnosti stavlja u odnos izvanredne prihode s izvanrednim rashodima.

$$ekonomičnost\ izvanrednih\ aktivnosti = \frac{izvanredni\ prihodi}{izvanredni\ rashodi\ rashodi}$$

2.3.5. Pokazatelji profitabilnosti

Pokazatelji profitabilnosti izražavaju snagu zarade tvrtke, odnosno pokazuju ukupni efekt likvidnosti, upravljanja imovinom i dugom na mogućnost ostvarenja profita[21]. Svrstava se u najvažnije dijelove financijske analize.

Najčešće korišteni pokazatelji profitabilnosti su:[22]

1. neto marža profita
2. bruto marža profita
3. neto rentabilnost imovine
4. stopa povrata imovine (ROA – return on assets)
5. stopa povrata glavnice (ROE – return on equity).

Neto profitna marža se koristi kao pokazatelj efikasnosti menadžmenta jer pokazuje kako menadžment kontrolira troškove, rashode i prihode. Neto profitna marža se izračunava kao omjer neto dobiti umanjenog za eventualne dividende na prioritetne dionice i ukupnog prihoda od prodaje.

[21] Vidučić, Lj. (2006): Financijski menadžment, RRIF-plus d.o.o. za nakladništvo i poslovne usluge, Zagreb, str. 383.

[22] Žager, K., Sačer, I., Sever, S., Žager, L., (2008.), Analiza financijskih izvještaja, Masmedia, Zagreb, str. 253.

$$neto\ profitna\ marža = \frac{neto\ dobitak - dividende\ prioritetnim\ dioničarima}{prihod\ od\ prodaje}$$

Bruto profitna marža stavlja u omjer prihod od prodaje umanjenih za trošak prodane robe i prihode od prodaje. Pokazatelj odražava politiku cijena koju tvrtka provodi.

$$bruto\ profitna\ marža = \frac{prodaja - troškovi\ za\ prodano}{prihod\ od\ prodaje}$$

Neto rentabilnost imovine je pokazatelj kojim se mjeri profitabilnost zbrajanjem neto dobiti i kamata u odnos s ukupnom imovinom. Veći pokazatelj ukazuje na veću profitabilnost.

$$neto\ rentabilnost\ imovine = \frac{neto\ dobit + kamate}{ukupna\ imovina}$$

Stopa povrata imovine (ROA – return on assets) je pokazatelj sposobnosti tvrtke da korištenjem raspoložive imovine ostvari dobit. Vrijednost stope povrata imovine uvelike varira ovisno o industriji ili djelatnosti poduzeće zbog toga što ne zahtijevaju sve djelatnosti podjednaku visinu kapitala (npr. proizvodnja sa skupom opremom koja zahtjeva značajan kapital ili uslužne djelatnosti koje ne zahtijevaju značajan kapital). Izračun stope povrata imovine se vrši pomoću sljedeće formule:

$$stopa\ povrata\ imovine\ (ROA) = \frac{neto\ dobitak - dividende\ prioritetnim\ dioničarima}{ukupna\ imovina}$$

Stopa povrata glavnice (ROE – return on equity) je pokazatelj snage zarade u odnosu na ulaganje dioničara. Pokazuje koliko novčanih jedinica dobiti poduzeće ostvaruje na jednu jedinicu vlastitog kapitala.

$$stopa\ povrata\ imovine\ (ROE) = \frac{neto\ dobitak\ nakon\ prioritetnih\ dividindi}{glavnica\ (vlastiti\ kapital)}$$

2.3.6. **Pokazatelji investiranja**

Pokazatelji investiranja se koriste za mjerenje uspješnosti ulaganja u redovne (obične) dionice poduzeća. Za izračunavanje ovih pokazatelja, osim podataka iz financijskih izvještaja, potrebni su i podaci o dionicama, posebice o broju i tržišnoj vrijednosti dionica.

Najčešće se koriste sljedeći pokazatelji investiranja[23]:

1. Dobit po dionici (EPS)
2. Dividenda po dionici (DPS)
3. Odnos isplate dividendi (DPR)
4. Odnos cijene i dobiti po dionici (P/E ratio)
5. Dividendna rentabilnost dionice.

Dobit po dionici (EPS – earnings per share) prikazuje odnos neto dobiti i broj dionica, odnosno izražava iznos (u novčanim jedinicama) dobiti ostvarene po jednoj dionici.

$$dobit\ po\ dionici = \frac{neto\ dobit}{broj\ dionica}$$

Dividenda po dionici (DPS - dividends per share) prikazuje iznos dividende koju će dioničar dobiti za svaku dionici koju posjeduje.

$$dobit\ po\ dividendi = \frac{dio\ neto\ dobiti\ za\ dividende}{broj\ dionica}$$

Odnos isplate dividendi (DPR- dividend payout ratio) stavlja u odnos dividende po dionici i dobit po dionici. S obzirom da se dio dobiti zadržava ovaj pokazatelj je u pravilu manji od 1,0.

$$odnos\ isplate\ dividiendi = \frac{dividende\ po\ dionci}{dobit\ po\ dionci}$$

Odnos cijene i dobiti po dionici (P/E ratio – price earnings ratio) je jedan od najznačajnijih pokazatelja investiranja. Ovim pokazateljem se stavlja u omjer dobit po dionici i tržišna

[23] Žager, K., Sačer, I., Sever, S., Žager, L., (2008.), Analiza financijskih izvještaja, Masmedia, Zagreb, str. 254.

cijenu dionice s tim da je potrebno naglasiti kako vlastiti kapital nije iskazan po knjigovodstvenoj, već po tržišnoj vrijednosti.

$$Pokazatelj\ cijena/zarada = \frac{tržišna\ cijna\ dionice}{neto\ dobitak\ nakon\ prior.divid.po\ običnoj\ dionici}$$

Dividendna rentabilnost dionice tj. prinos po dionici se izračunava kao omjer dividende po dionici i tržišne cijene dionice.

$$dividendna\ rentabilnost\ dionice = \frac{dividenda\ po\ dionici}{tržišna\ vrijednost\ dionice}$$

3. MODELI ZA PREDVIĐANJE POSLOVNOG NEUSPJEHA

Početkom dvadesetog stoljeća počinju se koristiti financijski pokazatelji kao instrument procjene kreditne sposobnosti, te je već u 1930-im godinama primijećeno kako se vrijednosti financijskih pokazatelja uspješnih poduzeća i onih kojima prijeti stečaj bitno razlikuju. Na temelju dostupnih financijskih informacija znanstvenici su korištenjem raznih statističkih i matematičkih metoda pokušali predvidjeti prijeti li poduzeću stečaj. Prva takva istraživanja su počela u šezdesetim godinama 20. stoljeća. U početnim istraživanjima je u svrhu predviđanja stečaja korištena metoda diskriminantne analize, ali je uskoro nastao i interes za implementiranjem modela linearne vjerojatnosti i logit analize. S vremenom su se ta istraživanja razvijala te su korištene različite metode koje se rezultirale sa popriličnom preciznošću u predviđanju poslovnog neuspjeha.

U nastavku će biti opisani neki od značajnijih modela koje nailazimo u literaturi te su ujedno i zastupljeniji u upotrebi i istraživanjima kod procjene predviđanja poslovnog neuspjeha.

3.1 Altmanovi modeli

Jednim od najznačajnijih modela za predviđanje stečaja smatra se model Edward I. Altmana koji je 1968. godine postavio model za predviđanje stečaja proizvodnih poduzeća u Americi. Model je definirao korištenjem statističke metode višestruke diskriminacijske analize. Nakon toga istraživanja dolazi do općeg saznanja kako su evaluacija i korištenje financijskih pokazatelja ključna komponenta u predviđanju poslovnog neuspjeha.

Analiza je provedena na uzorku od 66 proizvodnih poduzeća od kojih su 33 financijski zdrava, te 33 poduzeća koja su pokrenula stečajni postupak u razdoblju od 1946.do 1965. godine. Financijske informacije prikupljene su iz bilance i računa dobiti i gubitka poduzeća. Poduzeća su uparena prema vrsti industrije i veličini imovine kao kod Beavera. Ukupna točnost predviđanja Altmanova modela je iznosila 95% za jednu godinu prije stečaja, 83% za dvije godine prije stečaja, 48% za tri godine prije stečaja, 29% za četiri godine prije stečaja, te 36% za pet godina prije stečaja.

Na temelju tih financijskih izvještaja izračunata su 22 financijska pokazatelja. Pokazatelji su birani prema učestalosti ponavljanja u literaturi i potencijalnoj relevantnosti vezane sa temom studije, te je izračunato nekoliko novih pokazatelja. Altman je financijske pokazatelje grupirao u 5 skupina i to pokazatelje likvidnosti, profitabilnosti, zaduženosti, solventnosti i aktivnosti (Zenzerović i Peruško, 2006). Model koji je Altman razvio poznat je pod nazivom Z-score te se iskazuje slijedećom jednadžbom:

$$\boldsymbol{Z = 0,012\,X_1 + 0,014\,X_2 + 0,033\,X_3 + 0,006\,X_4 + 0,999\,X_5}$$

Gdje je:

X1 = radni kapital / ukupna aktiva

X2 = zadržana dobit / ukupna aktiva

X3 = operativna dobit (EBIT) / ukupna aktiva

X4 = tržišna vrijednost glavnice / ukupne obveze

X5 = prihod od prodaje / ukupna aktiva

Altman je utvrdio kritične vrijednosti diskriminantne funkcije na način da vrijednost Z-scora niža od 1,81 ukazuje na veliku opasnost od pokretanja stečajnog postupka. Druga kritična vrijednost je 2,99 koja označava stabilno financijsko poduzeće dok sve vrijednosti unutar intervala 1,88 – 2,99 predstavljaju „sivu zonu“ što znači da je njihova financijska stabilnost ugrožena, ali postoji potencijal ozdravljenja.[24]

S obzirom da su za izvorni model korištene financijske informacije proizvodnih poduzeća čije su vrijednosnice izlistane na burzi, Altman je 1983. izvršio korekcije modela kako bi ga prilagodio poduzećima čije dionice ne kotiraju na burzi te su u vlasništvu manjeg broja osoba. U revidiranom modelu je kod brojnika varijable X4 došlo do zamjene tržišne vrijednosti glavnice njezinom knjigovodstvenom vrijednošću, te su ujedno prilagođeni i parametri svih varijabli kao što sljedeća formula prikazuje:

$$\boldsymbol{Z' = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,42X_4 + 0,998X_5}$$

U ovom slučaju kritične vrijednosti za razgraničavanje poduzeća s financijskim poteškoćama i uspješnim poduzećima su 1,23 i 2,90**.**

[24] Zenzerović R., Peruško, T. (2006): Kratki osvrt na modele za predviđanje stečaja, Ekonomska istraživanja, str. 142.

Nakon što je originalni Altman Z-score model proširen Altman je nastavio istraživanje i 1993. godine proizveo još jedan revidirani model koji se koristio za predviđanje korporativnog neuspjeha. Ovaj model je prilagođen predviđanju stečaja neproizvodnih poduzeća i glasi:

$$Z'' = 6,56X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4$$

Može se primijetiti kako je varijabla X_5 uklonjena iz modela. Kod ovog modela kritične vrijednosti za raspoznavanje poduzeća u stečaju i uspješnih poduzeća su 1,10 i 2,60.

Pojednostavljen prikaz Altmanovih Z score modela sa kritičnim vrijednostima prikazan je u tablici 3.1.

Tablica 3.1. pojednostavljen prikaz Altmanovih modela

Godina	Model	Kritične vrijednosti
1968. godine Z score	*Z = 0,012 X1 + 0,014 X2 + 0,033 X3 + 0,006 X4 + 0,999 X5*	Z<1.81 stečaj Z>2.99 uspješna Z=1.81 do 2.99 siva zona
1983.godine Z' score	Z'= 0,717X1 + 0,847X2 + 3,107X3 + 0,42X4 + 0,998X5	Z<1.23 stečaj Z>2.90 uspješna Z=1.23 do 2.90 siva zona
1993. godine Z"score	6,56X1 + 3,26X2 + 6,72X3 + 1,05X4	Z<1.10 stečaj Z>2.60 uspješna Z=1.10 do 2.60 siva zona

Izvor: izdrada autora

Značajan broj istraživanja je dokazao uspješnost Altmanovog Z score modela u predviđanju poslovnog neuspjeha, ali ipak postoje i mnoge kritike autora vezane za generaliziranje podataka jer model prikazuje slabe rezultate kod klasificiranja poduzeća izvan Amerike te u ostalim razvijenim zemljama (u različitom ekonomskom i političkom okružju).

3.2. Kralicekovi modeli

Peter Kralicek je provodeći multivarijantnu analizu 2007. godine izveo model za predviđanje financijske nestabilnosti. Koristio je podatke njemačkih, švicarskih i austrijskih poslovnih subjekata te je model prilagođen europskom okruženju.

Formula za DF model glasi :

$$\boldsymbol{DF = 1,5\,X_1 + 0,08\,X_2 + 10\,X_3 + 5\,X_4 + 0,3\,X_5 + 0,1\,X_6}$$

Gdje su varijable:

$$X1 = \frac{čisti\ novčani\ tok}{ukupne\ obveze}$$

$$X2 = \frac{ukupna\ imovina}{ukupne\ obveze}$$

$$X3 = \frac{dobit\ prije\ kamata\ i\ poreza(EBIT)}{ukupna\ imovina}$$

$$X4 = \frac{dobit\ prije\ kamata\ i\ poreza(EBIT)}{ukupni\ prihodi}$$

$$X5 = \frac{zalihe}{ukupni\ prihodi}$$

$$X6 = \frac{poslovni\ prihodi}{ukupna\ imovina}$$

Vrijednost diskriminantne funkcije(DF) Kralicekovog modela može poprimiti negativne ili pozitivne vrijednosti pri čemu negativne vrijednosti ukazuju na insolventnost prema predefiniranim stupnjevima insolventnosti dok pozitivne vrijednosti ukazuju na solventnost subjekt. Ocjene financijske stabilnosti prema vrijednosti DF pokazatelja prikazane su u sljedećoj tablici:

Tablica 3.2. Prikaz vrijednosti pokazatelja i stupanj financijske stabilnosti

VRIJEDNOST DF POKAZATELJA	FINANCIJSKA STABILNOST
>3,0	Izvrsna
>2,2	Vrlo dobra
>1,5	Dobra
>1,0	Osrednja
>0,3	Loša
<=0,3	Početak insolventnosti
<=0,0	Umjerena insolventnost
<=-1,0	Izrazita insolventnost

Izvor: prilagođeno od Koban (1978) u Zenzerović i Peruško (2006): Kratki osvrt za predviđanje stečaja, Ekonomska istraživanja, 19. str 132. -151.

3.3. Springate model

1978. godine Gordon. L.V Springate je po uzoru na Altmanov model razvio model za predviđanje poslovnog neuspjeha prilagođen kanadskim tržišnim uvjetima. Pri izradi modela korištena je multi diskrimintna analiza (MDA) na uzorku od 40 poduzeća. Naknadno je odabrano 19 financijskih pokazatelja te su temelju njih određene četiri varijable pomoću koji se radi izračun za razlikovanje uspješnih poduzeća od onih kojima prijeti stečaj.

Springate model glasi:

$$\boldsymbol{Springate\ score = 1,03X_1 + 3,07X_2 + 0,66X_3 + 0,4X_4}$$

Varijable u modelu su:

$$X_1 = \frac{obrtni\ kapital}{ukupna\ imovina}$$

$$X_2 = \frac{dobit\ prije\ kamata\ i\ poreza}{ukupna\ imovina}$$

$$X_3 = \frac{dobit\ prije\ poreza}{kratkoročne\ obveze}$$

$$X_4 = \frac{prihodi\ od\ prodaje}{ukupna\ imovina}$$

Ako je vrijednost manja od 0,862 to znači da postoji velika mogućnost financijskog neuspjeha tj. stečaja poduzeća.

3.4. Zmijewski model

1984. godine razvijen je Zmijewski model za predviđanje stečaja unutar dvije godine. Pri izradi modela korištena je probit analiza na uzorku od 840 poduzeća od koji je 800 predstavljalo financijski stabilna poduzeća, a 40 ih je bilo u stečaju.

Osnovna jednadžba modela glasi:

$$\boldsymbol{Y = -4{,}3 - 4{,}5\,X_1 + 5{,}7\,X_2 - 0{,}004\,X_3}$$

gdje su varijable sljedeće:

$$X_1 = \frac{neto\ dobit}{ukupna\ imovina}$$

$$X_2 = \frac{ukupni\ dug}{ukupna\ imovina}$$

$$X_2 = \frac{kratkotrajna\ imovina}{kratkoročne\ obveze}$$

Odluka se donosi izračunavanjem vjerojatnosti za postizanje statusa neispunjavanja obveza na sljedeći način:

$$P = \frac{1}{1 + e^{-y}}$$

Ako je dobivena vjerojatnost veća od 0,5, tada poduzeće ima velike šanse za stečaj.

3.5. Ohlson model

1980. godine James Ohlson je predstavio model za predviđanje stečaja dobiven korištenjem statističke metode logističke regresije. Istraživanje je provedeno na uzorku od 2163 poduzeća i to na financijskim izvještajima prikupljenim za razdoblje od 1970. do 1976. godine, U ukupnom uzorku je bilo 2058 uspješnih poduzeća dok je 105 poduzeća imalo poteškoća u poslovanju ili im je prijetio stečaj.

James Ohlson je uočio da četiri varijable statistički značajno utječu na vjerojatnost stečaja. To su veličina poduzeća, pokazatelj zaduženosti, pokazatelj uspješnosti poslovanja i pokazatelj tekuće likvidnosti.[25].

Kako bi izbjegao neke od problema multivarijantne diskriminacijske analize (pretpostavke vrijednosti kovarijance i kovarijanci, interpretacija, itd.) korištene u dotadašnjim istraživanjima Ohlson je odlučio upotrijebiti metodu logističke regresije. Upotrebom modela logističke regresije osmislio je tri različita modela:

1. prvi model predviđa bankrot unutar jedne godine,
2. drugi model predviđa bankrot unutar dvije godine pod uvjetom da poduzeće nije bankrotiralo u sljedećoj godini
3. treći model koji predviđa bankrot unutar dvije godine.

S obzirom na točnost predviđanja koja kod prvog modela iznosi 96,12%, drugog modela 95,5%, te trećeg modela 92,84% može se zaključiti da je preciznost ovog modela zadovoljavajuća.

Ohlsonovi modeli glase:

Model 1 – predviđanje bankrota unutar jedne godine:

-1.32 - 0.407X1 + 6.03X2 - 1.43X3 + 0.08X4 - 1.72X5 - 2.71X6 - 1.83X7 + 0.285X8 - 0.52X9

[25] Ohlson, R. (1980): Financial Ratios and the Probabilistic Predicition of Bankruptcy, Journal of Accounting Reaserch,Spring, Vol. 18., No. 1., str. 110.

Model 2 - predviđa bankrot unutar dvije godine pod uvjetom da poduzeće nije bankrotiralo u sljedećoj godini:

1.84 - 0.519X1 + 4.76X2 - 1.71X3 - 0.3X4 - 1.98X5 - 2.74X6 - 2.18X7 - 0.780X8 + 0.42X9

Model 3 predviđanje bankrot unutar dvije godine:

1.13 - 0.478 X1 + 5.29 X2 - 0.990 X3 + 0.07 X4 - 1.71 X5 - 4.62 X6 - 2.25 X7 - 0.521X8 + 0.21 X9

Objašnjenje oznaka:

X**1** – veličina poduzeća mjerena logaritmom odnosa ukupne imovine i indeksa BDP-a

X**2** – omjer ukupnih obveza i ukupne imovine

X**3** – omjer radnog kapitala i ukupne imovine

X**4** – omjer kratkoročnih obveza i kratkotrajne imovine

X**5** – vrijednost 1 ako su ukupne obveze veće od ukupne imovine, u protivnom 0

X**6** – omjer neto dobiti i ukupne imovine

X**7** – omjer novca od poslovnih aktivnosti i ukupnih obveza

X**8** – vrijednost 1 ako je neto dobit negativna u posljednje dvije godine, u protivnom 0

$$X_9 = \frac{NI_t - Ni_{t_{-1}}}{|NI_t| - |Ni_{t_{-1}}|}$$

* NIt je neto dobit u posljednjem razdoblju.

3.6. Ostali modeli

Uz prethodno navedene modele koji su detaljno opisani u ovom radu postojao je i niz drugih istraživanja koja su vršena tijekom vremena uz primjene različitih metoda kako bi se definirao što precizniji model za predviđanje poslovnog neuspjeha.

Svakako treba navesti rad **William H. Beavera** koji je 1966. godine uporabom univarijantne analize izveo zaključak se poslovni neuspjeh može predvidjeti omjerom novčanog toka i ukupnog duga[26]. To je predstavljalo prvi značajni model za predviđanje poslovnog neuspjeha tj. stečaja. Uzorak se sastojao od 158 poduzeća iz različitih industrija te je obuhvaćao

[26] Beaver, W. (1967.) Financial Ratios as Predictor of Failure, Empirical Research in Accounting, Empirical Studies, Journal of Accounting Research, Br. 4, str. 71-111.

podjednak omjer uspješnih poduzeća i onih koja su ušla u stečajni postupak. U svom radu je također sugerirao korištenje diskriminantne analize u daljnjim istraživanjima.

1972. godine **Edward B. Deakin** je predložio alternativni model za predviđanje bankrota. U svom radu je kombinirao studije Beavera i Altmana kako bi došao do modela sa većom točnošću predviđanja bankrota[27]. Uzorak se sastojao od ukupno 64 poduzeća te podjednakim omjerom uspješnih poduzeća i onih koja su ušla u stečajni postupak u razdoblju od 1964. do 1970. godine. U svom istraživanju koristio je 14 financijskih pokazatelja koje je koristio Beaver. Uz upotrebu diskriminacijske analize pokušao je smanjiti broj varijabli, ali je zaključio kako tada značajno opada i točnost predviđanja bankrota[28]. Iz toga proizlazi zaključak da se relativni značaj varijabli tijekom promatranog perioda od 5 godina tijekom vremena mijenja, ali i da sve varijable značajno utječu na diskriminacijsku sposobnost funkcije.

Robert Edminster je bio među prvima koji je započeo istraživanje na predviđanju poslovnog neuspjeha kod malih poslovnih subjekata. U to vrijeme bilo je puno teže doći do podataka malih poduzeća nego velikih poduzeća sa javno dostupnim dionicama. Za potrebe istraživanja Edminster je prikupio podatke od Agencije za mala poduzeća (Small Business Administration) i tvrtke Robert Morris Associates. U istraživanju se koristilo 19 najčešćih financijskih pokazatelja koji su se koristili u to vrijeme. Uzorak je obuhvaćao 562 poslovna subjekta za razdoblje od 1958. do 1965. godine[29]. Edminster je koristio multivarijantnu diskriminacijsku analizu te trogodišnji prosjek i trogodišnji trend pokazatelja u svom istraživanju. Model za predviđanja neuspjeha koji je objavio u svom radu 1972. godine uključivao je 7 varijabli te rezultirao sa ukupnom točnošću predviđanja od 93%.

U nastojanju da se dođe do što preciznijeg modela za predviđanje poslovnog neuspjeha tijekom vremena su korištene su i razne druge statističke metode koje su rezultirale sa različitom preciznošću predviđanja. Rezultati empiričkih istraživanja su se također razlikovali kod provođenja na različitim uzorcima po granama industrije, veličinama poslovnih subjekata

[27] Deakin, E. (1972): A discriminant analysis of predictors of business failure, Journal of accounting research, str. 167.

[28] ibidem, str. 173.

[29] Edminster, R.O., (1972), Can Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction", Journal of Financial and Quantitative Analysis, March, str. 1485.

i različitim gospodarstvima te je s obzirom na važnost informacije o procjeni boniteta poduzeća ova tema je još uvijek vrlo aktualna.

3.7. Modeli iz Hrvatske

3.7.1. FP Rating

U 2010. godini Pervan i Filipović objavljuju FP RATING® model kojemu je cilj procijeniti vjerojatnosti blokade žiro-računa poslovnog subjekta tj. insolventnosti trgovačkog društva. Kao uzorak su se koristila trgovačka društava koja su kreditno zadužena u poslovnoj banci X d.d te je uz podatke iz financijskih izvješća korišten i podatak o broju dana blokade žiro računa (nastalih zbog nepodmirivanja obveza po glavnici. Inicijalni uzorak sastojao se od 3.629 malih, srednjih i velikih trgovačkih društava. Društva su naknadno grupirana u 'solventne kijamete' i 'insolventne klijente', a kriterij za grupiranje je bila granica od 90 dana neplaćanja dospjelih obveza po kreditima.
U konačnoj obradi uzorak se sveo na mala i srednje velika trgovačka društva, od kojih su 447 imala sve podatke potrebne za izračun financijskih pokazatelja dok su velika trgovačka društva eliminirana iz analize jer se pokazalo da su greške modela u tom slučaju previsoke. Od ukupno 447 trgovačkih društava 53 su bila insolventna dok su 394 društva bila solventna.
Pri oblikovanju modela koristila se statistička metoda diskriminantne analize kojom su utvrđene najutjecajnije varijable na klasifikaciju poduzeća u solventne i insolventne. Jednadžba modela glasi[30]:

FP RATING® = -1,0937 + 2,0956X1 – 0,005X2 + 0,6220X3 – 0,000005X4 + 0,1116X5

Objašnjenje oznaka:

$$X_1 = \frac{ukupan\ kapital}{ukupna\ imovina}$$

[30] Pervan, I., Filipović D. (2010): FP rating – model za predviđanje (in) solventnosti poslovnih partnera, RRiF br.7, str. 94.

$$X_2 = \frac{ukupne\ dugoročne\ obveze + ukupne\ kratkoročne\ obveze}{\frac{neto\ dobitak}{gubitak\ tekuće\ godine} + \frac{zadržani\ dobitak}{preneseni\ gubitak} + amortizacija}$$

$$X_3 = \frac{ukupni\ prihod}{ukupna\ imovina}$$

$$X_4 = \frac{365}{koeficijent\ obrtaja\ kratkoročnih\ potraživanja}$$

$$X_5 = \frac{EBITDA - \Delta obrtni\ kapital}{ukupan\ prihod}$$

FP RATING® model je u kategoriju solventnih klijenata klasificirao 327, dok je stvarni broj solventnih klijenata iznosio 394 (točnost modela u predviđanju solventnih klijenata iznosi 83%). U kategoriju insolventnih klijenata je klasificirao 37 klijenata, dok je stvarni broj insolventnih klijenata iznosio 53(točnost klasifikacije od 69,8%).[31]

3.7.2. Pervan i Kuvek model

Pervan i Kuvek su po prvi puta na uzorku hrvatskih poduzeća uz financijske varijable koristili i nefinancijske varijable. Kvaliteta financijskih izvještaja, kreditni bonitet vlasnika i kvaliteta uprave su uvrštene u model kao nefinancijske varijable koje imaju značajan utjecaj u predviđanju poslovne neuspješnosti. Istraživanje je vršeno na uzorku od 825 trgovačkih društava od kojih je 698 predstavljalo uspješna poduzeća dok je 127 imalo poteškoće u poslovanju ili im je prijetio stečaj[32]. Autori su odlučili koristiti logističku regresiju zbog određenih prednosti u odnosu na multi diskriminantnu analizu (koja zahtjeva striktne pretpostavke poput jednakosti matrica varijanci i kovarijanci za obje skupine poduzeća).
Kako bi se dokazala informacijska vrijednost i utjecaj nefinancijskih varijabli prvo je izračunat model samo sa financijskim vrijednostima, te je naknadno uspoređen sa drugim modelom koji je sadržavao financijske i nefinancijske varijable.
U prvom modelu korištene su sljedeće financijske varijable:

[31] Pervan, I., Filipović D. (2010): FP rating – model za predviđanje (in) solventnosti poslovnih partnera, RRiF br.7, str. 95.

[32] Pervan, I. i Kuvek, T. (2013.) The relative importance of fi nancial ratios and nonfi nancial variables in predicting of insolvency, Croatian Operational Research Review, Br. 13, Sv. 4, str. 187-197.

$$X_1 = (\frac{D}{A}) = \frac{dug\ (debt)}{ukupna\ imovina\ (assets)}$$

$$X_2 = (E/FA) = \frac{vlastiti\ kapital\ (equity)}{stalna\ imovina\ (fixed\ assets)}$$

$$X_3 = (\frac{CFO}{A}) = \frac{operativni\ novčani\ tok\ (operatin\ cash\ flow)}{ukupna\ imovina\ (assets)}$$

$$X_4 = (\frac{NI}{A}) = \frac{neto\ dobit\ (net\ income)}{ukupna\ imovina\ (assets)}$$

Model sa financijskim varijablama je rezultirao sa 88.4% (617 od 698) točnošću klasifikacije kod zdravih trgovačkih društava dok je za predviđanje neuspješnih trgovačkih društava točnost bila 52% (66 od 127). U drugom modelu su uz prethodno navedene financijske varijable dodane sljedeće nefinancijske varijable:

X5 = ACCQ tj. kvaliteta financijskih izvještaja; eng.quality of accounting information
X6 = MANQ) tj. kvaliteta uprave; eng. management quality
X7 = OFIN tj. kreditni bonitet vlasnika; eng. owners personal credit performance

U tablici 3.3 prikazan je pregled financijskih i nefinancijskih varijabli u Pervan Kuvek modelu

Tablica 3.3 Prikaz varijabli u Pervan Kuvek modelu

Variable	B	S.E.	Wald	df	Sig.
D/A	0.023	0.007	11.875	1	0.0010
E/FA	-0.040	0.018	4.791	1	0.0290
NI/A	-0.129	0.041	9.617	1	0.0020
CFO/A	-0.085	0.032	6.857	1	0.0090
ACCQ	1.083	0.250	18.747	1	0.0001
OFIN	-1.930	0.316	37.263	1	0.0001
MANQ	-1.132	0.361	9.833	1	0.0020
Constant	-3.270	0.254	166.043	1	0.0001

Izvor: Pervan, I. i Kuvek, T. (2013.) The relative importance of fi nancial ratios and nonfi nancial variables in predicting of insolvency, Croatian Operational Research Review, Vol. 4, str. 194.

U drugom modelu s nefinancijskim varijablama točnost predviđanja tj. klasifikacije uspješnih poduzeća iznosila je 92.4% dok je za poduzeća sa poteškoćama iznosila 64.6%. Rezultati istraživanja su pokazali kako je točnost klasifikacije (odnosno predviđanje poslovnog neuspjeha) veće kod modela koji kombinira financijske i nefinancijske varijable u odnosu na model koji sadrži samo financijske varijable.

3.7.3. Ivičić i Cerovac model

U 2009. godini Ivičić i Cerovac objavljuju svoj rad sa ciljem modeliranje kreditnog rizika nefinancijskih poslovnih subjekata procjenjivanjem vjerojatnosti migracija rejtinga i prognoziranjem vjerojatnosti neurednog podmirivanja kreditnih obveza u razdoblju od jedne godine na temelju financijskih izvješća poduzeća [33] .

Uzorak se sastojao od 7.719 poduzeća tijekom 2007. i 2008. godine tvoreći neujednačenu skupinu koja se sastoji od 12.462 promatranja binarne ovisne varijable, odnosno poduzeća za koja su postojali podaci o tome jesu li tijekom određene godine podmirivala obveze ili ne. Koristili su 84 potencijalno relevantna financijska pokazatelja koja su odabrana prema kriteriju uspješnosti predviđanja neurednog podmirenja obveza u prijašnjim istraživanjima.

Financijski pokazatelji su grupirani u pokazatelje likvidnosti, solventnosti, aktivnosti, ekonomičnosti, profitabilnosti i pokazatelje ulaganja. Konačni model za predviđanje vjerojatnosti neurednog podmirivanja obveza tijekom sljedeće godine dobiven je korištenjem multivarijantne logističke regresije na temelju veličine poduzeća (mjerene ukupnom prodajom), ekonomske aktivnosti (građevina i nekretnine prema ostalim sektorima) i pet financijskih pokazatelja:

- pokazatelja likvidnosti (mjerenoga kao gotovina prema ukupnoj imovini)
- pokazatelja vlastitog financiranja (dionički kapital prema ukupnoj imovini),
- pokazatelja aktivnosti (promet potraživanja od kupaca u danima)

[33] Ivičić, L., Cerovac S. (2009): Znanstveni članak; Procjena kreditnog rizika poduzeća u Hrvatskoj, Financijska teorija i praksa, Vol.33 br. 4.

- dva pokazatelja profitabilnosti (zarada prije oporezivanja i kamata prema ukupnim obvezama te prodaja i amortizacija prema ukupnoj imovini).

Konačni model glasi[34]:

$$\mathbf{F[Xi,\beta] = 1 / 1 + e^{-(-0,17-0,28Di,t-0,63w_1_10i,t-1,96w_2_2i,t+0,09w_3_4i,t-0,14w_5_16i,t-0,37w_5_22i,t-0,01w_7_5i,t)}}$$

Kao najvažniji pokazatelji rizika neurednog podmirivanja obveza navode se sljedeći:

- omjer dioničkog kapitala prema ukupnoj imovini
- omjer zarade prije kamata i oporezivanja prema ukupnim obvezama

Veća likvidnost, profitabilnost i prodaja, kao i poslovanje u sektoru građevine i nekretnina, smanjuju vjerojatnost neurednog podmirivanja kreditnih obveza poduzeća u sljedećoj godini. Model je točno klasificirao 74,4% poduzeća koja uredno podmiruju obveze i 71,2% poduzeća koja ih ne podmiruju uredno.

3.7.4. Zenzerović model

U 2009. godini Zenzerović Robert u svom radu prezentira model za predviđanje poslovne neuspješnosti koji je izveden korištenjem višestruke diskriminantne analize. Poduzeća su podijeljena u financijski stabilna i nestabilna poduzeća.

Uzorak se sastojao od 55 financijski stabilnih i jednak broj nestabilnih poduzeća koja su klasificirana prema veličini i djelatnosti. Financijski nestabilna poduzeća su ona koja su ušla u stečajni postupak ili koja su u svojim financijskim izvještajima objavila gubitak iznad visine kapitala. Informacije potrebne za izračun 50 financijskih pokazatelja su prikupljene iz dva glavna izvora; javno dostupnih financijskih izvješća trgovačkih društva čije dionice kotiraju

[34] Ivičić, L., Cerovac S. (2009): Znanstveni članak; Procjena kreditnog rizika poduzeća u Hrvatskoj, Financijska teorija i praksa, Vol.33 br. 4, str.397.

na hrvatskoj burzi i Fina-e (financijske agencije koja prikuplja statističke podatke za sve hrvatske tvrtke).[35]

Pod 50 izračunatih pokazatelja spadaju pokazatelji likvidnosti, solventnosti, aktivnosti, profitabilnosti, pokazatelji koji stavljaju u odnos različite skupine prihoda i rashoda, te pokazatelji temeljeni na izvještaju o novčanom tijeku.

Jednadžba za izračun Zenzerević modela glasi:

CGE1 = -2,207 – 0,026 FS + 0,733 N/I + 1,905 RK/I – 1,086 Z – 0,626 SF – 0,008 FZ + 2,812 A + 2,989 EUP – 0,047 ROA – 0,548 RTIF – 0,124 TL + 0,433 EP

Objašnjenja varijabli:

$$FS = \frac{dugotrajna\ imovina}{dugoročne\ obveze + kapital}$$

$$N/I = \frac{novac\ i\ novčani\ ekvivalenti}{kratkoročna\ imovina}$$

$$RK/I = \frac{radni\ kapital}{ukupna\ imovina}$$

$$Z = \frac{ukupne\ obveze}{ukupna\ imovina}$$

$$SF = \frac{vlastita\ imovina}{ukupna\ imovina}$$

$$FZ = \frac{ukupne\ obveze}{zadržani\ dobitak + deprecijacija}$$

$$A = \frac{zadržani\ dobitak}{ukupna\ imovina}$$

$$EUP = \frac{ukupni\ prihodi}{ukupni\ rashodi}$$

[35] Zenzerović R., Peruško T. (2009): Business financial problems prediction - Croatian experience, Economic Research-Ekonomska Istraživanja, Volume 22, Issue 4. str. 1-15.

$$FS = \frac{dugotrajna\ imovina}{dugoročne\ obveze + kapital}$$

ROA – povrat na imovinu

$$RTIF = \frac{neto\ dobit + kamate}{ukupne\ obveze}$$

TL – pokazatelj likvidnosti

$$EP = \frac{psolovni\ prihodi}{poslovni\ rashodi}$$

Rezultati modela prikazuju kako je 93,5% originalnih jedinica točno klasificirano, dok je analizom presjeka 89,8% jedinica točno klasificirano.

Zenzerović potom razvija drugi i treći CGE model. Drugi se razlikuje u tome što je iz modela izbačeno 6 financijskih pokazatelja. Varijable FS, ROA i RTIF su izbačene zbog negativnih predznaka koji nisu u skladu s postulatima financijske teorije, dok su varijable N/I, TL i EP izbačene zbog toga što su bile manje značajne. Jednadžba drugog modela glasi:

CGE2 = - 1,802 + 1,478 RK/I – 0,995 Z – 0,647 SF – 0,008 FZ + 3,048 A + 2,808 EUP

Rezultat drugog modela pokazuje kako je 95,4% originalnih jedinica točno klasificirano, dok je analizom presjeka 93,5% jedinica točno klasificirano što ukazuje na to da se rezultat poboljšao provođenjem navedenih promjena.

Treći model se razlikuje od drugoga po tome što su iz drugog modela izostavljene dvije jedinice uzorka koje su imale najveću standardnu grešku, dok su varijable ostale jednake kao kod drugog modela. Jednadžba trećeg modela glasi:
CGE3 = -1,74 + 1,517 RK/I – 1,079 Z – 0,601 SF – 0,008 FZ + 3,151 A + 2,771 EUP

Rezultat trećeg modela pokazuje kako je točno klasificirano 95,3% jedinica u oba slučaja što ukazuje da navedene promjene dodatno povećavaju preciznost modela.

3.7.5. Šarlija i ostali model

U 2009 godini Šarlija et al. objavljuju rad sa ciljem kreiranja modela za predviđanje kratkoročne nelikvidnosti poduzeća u Hrvatskoj. Model je specifičan za poduzeća u Hrvatskoj, a rezultat daje vjerojatnost da će poduzeće u idućem jednogodišnjem razdoblju biti nelikvidno.[36] Nelikvidno poduzeće definirano je kao ono poduzeće čiji je žiro-račun u blokadi kontinuirano 3 mjeseca i više.

Uzorak je obuhvaćao financijske podatke od 75.145 trgovačkih društva u Hrvatskoj koja su predala financijske izvještaje u FINA-i 2006. godine. Ovim uzorkom nisu obuhvaćene banke, štedionice i društva za osiguranje. Prikupljeni su podaci iz bilance i računa dobiti i gubitka te podaci o broju dana blokada u toj i idućoj godini. Uzorak je podijeljen na dvije skupine, a od toga je prvu skupinu predstavljala skupina za razvoj modela i drugu kao uzorak za testiranje modela (omjer skupina je 80:20). Dobiveni model definiran je na temelju uzorka za razvoj modela dok su daljina testiranja provođena na uzorku za testiranje modela.

Za potrebe istraživanje korišteno je 29 financijskih pokazatelja, ali se konačni model sastojao od 16 varijabli. Uz financijske pokazatelje koji su predstavljali nezavisne varijable u model su uvrštene i dvije kategoričke varijable (djelatnost i županija).

Primjenom metode logističke regresije na uzorku skupine za razvijanje modela dobiveni su rezultati koji ukazuju na to da su za predviđanje nelikvidnosti poduzeća bitni financijski koeficijenti iz svih pet grupa, dakle likvidnosti, zaduženosti, aktivnosti, ekonomičnosti i profitabilnosti. Rezultati istraživanja također pokazuju da postoje razlike u likvidnosti poduzeća u Hrvatskoj s obzirom na djelatnost i županiju. Značajni prediktori modela Šarlija et al. prikazani su u tablici 3.4.

[36] Šarlija, N., Penavin, S., Harc, M. (2009): Pregledni rad: Predviđanje nelikvidnosti poduzeća u Hrvatskoj, Zbornik Ekonomskog fakulteta u Zagrebu, br.2, str. 21-36.

Tablica 3.4 - Značajni prediktori modela Šarlija i ostali

Varijabla	p-vrijednost
Djelatnost	<.0001
Županija	<.0001
Likvidnost:	
Koeficijent tekuće likvidnosti	<.0001
Neto obrtni kapital	<.0001
Kratkotrajna imovina prema ukupnoj imovini	<.0001
Zaduženost:	
Faktor zaduženosti	<.0001
Stupanj pokrića 1	0.0046
Odnos obveza prema kapitalu	0.0081
Pokriće troškova kamata	<.0001
Aktivnost	
Koeficijent obrta ukupna imovine	<.0001
Koeficijent obrta kratkotrajne imovine	<.0001
Trajanje kreditiranja kod dobavljača	<.0001
Trajanje naplate potraživanja	<.0001
Dani vezivanja zaliha	0.0155
Ekonomičnost:	
Ekonomičnost ukupnog poslovanja	<.0001
Ekonomičnost poslovnih aktivnosti	0.0021
Ekonomičnost financiranja	<.0001
Profitabilnost:	
neto profitna marža	<.0001

Izvor: Šarlija, N., Penavin, S., Harc, M. (2009): Predviđanje nelikvidnosti poduzeća u Hrvatskoj, Zbornik Ekonomskog fakulteta u Zagrebu, godina 7, br. 2., str. 33.

Dobiveni model je naknadno testiran na uzorku skupine poduzeća za testiranje kod kojeg je zabilježena ukupna točnost modela od 68,16% za likvidna poduzeća, te 74,22% za nelikvidna poduzeća. Rezultati istraživanja su pokazala kako najmanju vjerojatnost da poduzeća postanu nelikvidna imaju ona u Zadarskoj, Šibensko-kninskoj i Zagrebačkoj županiji te Gradu Zagrebu, dok su su najrizičnija poduzeća, odnosno ona kod kojih postoji relativno visoka vjerojatnost da postanu nelikvidna u Međimurskoj, Osječko-baranjskoj, Požeško-slavonskoj i Varaždinskoj županiji. Istraživanje je također pokazalo da poduzeća koja pripadaju djelatnosti financijskog posredovanja i javne uprave imaju najmanju vjerojatnost da će biti nelikvidni u idućem razdoblju, dok suprotno vrijedi za prerađivačku industriju i hotele.[37]

[37] Šarlija, N., Penavin, S., Harc, M. (2009): Predviđanje nelikvidnosti poduzeća u Hrvatskoj, Zbornik Ekonomskog fakulteta u Zagrebu, godina 7, br. 2., str. 33

3.7.6. Ocjena financijskog rejtinga-Bonplus

Uz BON1 obrazac FINA-e koji predstavlja jedan od osnovnih izvora podataka pri ocjeni boniteta postoji i BONPLUS izvješće kao proširena verzija bonitetne informacije koja sadrži još kvalitetnije, jasnije, preglednije te lako razumljive podatke i informacije koje mogu pomoći u poslovnom odlučivanju. BONPLUS obrazac kao ključni dio sadrži ocjenu financijskog rejtinga, odnosno procjenu buduće sposobnosti poduzetnika da svoje obveze ispunjava u preuzetim rokovima iskazanu ocjenom od 1 do 10 prema Fininoj rejting skali. Skala ocjena rejtinga i usporedba sa Fitch standardima je prikazana u dole navedenoj tablici.

Tablica 3.3. Skala ocjena rejtinga Fininog BONPLUS izvješća

Razred	**Fitch**	**Opis**	**Finina ocjena rejtinga**
1	AAA AA+	Najviša kvaliteta poslovanja, vjerojatnost zastoja u plaćanjima do 2,5%.	1
2	AA AA	Vrlo visoka kvaliteta poslovanja, vjerojatnost zastoja u plaćanjima 2,5% do 5,0%	2
3	A+	Vrlo dobra kvaliteta poslovanja, vjerojatnost zastoja u plaćanjima od 5 do 7,5%.	3
4	A A-	Solidna kvaliteta poslovanja, znatne promjene u okolnostima i okolini mogu oslabjeti poslovni subjekt, vjerojatnost zastoja u plaćanjima 7,5% do 10,0%.	4
5	BBB+ BBB	Prosječna kvaliteta poslovanja, ugroženo plaćanje kamata i dugova kod negativnog razvoja, prihvatljiv rizik, vjerojatnost zastoja u plaćanjima 10,0% do 15,0%.	5
6	BBB-	Niža kvaliteta poslovanja, granično prihvatljiv rizik, vjerojatnost zastoja u plaćanjima 15,0% do 20,0%.	6
7	BB+	Nesigurnost poslovanja, potreban oprez, vjerojatnost zastoja u plaćanjima 20,0% do 25,0%.	7
8	BB BB-	Slaba kvaliteta poslovanja, visoka nesigurnost poslovne suradnje, vjerojatnost zastoja u plaćanjima 25,0% do 30,0%.	8

9	B+ B	Nesigurna kvaliteta poslovanja, vrlo visoka nesigurnost poslovne suradnje, vjerojatnost zastoja u plaćanjima 30,0% do 35,0%.	9
10	-	Otežano ispunjavanje obveza, vjerojatnost zastoja u plaćanjima više od 35%.	10

Ocjena financijskog rejtinga dana je u rasponu od 1 do 10, te niža ocjena znači bolji financijski rejting.

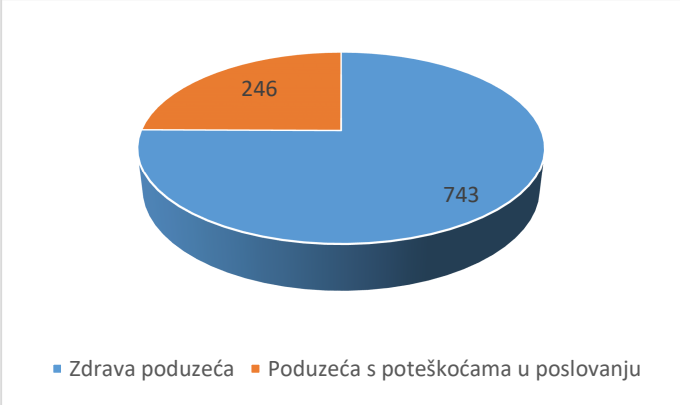
4. OBLIKOVANJE MODELA ZA PREDVIĐANJE POSLOVNOG NEUSPJEHA

4.1. Opis uzorka

U svrhu izrade analize i samog oblikovanja modela za predviđanje poslovnog neuspjeha potrebno je prikupiti financijske podatke o uspješnim poduzećima i onima sa poteškoćama u poslovanju. Potrebni financijski podaci o poduzećima u Republici Hrvatskoj su preuzeti iz baze Amadeus. Baza Amadeus sadrži financijske informacije od oko 21 milijuna tvrtki širom Europe. Baza podataka Amadeus se koristi za istraživanje i analize te je moguće dobiti informacije i podaci o javnim i privatnim trgovačkim društvima izdvojenim prema različitim kriterijima (prema zemlji, veličini poduzeća, vrsti djelatnosti, itd.).

Izvorni uzorak se sastojao od preko dvije tisuće poduzeća isključivo iz sektora proizvodnje, ali je naknadno reduciran na 989 poduzeća kako bi se uravnotežio omjer uspješnih poduzeća i poduzeća s poteškoćama u poslovanju (odnosno onima kojima prijeti stečaj). Iz izvornog uzorka su svakom poduzeću s poteškoćama u poslovanju dodijeljena 3 uspješna poduzeća s otprilike istom visinom ukupne imovine. Na taj način definiran je uzorak od 989 poduzeća od kojih je 743 zdravih i 246 sa poteškoćama (omjer 3:1).

4.1 Prikaz omjera uspješnih poduzeća i poduzeća s poteškoćama u poslovanju u ukupnom uzorku



Izvor: Izrada autora

S obzirom da su se na jedno poduzeće s poteškoćama dodjeljivala tri zdrava poduzeća prema kriteriju iste visine ukupne imovine dobiven je uzorak u kojemu je kroz sve veličine imovine

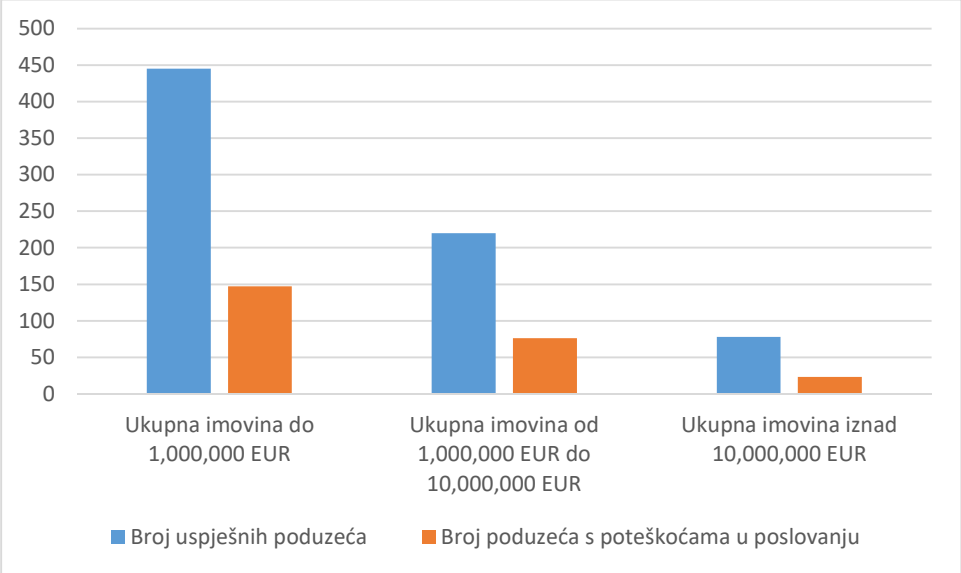
zadržan omjer 3:1. Raspoređenost zdravih i poduzeća sa poteškoćama u tri kategorije prema visini imovine (ukupna imovina do 1.000 EUR, od 1.000 do 10.000 EUR te iznad 10.000) prikazana je u tablici 4.1 te grafičkim prikazom 4.2.

4.1 Zdrava poduzeća i poduzeća sa poteškoćama u uzorku raspoređena prema ukupnoj imovini

Ukupna imovina u EUR	Broj zdravih poduzeća	Broj poduzeća s poteškoćama u poslovanju	Ukupno
0 - 1.000.000 EUR	445	147	592
1.000.000 - 10.000.000 EUR	220	76	296
> 10.000.000 EUR	78	23	101

Izvor: izrada autora

4.2 Grafički prikaz omjera uspješnih poduzeća i poduzeća s poteškoćama u poslovanju u ukupnom uzorku



Izvor: Izrada autora

Razmatrajući podatke iz tablice može se primijetiti kako čak 60% uzorka čine mala poduzeća s visinom imovine do 1.000 EUR, 30% čine poduzeća s imovinom u rasponu od 1.000.000 do 10.000.000 EUR-a, a tek 10% se odnosi na proizvodna poduzeća sa ukupnom imovinom iznad 10.000.000 EUR.

4.2. Opis metodologije

U ovom radu koristit će se metode primjerene u istraživanjima u društvenim znanostima te će se njihovom primjenom ustvrditi da li su postavljene hipoteze točne. Primijenjene metode istraživanja u teorijskoj razradit će biti metoda deskripcije, induktivna metoda, metoda slučaja, analitička metoda, metoda klasifikacije, metoda generalizacije i komparativna metoda. U empirijskom dijelu istraživanja korištena je statistička metoda logističke regresije.

Logistička regresija je oblik regresijske analize koja se koristi u predviđanju i objašnjavanju vrijednosti binarne (dvogrupne) zavisne varijable na osnovi nezavisnih varijabli. U usporedbi s diskriminacijskom analizom logistička regresija je ograničena na osnovni oblik dvije grupe za zavisnu varijablu, ali prednost je ta što se ne suočava sa striktnim pretpostavkama poput jednakosti matrica varijanci i kovarijanci za obje skupine poduzeća. To ujedno čini logističku regresiju mnogo djelotvornijom i vjerodostojnicom analizom u mnogim situacijama.

U ovom istraživanju kategoričku zavisnu varijablu u predstavljat će uspješna poduzeća te poduzeća sa poteškoćama (0 uspješna poduzeća i 1 poduzeća sa poteškoćama) dok će kao nezavisne varijable biti uvršteni različiti financijski pokazatelji. Za potrebe ovog istraživanja svi statistički testovi će biti provedeni uporabom programskog paketa IBM® SPSS®.

4.3. Opis varijabli

Na temelju dostupnih financijskih informacija iz uzorka odabrani su sljedeći financijski pokazatelji kao početne varijable za razmatranje: ROE, ROA, Operativni novčani tok/ prihod, obrtaj imovine, tekuća likvidnost i samofinanciranje. S obzirom da je metoda logističke regresije osjetljiva na problem multikolinearnosti tj. postojanje utjecaja jedne nezavisne varijable na drugu potrebno je takve varijable identificirati te isključiti iz modela. Za potrebe ovog istraživanja korišteni su financijski podaci iz zadnjeg obračunskog razdoblja.

Rezultati analize korelacije prikazani su u tablici 4.3. Iz tablice je vidljivo kako koeficijent korelacije između EBIT marže i Operativnog novčanog toka/prihod iznosi 0,841 što se smatra značajnim. Varijable EBIT marža i Operativni novčani tok/ prihod visoko koreliraju te je u svrhu izrade modela za predviđanje poslovnog neuspjeha varijabla Operativni novčani tok/ prihod uklonjena iz daljnjeg razmatranja, a EBIT marža zadržana.

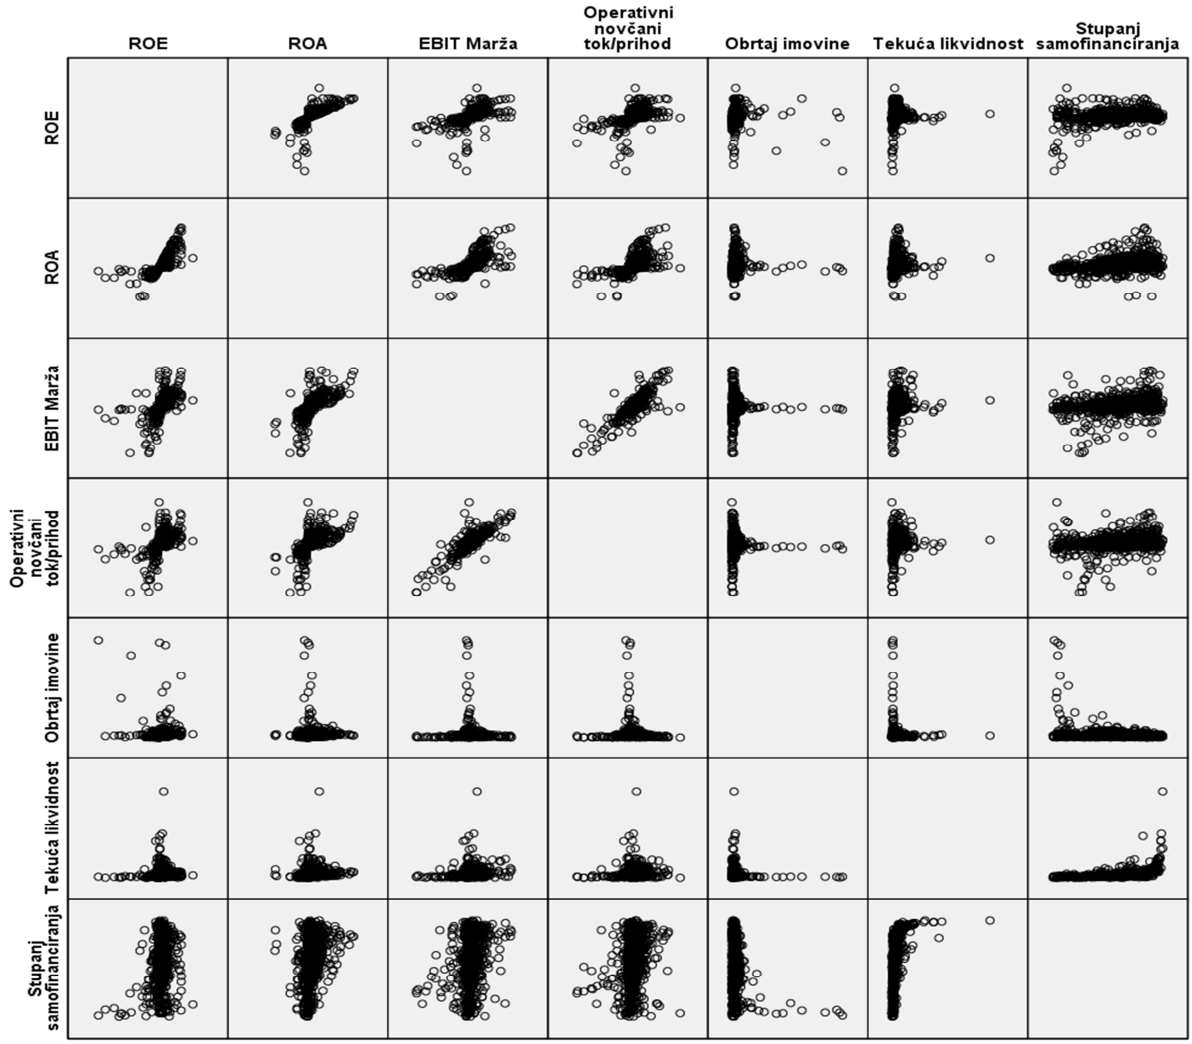
Tablica 4.3 Rezultati analize korelacije nezavisnih varijabli

		ROE	ROA	EBIT Marža	Operat. novčani tok/prihod	Obrtaj imovine	Tekuća likvidnost	Stupanj samofinanciranja
ROE	Pearson Correlation	1	0,729**	0,556**	0,527**	-0,127**	0,074*	0,211**
	Sig. (2-tailed)		0,000	0,000	0,000	0,000	0,027	0,000
	N	886	886	886	886	886	886	886
ROA	Pearson Correlation	0,729**	1	0,690**	0,612**	-0,006	0,133**	0,282**
	Sig. (2-tailed)	0,000		0,000	0,000	,858	0,000	0,000
	N	886	886	886	886	886	886	886
EBIT Marža	Pearson Correlation	0,556**	0,690**	1	0,841**	-0,025	0,167**	0,250**
	Sig. (2-tailed)	0,000	0,000		0,000	0,458	0,000	0,000
	N	886	886	886	886	886	886	886
Operativni novčani tok/prihod	Pearson Correlation	0,527**	0,612**	0,841**	1	-0,068*	0,115**	0,227**
	Sig. (2-tailed)	0,000	0,000	0,000		,043	,001	0,000
	N	886	886	886	886	886	886	886
Obrtaj imovine	Pearson Correlation	-0,127**	-0,006	-0,025	-0,068*	1	-0,088**	-0,278**
	Sig. (2-tailed)	0,000	,858	,458	,043		,009	0,000
	N	886	886	886	886	886	886	886
Tekuća likvidnost	Pearson Correlation	0,074*	0,133**	0,167**	0,115**	-0,088**	1	0,489**
	Sig. (2-tailed)	0,027	0,000	0,000	0,001	0,009		0,000
	N	886	886	886	886	886	886	886
Stupanj samofinanciranja	Pearson Correlation	0,211**	0,282**	0,250**	0,227**	-0,278**	0,489**	1
	Sig. (2-tailed)	0,000	0,000	0,000	0,000	0,000	0,000	
	N	886	886	886	886	886	886	886

Izvor: Izrada autora u SPSS-u

Grafički prikaz 4.4 također prikazuje znatnu korelaciju između varijable operativnog novčanog toka/ prihod i EBIT marže.

Grafički prikaz 4.4 – prikaz odnosa varijabli (matričnim) grafom raspršenosti vrijednosti



Izvor: izrada autora u SPSS

Kako bi se dodatno potvrdilo nepostojanje multikolinearnosti među preostalim varijablama izvršena je analiza faktora inflacije varijance (VIF analiza). Rezultati VIF analize su prikazani u tablici 4.5 i pokazuju kako su sve izračunate vrijednosti u rasponu od 1,0 do 2,8. S obzirom da ni jedna od njih ne premašuje vrijednost 5 utvrđuje se kako u razmatranom uzorku među odabranim varijablama ne postoji problem multikolinearnosti.

Tablica 4.5 – analiza faktora inflacije varijance

Model – zavisna varijabla ROE	Analiza korelacije	
	Tolerancija	VIF
ROA	0,511	1,956
EBIT marža	0,527	1,898
Obrtaj imovine	0,923	1,083
Tekuća likvidnost	0,783	1,278
Stupanj samofinanciranja	0,673	1,486
Model – zavisna varijabla ROA	Tolerancija	VIF
ROE	0,641	1,561
EBIT marža	0,633	1,580
Obrtaj imovine	0,919	1,088
Tekuća likvidnost	0,781	1,280
Stupanj samofinanciranja	0,691	1,446
Model – zavisna varijabla EBIT marža	Tolerancija	VIF
ROE	0,454	2,200
ROA	0,436	2,295
Obrtaj imovine	0,902	1,108
Tekuća likvidnost	0,784	1,276
Stupanj samofinanciranja	0,674	1,483
Model – zavisna varijabla obrtaj imovine	Tolerancija	VIF
ROE	0,451	2,216
ROA	0,358	2,791
EBIT Marža	0,511	1,956
Tekuća likvidnost	0,782	1,279
Stupanj samofinanciranja	0,723	1,383
Model – zavisna varijabla tekuća likvidnost	Tolerancija	VIF
ROE	0,442	2,265
ROA	0,352	2,844
EBIT Marža	0,513	1,951
Obrtaj imovine	0,903	1,108
Stupanj samofinanciranja	0,835	1,198
Model - zavisna varijabla samofinanciranje	Tolerancija	VIF
ROE	0,441	2,269
ROA	0,361	2,769
EBIT Marža	0,512	1,954
Obrtaj imovine	0,968	1,033
Tekuća likvidnost	0,969	1,032

Izvor: Izrada autora u SPSS-u

Nakon provjere postojanja problema multikolinearnosti izvršena je usporedba vrijednosti aritmetičkih sredina odabranih varijabli u grupi uspješnih poduzeća te u grupi poduzeća s poteškoćama u poslovanju. Prema podacima iz tablice 4.6 vidljivo je da su aritmetičke vrijednosti varijabli uspješnih poduzeća veće od poduzeća s poteškoćama. EBIT marža i ROE imaju negativne vrijednosti aritmetičke sredine kod poduzeća s poteškoćama .što je sukladno teorijskim očekivanjima. Aritmetička sredina varijable tekuća likvidnost iznosi 2,06 za poduzeća s poteškoćama dok za zdrava poduzeća iznosi 4,35.

Tablica 4.6 Usporedba aritmetičkih sredina nezavisnih varijabli

Nezavisne varijable modela		Broj opservacija	Aritmetička sredina	Standardna devijacija	Standardna greška
ROE	0- Zdrava poduzeća	743	12,27637	19,122506	0,701537
	1 - Poduzeća s poteškoćama	246	-3,27892	50,299897	3,207004
ROA	0- Zdrava poduzeća	743	8,46262	14,003385	0,513734
	1 - Poduzeća s poteškoćama	246	1,08030	11,485372	0,732281
EBIT Marža	0- Zdrava poduzeća	743	7,52929	12,631131	0,463391
	1 - Poduzeća s poteškoćama	246	-1,22391	26,514716	1,690517
Obrtaj imovine	0- Zdrava poduzeća	743	2,08992	1,503030	0,055141
	1 - Poduzeća s poteškoćama	246	3,75806	10,840314	0,691153
Tekuća likvidnost	0- Zdrava poduzeća	743	4,34956	5,599581	0,205429
	1 - Poduzeća s poteškoćama	246	2,05647	5,785739	0,368885
Stupanj samofinanciranja	0- Zdrava poduzeća	743	66,23869	17,222783	0,631843
	1 - Poduzeća s poteškoćama	246	34,81499	23,908649	1,524360

Izvor: Izrada autora u SPSS-u

Naknadno je izvedena analiza signifikantnosti razlika aritmetičkih sredina upotrebom T testa pomoću koje je utvrđeno da su razlike značajne na razini od 5% za sve promatrane pokazatelje.

Najveću razlika u aritmetičkim sredinama ima pokazatelj samofinanciranja kod kojega aritmetička sredina za uspješna poduzeća iznosi 66,24% dok kod poduzeća s poteškoćama iznosi 34,81%. Pregled svih razlika aritmetičkih sredina te njihovih signifikantnosti prikazan je u tablici 4.7.

Tablica 4.7 T-test razlike aritmetičkih sredina nezavisnih varijabli

Nezavisne varijable	Sig.	T-vrijednost	Stupanj slobode	Razlika aritmetičke sredine	Razlika standardne greške	Interval razlike	
						Donji	Gornji
ROE	0,000	7,037	987	15,555290	2,210367	11,217731	19,892849
ROA	0,001	7,477	987	7,382324	0,987346	5,444785	9,319862
EBIT Marža	0,000	6,935	987	8,753199	1,262247	6,276203	11,230194
Obrtaj imovine	0,000	-4,082	987	-1,668144	0,408687	-2,470140	-0,866149
Tekuća likvidnost	0,000	5,521	987	2,293088	0,415341	1,478035	3,108142
Stupanj samofinanciranja	0,000	22,364	987	31,423697	1,405125	28,666321	34,181074

Izvor: Izrada autora u SPSS-u

Nakon provedenih analiza definiraju se sljedećih 6 potencijalnih varijabli:

1. ROE (stopa povrata glavnice) = Neto dobit / Kapital
2. ROA (stopa povrata imovine) = Neto dobit / Ukupna imovina
3. EBIT Marža = Operativna dobit/Prihod
4. Obrtaj imovine = Prihod/Imovina
5. Tekuća likvidnost = Tekuća imovina/Tekuće obveze
6. Stupanj samofinanciranja = Kapital/Imovina

U daljnjem istraživanju uporabom logističke regresije će se analizirati utjecaj i važnost svake od varijabli modela na promatranom uzorku.

4.4. Rezultati istraživanja

Nakon provedenih analiza nezavisnih varijabli i potvrde o nepostojanju problema multikolinearnosti uporabom logističke regresije i metode enter definira se osnovni model predviđanja poslovnog neuspjeha. Uporabom ovog modela logističke regresije statistički alat SPSS klasificira poduzeća u grupu uspješnih poduzeća i grupu poduzeća sa poteškoćama na temelju postavljene granične vrijednosti klasifikacije. Poduzeća koja imaju vrijednost bližu 0 se klasificiraju kao uspješna dok poduzeća sa izračunatom vrijednosti bliže vrijednosti 1 se klasificiraju kao poduzeća s poteškoćama. Granična vrijednost za predviđanje klasifikacije (*eng. classification cut off*) ovog modela je postavljena na 0,5. Logistička regresija za ocjenu parametara koristi slijedeću formulu[38]:

$$\text{logit}(p) = b_0 + b_1X_1 + b_2X_2 + \ldots + b_nX_n; \text{ gdje je logit}(p) = \ln(p/(1-p))$$

Primjenom logističke regresije na osnovnom uzorku dobiven je preliminarni model koji je rezultirao sa točnošću predviđanja od 88%. Razmatrani su financijski podaci o posljednjem obračunskom razdoblju jer su u usporedbi s podacima iz prethodnih godina davali najveću točnost predviđanja. Rezultati su pokazali kako je postignuta visoka točnost predviđanja za uspješna poduzeća od 96,5% dok je model uspio točno predvidjeti poslovni neuspjeh za 62,2% poduzeća (tablica 4.8).

Tablica 4.8 prikaz točnosti predviđanja

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	717	26	96,5
	1 - Poduzeća s poteškoćama	93	153	62,2
Ukupan postotak				88,0

Izvor: Izrada autora u SPSS-u

U pregledu predviđanja pogrešno klasificiranih poduzeća primijećeno je kako postoji određeni broj poduzeća u stečaju tj. onih s poteškoćama kojima je izračunata vrijednost modela manja od 0,1 pa ih je model klasificirao u uspješna iako ona ne spadaju u tu

[38] Hair, J., F.; Black, W., C.; Babin, B., J. i Anderson, R., E. (2010.), *Multivariate Data Analysis*, Pearson Prentice Hall, Harlow, str. 323.

kategoriju. Može se smatrati kako postoje situacije kod kojih trgovačka društava pokrenu postupak stečaja iz nekih drugih razloga koji ne moraju biti nužno uvjetovani financijskim rezultatima, te nisu vidljiva iz temeljnih financijskih izvještaja. Podaci o takvim poduzećima mogu utjecati na vrijednosti varijabli definiranog modela te mogu 'prikrivati' stvarnu sliku modela što će utjecati na točnost predviđanja. Kako bi se eliminirale takve situacije bilo bi potrebno detaljno analizirati svaki od pogrešno klasificiranih poduzeća, ali će se za potrebe ovog istraživanje sva poduzeća sa izračunatom vrijednošću predviđanja ispod 0,1 izbaciti iz modela. Eliminiranje takvih poduzeća će utjecati na povećanje postotka točnosti predviđanja osnovnog modela, ali neće utjecati na valjanost rezultata pri usporedbi s drugim modelima primijenjenim na različite kategorije poduzeća po kriteriju visine imovine jer će se koristiti taj isti uzorak za daljnja razmatranja (koji ne uključuje poduzeća koja su bila prethodno pogrešno klasificirana u osnovnom modelu).

Iz uzorka je izbačeno 29 poduzeća s poteškoćama kojima je vrijednost predviđanja klasifikacije bila ispod 0,1. Od 29 pogrešno klasificiranih poduzeća njih 15 je imalo visinu ukupne imovine do 1.000.000 EUR, 10 ih je bilo u rasponu od 1.000.000 do 10.000.000 EUR dok su samo 4 poduzeća imala ukupnu imovinu iznad 10.000.000 EUR. Prilagođeni uzorak se sastoji od 960 poduzeća od kojih je 743 uspješnih poduzeća a 217 poduzeća s poteškoćama u poslovanju.

Korištenjem logističke regresije i metode enter na prilagođenom uzorku dobivena je točnost od 90,8%. Točnost predviđanja uspješnih poduzeća je 96,2% (715 točno klasificiranih uspješnih poduzeća od ukupna 743), a točnost predviđanja poduzeća s poteškoćama u poslovanju je 72,4% (157 točno klasificiranih poduzeća s poteškoćama od ukupno 217). Prikaz točnosti predviđanja prikazan je u tablici 4.9.

Tablica 4.9 prikaz točnosti predviđanja osnovnog modela

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	715	28	96,2
	1 - Poduzeća s poteškoćama	60	157	72,4
Ukupni postotak				90,8

Izvor: Izrada autora u SPSS-u

Vrijednost Nagelkerke R2 iznosi 65,8% što ukazuje na postojanje umjereno jake veze između navedenih nezavisnih varijabli i predviđanja uspješnosti poduzeća.

Tablica 4.10 Sažetak modela

Step	-2 Log likelihood	Cox & Snell R^2	Nagelkerke R^2
1	483,415[a]	0,432	0,658

a. Proces je okončan u 7. koraku jer su promjene ocjene paramatra manje od ,001.

Izvor: Izrada autora u SPSS-u

Razmatrajući dobivene parametre nezavisnih varijabli te njihovih signifikantnosti može se zaključiti kako su u dobivenom modelu sve varijable značajne osim varijable ROE čija je vrijednost parametra samo 0,005 uz signifikantnost od 0,475. Za potrebe ovog istraživanja varijabla ROE će ipak biti zadržana u modelu kako bi se pri usporedbi osnovnog modela sa ostalim modelima posebno prilagođenim za poduzeća različite veličine (različitim visinama ukupne imovine) mogla vršiti analiza značaja varijable praćenjem promjena vrijednosti signifikantnosti.

Tablica 4.11 Prikaz parametara i signifikantnosti nezavisnih varijabli

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	0,005	0,007	0,510	1	0,475	1,005
ROA	-0,042	0,022	3,685	1	0,055	,958
EBIT Marža	-0,020	0,009	4,504	1	0,034	,981
Obrtaj imovine	-0,034	0,017	4,043	1	0,044	,966
Tekuća likvidnost	0,078	0,020	15,767	1	0,000	1,081
Stupanj samofinanciranja	-0,123	0,009	173,119	1	0,000	,885
Konstanta	4,616	0,423	118,831	1	0,000	101,040

Izvor: Izrada autora u SPSS-u

Iz prethodno prikazane tablice 4.11 definira se osnovni model (M_o) za predviđanje poslovnog neuspjeha proizvodnih poduzeća koji glasi:

$$M_o = 4{,}616 + 0.005\ X_1 - 0{,}042\ X_2 - 0{,}020\ X_3 - 0{,}034\ X_4 + 0{,}078\ X_5 - 0{,}123\ X_6$$

Objašnjenje oznaka:

M_o - osnovni model predviđanja poslovnog neuspjeha

M_1 - ROE

M_2 - ROA

M_3 – EBIT marža

M_4 – obrtaj imovine

M_5 – tekuća likvidnost

M_6 – stupanj samofinanciranja

Kako bi se dokazala hipoteza da se točnost modela za predviđanje poslovnog neuspjeha povećava ako se poduzeća grupiraju u više skupina, ovisno o veličini poduzeća potrebo je odrediti jasne kriterije po kojima će se vršiti daljnja razmatranja. Kao kriterij razvrstavanja poduzeća po različitim veličinama odabrana je visina ukupne imovine kojom poduzeće raspolaže. Osnovni uzorak podijeljen je u dvije grupe poduzeća koristeći aritmetičku sredinu ukupne imovine kao vrijednost koja razgraničava te dvije grupe. Aritmetička vrijednost ukupne imovine iznosi 4,450,400 EUR te je osnovni uzorak podijeljen na grupu 1 koja obuhvaća poduzeća s ukupnom imovinom do 4.500.000 EUR te grupu 2 koja obuhvaća poduzeća sa ukupnom imovinom većom od 4.500.000 EUR.

Pregled uzorka raspodijeljenog u dvije grupe prema visini ukupne imovine je prikazan u tablici 4.12.

Tablica 4.12 pregled uzorka raspodijeljenog prema kriteriju visine ukupne imovine

Grupa	Uspješna poduzeća	Poduzeća s poteškoćama	Ukupan broj poduzeća
Grupa 1 - ukupna imovina do 4.500.000 EUR	585	177	762
Grupa 2 - ukupna imovina iznad 4.500.000 EUR	158	40	198
Ukupno	743	217	960

Izvor: Izrada autora

Rezultati grupe 1 – ukupna imovina do 4.500.000 EUR

Primjenom logističke regresije uz metodu enter na uzorku grupe 1 i pri tom koristeći iste varijable kako kod osnovnog modela dobivamo prilagođeni model sa novim parametrima. Rezultati pokazuju kako je točnost predviđanja ovog prilagođenom modela otprilike ista kao i kod osnovnog modela korištenog na cijelom uzorku. Ukupna točnost predviđanja uspješnosti poduzeća iznosi 90,7%. Model je točno klasificirao 562 uspješnih poduzeća od ukupno 585

(točnost predviđanja 96,1%), te 129 točno klasificiranih neuspješnih poduzeća od ukupno 177 (točnost predviđanja 79,9%).

Rezultati prilagođenom modela za poduzeća ukupne imovine do 4.500.000 EUR (grupa 1) su prikazani u tablici 4.13.

Tablica 4.13 Prikaz točnosti predviđanja prilagođenog modela grupe 1

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	562	23	96,1
	1 - Poduzeća s poteškoćama	48	129	72,9
Ukupni postotak				90,7

Izvor: Izrada autora u SPSS-u

Vrijednost Nagelkerke R^2 od 67,7% ukazuje na postojanje umjereno jake veze između korištenih varijabli tj. financijskih pokazatelja i predviđanja poslovnih neuspjeha (tablica 4.14)

Tablica 4.14 Prikaz jakosti veze varijabli i predviđanja neuspješnosti

Step	-2 Log likelihood	Cox & Snell R^2	Nagelkerke R^2
1	372,899[a]	0,448	0,677

Izvor: Izrada autora u SPSS-u

Analiza parametara varijabli i vrijednosti signifikantnosti na prilagođenom modelu izvedenom na grupi 1 je prikazana u tablici 4.15.

Tablica 4.15 Prikaz parametara i signifikantnosti nezavisnih varijabli prilagođenog modela grupe 1

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	0,005	0,007	0,391	1	0,532	1,005
ROA	-0,037	0,025	2,199	1	0,138	0,964
EBIT marža	-0,009	0,010	0,819	1	0,366	0,991
Obrtaj imovine	-0,030	0,019	2,556	1	0,110	0,970
Tekuća likvidnost	0,080	0,020	16,672	1	0,000	1,084
Stupanj samofinanciranja	-0,126	0,011	138,979	1	0,000	0,881
Konstanta	4,742	0,482	96,879	1	0,000	114,607

Izvor: Izrada autora u SPSS-u

Iz prethodno navedene tablice može se zaključiti kako najutjecajnije varijable u modelu za poduzeća ukupne imovine do 4.500.000 EUR predstavljaju tekuća likvidnost i stupanj samofinanciranja dok se utjecaj nezavisnih varijabli ROA, EBIT marža i obrtaj imovine smanjuje. Varijabla ROE za koju je već u prethodnoj analizi utvrđeno kako nema značajnog utjecaja na model dodano se smanjila signifikantnost odnosno njen utjecaj u razmatranom modelu. Prilagođeni model za grupu 1 odnosno poduzeća s ukupnom imovinom do 4.500.000 EUR glasi:

$M_1 = 4{,}742 + 0.005\ X_1 - 0{,}037\ X_2 - 0{,}009\ X_3 - 0{,}030\ X_4 + 0{,}080\ X_5 - 0{,}126\ X_6$

Oznake varijabli su nepromijenjene u odnosu na osnovni model.

Rezultati grupe 2 – ukupna imovina iznad 4.500.000 EUR

Iz navedenih rezultata na uzorku grupe 1 moglo bi se zaključiti kako postoji mogućnost da nema značajnih promjena u točnosti predviđanja prilikom grupiranja poduzeća, ali uporabom istih statističkih metoda na uzorku grupe 2 za poduzeća ukupne imovine iznad 4.500.000 EUR dolazi se do zaključka kako ipak postoje određena povećanja u točnosti predviđanja kod dodatnog grupiranja.

Točnosti ukupnog predviđanja grupe 2 iznosi 92,9% što je povećanje od 2.1 postotna poena u odnosu na osnovni model. Točnost predviđanja poslovnog neuspjeha iznosi 77,5% što je povećanje od 5,1 postotnih poena u odnosu na osnovni model (točnost predviđanja poduzeća s poteškoćama u osnovnom modelu iznosi 72,4%).
Točnost predviđanja prilagođenog modela za grupu 2 prikazana je u sljedećoj tablici:

Tablica 4.16 Prikaz točnosti predviđanja prilagođenog modela grupe 2

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	153	5	96,8
	1 - Poduzeća s poteškoćama	9	31	77,5
Ukupni postotak				92,9

Izvor: Izrada autora u SPSS-u

Vrijednost Nagelkerke R^2 vrijednosti u ovoj grupi iznosila je 79,2%- (tablica 4.17)

Tablica 4.17 Prikaz jakosti veze varijabli i predviđanja neuspješnosti

Step	-2 Log likelihood	Cox & Snell R^2	Nagelkerke R^2
1	61,136[a]	0,502	0,792

Izvor: Izrada autora u SPSS-u

Analizom novih vrijednosti parametara nezavisnih varijabli te njihove signifikantnosti u modelu grupe 2 može se primijetiti kako se utjecaj varijable obrtaj imovine znatno povećava u promatranoj grupi poduzeća sa ukupnom imovinom iznad 4.500.000 EUR. U osnovnom modelu parametre varijable obrtaj imovine iznosi -0,034 dok u modelu predviđanja grupe 2 iznosi -1,793. Također se može primijetiti kako u grupi 2 raste utjecaj EBIT marže u odnosu na model predviđanja grupe 1. U modelu grupe 1 parametar EBIT marže iznosi -0,009 dok u modelu grupe 2 iznosi -0,067. Stupanj samofinanciranja i dalje je vrlo značajna varijabla modela dok se utjecaj varijabli ROA, ROE i tekuća likvidnost smanjuju u odnosu na osnovni model te model grupe 1.

Tablica 4.18 Prikaz parametara i signifikantnosti nezavisnih varijabli prilagođenog modela grupe 2

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	-0,014	0,042	0,109	1	0,741	0,986
ROA	-0,067	0,170	0,155	1	0,694	0,935
EBIT marža	-0,089	0,076	1,372	1	0,241	0,915
Obrtaj imovine	-1,793	0,464	14,908	1	0,000	0,166
Tekuća likvidnost	0,264	0,352	0,564	1	0,453	1,303
Stupanj samofinanciranja	-0,166	0,040	17,034	1	0,000	0,847
Konstanta	8,975	2,047	19,223	1	0,000	7903,911

Izvor: Izrada autora u SPSS-u

Prilagođeni model za grupu 2 odnosno poduzeća s ukupnom imovinom iznad 4.500.000 EUR glasi:

$$M_1 = 8{,}975 + 0.014\ X_1 - 0{,}067\ X_2 - 0{,}089\ X_3 - 1{,}793\ X_4 + 0{,}264\ X_5 - 0{,}166\ X_6$$

Kako bi se dokazala hipoteza o povećanju točnosti predviđanja kod kategorizacije poduzeća u više grupa po kriteriju ukupne imovine svaka od dvije grupe će se dodatno razdijeliti u dvije podgrupe.

Grupa 1 s poduzećima ukupne imovine do 4.500.000 EUR-a se dijeli na grupu 1.1 s poduzećima ukupne imovine do 800.000 EUR i onima u rasponu od 800.000 EUR do 4.500.000 EUR. Grupe su prikazane u tablici 4.19.

Tablica 4.19 Prikaz podjele poduzeća grupe 1.1 i 1.2

Grupa	Uspješna poduzeća	Poduzeća s poteškoćama	Ukupni broj poduzeća
Grupa 1.1- ukupna imovina do 800.000 EUR	419	124	543
Grupa 1.2- ukupna imovina od 800.000 do 4.500.000 EUR	166	53	219
Ukupno	585	177	762

Izvor: Izrada autora

Grupa 2 s poduzećima ukupne imovine iznad 4.500.000 EUR je podijeljena na grupu 2.1 koja obuhvaća poduzeća s ukupnom imovinom od 4.500.000 EUR do 10.000.000 EUR i grupu 2.2 s ukupnom imovinom iznad 10.000.000 EUR (prikaz u tablici 4.20)

Tablica 4.20 Prikaz podjele poduzeća grupe 2.1 i 2.2

Grupa	Uspješna poduzeća	Poduzeća s poteškoćama	Ukupni broj poduzeća
Grupa 2.1- ukupna imovina od 4.500.000 do 10.000.000 EUR	80	21	101
Grupa 2.2- ukupna imovina od iznad 10.000.000 EUR	78	19	97
Ukupno	158	40	198

Izvor: Izrada autora

Rezultati grupe 1.1 – ukupna imovina do 800.000 EUR

Nakon primjene metode logističke regresije na uzorku grupe 1.1 koji obuhvaća poduzeća ukupne imovine do 800.000 EUR dobiven je model s ukupnom točnošću predviđanja od 91,5% što je povećanje od samo 0,4 postotnih poena u odnosu na model grupe 1. Točnost predviđanja uspješnih poduzeća je 96,5% (povećanje od 0,4 p.p u odnosu na model grupe 1),

a točnost predviđanja poduzeća sa poteškoćama iznosi 73,4% što predstavlja povećanje od 0,5 postotnih poena u odnosu na prethodni model grupe 1.

Tablica 4.21 Prikaz točnosti predviđanja modela grupe 1.1 (ukupna imovina do 800.000 EUR)

Promatrane grupe		Predviđanje		
		Klasifikacija		
		0	1,0	Postotak točnosti
Status	0 - Uspješna poduzeća	409	15	96,5
	1 - Poduzeća s poteškoćama	33	91	73,4
Ukupni postotak				91,2

Izvor: Izrada autora u SPSS-u

Prikaz parametara te njihove signifikantnosti (tablica 4.22) u ovom modelu predviđanja poslovnog neuspjeha ukazuje na to kako u grupi poduzeća s ukupnom imovinom do 800.000 EUR najveći utjecaj imaju pokazatelji tekuće likvidnosti i stupnja samofinanciranja.

Tablica 4.22 Prikaz parametara i signifikantnosti nezavisnih varijabli prilagođenog modela grupe 1.1

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	0,007	0,008	0,631	1	0,427	1,007
ROA	-0,025	0,028	0,825	1	0,364	0,975
EBIT marža	-0,012	0,011	1,176	1	0,278	0,988
Obrtaj imovine	-0,020	0,024	0,741	1	0,389	0,980
Tekuća likvidnost	0,082	0,020	17,774	1	0,000	1,086
Stupanj samofinanciranja	-0,125	0,012	101,124	1	0,000	0,882
Konstanta	4,601	0,558	67,994	1	0,000	99,633

Izvor: Izrada autora u SPSS-u

Izračunata vrijednost Nagelkerke R^2 od 68,5% ukazuje na postojanje umjereno jake veze između korištenih varijabli tj. financijskih pokazatelja i predviđanja poslovnih neuspjeha (tablica 4.23)

Tablica 4.23 Prikaz jakosti veze varijabli i predviđanja neuspješnosti

Step	-2 Log likelihood	Cox & Snell R^2	Nagelkerke R^2
1	258,648[a]	0,450	0,685

Izvor: Izrada autora u SPSS-u

Rezultati grupe 1.2 – ukupna imovina od 800.000 EUR do 4.500.000 EUR

Kod primjene modela logističke regresije na podatcima grupe 1.2 s imovinom u rasponu od 800.000 EUR do 4.500.000 EUR ukupna točnost predviđanja iznosi 90,9% odnosno povećanje od 0,2 postotna poena u odnosu na prethodni model grupe . Točnost predviđanja poduzeća s poteškoćama iznosi 75,5% što predstavlja povećanje od 2,6 postotna poena u odnosu na prethodni model grupe 1. Pregled točnosti predviđanja za grupu 1.2 prikazan je u sljedećoj tablici:

Tablica 4.24 Prikaz točnosti predviđanja modela grupe 1.2 (ukupna imovina od 800.000 EUR do 4.500.000 EUR)

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	159	7	95,8
	1 - Poduzeća s poteškoćama	13	40	75,5
Ukupan postotak				90,9

Izvor: Izrada autora u SPSS-u

U usporedbi s rezultatima i značajem varijabli iz grupe 1.1 poduzeća s ukupnom imovinom do 800.000 EUR primijećeno je povećanje utjecaja varijable obrtaja imovine i smanjenje utjecaja tekuće likvidnosti.

Tablica 4.25 Prikaz parametara i signifikantnosti nezavisnih varijabli prilagođenog modela grupe 1.2

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	0,020	0,017	1,509	1	0,219	1,021
ROA	-0,151	0,078	3,775	1	0,052	0,860
EBIT marža	0,014	0,024	0,309	1	0,578	1,014
Obrtaj imovine	-0,090	0,052	3,040	1	0,081	0,914
Tekuća likvidnost	-0,066	0,206	0,103	1	0,749	0,936
Stupanj samofinanciranja	-0,131	0,024	30,604	1	0,000	0,878
Konstanta	5,483	1,069	26,309	1	0,000	240,519

Izvor: Izrada autora u SPSS-u

Izračunata vrijednost Nagelkerke R^2 od 68,0% ukazuje na postojanje umjereno jake veze između korištenih varijabli tj. financijskih pokazatelja i predviđanja poslovnih neuspjeha (tablica 4.26).

Tablica 4.26 Prikaz jakosti veze varijabli i predviđanja neuspješnosti grupe 1.2

Step	-2 Log likelihood	Cox & Snell R^2	Nagelkerke R^2
1	109,503[a]	0,455	0,680

Izvor: Izrada autora u SPSS-u

Usporedbom rezultata primjene logističke regresije na modelu grupe 1 te zasebno na modelima grupe 1.1 i 1.2 dolazi se do zaključka kako postoji povećanje u točnosti predviđanja u grupi ali nije značajno.

Rezultati grupe 2.1 – ukupna imovina od 4.500.000 EUR do 10.000.000 EUR

Model predviđanja logističkom regresiji na grupi 2.1 poduzeća s ukupnom imovinom od 4.500.000 do 10.000.000 EUR je pokazao značajna povećanja u odnosu na prethodne modele (tablica 4.27). Kod primjene logističke regresije na ovoj grupi ukupna točnost predviđanja iznosi 97% što predstavlja povećanje od 4,1 postotna poena u odnosu na prethodni model grupe 2. Točnost predviđanja poslovnog neuspjeha za poduzeća s poteškoćama u poslovanju iznosi 90.5% što predstavlja povećanje od 13 postotnih poena u odnosu na prethodni model grupe 2.

Tablica 4.27 Prikaz točnosti predviđanja modela grupe 2.1 (ukupna imovina od 4.500.000 do 10.000.000 EUR)

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	79	1	98,8
	1 - Poduzeća s poteškoćama	2	19	90,5
Ukupan postotak				97,0

Izvor: Izrada autora u SPSS-u

Parametri varijabli te njihove signifikantnosti u modelu predviđanja poslovnog neuspjeha pokazuju kako varijable ROE i ROA i dalje nisu značajne dok se utjecaj varijable Obrtaj imovine povećava. Stupanj financiranja i dalje ostaje kao vrlo značajna varijabla u modelu predviđanje neuspjeha (tablica 4.28).

Tablica 4.28 Prikaz parametara i signifikantnosti nezavisnih varijabli prilagođenog modela grupe 2.1

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	-0,011	0,057	0,036	1	0,849	0,989
ROA	0,007	0,459	0,000	1	0,988	1,007
EBIT marža	-0,297	0,350	0,720	1	0,396	0,743
Obrtaj imovine	-1,618	0,853	3,595	1	0,058	0,198
Tekuća likvidnost	-0,554	1,610	0,118	1	0,731	0,575
Stupanj samofinanciranja	-0,197	0,097	4,100	1	0,043	0,822
Konstanta	11,725	5,428	4,665	1	0,031	123636,826

Izvor: Izrada autora u SPSS-u

Izračunata vrijednost Nagelkerke R^2 od 86,1% ukazuje na postojanje jake veze između korištenih varijabli tj. financijskih pokazatelja i predviđanja poslovnih neuspjeha (tablica 4.29).

Tablica 4.29 Prikaz jakosti veze varijabli i predviđanja neuspješnosti

Step	-2 Log likelihood	Cox & Snell R^2	Nagelkerke R^2
1	22,372[a]	0,551	0,861

Izvor: Izrada autora u SPSS-u

Rezultati grupe 2.2 – ukupna imovina iznad 10.000.000 EUR

Primjenom metode logističke regresije na grupi 2.2 poduzeća s ukupnom imovinom iznad 10.000.000 EUR također dolazi do značajnih povećanja u točnosti predviđanja poslovnog neuspjeha koja u ovoj grupi za ukupno predviđanje iznosi 95,9%. Točnost predviđanja za poduzeća s poteškoćama iznosi 89,5% što predstavlja povećanje od 12 postotnih poena u odnosu na prethodni model razvijen na grupi 2 (poduzeća s ukupnom imovinom iznad

4.500.000 EUR). Prikaz točnosti predviđanja odnosno klasifikacije poduzeća za grupu 2.2 je prikazan tablicom 4.30.

Tablica 4.30 Prikaz točnosti predviđanja modela grupe 2.1 (ukupna imovina iznad 10.000.000 EUR)

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	76	2	97,4
	1 - Poduzeća s poteškoćama	2	17	89,5
Ukupan postotak				95,9

Izvor: Izrada autora u SPSS-u

Podaci iz tablice 4.31 upućuju na to da financijski pokazatelj obrtaj imovine raste ima uz stupanj samofinanciranja veliki utjecaj na model za predviđanje poslovnog neuspjeha poduzeća s ukupnom imovinom iznad 10.000.000 EUR. Usporedbom utjecaja varijable EBIT marža u ostalim modelima sa nižom ukupnom imovinom može se doći do zaključka kako ova varijabla ima najveći utjecaj upravo u poduzećima sa visokom ukupnom imovinom (iznad 10.000.000 EUR).

Tablica 4.31 Prikaz parametara i signifikantnosti nezavisnih varijabli prilagođenog modela grupe 2.2

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	-0,050	0,319	0,024	1	0,876	0,952
ROA	0,668	0,729	0,839	1	0,360	1,951
EBIT marža	-0,341	0,260	1,726	1	0,189	0,711
Obrtaj imovine	-10,050	3,929	6,541	1	0,011	0,000
Tekuća likvidnost	-0,374	0,745	0,252	1	0,616	0,688
Stupanj samofinanciranja	-0,276	0,114	5,819	1	0,016	0,759
Konstanta	24,118	9,411	6,567	1	0,010	29792623085,912

Izvor: Izrada autora u SPSS-u

Izračunata vrijednost Nagelkerke R^2 od 89,8% ukazuje na postojanje jake veze između korištenih varijabli tj. financijskih pokazatelja i predviđanja poslovnih neuspjeha (tablica 4.32).

Tablica 4.32 Prikaz jakosti veze varijabli i predviđanja neuspješnosti

Step	-2 Log likelihood	Cox & Snell R^2	Nagelkerke R^2
1	15,450[a]	0,564	0,898

Izvor: Izrada autora u SPSS-u

Usporedba rezultata grupiranja i daljnja razmatranja

Nakon definiranja osnovnog modela te usporedbe istog sa modelima namijenjenima za različite grupe poduzeća koji se razlikuju po visini ukupne imovine dolazi se do zaključka kako dodatnim grupiranjem dolazi do povećanja točnosti predviđanja poslovne neuspješnosti i to ponajviše kod poduzeća sa visinom kapitala iznad 4.500.000 EUR-a. U osnovnom modelu primjenjivom na sva poduzeća točnost klasifikacije poduzeća s poteškoćama iznosi 72,4% dok se primjenom grupiranja točnost povećala na 73,4% za poduzeća ukupne imovine do 800.000 EUR. Točnost predviđanja za poduzeća s poteškoćama ukupne imovine od 800.000 EUR do 4.500.000 EUR iznosila je 75,5%, a za poduzeća ukupne imovine od 4.500.000 EUR do 10.000.000 EUR točnost predviđanja neuspjeha iznosi 90,5% što predstavlja povećanje od čak 18.1 postotnih poena u odnosu na preciznost osnovnog modela. Kod grupiranja poduzeća u ona s ukupnom imovinom iznad 10.000.000 EUR preciznost predviđanja poduzeća s poteškoćama iznosi 89,5% što je razlika od 17,1 postotnih poena u odnosu na osnovni model (tablica 4.33).

Razmatranjem Nagelkerke R^2 vrijednosti također se primjećuje kako jakost veze između odabranih varijabli kod osnovnog modela raste kod grupiranja poduzeća u nekoliko grupa prema kriteriju visine ukupne imovine. U osnovnom modelu vrijednost Nagelkerke R^2 iznosi 65.7%, kod modela za poduzeća ukupne imovine ispod 800.000 EUR iznosi 68.4%, a za model grupe poduzeća od 800.000 EUR do 4.500.000 EUR iznosi 67,9%. Značajnije razlike su prisutne u modelu poduzeća ukupne imovine od 4.500.000 EUR do 10.000.000 EUR gdje Nagelkerke R^2 vrijednost iznosi čak 86,1%, a kod modela za predviđanje poslovnog neuspjeha poduzeća ukupne imovine iznad 10.000.000 EUR vrijednost Nagelkerke R^2 je 89,8% što potvrđuje vrlo jaku vezu između odabranih varijabli i modela predviđanja poslovnog neuspjeha.

Tablica 4.33 Prikaz točnosti predviđanja osnovnog modela i modela po različitim grupama ukupne imovine

Promatrane grupe			Predviđanje			Nagelkerke R^2
			Klasifikacija		Postotak točnosti	
			0	1,0		
Osnovni model	Status	0 - Uspješna poduzeća	715	28	96,2	0,6576681
		1 - Poduzeća s poteškoćama	60	157	72,4	
	Ukupan postotak				90,8	
Grupa 1 - ukupna imovina do 4.500.000 EUR	Status	0 - Uspješna poduzeća	562	23	96,1	0,6773567
		1 - Poduzeća s poteškoćama	48	129	72,9	
	Ukupan postotak				90,7	
Grupa 2 - ukupna imovina iznad 4.500.000 EUR	Status	0 - Uspješna poduzeća	153	5	96,8	0,7915837
		1 - Poduzeća s poteškoćama	9	31	77,5	
	Ukupan postotak				92,9	
Grupa 1.1- ukupna imovina ispod 800.000 EUR	Status	0 - Uspješna poduzeća	409	15	96,5	0,6848389
		1 - Poduzeća s poteškoćama	33	91	73,4	
	Ukupan postotak				91,2	
Grupa 1.2- ukupna imovina od 800.000 EUR do 4.500.000 EUR	Status	0 - Uspješna poduzeća	159	7	95,8	0,6795646
		1 - Poduzeća s poteškoćama	13	40	75,5	
	Ukupan postotak				90,9	
Grupa 2.1- ukupna imovina od 4.500.000 EUR do 10.000.000 EUR	Status	0 - Uspješna poduzeća	79	1	98,8	0,8606816
		1 - Poduzeća s poteškoćama	2	19	90,5	
	Ukupan postotak				97,0	
Grupa 2.2- ukupna imovina iznad 10.000.000 EUR	Status	0 - Uspješna poduzeća	76	2	97,4	0,8977891
		1 - Poduzeća s poteškoćama	2	17	89,5	
	Ukupan postotak				95,9	

Izvor: Izrada autora

S obzirom na to da su nastala puno značajnija poboljšanja točnosti predviđanja kod grupe poduzeća ukupne imovine iznad 4.500.000 EUR-a nego kod poduzeća ukupne imovine ispod 4.500.000 EUR postavlja se pitanje da li je moguće dodatno utjecati na povećanje preciznosti modela predviđanja neuspjeha za poduzeća s ukupnom imovinom manjom od 4.500.000 EUR ukoliko se koristi neka druga vrijednost ukupne imovine za grupiranje. Uzorak grupe 1 koji

obuhvaća poduzeća ukupne imovine ispod 4.500.000 EUR sadrži 762 poduzeća te će se ovaj put za dodatno grupiranje uzeti vrijednost ukupne imovine od 250.000 EUR-a. Na taj način definira se grupa od 342 poduzeća sa vrlo malom visinom ukupne imovine (grupa 1.1_{VM}) do 250.000 EUR te druga grupa sa 420 malih poduzeća ukupne imovine od 250.000 do 4.500.000 EUR (grupa 1.1_{M}).

Primjenom logističke regresije na grupi vrlo malih poduzeća dobiva se model sa ukupnom točnošću predviđanja od 93,6%. Model je uspješno klasificirao 79,2% poduzeća s poteškoćama što predstavlja povećanje preciznosti za 6,8 postotnih poena u odnosu na osnovni model (odnosno dodatno povećanje od 5,8 postotnih poena u odnosu na model grupe 1.1 za poduzeća do 800.000 EUR).

Tablica 4.34 Prikaz točnosti predviđanja modela grupe 1.1_{VM} (ukupna imovina do 250.000 EUR)

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	259	6	97,7
	1 - Poduzeća s poteškoćama	16	61	79,2
Ukupan postotak				93,6

Izvor: Izrada autora u SPSS-u

Izračunata Nagelkerke R^2 vrijednost od 71.1% ukazuje na umjereno jaku vezu između varijabli i modela predviđanja neuspjeha.

Tablica 4.35 Prikaz jakosti veze varijabli i predviđanja neuspješnosti grupe 1.1_{VM}

-2 Log likelihood	Cox & Snell R Square	Nagelkerke R^2
150,033[a]	0,466	0,711

Izvor: Izrada autora u SPSS-u

Prikaz parametara varijabli i njihove signifikantnosti u modelu predviđanja poslovnog neuspjeha prikazuju kao što je i očekivano s obzirom na prethodne rezultate malih poduzeća kako su najutjecajnije varijable u skupini vrlo malih poduzeća tekuća likvidnost i stupanj samofinanciranja. Prikaz parametara u modelu predviđanja poslovnog neuspjeha za poduzeća ukupne imovine do 250.000 EUR prikazan je u tablici 4.36.

Tablica 4.36 Prikaz parametara i signifikantnosti nezavisnih varijabli prilagođenog modela grupe 1.1_{VM}

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	0,008	0,011	0,493	1	0,483	1,008
ROA	0,020	0,033	0,367	1	0,545	1,020
EBIT marža	-0,023	0,013	3,003	1	0,083	0,977
Obrtaj imovine	-0,011	0,033	0,115	1	0,735	0,989
Tekuća likvidnost	0,097	0,021	21,548	1	0,000	1,102
Stupanj samofinanciranja	-0,138	0,018	57,856	1	0,000	0,871
Konstanta	4,802	0,774	38,465	1	0,000	121,731

Izvor: Izrada autora u SPSS-u

Za poduzeća ukupne imovine u rasponu od 250.000 EUR do 4.500.000 EUR uporabom logističke regresije dolazi se do modela sa ukupnom točnošću predviđanja od 91% (zanemarivo povećanje od 0,2 postotna poena u odnosu na osnovni model). Točnost predviđanja poduzeća s poteškoćama iznosi 76% što je povećanje od 3,6 postotna poena u odnosu na osnovni model.

Tablica 4.37 Prikaz točnosti predviđanja modela grupe 1.1_{M} (ukupna imovina od 250.000 do 4.500.000 EUR)

Promatrane grupe		Predviđanje		
		Klasifikacija		Postotak točnosti
		0	1,0	
Status	0 - Uspješna poduzeća	306	14	95,6
	1 - Poduzeća s poteškoćama	24	76	76,0
Ukupan postotak				91,0

Izvor: Izrada autora u SPSS-u

Izračunata vrijednost Nagelkerke R_2 iznosi 69%. te nema značajne promjene u odnosu na prethodni model grupe 1.

Tablica 4.38 Prikaz jakosti veze varijabli i predviđanja neuspješnosti grupe 1.1_{M}

Step	-2 Log likelihood	Cox & Snell R^2	Nagelkerke R^2
1	202,645[a]	0,460	0,690

Izvor: Izrada autora u SPSS-u

Parametri varijabli te signifikantnost na model predviđanja ukazuju na to da je stupanj samofinanciranja i dalje značajna varijabla dok utjecaj varijable obrtaj imovine i ROA raste u odnosu na prethodni model sa vrlo niskom ukupnom imovinom.

Tablica 4.39 Prikaz parametri i signifikantnosti nezavisnih varijabli prilagođenog modela grupe 1.1_M

Nezavisne varijable	Parametar	Standardna greška	Wald	df	Sig.	Exp(B)
ROE	0,018	0,011	2,694	1	0,101	1,018
ROA	-0,117	0,040	8,711	1	0,003	0,890
EBIT marža	0,002	0,015	0,010	1	0,918	1,002
Obrtaj imovine	-0,105	0,040	6,686	1	0,010	0,901
Tekuća likvidnost	-0,189	0,174	1,177	1	0,278	0,828
Stupanj samofinanciranja	-0,122	0,016	59,344	1	0,000	0,885
Konstanta	5,387	0,736	53,572	1	0,000	218,638

Izvor: Izrada autora u SPSS-u

Temeljem provedenih istraživanja na uzorku i grupiranjem poduzeća prema različitim visinama ukupne imovine može se zaključiti kako posebno prilagođeni modeli za pojedinu veličinu poduzeća daju preciznija predviđanja u odnosu na jedan jedinstveni model za sve veličine poduzeća. Jedna od optimalnijih grupacija poduzeća prema visini imovine u svrhu povećanje preciznosti predviđanja poslovnog neuspjeha postignuta je raščlanjivanjem poduzeća na 4 grupe (kao što je prikazano u tablici 4.40).

Razmatrajući podatke navedene u tablici 4.40 potvrđuje se hipoteza o povećanju točnosti predviđanja poslovnog neuspjeha grupiranjem poduzeća u nekoliko skupina prema njihovoj veličini. Osnovni model izveden logističkom regresijom je rezultirao sa točnošću predviđanja poslovnog neuspjeha od 72,4% dok se kod ostalih modela definiranih prema određenoj grupi poduzeća (uzimajući u obzir visinu njihove ukupne imovine) točnost predviđanja neuspjeha povećala u odnosu na osnovni model.

Tablica 4.40 Prikaz točnosti predviđanja osnovnog modela i 4 zasebna modela prema grupama s različitom visinom ukupne imovine

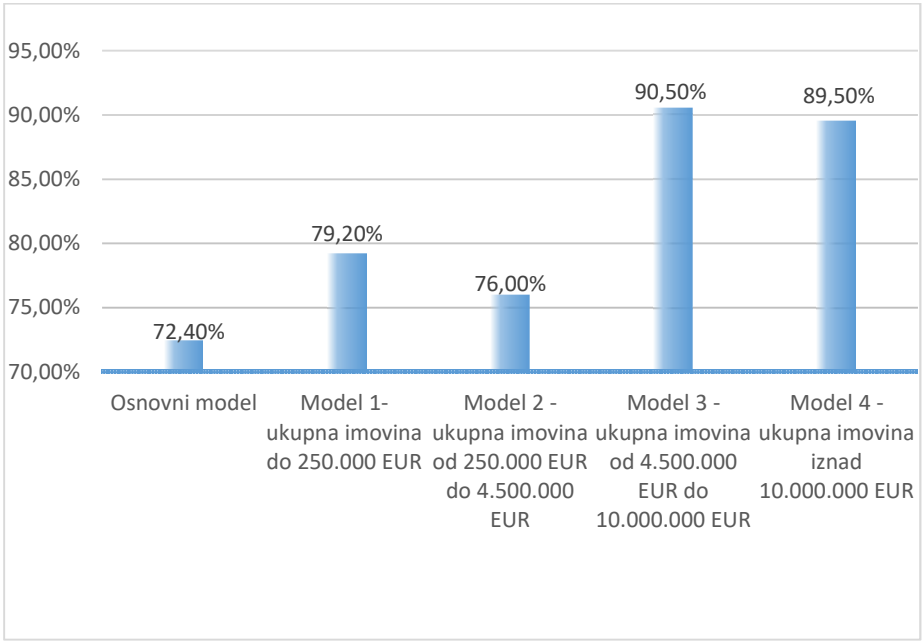
Promatrane grupe			Predviđanje			
			Klasifikacija		Postotak točnosti	Nagelkerke R^2
			0	1,0		
Osnovni model	Status	0 - uspješna poduzeća	715	28	96,2	0,658
		1 - poduzeća s poteškoćama	60	157	72,4	
	Ukupni postotak				90,8	
Grupa 1 - ukupna imovina ispod 250.000 EUR	Status	0 - uspješna poduzeća	259	6	97,7	0,711
		1 - poduzeća s poteškoćama	16	61	79,2	
	Ukupni postotak				93,6	
Grupa 2 - ukupna imovina od 250.000 EUR do 4.500.000 EUR	Status	0 - uspješna poduzeća	306	14	95,6	0,690
		1 - poduzeća s poteškoćama	24	76	76,0	
	Ukupni postotak				91,0	
Grupa 3 - ukupna imovina od 4.500.000 do 10.000.000 EUR	Status	0 - uspješna poduzeća	79	1	98,8	0,861
		1 - poduzeća s poteškoćama	2	19	90,5	
	Ukupni postotak				97,0	
Grupa 4 - ukupna imovina iznad 10.000.000 EUR	Status	0 - uspješna poduzeća	76	2	97,4	0,898
		1 - poduzeća s poteškoćama	2	17	89,5	
	Ukupni postotak				95,9	

Izvor: Izrada autora

Manji porast točnosti predviđanja poslovnog neuspjeha zabilježen je na skupinama poduzeća s ukupnom imovinom do 4.500.000 EUR-a koji za poduzeća s ukupnom imovinom do 250.000 EUR iznosi 79,2% (povećanje od 6.8 postotnih poena u odnosu na osnovni model), a u skupini s ukupnom imovinom od 250.000 EUR do 4.500.000 EUR točnost predviđanja poslovnog neuspjeha iznosi 76%.

Značajnije povećanje predviđanja poslovnog neuspjeha nastaje kod poduzeća s ukupnom imovinom od 4.500.000 EUR do 10.000.000 EUR gdje točnost predviđanja iznosi 90,5% (porast od 18,1 postotnih poena). Kod skupine poduzeća s ukupnom imovinom iznad 10.000.000 EUR točnost predviđanja prilagođenog modela iznosi 89,5% što predstavlja porast od 17.1 postotnih poena u odnosu na osnovni model).

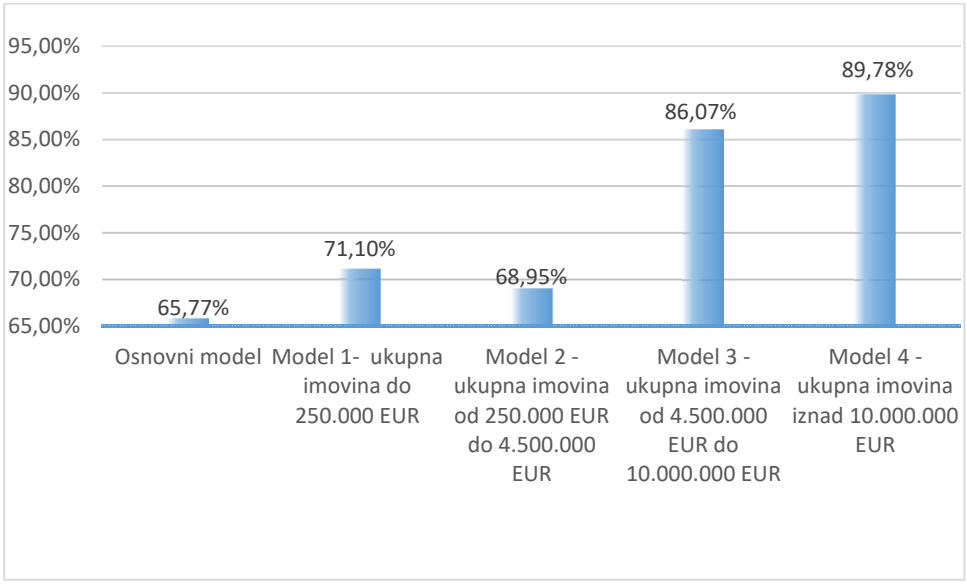
Grafički prikaz 4.41 Usporedba postotka točnosti predviđanja poslovnog neuspjeha kod različitih modela



Izvor: izrada autora

S obzirom da se Nagelkerke R^2 koristi kao mjera prikladnosti modela uspoređene su i izračunate vrijednosti Nagelkerke R2 pojedinih modela po skupinama. Jakost veze između varijabli i sposobnosti predviđanja poslovnog neuspjeha kod osnovnog modela iznosi 65,77% dok kod modela prilagođenog za poduzeća ukupne imovine do 250.000 EUR iznosi 71,1%, odnosno 68,95% kod modela namijenjenog poduzećima ukupne imovine od 250.000 EUR do 4.500.000 EUR. Do značajnijeg porasta vrijednosti mjere prikladnosti modela dolazi kod primjene modela prilagođenih za poduzeća ukupne imovine iznad 4.500.000 EUR. Kod modela namijenjenog za poduzeća ukupne imovine od 4.500.000 EUR do 10.000.000 EUR vrijednost Nagelkerke R^2 iznosi 86,07% što predstavlja povećanje od 20,03 postotna poena u odnosu na osnovni model. Izračunata vrijednost Nagelkerke R^2 kod modela namijenjenog poduzećima ukupne imovine iznad d 10.000.000 EUR iznosi 89,78% što predstavlja povećanje prikladnosti modela od čak 24,01 postotna poena. Uspoređene vrijednosti Nagelkerke R^2 kod primjene na modelima različitih skupina poduzeća prema ukupnoj imovini su prikazane u grafičkom prikazu 4.42.

Grafički prikaz 4.42 Usporedba vrijednosti Nagelkerke R^2 kod osnovnog modela i modela za pojedine skupine poduzeća



Izvor: izrada autora

5. ZAKLJUČAK

Predviđanje poslovnog neuspjeha je uvijek aktualna tema te se već duži niz godina provede mnoga istraživanja uz korištenje različitih statističkih metoda kako bi se oblikovao model sa što većom preciznošću predviđanja poslovnog neuspjeha. U uvjetima povećane nelikvidnosti i financijske nestabilnosti raste i interes za takvim modelima. Rezultati modela mogu služiti kao ocjena financijskog rejting poduzeća, te kao pomoć u poslovnom odlučivanju, odabiru novih poslovnih partnera, odluke o kreditiranjem određenih poduzeća, itd.

Upravo zbog različitosti u vrstama djelatnosti, veličinama poduzeća i gospodarskim uvjetima unutar određene države dolazi i do različitih empiričkih rezultata, te nije moguće oblikovati jedinstven model sa stopostotnom preciznošću za sva poduzeća. U ranim fazama istraživanja postojao je veći broj istraživanja temeljen na financijskim podacima velikih poduzeća dok je s vremenom porastao i interes za izradu modela predviđanja poslovnog neuspjeha malih i srednjih poduzeća.

Cilj ovog rada je bio oblikovanje jednog osnovnog modela za predviđanje poslovnog neuspjeha uz upotrebu metode logističke regresije na uzorku proizvodnih poduzeća u Hrvatskoj, te usporedba rezultata tog modela sa posebno razvijenim modelima za pojedine skupine poduzeća uzimajući u obzir njihovu veličinu odnosno visinu ukupne imovine kojom raspolažu.

Rezultati istraživanja su pokazali kako grupiranjem poduzeća u nekoliko skupina uz korištenje kriterija veličine poduzeća tj. visine ukupne imovine poduzeća kod razvrstavanja poduzeća u različite skupine, te upotrebom metode logističke regresija na pojedinu skupinu rezultira sa povećanjem točnosti predviđanja poslovnog neuspjeha u odnosu na osnovni model primijenjen na poduzeća svih veličina. Primjenom modela prilagođenih za poduzeća ukupne imovine do 4.500.000 EUR dolazi do povećanja od nekoliko postotnih poena dok kod primjene modela za poduzeća ukupne imovine iznad 4.500.000 EUR dolazi do vrlo značajnih povećanja preciznosti predviđanja poslovnog neuspjeha koja iznose i do 18 postotnih poena.

LITERATURA

1. Altman, E., (1973): Predicting Railroad Bankruptcies in America, Bell Journal of Economics and Management Service, Vol. 4, Issue 1, str. 184-211.
2. Altman, I., Sabato, G. (2007): Modeling Credit Risk for SMEs: Evidence from the US Market, Abacus, vol. 43, issue 3, str.332-357.
3. Altman, I., Sabato, G., Wilson N., (2008): The Value of Non-Financial Information in SME Risk Management, raspoloživo na : https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1320612
4. Altman, E.I., Hotchkiss, E. (2006): Corporate financial distress and bankruptcy: predict and avoid bankruptcy, analyze and invest in distressed debt, 3rd Edition, Wiley Finance, New York, U.S.A.
5. Altman, E., Laitinen, E. K., Iwanicz-Drozdowska, M., Suvas, A., (2014): Firm and Bankruptcy prediction in an international context: a review and empirical analysis of Altman's Z-Score Model, raspoloživo na: http://dx.doi.org/10.2139/ssrn.2536340
6. Bahtijarević-Šiber, F. (2001): Leksikon menadžmenta, Zagreb, Masmedia
7. Beaver, W., (1966): Financial Ratios as Predictor of Failure, Journal of Accounting Research, Vol 4, Empirical Research in Accounting, str. 71-111.
8. Belak, V., Aljinović Barać, Ž. (2007): Business excellence (BEX) indeks – za procjenu poslovne izvrsnosti tvrtki na tržištu kapitala u Republici Hrvatskoj, RRiF br.10, str. 15-25.
9. Bešvir, B., (2010): Bonitest brza provjera boniteta poduzetnika, RRiF br.11, str. 96-100.
10. Carter, R., Van Auken, H., (2006): Smal firm bankruptcy, Journal of Small Business Management, br. 44, str. 493-512.
11. Chuvakhin, N.V., Gertmenian, L.W. (2003): Predicting Bankruptcy in the WorldCom Age, Graziadio Business Review, Vol. 3, Issue1 (članak dostupan na https://gbr.pepperdine.edu/2010/08/predicting-bankruptcy-in-the-worldcom-age/)
12. Ciampi, F., Gordini, N. (2008): Using economic-financial ratios for small enterprise default prediction modelling: an empirical analysis, Oxford Business & Economics, Conference Program, str. 1-21., 22-24.

13. Deakin, E. (1972): A discriminant analysis of predictors of business failure, Journal of accounting research, str. 167.
14. Edminster, R.O., (1972), Can Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction", Journal of Financial and Quantitative Analysis, March, 1477 - 1493.
15. Habek, M. (1984).: Računovodstvo, Narodne novine, Zagreb
16. Hair, F. Jr., Black, W.C., Barry, J. B., Anderson, R.E. (2009): Multivariate Data Analysis, Publisher: Pearson, Harlow, Ujedinjeno Kraljevstvo
17. Ivičić, L., Cerovac, S. (2009): Znanstveni članak; Procjena kreditnog rizika poduzeća u Hrvatskoj, Financijska teorija i praksa, Vol.33 br. 4.
18. Kavur, V. (2013): Bonitetne informacije za procjenu rizika poslovnog odnosa RriF br. 5, str. 91 – 92.
19. Kozjak, K., Šestanj Perić T., Bešvir B. (2014): Assessment of bankruptcy prediction models - Applicability in Croatia, An Enterprise Odyssey, International Conference Proceedings, str. 543-561.
20. Leko, V.(1996); Procjena boniteta trgovačkog društva, Masmedia, Zagreb
21. Lennox, C. (1999): Identifying failing companies: a reevaluation of the logit, probit and DA approaches, Journal of Economics and Business, Vol. 51, str. 347-364.
22. Lugovskaya, L. (2010): Predicting default of Russian SMEs on the basis of financial and non-financial variables, Journal of Financial Services Marketing, Vol. 14, 4, str. 301–313.
23. Ljubic, D. (2004): Modeli za ocjenu boniteta poslovnih partnera, RRiF br. 6, str. 52-60.
24. Ohlson, J. (1980): Financial ratios and the probabilistic prediction of bankruptcy, Journal of Accounting Research, br.18, str. 109-131.
25. Osmanagić Bedenik, N. (2003): Rejting kao suvremeni instrument ocjene boniteta, RRiF br.3, str. 74-80.
26. Osmanagić Bedenik, N. (2003): Instrumenti analize i ocjene boniteta, RRiF br. 9, str. 66-80.
27. Pervan, I., Filipović, D. (2010): FP rating – model za predviđanje (in) solventnosti poslovnih partnera, RRiF br.7, str. 92-96.
28. Pervan, I., Peko, B. (2008.): Financijski pokazatelji u bankarskim modelima za procjenu boniteta trgovačkih društva, RRiF br. 9, str. 35-42.

29. Pervan, I., Kuvek, T. (2013): The relative importance of financial ratios and nonfinancial variables in predicting of insolvency, Croatian Operational Research Review (CRORR), Vol.4, str. 187-197.
30. Pervan, I., Pervan, M., Vukoja, B. (2011): Prediction of company bankruptcy using statistical techniques – case of Croatia, Croatian Operational Research Review (CRORR), Vol.2, str. 158-167.
31. Pervan, I. (2017): Predviđanje poslovnog neuspjeha, RRiF br.7, str. 160-167.
32. Pervan, I. (2017): Predviđanje stečaja - SME proizvodna poduzeća u Hrvatskoj, Zbornik radova Veleučilišta u Šibeniku, No.3-4.
33. Polo, A., Caca, E. (2014): Kralicek quick test – an analysis tool for economic units determination in liability difficulty, European Scientific Journal, July, Vol.10. nr.19. str. 142-152.
34. Shumway, T. (1999): Forecasting Bankruptcy More Accurately: A Simple Hazard Model, The Journal of Business, Vol 74, no.1, str. 101-24.
35. Šarlija, N., Penavin, S., Harc, M. (2009): Pregledni rad: Predviđanje nelikvidnosti poduzeća u Hrvatskoj, Zbornik Ekonomskog fakulteta u Zagrebu, br.2, str. 21-36.
36. TEB-poslovno savjetovanje (2011): Međunarodni standardi financijskog izvještavanja, prijevod s engleskog jezika, Tiskara Zelina d.d., Zagreb
37. Vidučić, Lj. (2006): Financijski menadžment, RRIF-plus d.o.o. za nakladništvo i poslovne usluge, Zagreb
38. Zakon o računovodstvu, pročišćeni tekst, Narodne Novine, (Nar.nov., 78/15, 134/15)
39. Zenzerović, R., Peruško, T. (2006): Kratki osvrt na modele za predviđanje stečaja, Economic research - Ekonomska istraživanja, Vol.19 No.2, str. 132-151.
40. Zenzerović, R., Peruško, T. (2009): Business financial problems prediction - Croatian experience, Economic Research-Ekonomska Istraživanja, Volume 22, Issue 4. str. 1-15.
41. Zmijewski, E. (1984): Methodological Issues Related to the Estimation of Financial Distress Prediction Models, Journal of Accounting Research, vol. 22, Studies on Current Econometric Issues in Accounting Research str. 59-82.
42. Žager, K., Žager, L. (1999): Analiza financijskih izvještaja, Masmedia, Zagreb.

SAŽETAK

Predviđanje poslovnog neuspjeha je uvijek aktualna tema te se već duži niz godina provode mnoga istraživanja uz korištenje različitih statističkih metoda kako bi se oblikovao model sa što većom preciznošću predviđanja poslovnog neuspjeha. Kroz ovaj rad objašnjena je važnost bonitetne informacije, temeljna financijska izvješća i financijski pokazatelji te je izvedeno istraživanje u svrhu izrade osnovnog modela predviđanja poslovnog neuspjeha i usporedbe sa zasebnim modelima za predviđanje poslovnog neuspjeha prilagođenih za različite veličine poduzeća uzimajući pri tom visinu ukupnoe imovine kao kriterij za razvrstavanje poduzeća u skupine. Istraživanje je provedeno na temelju dostupnih financijskih informacija 989 poduzeća proizvodnog sektora u Hrvatskoj. Financijski pokazatelji korišteni kao varijable u modelima za predviđanje su: ROA, ROE, EBIT marža, obrtaj imovine, tekuća likvidnost i stupanj samofinanciranja. Empirijsko istraživanje je pokazalo da se točnost predviđanja poslovnog neuspjeha može povećati grupiranjem poduzeća u različite skupine prema visini ukupne imovine i primjenom metode logističke regresije na svaku skupinu zasebno. Točnost predviđanja poslovnog neuspjeha u modelima prilagođenim za poduzeća određene visine imovine je bila veća za 3,6 postotnih poena do čak 18,10 postotnih poena za određene skupine u odnosu na osnovni model korišten za sve veličine poduzeća.

Ključne riječi: *model predviđanja, poslovni neuspjeh, financijsku pokazatelji, točnost predviđanja, proizvodni sektor, logistička regresija.*

SUMMARY

Prediction of business failure is always a topical issue and has been carrying out many researches for many years using various statistical methods in order to shape the model with the most accuracy in predicting a business failure. This thesis explains the importance of prudent information, main financial statements, financial indicators and presents research carried out for the purpose of creating a basic model of business failure prediction and comparison with separate models for predicting business failure for different size of companies using the amount of total assets as criteria for sorting the companies in groups. The research was conducted based on available financial information of 989 companies in the manufacturing sector in Croatia. The financial indicators used as variables in the prediction models are: ROA, ROE, EBIT margin, asset turnover, current liquidity and self-financing rate. The empirical research has shown that the accuracy of predicting a business failure can be increased by sorting companies into different groups by the amount of total assets and by applying the logistic regression method to each group separately. The accuracy of predicting a business failure in models adjusted for companies of certain asset amount was higher by 3.6 percentage points to 18.10 percentage points for particular groups compared to the basic model used for all sizes of companies.

Key words: *prediction model, business failure, financial indicators, prediction accuracy, manufacturing sector, logistic regression.*