



**UNIVERZITET U NOVOM SADU
EKONOMSKI FAKULTET U SUBOTICI**



**STUDIJSKI MODUL:
POSLOVNE FINANSIJE,
RAČUNOVODSTVO I REVIZIJA**

PREDIKCIJA STEČAJA MALIH I SREDNJIH ENTITETA U REPUBLICI SRBIJI

DOKTORSKA DISERTACIJA

**Mentor:
Prof. dr Bojana Vuković**

**Kandidat:
Denis Kušter**

Subotica, 2024. godina



**UNIVERZITET U NOVOM SADU
EKONOMSKI FAKULTET U SUBOTICI**



**STUDIJSKI MODUL:
POSLOVNE FINANSIJE,
RAČUNOVODSTVO I REVIZIJA**

PREDIKCIJA STEČAJA MALIH I SREDNJIH ENTITETA U REPUBLICI SRBIJI

DOKTORSKA DISERTACIJA

Mentor:
Prof. dr Bojana Vuković

Kandidat:
Denis Kušter

Subotica, 2024. godina

KLJUČNA DOKUMENTACIJSKA INFORMACIJA¹

Vrsta rada:	Doktorska disertacija
Ime i prezime autora:	Denis Kušter
Mentor (titula, ime, prezime, zvanje, institucija)	Prof. dr Bojana Vuković, vanredni profesor, Ekonomski fakultet u Subotici, Univerzitet u Novom Sadu
Naslov rada:	„Predikcija stečaja malih i srednjih entiteta u Republici Srbiji“
Jezik publikacije (pismo):	Srpski (latinica)
Fizički opis rada:	Uneti broj: Stranica 250 Poglavlja 7 Referenci 303 Tabela 58 Šema 3 Slika 40 Grafikona / Priloga 10
Naučna oblast:	Ekonomske nauke
Uža naučna oblast (naučna disciplina):	Finansijska analiza
Ključne reči / predmetna odrednica:	Stečaj, finansijska analiza, racio analiza, mali i srednji entiteti, ekonometrija, statistika, mašinsko učenje
Rezime na jeziku rada:	Brzi ritam savremenog poslovnog ambijenta, oštra konkurencija, opšta ekonomska neizvesnost i rizici stavljaju izazove pred kompanije, a pogotovo pred one koje su osetljivije i teže apsorbuju pomenute uticaje. Sve prethodno pomenuto čini predikciju stečaja ključnim aspektom upravljanja i donošenja odluka. Dok se tradicionalne metode ocene performansi preduzeća oslanjaju na racio analizu, te najčešće ispituju nekoliko ključnih aspekata poslovanja kao što su prinosni, imovinski i finansijski položaj, ova doktorska disertacija ispituje mogućnost da se u predikciji stečaja, pored finansijske racio analize, upotrebe i savremene metode kroz kombinovanje tradicionalnih statističkih metoda i algoritama mašinskog učenja sa ciljem razumevanja obrazaca u finansijskim i nefinansijskim podacima preduzeća. Na teritoriji Republike Srbije je do sada kreirana nekolicina modela predikcije stečaja na bazi finansijskih izveštaja, ali nijedan ne predviđa stečaj do dve godine unapred. Takođe nijedan model nije usmeren na mala i srednja preduzeća (MSP/MSE). Osnovni cilj disertacije jeste da utvrdi da li finansijska racio analiza u kombinaciji sa statističkim metodama i mašinskim učenjem može da rezultuje pouzdanim modelima predikcije

¹ Autor doktorske disertacije potpisao je i priložio sledeće Obrasce:

56 – Izjava o autorstvu;

5b – Izjava o istovetnosti štampane i elektronske verzije i o ličnim podacima;

5r – Izjava o korišćenju.

Ove Izjave se čuvaju na fakultetu u štampanom i elektronskom obliku i ne koriče se sa tezom.

	stečaja godinu (Y-1) i dve (Y-2) unapred. Istraživanje je sprovedeno na uzorku od 212 malih i srednjih preduzeća u Republici Srbiji, a isti je izbalansiran po uzoru na vladajuću literaturu, tako da je uključeno 106 solventnih preduzeća i 106 preduzeća koja su pokrenula stečajni postupak. Inicijalno je uključeno 66 nezavisnih varijabli (finansijskih i nefinansijskih), koje su pažljivo analizirane, tako da se smanji dimenzionalnost, te u modelovanje uključe samo one prediktor varijable koje zaista mogu dati doprinos predviđanju stečaja MSP. Kada je reč o statističkim metodama, korišćena je logistička regresija (LR) i diskriminantna analiza (DA), dok je kod mašinskog učenja upotrebljen algoritam neuronskih mreža (NN), stabala odlučivanja (DT) i k-najbližih suseda (KNN). Konačan rezultat istraživanja je 5 razvijenih modela predikcije stečaja godinu dana unapred (Y-1) čija tačnost na treningu ide i do 90%, te 5 modela predikcije stečaja dve godine unapred (Y-2), čija ukupna tačnost na treningu ide i do 76%. Testiranje modela je urađeno u skladu sa preporukama vodeće literature, te spram mogućnosti IBM-ovog SPSS softvera koji je korišćen. Dodatno, razvijeni modeli su upoređeni sa dobro poznatim Altman-ovim Z' skorom i EMS modelom i pokazali su bolje performanse od istih u oba vremenska horizonta. Razvojem modela predikcije stečaja omogućava se identifikovanje ranih upozoravajućih znakova koji ukazuju na postojanje finansijskih poteškoća, te omogućavaju stejkholderima da donesu bolje poslovne odluke i preduzmu proaktivne mere za unapređenje finansijskog zdravlja MSP. Pored toga, oslanjajući se na rezultate istraživanja, razvijeni modeli mogu poslužiti i regulatornim organima budući da mogu reagovati u pravcu unapređenja poslovnih uslova za MSP. Finansijske institucije, kreditori i investitori mogu da se oslone na modele predikcije stečaja za efikasnije upravljanje rizicima.
Datum prihvatanja teme od strane nadležnog veća	28.06.2024.
Datum odbrane (Popunjava odgovarajuća služba)	
Članovi komisije: (titula, ime, prezime, zvanje, institucija)	Predsednik: Član: Član:
Napomena:	

UNIVERSITY OF NOVI SAD
FACULTY OF ECONOMICS IN SUBOTICA

KEYWORD DOCUMENTATION²

Document type:	Doctoral Dissertation
Author:	Denis Kušter
Supervisor (title, first name, last name, position, institution)	Ph.D. Bojana Vuković, Associate Professor, Faculty of Economics in Subotica, University of Novi Sad
Thesis title:	„Bankruptcy Prediction of Small and Medium-Sized Entities in the Republic of Serbia“
Language of text (script):	Serbian language (Latin)
Physical description:	Number of: Pages 250 Chapters 7 References 303 Tables 58 Scheme 3 Illustrations 40 Graphs / Appendices 10
Scientific field:	Economic Sciences
Scientific subfield (scientific discipline):	Financial Analysis
Subject, Key words:	Bankruptcy, financial analysis, ratio analysis, SME, econometrics, statistics, machine learning
Abstract in English language:	The rapid pace of the modern business environment, fierce competition, general economic uncertainty, and associated risks present challenges for companies, especially for those that are more sensitive and struggle to absorb these influences. These factors make bankruptcy prediction a crucial aspect of management and decision-making. While traditional methods of evaluating company performance rely on ratio analysis, typically examining key business aspects such as profitability, assets, and financial position, this doctoral dissertation explores the possibility of utilizing contemporary methods in bankruptcy prediction. It combines traditional statistical methods with machine learning algorithms to uncover patterns in both financial and non-financial company data. In the Republic of Serbia, only a few bankruptcy prediction models based on financial statements have been developed so far, and to date, none predict bankruptcy up to two years in advance. Additionally, none of these models focus on small and medium-sized enterprises (SMEs). Since SMEs are essential drivers of the economy, especially in developing markets, predicting their bankruptcy is critically important. The primary objective of this dissertation is to examine if

² The author of doctoral dissertation has signed the following Statements:

56 – Statement on the authority,

5B – Statement that the printed and e-version of doctoral dissertation are identical and about personal data,

5r – Statement on copyright licenses.

The paper and e-versions of Statements are held at the faculty and are not included into the printed thesis.

	financial ratio analysis combined with statistical methods and machine learning results in reliable bankruptcy prediction models one (Y-1) and two years (Y-2) in advance. The research was conducted on a sample of 212 SMEs in Serbia, balanced according to prevailing literature, including 106 solvent companies and 106 companies that initiated bankruptcy proceedings. Initially, 66 independent variables (both financial and non-financial) were included, and carefully analyzed to reduce dimensionality, and only predictor variables that could genuinely contribute to predicting SME bankruptcy were included in the modeling. Regarding statistical methods, logistic regression (LR) and discriminant analysis (DA) were applied, while machine learning algorithms included neural networks (NN), decision trees (DT), and k-nearest neighbors (KNN). The final result of the research includes five developed bankruptcy prediction models one year in advance (Y-1) with a training accuracy of up to 90%, and five models predicting bankruptcy two years in advance (Y-2) with a training accuracy of up to 76%. Model testing followed leading literature recommendations and was conducted using IBM's SPSS software capabilities. Additionally, the developed models were compared with the well-known Altman Z'-score and EMS model, showing better performance than these in both time horizons. The development of bankruptcy prediction models enables the identification of early warning signs that indicate financial distress, allowing stakeholders to make better business decisions and take proactive measures to improve the financial health of SMEs. Furthermore, based on the research findings, these developed models can also assist regulatory bodies in enhancing business conditions for SMEs. Financial institutions, creditors, and investors can rely on bankruptcy prediction models for more effective risk management.
Accepted on Scientific Board on:	28 th of June, 2024.
Defended: (Filled by the faculty service)	
Thesis Defend Board: (title, first name, last name, position, institution)	President: Member: Member:
Note:	

APSTRAKT

Brzi ritam savremenog poslovnog ambijenta, oštra konkurencija, opšta ekonomska neizvesnost i rizici stavljaju izazove pred kompanije, a pogotovo pred one koje su osetljivije i teže apsorbuju pomenute uticaje. Sve prethodno pomenuto čini predikciju stečaja ključnim aspektom upravljanja i donošenja odluka. Dok se tradicionalne metode ocene performansi preduzeća oslanjaju na racio analizu, te najčešće ispituju nekoliko ključnih aspekata poslovanja kao što su prinosni, imovinski i finansijski položaj, ova doktorska disertacija ispituje mogućnost da se u predikciji stečaja, pored finansijske racio analize, upotrebe i savremene metode kroz kombinovanje tradicionalnih statističkih metoda i algoritama mašinskog učenja sa ciljem razumevanja obrazaca u finansijskim i nefinansijskim podacima preduzeća. Na teritoriji Republike Srbije je do sada kreirana nekolicina modela predikcije stečaja na bazi finansijskih izveštaja, ali nijedan ne predviđa stečaj do dve godine unapred. Takođe nijedan model nije usmeren na mala i srednja preduzeća (MSP/MSE). Osnovni cilj disertacije jeste da utvrdi da li finansijska racio analiza u kombinaciji sa statističkim metodama i mašinskim učenjem može da rezultuje pouzdanim modelima predikcije stečaja godinu (Y-1) i dve (Y-2) unapred. Istraživanje je sprovedeno na uzorku od 212 malih i srednjih preduzeća u Republici Srbiji, a isti je izbalansiran po uzoru na vladajuću literaturu, tako da je uključeno 106 solventnih preduzeća i 106 preduzeća koja su pokrenula stečajni postupak. Inicijalno je uključeno 66 nezavisnih varijabli (finansijskih i nefinansijskih), koje su pažljivo analizirane, tako da se smanji dimenzionalnost, te u modelovanje uključuje samo one prediktor varijable koje zaista mogu dati doprinos predviđanju stečaja MSP. Kada je reč o statističkim metodama, korišćena je logistička regresija (LR) i diskriminantna analiza (DA), dok je kod mašinskog učenja upotrebljen algoritam neuronskih mreža (NN), stabala odlučivanja (DT) i k-najbližih suseda (KNN). Konačan rezultat istraživanja je 5 razvijenih modela predikcije stečaja godinu dana unapred (Y-1) čija tačnost na treningu ide i do 90%, te 5 modela predikcije stečaja dve godine unapred (Y-2), čija ukupna tačnost na treningu ide i do 76%. Testiranje modela je urađeno u skladu sa preporukama vodeće literature, te spram mogućnosti IBM-ovog SPSS softvera koji je korišćen. Dodatno, razvijeni modeli su upoređeni sa dobro poznatim Altman-ovim Z' skorom i EMS modelom i pokazali su bolje performanse od istih u oba vremenska horizonta. Razvojem modela predikcije stečaja omogućava se identifikovanje ranih upozoravajućih znakova koji ukazuju na postojanje finansijskih poteškoća, te omogućavaju stejkholderima da donesu bolje poslovne odluke i preduzmu proaktivne mere za unapređenje finansijskog zdravlja MSP. Pored toga, oslanjajući se na rezultate istraživanja, razvijeni modeli mogu poslužiti i regulatornim organima budući da mogu reagovati u pravcu unapređenja poslovnih uslova za MSP. Finansijske institucije, kreditori i investitori mogu da se oslone na modele predikcije stečaja za efikasnije upravljanje rizicima.

ABSTRACT

The rapid pace of the modern business environment, fierce competition, general economic uncertainty, and associated risks present challenges for companies, especially for those that are more sensitive and struggle to absorb these influences. These factors make bankruptcy prediction a crucial aspect of management and decision-making. While traditional methods of evaluating company performance rely on ratio analysis, typically examining key business aspects such as profitability, assets, and financial position, this doctoral dissertation explores the possibility of utilizing contemporary methods in bankruptcy prediction. It combines traditional statistical methods with machine learning algorithms to uncover patterns in both financial and non-financial company data. In the Republic of Serbia, only a few bankruptcy prediction models based on financial statements have been developed so far, and to date, none predict bankruptcy up to two years in advance. Additionally, none of these models focus on small and medium-sized enterprises (SMEs). Since SMEs are essential drivers of the economy, especially in developing markets, predicting their bankruptcy is critically important. The primary objective of this dissertation is to examine if financial ratio analysis combined with statistical methods and machine learning results in reliable bankruptcy prediction models one (Y-1) and two years (Y-2) in advance. The research was conducted on a sample of 212 SMEs in Serbia, balanced according to prevailing literature, including 106 solvent companies and 106 companies that initiated bankruptcy proceedings. Initially, 66 independent variables (*both financial and non-financial*) were included, and carefully analyzed to reduce dimensionality, and only predictor variables that could genuinely contribute to predicting SME bankruptcy were included in the modeling. Regarding statistical methods, logistic regression (LR) and discriminant analysis (DA) were applied, while machine learning algorithms included neural networks (NN), decision trees (DT), and k-nearest neighbors (KNN). The final result of the research includes five developed bankruptcy prediction models one year in advance (Y-1) with a training accuracy of up to 90%, and five models predicting bankruptcy two years in advance (Y-2) with a training accuracy of up to 76%. Model testing followed leading literature recommendations and was conducted using IBM's SPSS software capabilities. Additionally, the developed models were compared with the well-known Altman Z'-score and EMS model, showing better performance than these in both time horizons. The development of bankruptcy prediction models enables the identification of early warning signs that indicate financial distress, allowing stakeholders to make better business decisions and take proactive measures to improve the financial health of SMEs. Furthermore, based on the research findings, these developed models can also assist regulatory bodies in enhancing business conditions for SMEs. Financial institutions, creditors, and investors can rely on bankruptcy prediction models for more effective risk management.

SADRŽAJ:

UVODNA RAZMATRANJA.....	1
➔ <i>Problem istraživanja</i>	<i>1</i>
➔ <i>Ciljevi istraživanja i hipoteze</i>	<i>1</i>
➔ <i>Opis metodologije istraživanja.....</i>	<i>2</i>
➔ <i>Rezultati istraživanja.....</i>	<i>3</i>
 1. OSNOVNI TEORIJSKI I METODOLOŠKI PRINCIPI FINANSIJSKE ANALIZE I DETEKCIJE POTEŠKOĆA U POSLOVANJU PREDUZEĆA.....	 5
1.1. Analiza finansijskih izveštaja kao polazna osnova ocene uspešnosti poslovanja .	5
1.2. Tradicionalne metode ocene poslovnih performansi	8
 2. STEČAJ U REPUBLICI SRBIJI: ANALIZA PROCEDURA I REGULATORNOG OKVIRA	 11
2.1. Otvaranje stečajnog postupka	11
2.2. Razlozi za pokretanje stečajnog postupka	12
2.3. Načela stečajnog postupka.....	12
2.4. Nadležnost i organi stečajnog postupka.....	13
2.4.1. Nadležnost stečajnog postupka	13
2.4.2. Organi stečajnog postupka	13
2.5. Osnovne odredbe i učesnici u postupku	15
2.5.1. Osnovne procesne odredbe	15
2.5.2. Poverioci i drugi učesnici u postupku	15
2.6. Proces pokretanja stečajnog postupka	15
2.7. Otvaranje i posledice otvaranja stečajnog postupka	16
 3. POSLOVANJE MALIH I SREDNJIH PREDUZEĆA (MSP/MSE) U REPUBLICI SRBIJI	 19
3.1. Osnovna obeležja i značaj MSP za ekonomiju Republike Srbije.....	19
3.2. Analiza finansijske stabilnosti MSP u Republici Srbiji.....	27

3.3.	Statistika malih i srednjih preduzeća u likvidaciji i stečaju u Republici Srbiji ...	33
------	--	----

4. SISTEMATSKI PREGLED TEHNIKA I POSTOJEĆIH MODELA ZA PREDVIĐANJE STEČAJA..... 35

4.1.	Statističke tehnike	38
4.1.1.	<i>Logistička regresija (LR)</i>	38
4.1.1.1.	Teorijsko-metodološka osnova logističke regresije	38
4.1.1.2.	Pregled postojećih modela predikcije stečaja zasnovanih na logističkoj regresiji	41
4.1.2.	<i>Diskriminantna analiza (DA)</i>	43
4.1.2.1.	Teorijsko-metodološka osnova diskriminantne analize	43
4.1.2.2.	Pregled postojećih modela predikcije stečaja zasnovanih na diskriminantnoj analizi	46
4.2.	Tehnike mašinskog učenja	47
4.2.1.	<i>Neuronske mreže (NN)</i>	48
4.2.1.1.	Teorijsko-metodološka osnova neuronskih mreža	48
4.2.1.2.	Pregled postojećih modela predikcije stečaja zasnovanih na neuronskim mrežama	51
4.2.2.	<i>Stabla odlučivanja (DT)</i>	53
4.2.2.1.	Teorijsko-metodološka osnova stabala odlučivanja	53
4.2.2.2.	Pregled postojećih modela predikcije stečaja zasnovanih na stablima odlučivanja	55
4.2.3.	<i>K-najbližih suseda (kNN)</i>	56
4.2.3.1.	Teorijsko-metodološka osnova tehnike k-najbližih suseda	56
4.2.3.2.	Pregled postojećih modela predikcije stečaja zasnovanih na tehnici k-najbližih suseda	58

5. OSNOVE MODELOVANJA PREDIKCIJE STEČAJA..... 60

5.1.	Identifikacija naučnog problema	60
5.2.	Konceptualni okvir, proces i tehnike istraživanja.....	62
5.3.	Definisanje uzorka istraživanja.....	66
5.4.	Varijable istraživanja	67
5.5.	Verifikacija modela.....	79

6. GENERISANJE I TESTIRANJE MODELA PREDIKCIJE STEČAJA JEDNU I DVE GODINE PRE POKRETANJA STEČAJNOG POSTUPKA 81

6.1.	Identifikovanje ključnih varijabli za kreiranje modela	81
6.1.1.	<i>Testiranje normalnosti distribucije nezavisnih varijabli</i>	82
6.1.2.	<i>Testiranje statističke značajnosti razlika između vrednosti varijabli za solventna preduzeća i preduzeća u stečaju</i>	86
6.1.3.	<i>Analiza multikolinearnosti</i>	91
6.2.	Kreiranje modela na bazi statističkih metoda	96
6.2.1.	<i>Logistička regresija (LR)</i>	96
6.2.1.1.	Kreiranje modela	96
6.2.1.2.	Testiranje modela	100
6.2.2.	<i>Diskriminantna analiza (DA)</i>	103
6.2.2.1.	Kreiranje modela	103
6.2.2.2.	Testiranje modela	110

6.3.	Kreiranje modela na bazi tehnika mašinskog učenja.....	113
6.3.1.	<i>Neuronska mreža (NN)</i>	113
6.3.1.1.	Kreiranje modela	113
6.3.1.2.	Testiranje modela	127
6.3.2.	Stablo odlučivanja (DT).....	130
6.3.2.1.	Kreiranje modela	130
6.3.2.2.	Testiranje modela	133
6.3.3.	<i>K-najbližih suseda (kNN)</i>	135
6.3.3.1.	Kreiranje modela	135
6.3.3.2.	Testiranje modela	139
7.	DISKUSIJA, PRAKTIČNE IMPLIKACIJE I OGRANIČENJA MODELA	
	141	
7.1.	Analiza razvijenih modela i komparacija sa postojećim modelima	141
7.2.	Praktične implikacije, ograničenja modela i smernice za buduća istraživanja..	150
	ZAKLJUČNA RAZMATRANJA	153
	LITERATURA.....	159
	SPISAK TABELA, SLIKA I ŠEMATSKIH PRIKAZA.....	189
	PRILOZI.....	198
	BIOGRAFIJA AUTORA	249

*Nikada ne završavamo put do znanja.
Svakim korakom otkrivamo nova vrata,
nove poglede i spoznaje...*

UVODNA RAZMATRANJA

Pitanje predikcije stečaja, uvek je aktuelno u svim ekonomijama, jer nema privrede koja nije afektovana ovim problemom, pa se isti može smatrati svetskim fenomenom (Kovacova, 2019). Prvi radovi na temu predikcije stečaja počinju sa istraživanjima Fitzpatrick-a (1932), a isti se prožimaju kroz naučnu zajednicu do današnjeg dana. Nedovoljna pokrivenost ove oblasti na tržištu Republike Srbije, sa fokusom na male i srednje entitete, motivacija je za istraživanje. U nastavku, predstavljeni su problem, cilj(evi), hipoteze, metodologija, kao i osnovni rezultati istraživanja.

→ *Problem istraživanja*

Problem istraživanja jeste predikcija stečaja malih i srednjih preduzeća (MSP/MSE) u Republici Srbiji. Aktuelni uslovi poslovanja zahtevaju od MSP brzo prilagođavanje i reagovanje sa ciljem opstanka u konkurentskoj borbi. U uslovima pojačane konkurencije i neizvesnosti, rizici su veliki, kao i šanse da će se entitet suočiti sa finansijskom krizom. MSE imaju veliki značaj za svaku ekonomiju, a pogotovo na tržištima koja su u razvoju. Pitanje razvoja modela predikcije stečaja i dalje nije dovoljno istraženo područje globalno, a pogotovo na teritoriji Republike Srbije. Dodatno, kada se u analizu uključe samo MSP uz upotrebu naprednih tehnika poput mašinskog učenja, polje istraživanja je potpuno nepokriveno u Srbiji. Kako postojeći modeli razvijeni u jednoj zemlji ne moraju nužno biti precizni u drugoj zemlji (usled specifičnosti tržišta, zakona i sl.), javlja se potreba za razvojem modela na uzorku MSP baš sa teritorije Republike Srbije.

→ *Ciljevi istraživanja i hipoteze*

Osnovni cilj istraživanja je generisanje modela predikcije stečaja godinu dana i dve godine pre nego što se pokrene postupak. Modeli bi omogućili da se na bazi javno

obelodanjenih informacija u finansijskim izveštajima, predvidi verovatnoća da će MSP pokrenuti stečajni postupak u narednih godinu dana ili dve godine.

Oslanjajući se na osnovni cilj istraživanja, definisani su sledeći **specifični ciljevi**:

- a) Predstavljanje postojećih teorijskih polazišta predikcije stečaja privrednih subjekata, kao i rezultata sprovedenih empirijskih studija;
- b) Ispitivanje uticaja odabranih nezavisnih varijabli (finansijske, nefinansijske, statističke i makroekonomske) na mogućnost predikcije stečaja godinu i dve godine pre pokretanja stečajnog postupka;
- c) Sistematski pristup obradi podataka u skladu sa definisanim pravilima i procedurama za odabrane tehnike mašinskog učenja i statističke metode, te jasno prezentovanje svih koraka neophodnih da analiza bude precizna i pouzdana u cilju primenjivosti rezultata na nove setove podataka;
- d) Analiza prednosti i nedostataka pojedinih metoda predikcije pokretanja stečajnog postupka;
- e) Generisanje modela predikcije stečaja godinu dana i dve godine pre pokretanja stečajnog postupka na bazi statističkih metoda (logistička regresija i diskriminantna analiza) i tehnika mašinskog učenja (neuronske mreže, stabla odlučivanja i k-najbližih suseda);
- f) Testiranje pouzdanosti generisanih modela za predikciju stečaja godinu dana i dve godine pre pokretanja stečajnog postupka.

U skladu sa definisanim problemom, odnosno, predmetom istraživanja, kao i postavljenim istraživačkim ciljevima, formulisana je sledeća glavna (X_1) i pomoćne (X_2 , X_3 , X_4) **hipoteze**:

- **X₁**: Na bazi tehnika mašinskog učenja i statistike, moguće je kreirati pouzdane modele predikcije stečaja godinu dana i dve godine pre pokretanja stečajnog postupka za male i srednje entitete u Republici Srbiji.
- **X₂**: Finansijski ratio pokazatelji (finansijske varijable – statičke) predstavljaju najznačajnije nezavisne varijable za predikciju stečaja godinu dana i dve godine unapred, dok nefinansijske, statističke, makroekonomska (hibridna), te varijable rasta, dodatno doprinose performansama modela;
- **X₃**: Neuronske mreže su superiornije u predviđanju stečaja u poređenju sa logističkom regresijom i metodom k-najbližih suseda;
- **X₄**: Stabla odlučivanja su superiornija u predviđanju stečaja u poređenju sa diskriminantnom analizom.

➔ *Opis metodologije istraživanja*

Teorijski deo istraživanja doktorske disertacije će se bazirati na prikupljanju i analizi postojeće literature u vezi sa temom predikcije stečaja, kako u Srbiji, tako i na inostranom tržištu. Cilj prethodno pomenutog jeste upoznavanje sa trenutnim nivoom znanja u vezi sa temom, kao i identifikacija prostora za dalja istraživanja u ovoj oblasti. Analizom postojeće literature, stremlje se ka boljem razumevanju koncepata, teorijskih osnova i empirijskih istraživanja koja su već sprovedena. Ovaj sistematizovani pregled literature služi kao osnova za definisanje problema i postavljanje hipoteza, omogućavajući preciznije usmeravanje istraživanja.

Empirijski deo istraživanja doktorske disertacije će se sastojati od primene i kombinovanja nekoliko metoda u cilju generisanja modela predikcije stečaja u Republici Srbiji na bazi finansijskih i nefinansijskih podataka. Metode su podeljene u tri kategorije:

- a) Finansijske, koje obuhvataju racio analizu (obračun nezavisnih varijabli za modelovanje);
- b) Statističke, koje obuhvataju logističku regresiju i diskriminantnu analizu i
- c) Mašinsko učenje, koje obuhvata neuronske mreže, stabla odlučivanja i k-najbližih suseda (k-NN).

Pre nego što se pristupi razvoju modela, izračunati racio pokazatelji, kao i nefinansijski podaci, biće pažljivo analizirani i obrađeni. Odnosno, svih 66 nezavisnih varijabli biće podvrgnuto testu normalnosti, te će se, zavisno od rezultata testa, definisati da li se za utvrđivanje statističke značajnosti razlika u vrednostima varijabli koristi parametarski t-test ili neparametarski Men-Vitni (*en. Mann-Whitney*). Sve varijable koje imaju statistički značajne razlike u vrednostima za preduzeća u stečaju poređeno sa solventnim preduzećima će se zadržati u daljoj analizi. Nakon ovog testiranja, u cilju sprečavanja postojanja multikolinearnosti, biće sproveden Spirman-ov (*en. Spearman*) test korelacije, kao i VIF (*en. Variance Inflation Factor*) analiza. Pored prethodnih metoda redukovanja broja nezavisnih varijabli, kod neuronskih mreža će, dodatno, biti sprovedena i PCA (*en. Principal Components Analysis*). Celokupna obrada podataka biće izvršena putem IBM-ovog programa SPSS v.26 za statističke tehnike i mašinsko učenje, kao i MS Eksel (*en. Excel*) programa za deo koji se odnosi na finansijsku racio analizu i tabelarnu pripremu podataka. Varijable koje će biti korišćene u cilju testiranja hipoteze se grupišu u dve sekcije: zavisna i nezavisne. Zavisna varijabla istraživanja se odnosi na status preduzeća: u stečaju i solventno. Dakle, zavisna varijabla je binarna ili kategorička, što znači da ima samo dva ishoda. Za potrebe statističke analize i analize tehnikama mašinskog učenja, ova varijabla se kodira na sledeći način:

- ✓ Preduzeće u stečaju = 0
- ✓ Solventno preduzeće = 1

Nezavisne varijable istraživanja obuhvataju čak 66 racio pokazatelja: 52 standardne statične finansijske (racio) varijable, 2 nefinansijske interne varijable, 1 makroekonomsku hibridnu varijablu, 5 varijabli trenda/varijacije i 6 statističkih varijabli. Više detalja o samoj metodologiji istraživanja, kao i konceptualnom okviru istog, biće predstavljeno u 5. poglavlju.

➔ **Rezultati istraživanja**

Rezultat istraživanja jeste ukupno 5 razvijenih modela za predviđanje verovatnoće pokretanja stečaja godinu dana unapred (Y-1), te 5 razvijenih modela predikcije stečaja dve godine unapred (Y-2). Sve prethodno pomenuto, izvršeno je putem 5 tehnika: logistička regresija, diskriminantna analiza, neuronske mreže, stabla odlučivanja i k-najbližih suseda.

Doktorska disertacija se sastoji iz **7 poglavlja**. Prvo poglavlje definiše tradicionalne metode analize poslovnih performansi preduzeća koje se oslanjaju samo na racio analizu u najvećoj meri. Drugo poglavlje obrađuje regulatorni okvir, odnosno *Zakon o stečaju*, kojim se preciznije definiše stečaj, sam postupak, načela, učesnici u postupku, posledice i slično. Poglavlje koje u fokus stavlja mala i srednja preduzeća, odnosno njihov značaj za privredu Republike Srbije, je treće. Tu je prvo prikazano kako MSP/MSE učestvuju u

makroekonomskim pokazateljima poput uvoza i izvoza, ali i u računovodstveno-finansijskim parametrima poput strukture poslovne imovine, obaveza i rezultata. Zatim, sprovedena je originalna analiza sektora MSP primenom tradicionalnih tehnika finansijske analize na konsolidovane izveštaje za sva MSP u Republici Srbiji. Na kraju poglavlja, prikazani su statistički podaci o MSP koji su u stečaju i likvidaciji. Četvrto poglavlje sistematizuje pet tehnika koje su korišćene u doktorskoj disertaciji: logističku regresiju, diskriminantnu analizu, neuronske mreže, stabla odlučivanja i k-najbližih suseda. Ovde se ukazuje na osnovne principe i pravila koja važe za svaku tehniku, a zatim je urađen pregled literature iz oblasti predikcije stečaja po svakoj tehnici. Peto poglavlje je uvod u samo praktično istraživanje, gde se definiše detaljnije naučni problem, metode istraživanja, varijable, uzorak i slično. Razvoj modela predikcije upotrebom prethodno pomenutih tehnika, te njihovo testiranje, izvršeno je u šestom poglavlju. Poslednje, sedmo poglavlje, predstavlja sintezu svega što je prethodno rečeno, sa fokusom na rezultate razvijenih modela i upotrebljene varijable. Izvršeno je poređenje razvijenih modela sa već postojećim modelima predikcije stečaja, te ukazano na praktičnu primenu rezultata istraživanja, ograničenja i preporuke za dalja istraživanja.

1. OSNOVNI TEORIJSKI I METODOLOŠKI PRINCIPI FINANSIJSKE ANALIZE I DETEKCIJE POTEŠKOĆA U POSLOVANJU PREDUZEĆA

Kroz analizu finansijskih izveštaja, moguća je procena rizika i razumevanje trendova u poslovanju preduzeća. Sama finansijska analiza obuhvata brojne tehnike i pokazatelje, a rezultati iste značajno pomažu u razumevanju načina upotrebe resursa kompanije, te njihove veze sa ostvarenim rezultatima poslovanja. Savremeni dinamični uslovi na tržištu zahtevaju kvalitetne informacije. Veliki broj podataka se nalazi u finansijskim izveštajima preduzeća, ali je potrebno uraditi kvalitetnu obradu istih, kako bi se pretvorili u informacije koje mogu stejkholderima biti vredne za donošenje odluka. Upravo ta obrada podataka i njihova konverzija u korisne informacije je veština finansijske analize.

1.1. Analiza finansijskih izveštaja kao polazna osnova ocene uspešnosti poslovanja

Analiza finansijskih izveštaja se smatra osnovnim alatom za procenjivanje stepena uspešnosti poslovanja. Upotrebom velikog broja pokazatelja (kao što su zaduženost, likvidnost, solventnost), moguće je utvrditi koje su slabosti, a koje snage posmatranog entiteta. Finansijski izveštaji, zajedno sa instrumentarijumom finansijske analize, značajna su podrška internim i eksternim stejkholderima u procesu donošenja odluka i definisanju strategija.

Da bi finansijska analiza mogla da obezbedi stejkholderima korisne informacije, ona mora da obuhvati sledeće kategorije (Robinson, 1989, str. 99):

- Finansijski rezultat,
- Finansijske uslove,
- Finansijsku strukturu, kao i
- Promene u finansijskoj strukturi.

Finansijska analiza je uvek fokusirana na rezultate, a oslanja se na finansijske izveštaje. Oni predstavljaju strukturiran skup podataka o poslovanju preduzeća i transakcijama koje su se dogodile u nekom vremenskom intervalu. Svi finansijski izveštaji u Republici Srbiji

su dostupni na sajtu Agencije za privredne registre, a obuhvataju (Zakon o računovodstvu, 2021)³:

1. Bilans uspeha,
2. Bilans stanja,
3. Izveštaj o tokovima gotovine,
4. Izveštaj o promenama na kapitalu,
5. Izveštaj o ostalom rezultatu i
6. Napomene uz finansijske izveštaje.

Najopštija podela finansijske analize jeste na *internu* i *eksternu*. Interna se ne zasniva isključivo na bilansu stanja i ostalim javno dostupnim izveštajima, već je često organizovana i kao departmanska analiza koja obuhvata brojne interne podatke koji su poznati samo konkretnom preduzeću. Sa druge strane, eksterna analiza je zasnovana na javno dostupnim izveštajima. Dakle, interna analiza je karakteristična za funkcije unutar samog preduzeća, poput Kontrolinga ili Računovodstva. Eksterna analiza je karakteristična za stejkholdere koji nisu angažovani u preduzeću, poput kreditora i investitora (Paramasivan i Subramanian, 2009), a zbog oslanjanja na eksterno dostupne podatke, njena moć je limitirana (Ranković, 1995). Najčešće primenjena tehnika, nezvezano za to da li je analiza interna ili eksterna, jeste – *racio analiza*. Ovaj vid analize dovodi u vezu dve veličine iste vrste, te objašnjava njihov odnos i dinamiku. Sama analiza se najčešće sprovodi kroz *upoređivanje podataka*, *njihovo raščlanjavanje* ili pak *uopštavanje* sa ciljem da se podaci iz izveštaja konvertuju u upotrebljivu informaciju za biznis (Jelušić i Gligorić, 2016, str. 78).

Upoređivanje je značajno, jer nijedan predmet ne može da se posmatra izolovano. Ova tehnika podrazumeva da finansijski analitičar uzima podatke preduzeća iz više vremenskih intervala, te vrši njihovo poređenje sa ciljem razumevanja tendencija u poslovanju. Dodatno, upoređivanje može da podrazumeva i komparaciju sa konkurencijom, što bi značilo da se iste kategorije podataka uzimaju za više preduzeća i analiziraju sa ciljem razumevanja polja za unapređivanje. Kada je reč o raščlanjivanju, polazna pretpostavka jeste da se posmatrana pojava tretira kao kompleksna i da je potrebno njeno dekomponovanje na sitnije delove. Ukoliko se, na primer, govori o fenomenu stečaja preduzeća i predviđanju istog, dekomponovanje bi podrazumevalo da se svi podaci iz izveštaja raščlane sa ciljem razumevanja njihovog kretanja u godinama pre nego što je pokrenut stečajni postupak. Nakon prethodne dve tehnike analize, uopštavanje je srž i ono se oslanja na znanje i iskustvo finansijskog analitičara u razumevanju posmatranih podataka, kao i povlačenje veza između različitih aspekata poslovanja radi donošenja globalnih zaključaka.

Prilikom procene finansijskih izveštaja, analitičari često na umu imaju donošenje ekonomskih odluka poput (Robinson i dr, 2009, str. 2):

- Evaluacija vezana za investiranje u akcije,
- Evaluacija u vezi sa merdžerom ili akvizicijom,
- Evaluacija poslovanja neke od divizija matične kompanije,
- Odluka o realizaciji kritične kapitalne investicije,
- Utvrđivanje kreditne sposobnosti preduzeća,

³ www.paragraf.rs (Preuzeto sa: <https://www.paragraf.rs/propisi/zakon-o-racunovodstvu-2020.html>. Datum pristupa: 20.12.2023.)

- Odobravanje kredita
- Dodeljivanje kreditnog rejtinga,
- Predviđanje budućeg neto prihoda, itd.

Prilikom analize finansijskih izveštaja, neophodno je dobro definisati svrhu analize i spram toga kreirati plan kako će ista biti sprovedena. Nakon što je cilj analize jasan, pristupa se prikupljanju podataka. Podaci se mogu naći kao javno dostupni na Internet stranicama preduzeća ili pak centralizovanim bazama podataka. Mimo zvaničnih izveštaja, do podataka se može doći i putem intervjuisanja menadžmenta i zaposlenih u kompanijama. Nakon što su podaci prikupljeni, sledi analiza istih. Faza koja sledi posle samog analiziranja podataka je donošenje zaključaka i interpretiranje rezultata. Prema Robinsonu i ko-autorima (2009), alati i tehnike finansijske analize obuhvataju:

1. Racio analizu,
2. Vertikalnu (i horizontalnu) analizu,
3. Upotrebu grafičkih prikaza i
4. Regresionu analizu

Najjednostavnije rečeno, *finansijski racio* predstavlja odnos između dve računovodstvene vrednosti, najčešće iz finansijskih izveštaja (Dauderis i Annand, 2014). Kao što je već pomenuto, ovaj vid analize je značajan, jer omogućava da se vrši poređenje vrednosti između nekoliko godina. Takođe, može da se vrši upoređivanje sa drugim preduzećima iz slične delatnosti ili pak sa nekim referentnim vrednostima (Palepu i dr, 1999). Najčešće se govori o sledećim grupama racio pokazatelja: aktivnost, solventnost, likvidnost, efikasnost i profitabilnost. Racio analiza sa sobom nosi izvesna ograničenja (Choundry, 2006):

- Primena različitih principa u računovodstvu može dovesti do problema vezano za tumačenje i uporedivost nekih racia;
- Definisanje adekvatnih referentnih vrednosti i proseka za granu privrede;
- Prilikom komparacije vrednosti racio pokazatelja, potrebno je da se u obzir uzmu i druge okolnosti koje se dešavaju u periodu analize;
- Odabir adekvatnih racio pokazatelja za određeno preduzeće može biti problem.

Vertikalna analiza se može vršiti sa raznim izveštajima, a najčešće su u pitanju bilans uspeha i bilans stanja. Ona podrazumeva da se vrši stavljanje u odnos svih pozicija izveštaja po vertikali sa jednom od stavki; u bilansu stanja, najčešće je to ukupna imovina, dok je u bilansu uspeha to najčešće ukupan prihod. *Horizontalna analiza*, sa druge strane, podrazumeva da se vrši horizontalno poređenje iste pozicije izveštaja sa njenom prethodnom ili narednom vrednošću ili pak poređenje sa vrednostima druge kompanije.

Grafička analiza, odnosno grafičko predstavljanje rezultata, moćan je alat finansijske analize. Podrazumeva adekvatan izbor grafikona kojim se na najbolji način može preneti poruka. Na primer, linijski dijagrami su poželjni kod prikazivanja trenda, dok su kružni („pita“) dijagrami adekvatniji za prikazivanje strukture neke celine.

Regresiona analiza podrazumeva primenu statistike u finansijskoj analizi i pomaže u razumevanju veze (ili korelacije) između varijabli. Recimo, regresionom analizom je moguće utvrditi da li postoji veza između kretanja GDP-a i visine prihoda od prodaje, te spram toga raditi planiranje.

1.2. Tradicionalne metode ocene poslovnih performansi

Uspeh svakog biznisa, pa tako i MSE, dominantno se meri kroz rast prihoda i broja zaposlenih (Berkham i dr, 1996, Holmes i Zimmer, 1994; Acs i Audretsch, 1990). Svaka merljiva veličina koju dostigne neko preduzeće u bilo kojoj oblasti, može se nazvati *performansom*. Međutim, merenje performansi se ne može zasnivati samo na prihodima ili broju zaposlenih; one se kontinuirano menjaju u savremenim uslovima, te je potrebno raditi njihovu proveru u određenim kadencama. Kroz adekvatno merenje performansi, ostvaruje se efikasnije upravljanje preduzećem, kao i efikasnije poslovanje (Neely, 1998). Tačnije, kroz analizu poslovnih performansi, teži se uspostavljanju trenutne dijagnoze preduzeća, te definisanje mera za unapređenje (Andrić i Vuković, 2011).

Ocena poslovnih performansi može da se podeli u dve kategorije: kvantitativna ocena i tradicionalna ocena performansi. *Kvantitativna ocena* podrazumeva generisanje statističkih modela, kao i modela mašinskog učenja. Kroz veći broj varijabli se teži razviti model u koji se kasnije unose finansijski i nefinansijski podaci o poslovanju preduzeća, što za krajnji autput ima definisanje klase boniteta kojoj preduzeće pripada. *Tradicionalne metode* ocene poslovnih performansi se odnose na upotrebu instrumentarijuma finansijske analize, te upotrebu finansijskih izveštaja, čime se dolazi do željenih informacija. Ovakav vid analize je od suštinskog značaja za donošenje brojnih odluka. Međutim, sa razvojem tehnike i tehnologije, rezultati finansijske analize su dalje uključeni, zajedno sa nefinansijskim karakteristikama preduzeća, u napredne modele za ocenu poslovnih performansi (poput neuronskih mreža).

Tradicionalne metode analize poslovanja i ocene performansi podrazumevaju pokazatelje (Rodić i dr, 2024):

1. Poslovne aktivnosti, odnosno finansijskog položaja;
2. Imovinske strukture, odnosno imovinskog položaja;
3. Uspešnosti, odnosno prinosnog položaja;
4. Upravljanja i
5. Tržišne vrednosti akcija.

Analiza finansijskog položaja se odnosi na usklađenost finansijske strukture preduzeća i njegovog uspeha sa osnovnim principima u ekonomiji. Tačnije, kod ove analize, vrši se procena stepena u kojem je preduzeće sposobno da stabilno posluje i ispunji svoje obaveze prema poveriocima. Pored uvida u sadašnje stanje, analiza finansijskog položaja podrazumeva i ispitivanje mogućnosti za održiv rast i razvoj. Ovaj tip analize se najčešće oslanja na obračun sledećih koeficijenata (Rodić i dr, 2024):

- Rigorozne likvidnosti,
- Opšte likvidnosti,
- Novčane likvidnosti,
- Solventnosti,
- Strukture zaduženosti,
- Koeficijenta finansijske stabilnosti i
- Neto obrtnog fonda.

Kada je reč o analizi *imovinske strukture*, bitno je napomenuti da na tumačenje ovog segmenta značajno utiče priroda posla kojom se bavi preduzeće, odnosno delatnost, likvidnost kupaca, ali i veličina preduzeća. Ovaj tip analize omogućava uvid u to koja je struktura imovine, kao i koliko efikasno je ona korišćena. Kroz ispitivanje imovine

preduzeća, stiče se utisak o tome koliki se deo iste finansira iz sopstvenog kapitala, a koliko kroz zajmove. Dodatno, analiza likvidnosti imovine, odnosno koliko brzo se ona pretvara u gotovinu, predstavlja značajan korak kod ovog tipa analize. Na ovaj način, moguće je identifikovati eventualne slabosti u poslovanju, kao što je, na primer, visoka vrednost nenaplaćenih potraživanja ili visoke vrednosti zaliha. Imovinski položaj podrazumeva obračun sledećih racio pokazatelja (Rodić i dr, 2024):

- Koeficijent obrta obrtne imovine,
- Koeficijent obrta poslovne imovine i
- Koeficijent obrta zaliha.

Kako je cilj svakog preduzeća da ostvari maksimalan rezultat, pitanje analize *prinosnog položaja* se nameće kao imperativ. Pitanja prinosnog položaja su vezana za uvećavanje kapitala, a podrazumevaju stopu neto prinosa na sopstveni i ukupni kapital.

Mimo podataka dostupnih u finansijskim izveštajima, ocena poslovnih performansi podrazumeva i razumevanje načina organizacije entiteta, hijerarhiju menadžmenta, te načina na koji se *upravlja* i donose odluke. Ova pitanja su od velikog značaja, jer su finansijski rezultati u izveštajima u velikoj meri posledica upravo odluka menadžmenta i efikasnosti same organizacije, kao i sposobnosti da ista ide ka identičnom cilju.

Analiza *pokazatelja vrednosti akcija*, zastupljen je metod procene performansi preduzeća. Najčešće podrazumeva obračun sledećih racio pokazatelja (Malinić i dr, 2017):

- Dobitak po akciji, koji se još naziva i zaradom po akciji (*en. Earnings per Share*). Razlikuje se osnovni i umanjeni dobitak po akciji. EPS je značajan pokazatelj poslovanja, jer pokazuje akcionarima da izračunaju svoj udeo u zaradi kompanije (Robinson i dr, 2009).
- Pored prethodno pomenutih, često korišćeni u praksi jesu i P/E racio (odnos između tržišne vrednosti akcija i osnovnog dobitka po akciji), kao i P/B racio (racio tržišne i knjigovodstvene vrednosti akcija). Ovi pokazatelji su ključni, jer investitorima pomažu u razumevanju da li je neka akcija potcenjena ili precenjena.
- Racio plaćanja dividendi, te stopa zadržavanja dobitka, takođe su značajni pokazatelji u vezi sa akcijama. Racio plaćanja dividendi ukazuje na deo neto dobitka koji se kroz dividende isplaćuje akcionarima. Stopa zadržavanja dobitka se odnosi na onaj procenat dobitka koji kompanija planira da reinvestira u poslovanje.
- Interna stopa rasta koja služi da se proceni da li je i u kojoj meri kompanija sposobna da koristi svoj profit za postizanje održivog rasta, bez zaduživanja ili emisije novih akcija.
- Dividendni prinos koji ukazuje na vrednost koju ostvaruju vlasnici običnih akcija u vidu novčanih dividendi

Uopšteno posmatrano, sva merila performansi preduzeća se mogu podeliti u sledeće kategorije (Todorović, 2010):

1. Računovodstvena,
2. Tržišna i
3. Hibridna.

Kada je reč o *računovodstvenim* performansama preduzeća, one se mere upotrebom finansijskih izveštaja, a najčešće se zasnivaju na pokazateljima profitabilnosti. Pod uslovom objektivnosti podataka u izveštajima, ovaj princip analize nije zahtevan.

Međutim, u savremenim uslovima poslovanja, stejkholderima nisu značajna samo merila performansi na bazi profitabilnosti, već i pokazatelji koji demonstriraju performanse na polju novčanih tokova. Prema rečima nekih autora (Nelson, 2003), upotreba ovih metoda koje se zasnivaju na finansijskim izveštajima može dovesti do pogrešnih zaključaka u uslovima kada finansijski izveštaji ne prikazuju verodostojno i objektivno poslovanje preduzeća. Stoga, ova merila performansi često ne uspevaju da zadovolje potrebe stejkholdera.

Tržišna vrednost se odnosi na onu vrednost koja je kompaniji dodeljena od strane tržišta. Rastući rizik koji karakteriše savremene tržišne uslove zahteva da se tržišne potrebe uzmu u razmatranje kada je reč o ponudi i tražnji proizvoda. Problem kod merenja performansi na bazi tržišne vrednosti je otežano apsolutno izražavanje, kao i otežano poređenje kroz vreme. Dodatno, teško je reći u kom trenutku je generisana izvesna tržišna vrednost.

Hibridni pokazatelji, kao što i samo ime kaže, predstavljaju kombinovanje internih računovodstvenih i eksternih tržišnih pokazatelja. Ova merila je lakše utvrditi i porediti kroz vreme. Najčešće obuhvataju sledeće ratio pokazatelje: P/E i P/B. Pomenuti pokazatelji su važni, jer investitorima omogućavaju procenu vrednosti akcija, te identifikaciju investicionih prilika. Dodatno, moguće je sagledati očekivanja u vezi sa daljim rastom kompanije.

2. STEČAJ U REPUBLICI SRBIJI: ANALIZA PROCEDURA I REGULATORNOG OKVIRA

Stečajni postupak u Republici Srbiji je uređen Zakonom o stečaju ("Sl. glasnik RS", br. 104/2009, 99/2011 - dr. zakon, 71/2012 - odluka US, 83/2014, 113/2017, 44/2018 i 95/2018), kojim se definiše pojam stečaja, načela stečaja, otvaranje stečajnog postupka, razlozi za otvaranje postupka, organi stečaja itd. U kontekstu pomenutog zakona, postoje dva ishoda stečaja: *bankrotstvo i reorganizacija*. Bankrotstvo podrazumeva da se izvrši namirivanje poverilaca upotrebom vrednosti celokupne imovine preduzeća nad kojim se stečaj sprovodi, dok reorganizacija podrazumeva da se izvrši namirivanje poverilaca u skladu sa definisanim planom reorganizacije (kroz ponovno definisanje dužničko-poverilačkih odnosa), kao i izmena dužnikovog statusa ili na drugi način definisan samim planom. Osnovni aspekti regulatornog okvira stečajnog postupka za Republiku Srbiju, predstavljeni su u nastavku.

2.1. Otvaranje stečajnog postupka

Ukoliko je stečajni postupak otpočeo, zakazuje se ročište u cilju rasprave o postojanju razloga za isti. Ročište zakazuje stečajni sudija, a isto mora biti definisano u periodu ne dužem od 30 dana (posmatrano od dana kada je otvaranje stečajnog postupka predloženo). Postupak se otvara kada se donese rešenje o otvaranju stečajnog postupka kojim se predlog za otvaranje smatra usvojenim. Rešenje donosi stečajni sudija. Ako nisu ispunjeni uslovi za pokretanje postupka, odbija se predlog za pokretanje procesa od strane stečajnog sudije. Rešenje o otpočinjanju postupka stečaja sadrži sledeće elemente (Zakon o stečaju, 2018, čl. 70):

- [1] Naziv i lokaciju suda koji je doneo rešenje o pokretanju postupka stečaja;
- [2] Podatke o stečajnom dužniku (matični broj, sedište...);
- [3] Informacije o postojanju razloga za pokretanje postupka;
- [4] Odluku o odabiru stečajnog upravnika i njegove podatke;
- [5] Poziv poveriocima da prijave svoja potraživanja, u roku između 30 i 120 dana od objave oglasa o otvaranju postupka stečaja u "Službenom glasniku";
- [6] Poziv dužnicima stečajnog dužnika da ispune svoje obaveze prema stečajnoj masi;
- [7] Vreme i lokaciju ročišta za analizu i ispitivanje potraživanja;
- [8] Vreme i lokaciju održavanja prvog poverilačkog ročišta, zajedno sa prvom sednicom skupštine poverilaca i
- [9] Datum postavljanja oglasa u sudu (oglasna tabla).

Rešenje o otvaranju postupka se dostavlja prvo stečajnom dužniku, kao i licu koje je podnelo predlog za otvaranje postupka, zatim licu ili organizaciji koji će sprovoditi proces

prinudne naplate i na kraju registru privrednih subjekata. Ukoliko se proceni da postoji potreba, rešenje se može dostaviti i drugim licima. Oglas u vezi sa otvaranjem stečajnog postupka, koji obuhvata sve elemente iz rešenja o pokretanju postupka stečaja, objavljuje se u sudu (oglasna tabla). Po donošenju rešenja, stečajni sudija treba da zakaže ročište koje se odnosi na pregled i analizu potraživanja, kao i ročište poverilaca.

2.2. Razlozi za pokretanje stečajnog postupka

Zakonom su definisani sledeći razlozi za otpočinjanje stečajnog postupka (Zakon o stečaju, 2018, čl. 11):

- [1] Dugotrajna nemogućnost izmirenja obaveza;
- [2] Nadolazeća nesposobnost plaćanja;
- [3] Prekomerna zaduženost i
- [4] Neizvršavanje obaveza prema odobrenom planu reorganizacije, ili ukoliko je taj plan usvojen prevarom ili nezakonitim radnjama.

Dugotrajna nemogućnost izmirenja obaveza se dešava ukoliko preduzeće nije u mogućnosti da 45 dana od dospeća obaveza ispuni iste ili pak izvrši obustavu svih plaćanja sa kontinuiranim trajanjem 30 dana. Nadolazeća nesposobnost podrazumeva situaciju u kojoj preduzeće ukaže na veliku verovatnoću da neće moći po dospeću da izvrši one obaveze koje su već postojeće. Kada je imovina niža od vrednosti obaveza stečajnog dužnika, tada govorimo o prekomernoj zaduženosti. Kada se stečajni dužnik ne pridržava plana organizacije ili pak postupuje u suprotnosti sa istim, reč je o poslednjem razlogu za otpočinjanje postupka stečaja.

Postoje posebne situacije kada se vrši obustava ili zaključivanje stečajnog postupka bez daljeg odlaganja: ukoliko je stečajni dužnik imao samo jednog poverioca ili ako se ispostavi da je celokupna imovina dužnika u postupku ispod vrednosti troškova stečajnog postupka. Prema Zakonu, stečajni postupak se ne sprovodi prema (Zakon o stečaju, 2018, čl. 14):

- [1] Državi Srbiji;
- [2] Autonomnim pokrajinama i lokalnim vlastima;
- [3] Fondovima i institucijama koje upravljaju obaveznim penzijskim, invalidskim, socijalnim i zdravstvenim osiguranjem;
- [4] Pravnim subjektima koje su osnovale Republika Srbija, pokrajine ili lokalne samouprave;
- [5] Narodnoj banci Srbije;
- [6] Centralnom registru i
- [7] Javnim agencijama.

2.3. Načela stečajnog postupka

Osnovna svrha postupka stečaja jeste kolektivno namirenje stečajnih poverilaca na najpovoljniji način, tako što će se ostvariti najveća moguća vrednost imovine stečajnog dužnika. Zakonom o stečaju (2018), definisana su sledeća načela (čl. 3-10):

- [1] *Načelo zaštite stečajnih poverilaca* – podrazumeva da stečaj treba da obezbedi zajedničko, te srazmerno namirivanje poverilaca kroz realizaciju najviše moguće vrednosti imovine stečajnog dužnika;

- [2] *Načelo jednakog tretmana i ravnopravnosti* – podrazumeva da u postupku stečaja treba da se obezbedi identičan tretman poverioca koji spadaju u istu klasu, odnosno isplatni red;
- [3] *Načelo ekonomičnosti* – podrazumeva težnju da se uz što manje troškove i u što kraćem periodu, ostvari najviša moguća vrednost imovine stečajnog dužnika, odnosno najviši mogući stepen podmirenja poverilaca;
- [4] *Načelo sudskog sprovođenja postupka* – podrazumeva da stečajni postupak realizuje sud;
- [5] *Načelo imperativnosti i prekluzivnosti* – podrazumeva da se postupak stečaja realizuje u skladu sa Zakonom o stečaju ukoliko drugačije nije određeno u samom Zakonu. Sva pitanja koja nisu obuhvaćena prethodno pomenutim zakonom, regulišu se zakonom koji uređuje parnični postupak.
- [6] *Načelo hitnosti* – podrazumeva da u stečajnom postupku nisu dopušteni prekidi, a sam postupak se tretira kao hitan.
- [7] *Načelo dvostepenosti* – podrazumeva da se postupak stečaja sprovodi kroz dve faze, odnosno dva nivoa, osim ukoliko je zakonom zabranjena žalba ili neki drugi pravni lek;
- [8] *Načelo javnosti i informisanosti* – postupak stečaja ima javni status, odnosno, svi učesnici procesa mogu tražiti sve podatke u vezi sa realizacijom postupka. Prethodno pomenuto se jedino ne odnosi na poslovne tajne. Zaključke o podacima koji su klasifikovani kao poslovna tajna, donosi stečajni sudija.

2.4. Nadležnost i organi stečajnog postupka

2.4.1. Nadležnost stečajnog postupka

Zakon o stečaju poznaje (Čl. 15 i 16):

- [1] Stvarnu nadležnost i
- [2] Mesnu nadležnost.

Stvarna nadležnost znači da stečajni postupak vodi onaj sud koji je određen zakonom o nadležnosti sudova. Stečajni sudija obavlja izvršne radnje u samom postupku. Mesna nadležnost podrazumeva da, u zavisnosti od sedišta stečajnog dužnika, sam postupak sprovodi onaj sud koji je na tom području. Ukoliko stečajni dužnik nije registrovan na teritoriji Republike Srbije, onda se odabir suda vrši spram područja gde je centar interesa stečajnog dužnika.

2.4.2. Organi stečajnog postupka

Zakon definiše sledeće organe postupka stečaja (Zakon o stečaju, 2018, čl. 17): stečajni sudija, stečajni upravnik, skupština poverilaca i odbor poverilaca. *Stečajni sudija* (Zakon o stečaju, 2018, čl. 18):

- [1] Odlučuje o početku prethodnog postupka stečaja;
- [2] Identifikuje postojanje uslova za stečaj i donosi odluku o njegovom otvaranju;
- [3] Određuje i smenjuje stečajnog upravnika;
- [4] Odobrava troškove stečaja i obaveze stečajne mase pre nego što se isplate;
- [5] Definiše visinu privremenih i konačnih naknada i nagrada za stečajnog upravnika;
- [6] Odlučuje o prigovorima na aktivnosti stečajnog upravnika;

- [7] Razmatra predlog reorganizacionog plana, organizuje ročište za raspravu o planu ili odbacuje plan;
- [8] Potvrđuje usvajanje reorganizacionog plana ili da plan nije usvojen;
- [9] Odlučuje o raspodeli imovine stečajne mase, preduzima ostale radnje i donosi druge odluke propisane zakonom.

Stečajni upravnik se bavi zastupanjem dužnika u stečajnom postupku. On ima status službenog lica, te legitimaciju koja je izdata od strane ovlašćene organizacije. Legitimacija može da se koristi isključivo za službena pitanja koja se rešavaju u skladu sa Zakonom i u granicama ovlašćenja. Rešenjem o pokretanju postupka stečaja, stečajnog upravnika imenuje sudija. Sa liste upravnika za stečajni postupak se slučajnim izborom bira upravnik koji će voditi stečajni postupak. Postoje izvesna pravila prilikom imenovanja stečajnog upravnika, tako da se nije moguće imenovati osobu protiv koje je pokrenut krivični postupak po službenoj dužnosti. Zatim, krvni srodnici organa upravljanja stečajnog dužnika ne smeju biti imenovani kao stečajni upravnici. Takođe, vlasnici i članovi nadzornih i upravljačkih organa stečajnog dužnika ne mogu biti imenovani kao stečajni upravnici.

Skupština poverilaca se formira prilikom prvog poverilačkog ročišta, a čine je poverioci stečajnog postupka nezavisno za to da li su do momenta realizacije skupštinskog sastanka predali prijave potraživanja ili ne. Tokom prve sednice skupštine poverilaca, vrši se odabir predsednika skupštine, kao i članova odbora poverilaca. Odgovornost predsednika skupštine je vođenje i zakazivanje svih naknadnih sednica, kao i obaveštavanje o njima, te definisanje dnevnog reda, a sve prethodno pomenuto na predlog stečajnih poverilaca. Zakonom je definisan sledeći delokrug skupštine poverilaca (Zakon o stečaju, 2018, čl. 37):

- [1] Donosi odluku o proglašenju bankrotstva stečajnog dužnika;
- [2] Bira i smenjuje predsednika i članove odbora poverilaca iz redova stečajnih poverilaca;
- [3] Odobrava izbor ili daje predlog novog stečajnog upravnika;
- [4] Pregleda izveštaje stečajnog upravnika o napretku postupka i stanju stečajne mase;
- [5] Pregleda izveštaje poverilačkog odbora i obavlja ostale zadatke koji su predviđeni zakonom;

Odbor poverilaca je definisan od strane skupštine poverilaca, a isti mora uvek da ima neparan broj članova, do maksimalnih 7. Visina potraživanja poverioca nije kriterijum za izbor. Članovi odbora biraju predsednika odbora poverilaca, a stečajni sudija može da reši funkcije člana odbora ukoliko se zaključi da ne obavlja obaveze koje Zakon propisuje. Delokrug odbora poverilaca je (Zakon o stečaju, 2018, čl. 40):

- [1] Savetuje stečajnog upravnika o načinu prodaje imovine kada se prodaja ne sprovodi putem javne licitacije i odobrava aktivnosti od izuzetnog značaja;
- [2] Daje mišljenje o nastavku preostalih poslova stečajnog dužnika;
- [3] Pregleda izveštaje stečajnog upravnika o napretku stečajnog postupka i stanju imovine stečajne mase;
- [4] Odobrava završni račun dužnika stečajnog postupka;
- [5] Pregleda i po sopstvenom trošku pribavlja kopije svih dokumenata;
- [6] Izveštava poverilačku skupštinu o svom radu na njen zahtev i obavlja ostale zadatke u skladu sa ovim zakonom;

2.5. Osnovne odredbe i učesnici u postupku

2.5.1. Osnovne procesne odredbe

Predlogom ovlašćenih predlagača, pokreće se postupak stečaja. U samom stečajnom postupku ne postoji mogućnost da se traži povraćaj u prethodno stanje, kao što se ne može zahtevati da se postupak ponovi. Kada je reč o aktima u postupku stečaja, donose se zaključci i rešenja. Rešenjem se donosi odluka o postupku, dok zaključci rešavaju primedbe, te se njima izdaje nalog službenim licima ili organima koji sprovode postupak stečaja. Žalba ili prigovor nisu mogući protiv zaključka. Sa druge strane, postoji mogućnost da se protiv rešenja izjavi žalba kod suda višeg stepena u definisanom roku od 8 dana od momenta kada se rešenje objavi na oglasnoj tabli suda. Najkasnije 30 dana od prijema žalbe, mora se doneti rešenje po istoj. Sve neblagovremene i nepotpune žalbe se odbacuju.

2.5.2. Poverioci i drugi učesnici u postupku

Stečajni poverilac je lice koje u momentu otpočinjanja postupka stečaja ima neko potraživanje od stečajnog dužnika. Sa druge strane, *razlučni poverioci* imaju prvenstveno pravo namirenja kroz prodaju imovine zbog založnog prava, zakonskog prava zadržavanja ili prava naplate. Bitno je napomenuti da oni nisu stečajni poverioci, ali kada njihov dug prevazilazi vrednost imovine, ostatak može da se namiri kao stečajni dug. Pravo koje je stečeno prinudnim izvršenjem u poslednjih 60 dana pre stečaja - prestaje važiti. *Založni poverioci* poseduju založno pravo na imovini dužnika u stečajnom postupku, ali nemaju potraživanja. Oni nisu ni stečajni ni razlučni poverioci, a svoje pravo moraju da prijave sudu da bi se steklo svojstvo stranke. Oni nemaju pravo učešća u izboru odbora poverilaca. *Izlučni poverioci* su lica koja mogu da zahtevaju izolovanje određene stvari, odnosno izdvajanje iz stečajne mase, ali oni nisu stečajni poverioci. U postupku mogu učestvovati i ostala lica: garanti, jemci itd. Kada je reč o ovlašćenom licu (*procenitelju*) u stečajnom postupku, to mora da bude lice koje poseduje licencu, a procena koja je podneta sudu ne sme biti starija od 12 meseci, osim ukoliko se uz procenu ne dostavi potvrda (takođe ne starija od 12 meseci), kojom se potvrđuje da je procena i dalje važeća.

2.6. Proces pokretanja stečajnog postupka

Po predlogu dužnika, likvidacionog upravnika ili poverioca, otpočinje stečajni postupak. U slučaju dugotrajne nemogućnosti izmirenja obaveza, nadolazeće nesposobnosti plaćanja, prekomerne zaduženosti i neizvršavanja obaveza prema odobrenom planu reorganizacije, stečajni dužnik podnosi predlog za pokretanje postupka stečaja. Likvidacioni upravnik podnosi zahtev za otpočinjanje postupka stečaja u skladu sa zakonom. Poverilac podnosi predlog kada postoji trajnija nesposobnost plaćanja, odnosno kada se ne postupa po definisanom planu reorganizacije. Predlog pokretanja postupka (koji se podnosi sudu) sadrži sledeće elemente (Zakon o stečaju, 2018, čl. 56):

- [1] Ime suda kojem se zahtev podnosi;
- [2] Podatke predlagača ili ovlašćenog zastupnika za prijem pismenih dokumenata i predstavljanje predlagača (ime/poslovno ime i adresa);

- [3] Poslovno ime dužnika stečajnog postupka i njegova adresa;
- [4] Detaljan spisak stečajnih i drugih poverilaca, uključujući tačne iznose i osnove potraživanja, te podatke članova društva koji lično odgovaraju za dugove stečajnog dužnika ukoliko je podnosilac sam dužnik;
- [5] Dokazna dokumentacija koja potvrđuje vrstu, osnovu i iznos neizmirenih potraživanja ukoliko predlog podnosi poverilac;
- [6] Kompletna lista priloženih dokumenata uz predlog za otpočinjanje postupka stečaja.

U situaciji kada predlog ne sadrži sve navedene, obavezne elemente, stečajni sudija informiše predlagača i definiše rok koji nije duži od osam dana, u kojem se nedostaci moraju otkloniti. Ukoliko se nedostaci ne otklone, predlog za otpočinjanje stečaja se rešenjem – odbacuje.

Podnosilac predloga mora u definisanom roku, (5 dana od prijema naloga suda) da plati predujam za troškove oglasa, angažovanja stečajnog upravnika, obaveštavanja poverilaca, te troškove obezbeđenja imovine i to u iznosu koji odredi stečajni sudija. U zavisnosti od klasifikacije entiteta po veličini, definiše se vrednost predujma, ali prema Zakonu (čl. 59) ne može da bude veći od:

- [1] 50.000 RSD za mikro preduzeća;
- [2] 200.000 RSD za mala preduzeća;
- [3] 600.000 RSD za srednja preduzeća i
- [4] 1.000.000 RSD za velika preduzeća.

Stečajni sudija odbacuje predlog za pokretanje postupka ukoliko se u definisanom roku ne uplate sredstva.

2.7. Otvaranje i posledice otvaranja stečajnog postupka

Kao što je prethodno pomenuto, kada se pokrene stečajni postupak, stečajni sudija zakazuje ročište gde se utvrđuje postojanje razloga za otpočinjanje postupka stečaja. Ukoliko sudija donese rešenje o otvaranju postupka – predlog je usvojen. Rešenje ima standardnu formu i sadrži ključne informacije kao što su: naziv suda, postojanje stečajnog razloga, matični broj stečajnog dužnika, itd. Oglas u vezi sa otvaranjem stečaja se objavljuje na oglasnoj tabli suda. Otvaranje postupka sa sobom nosi izvesne posledice. Pravne posledice otvaranja postupka stupaju na snagu onog dana kada je objavljen oglas da je stečajni postupak otvoren. Prema Zakonu o stečajnom postupku (2018) posledice otvaranja postupka su sledeće (čl. 74-100):

[1] *Posledice po stečajnog dužnika*

Sa otvaranjem stečajnog postupka, prestaju sva prava zastupanja i upravljanja za direktora, punomoćnika i zastupnika. Isto važi i za nadzorne i upravne organe. Prethodno pomenuta prava prelaze na stečajnog dužnika. Sva prethodno stečena prava preče kupovine u vezi sa imovinom dužnika, gase se sa otvaranjem stečajnog postupka. Pokretanje postupka se smatra razlogom za otkazivanje ugovora o radu sa zaposlenima. Stečajni upravitelj, sa druge strane, mimo lica kojima nije dat otkaz, može da uposli dodatna lica za vođenje stečajnog postupka, ali uz saglasnost stečajnog sudijske. Uz ime preduzeća koje je pokrenulo stečajni postupak, dodaje se nastavak “ - u stečaju”. Organizacija koja je zadužena za

vođenje stečajnog postupka, čim primi rešenje o otvaranju stečajnog postupka, isto dostavlja bankama kako bi se sprečilo prenošenje sredstava sa računa. Banka blokira račune i sva prava lica koja su prethodno upravljala računima – prestaju. Po zahtevu stečajnog upravnika, banka može otvoriti novi račun za obavljanje daljeg poslovanja preduzeća koje je pokrenulo stečajni postupak.

[2] *Posledice na potraživanja*

Samo u okviru stečajnog postupka, stečajni poverioci mogu da ostvare svoja potraživanja prema stečajnim dužnicima. Sva ona potraživanja koja nisu dospela sa danom kada je otvoren stečajni postupak – smatraju se dospelim. Ukoliko je neki poverilac pre pokretanja stečaja stekao pravo na prebijanje potraživanja, otvaranjem samog postupka, to pravo se ne gubi. Kako bi ostvario svoje pravo, stečajni poverilac mora da dostavi sudu prijavu koja ukazuje na ukupnu vrednost potraživanja, kao i izjavu o prebijanju. Ovo se mora realizovati do isteka roka za prijavu potraživanja. Ukoliko ne postupi u skladu sa prethodno rečenim, gubi se pravo na prebijanje. Pravo na prebijanje nije izvodljivo ukoliko je stečajni poverilac svoje potraživanje stekao u periodu od 6 meseci pre momenta pokretanja postupka stečaja. Pored prethodno pomenutog, prebijanje je nedopustivo ukoliko je uslov za prebijanje stečen po osnovu posla koji se može pobijati. Sva nenovčana potraživanja preduzeća koje je pokrenulo stečajni postupak, bivaju uključena u stečajnu masu, te izražena u novčanoj vrednosti na dan kada je otvoren sam stečajni postupak. Kada je reč o kamatama, za sva potraživanja u stečajnom postupku koja nisu obezbeđena, prestaje obračun zateznih kamata onog dana kada je otvoren postupak. Sa druge strane, na obezbeđena potraživanja se vrši obračun ugovorene i zatezne kamate i to do visine vrednosti imovine koja se koristi za obezbeđivanje potraživanja. Zastarelost potraživanja stečajnog dužnika prestaje prijavljivanjem potraživanja.

[3] *Procesnopravne posledice*

Onog momenta kada se pokrene stečajni postupak, prestaju svi drugi sudski postupci u vezi sa tim preduzećem i njegovom imovinom. Nastavak parničnog postupka moguć je ukoliko su ispunjeni sledeći uslovi (Zakon o stečaju, 2018, član 90):

- Tužilac je podneo pravovremenu i urednu prijavu potraživanja;
- Na ispitnom ročištu, stečajni upravnik je osporio prethodno pomenutu prijavu;
- Tužilac je, po nalogu sudije stečajnog postupka, upućen na nastavak prekinutog parničnog postupka kako bi se utvrdilo osporeno potraživanje;
- Tužilac je, u periodu od 8 dana od prijema zaključka sudije, podneo predlog za nastavak prekinutog postupka.

[4] *Posledice na pravne poslove*

Ukoliko je lice koje je pokretač stečajnog postupka ujedno i primalac lizinga, davalac lizinga mora da podnese zahtev da se predmet lizinga izdvoji iz stečaja. Kada je reč o fiksnim poslovima, ukoliko je momenat za ispunjenje neke obaveze iz fiksnog ugovora usledio nakon što je stečajni postupak otvoren, saugovarač stečajnog dužnika nije u poziciji da traži ispunjenje obaveze, ali ima mogućnost da traži naknadu usled neispunjenja. Ukoliko stečajni upravnik ne donese drugačiju odluku, nalozi koje je izdao stečajni dužnik prestaju da imaju dejstvo sa onim danom kada je otvoren stečajni

postupak. Isto važi i za sve ponude koje je stečajni dužnik učinio ili primio. Sa druge strane, zakup nepokretnosti ne prestaje sa otvaranjem stečajnog postupka. Kod robe u prevozu, može se tražiti povraćaj robe koja je stečajnom dužniku isporučena, a nije dospela na ugovorenu lokaciju.

3. POSLOVANJE MALIH I SREDNJIH PREDUZEĆA (MSP/MSE) U REPUBLICI SRBIJI

Mali i srednji entiteti/preduzeća (MSE/MSP) imaju izuzetan značaj za svaku državu. Oni su razvojni pokretači u celokupnoj privredi, te lideri zapošljavanja stanovništva (Klikovac, 2009, str. 101). Ožegović i Pavlović (2012) tvrde da je konstantno napredovanje MSP sektora posle 2000. godine u Srbiji posledica unapređivanja opštih uslova za privređivanje, kao i podsticajnih mera od strane države (str. 77-80). U Srbiji, tokom 2021. godine, sektor malih i srednjih preduzeća angažuje 35% ukupnog broja zaposlenih⁴ (Republički zavod za statistiku, 2023).

3.1. Osnovna obeležja i značaj MSP za ekonomiju Republike Srbije

Zakonom o računovodstvu ("Sl. glasnik RS", br. 73/2019 i 44/2021 - dr. zakon)⁵, član 6, definisana je klasifikacija entiteta prema veličini u Republici Srbiji, tako da:

- ➔ *Mala pravna lica* obuhvataju pravna lica i preduzetnike koji na datum bilansa prekoračuju granične vrednosti za mikro preduzeća, ali ne prelaze granične vrednosti dva od sledećih kriterijuma:
 - Prosečan broj zaposlenih 50;
 - Poslovni prihod 8.000.000 evra u dinarskoj protivvrednosti i
 - Vrednost ukupne aktive na datum bilansa 4.000.000 evra u dinarskoj protivvrednosti.
- ➔ *Srednja pravna lica* obuhvataju pravna lica i preduzetnike koji na datum bilansa prekoračuju granične vrednosti za mala pravna lica, ali ne prelaze granične vrednosti dva od sledećih kriterijuma:
 - Prosečan broj zaposlenih 250;
 - Poslovni prihod 40.000.000 evra u dinarskoj protivvrednosti i
 - Vrednost ukupne aktive na datum bilansa 20.000.000 evra u dinarskoj protivvrednosti.


⁴ www.stat.gov.rs (Preuzeto sa: <https://publikacije.stat.gov.rs/G2023/Pdf/G20236005.pdf>; datum pristupa – 16.06.2024.)

⁵ www.paragraf.rs (Preuzeto sa: <https://www.paragraf.rs/propisi/zakon-o-racunovodstvu-2020.html>. Datum pristupa: 16.06.2024.)

Sektor MSE je bitan za srpsku privredu, o čemu svedoče brojni makroekonomski podaci koji se odnose na promet, bruto dodatu vrednost, broj izvoznika i izvoz robe, kao i broj uvoznika i uvoz robe. Svi podaci o prethodno pomenutim kategorijama, sa granularnošću po veličini preduzeća, dostupni su na sajtu Republičkog zavoda za statistiku⁶ u okviru publikacije “*Preduzeća po veličini i preduzetnici u Republici Srbiji 2019-2021.*” koja je objavljena 2023. godine.

Promet malih preduzeća za 2019, 2020. i 2021. godinu iznosi 2.486.715, 2.470.617 i 3.036.410 miliona dinara respektivno. Dominantan udeo u ostvarenom prometu u sve tri godine ima grana “Trgovina na veliko i malo i popravka motornih vozila” sa ostvarenim prometom 1.132.090, 1.101.487 i 1.372.961 miliona dinara za 2019, 2020. i 2021. godinu respektivno. Odmah nakon prethodno pomenute grane privrede, nalazi se promet ostvaren od strane “Prerađivačke industrije” koji iznosi 430.060, 456.873 i 517.776 miliona dinara za 2019, 2020. i 2021. godinu respektivno. Kod *srednjih preduzeća* je ostvaren ukupan promet 2.740.651, 2.772.480 i 3.347.769 miliona dinara za 2019, 2020. i 2021. godinu. Prisutan je isti obrazac kao i kod malih preduzeća u kontekstu dominantnih grana privrede, pa tako “Trgovina na veliko i malo i popravka motornih vozila” čini 1.066.433, 1.057.134 i 1.216.622 miliona dinara u ukupnom prometu preduzeća srednje veličine i to za 2019, 2020. i 2021. godinu respektivno. Takođe, “Prerađivačka industrija” je druga po veličini u ukupnom prometu sa vrednostima 775.163, 794.435 i 996.159 miliona dinara za 2019, 2020. i 2021. godinu. U cilju boljeg razumevanja doprinosa MSP celokupnom prometu Republike Srbije, sledi grafički prikaz na Slici 1. U 2021. godini MSP čine 41% ukupnog prometa u Republici Srbiji ukoliko se uključe i preduzetnici u analizu.

Slika 1: Promet po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina (mil. RSD)




Izvor: Republički zavod za statistiku, 2023

⁶ www.stat.gov.rs (Preuzeto sa: <https://publikacije.stat.gov.rs/G2023/Pdf/G20236005.pdf>; datum pristupa – 16.06.2024.)

Bruto dodata vrednost (BDV) malih preduzeća iznosi 449.030, 477.248 i 600.131 miliona dinara za 2019, 2020. i 2021. godinu. Kao i kod prometa, u BDV segmentu najveće vrednosti ostvaruje “Trgovina na veliko i malo i popravka motornih vozila” sa bruto dodatom vrednošću od 131.031, 136.148 i 174.205 miliona dinara za 2019, 2020. i 2021. godinu respektivno. Odmah iza je “Prerađivačka industrija” sa BDV vrednostima 90.072, 98.453 i 108.437 miliona dinara respektivno za 2019, 2020. i 2021. godinu. Preduzeća *srednje veličine* imaju rastući trend bruto domaće vrednosti u periodu 2019-2021. godina, a vrednosti respektivno iznose 571.280, 604.631 i 754.221 miliona dinara. Za razliku od situacije koja je prisutna kod malih preduzeća, ovde u ukupnoj vrednosti najznačajniji udeo ima “Prerađivačka industrija” za celokupan posmatrani period sa vrednostima 181.446, 197.385 i 226.860 miliona dinara za 2019, 2020. i 2021. godinu. Odmah iza prethodno pomenute grane, nalazi se “Trgovina na veliko i malo i popravka motornih vozila” sa ostvarenom bruto dodatom vrednošću 114.150, 123.877 i 151.521 miliona dinara u 2019, 2020 i 2021. godini. Na Slici 2, prikazana je bruto dodata vrednost za celu Srbiju u cilju komparacije između preduzeća po veličini. Tokom 2021. godine, MSP su generisala 36% ukupne bruto dodate vrednosti u Republici Srbiji.

Slika 2: Bruto dodata vrednost po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina (mil. RSD)




Izvor: Republički zavod za statistiku, 2023

Broj izvoznika malih preduzeća je 3.923, 3.877 i 4.000 za 2019, 2020. i 2021. godinu respektivno. Najveći broj izvoznika se u celom posmatranom periodu nalazi u okviru “Prerađivačke industrije” i to 1.919, 1.900 i 1.961 za 2019, 2020. i 2021. godinu. Odmah uz prethodno pomenutu granu, nalazi se “Trgovina na veliko i malo i popravka motornih vozila” sa preko 1.250 izvoznika u svakoj posmatranoj godini. *Srednja preduzeća* ukupnom broju doprinose sa 1.345, 1.367 i 1.414 izvoznika za 2019, 2020. i 2021. godinu. Kao i kod malih preduzeća, dominantni su izvoznici iz “Prerađivačke industrije” sa 794, 795 i 827 izvoznika u 2019, 2020. i 2021. godini. Odmah iza, pozicionirana je grana “Trgovine na veliko i malo i popravke motornih vozila” koja u svakoj od posmatranih

godina ima preko 285 izvoznika. Radi poređenja, prikaz izvoznika je dat na Slici 3. Mala i srednja preduzeća čine 34% ukupnog broja izvoznika.

Slika 3: Broj izvoznika po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina




Izvor: Republički zavod za statistiku, 2023

Izvoz robe malih preduzeća iznosi 205.179, 213.973 i 275.310 miliona dinara za 2019, 2020. i 2021. godinu respektivno. U 2019. i 2021. godini, najveći doprinos ukupnom izvozu malih preduzeća ima “Prerađivačka industrija” sa rezultatom od 94.114 i 128.303 miliona dinara, dok u 2020. godini “Trgovina na veliko i malo i popravka motornih vozila” ostvaruje ukupan izvoz robe 94.565 miliona dinara, a to je za 2.206 miliona dinara više od onoga što je ostvarila “Prerađivačka industrija” u pomenutoj godini.

Preduzeća *srednje veličine* ostvaruju izvoz u vrednosti 396.219, 410.289 i 460.698 miliona dinara u 2019, 2020. i 2021. godini respektivno. Daleko najveće vrednosti izvoza ostvaruje “Prerađivačka industrija” i to 298.721, 303.087 i 363.944 miliona dinara u 2019, 2020. i 2021. godini. Nakon prethodno pomenute grane, druga po vrednosti izvoza je “Trgovina na veliko i malo i popravka motornih vozila”, sa vrednošću izvoza koji je veći od 65.000 miliona dinara u celom posmatranom periodu. Rast je zabeležen na prelazu iz 2019. u 2020. godinu, dok je prelazom iz 2020. u 2021. godinu zabeležen pad vrednosti izvoza ove grane. Na Slici 4, dat je uporedni prikaz izvezeno vrednosti robe. Mala i srednja preduzeća tokom 2021. godine učestvuju sa 29% u ukupnom izvozu Republike Srbije.

Slika 4: Izvoz robe po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina




Izvor: Republički zavod za statistiku, 2023

Mala preduzeća broje 5.494, 5.547 i 5.725 **uvoznika** respektivno za 2019, 2020. i 2021. godinu. Tokom 2019. i 2020. godine, najveći broj uvoznika se nalazi unutar “Prerađivačke industrije” i to 1.913 i 1.928 respektivno. U 2021. godini, “Trgovina na veliko i malo i popravka motornih vozila” ostvaruje značajniji rast uvoznika na 1.910, te broji 3 uvoznika više u odnosu na industriju prerade.

U kategoriji *srednjih preduzeća*, zabeleženo je 1.806, 1.852 i 1.905 uvoznika za 2019, 2020. i 2021. godinu. Daleko najveći broj uvoznika je pozicioniran unutar “Prerađivačke industrije”: 824, 838 i 851 za 2019, 2020. i 2021. godinu. “Trgovina na veliko i malo i popravka motornih vozila” broji do 387 uvoznika u posmatranom vremenskom intervalu i nije prisutan trend konstantnog rasta broja iz godine u godinu. Uporedni prikaz za celu srpsku privredu, dat je na Slici 5. MSE/MSP čine 31% ukupnog broja uvoznika u 2021. godini.

Slika 5: Broj uvoznika po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina




Izvor: Republički zavod za statistiku, 2023

Uvoz robe malih preduzeća iznosi 506.430, 493.746 i 618.284 miliona dinara u 2019, 2020. i 2021. godini respektivno. Najveći udeo u uvozu ima “Trgovina na veliko i malo i popravka motornih vozila” sa vrednostima 355.122, 335.285 i 438.274 miliona dinara respektivno za period 2019, 2020. i 2021. godina. “Prerađivačka industrija” se nalazi iza sa vrednostima uvoza koje u celokupnom periodu prelaze 100.000 miliona dinara. Srednja preduzeća ostvaruju veće vrednosti uvoza u poređenju sa malim preduzećima i to 607.195, 625.444 i 768.520 miliona dinara.

U celom posmatranom periodu, “Trgovina na veliko i malo i popravka motornih vozila” beleži najveće vrednosti uvoza: 328.084, 326.411 i 380.742 miliona dinara za 2019, 2020. i 2021. godinu respektivno. Odmah iza se nalazi “Prerađivačka industrija” koja u periodu 2019-2020. godina u kontinuitetu beleži uvoz robe iznad 225.000 miliona dinara. Uporedni prikaz je dat na Slici 6. Mala i srednja preduzeća čine 43% ukupne vrednosti uvoza tokom 2021. godine.

Slika 6: Vrednost uvoza robe po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina




Izvor: Republički zavod za statistiku, 2023

Kada se posmatra **rezultat** iz 2022. godine, prema poslednjim dostupnim podacima u “Godišnjem izveštaju o poslovanju privrede” Agencije za privredne registre⁷, *srednja preduzeća* su poslovala sa povećanjem i ukupnih rashoda i ukupnih prihoda, a njihov udeo u celokupnoj privredi je 23%. *Mala preduzeća* su takođe ostvarila veći nivo ukupnih prihoda i rashoda poređeno sa prethodnom godinom, a isti su pretežno iskazani u okviru grana trgovine i prerađivačke industrije. Udeo MSP u ukupnim prihodima privrednih društava za 2022. godinu je prikazan na Slici 7, gde se vidi da MSP generišu 42.5% ukupnih prihoda.

Kada je reč o **imovini i izvorima finansiranja**, bitno je napomenuti da su *srednja preduzeća* angažovala poslovnu imovinu u vrednosti 4.061.282 miliona dinara, te kapital vredan 1.733.461 milion dinara. Najveći deo prethodno pomenutih kapaciteta je angažovan od strane prerađivačke industrije i trgovine. Sa druge strane, *mali entiteti* su angažovali 17.9% poslovne imovine, te 18.4% kapitala. Na Slici 8 je prikazana poslovna imovina privrednih društava po veličini, gde se vidi da MSP čine 37% ukupne vrednosti poslovne imovine u Republici Srbiji u 2022. godini.

⁷ [www.apr.gov.rs](https://www.apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-izvestaji-o-poslovanju-pravnih-lica-preduzetnika-i-ekonomskih-celina.2126.html) (Dostupno na: <https://www.apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-izvestaji-o-poslovanju-pravnih-lica-preduzetnika-i-ekonomskih-celina.2126.html>. Datum pristupa: 17.06.2024.)


Slika 7: Ukupni prihodi privrednih društava prema veličini u 2022. godini



Izvor: Agencija za privredne registre, 2023⁸

Mala privredna društva beleže rast ukupnih **obaveza** u iznosu od 6.2% i to na nivo od 2.148.460 miliona dinara, a srednja preduzeća su tokom 2022. godine smanjila svoj dug za 2.5%, tako da on iznosi 2.526.361 milion dinara. Kada je reč o kapitalu, mala preduzeća ostvaruju rast za 10.6%, na iznos 1.675.494 miliona dinara, dok srednja preduzeća imaju sopstveni kapital u vrednosti od 1.530.625 miliona dinara.

Slika 8: Poslovna imovina privrednih društava prema veličini u 2022. godini



Izvor: Agencija za privredne registre, 2023⁹

⁸ [www.apr.gov.rs](https://www.apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-izvestaji-o-poslovanju-pravnih-lica-preduzetnika-i-ekonomskih-celina.2126.html) (Dostupno na: <https://www.apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-izvestaji-o-poslovanju-pravnih-lica-preduzetnika-i-ekonomskih-celina.2126.html>. Datum pristupa: 17.06.2024.)

⁹ [www.apr.gov.rs](https://www.apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-izvestaji-o-poslovanju-pravnih-lica-preduzetnika-i-ekonomskih-celina.2126.html) (Dostupno na: <https://www.apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-izvestaji-o-poslovanju-pravnih-lica-preduzetnika-i-ekonomskih-celina.2126.html>. Datum pristupa: 17.06.2024.)

3.2. Analiza finansijske stabilnosti MSP u Republici Srbiji

Analiza finansijske stabilnosti MSP sektora će biti urađena po uzoru na analizu iz već objavljenog istraživanja (Kušter, 2021) i to primenom instrumentarijuma finansijske analize na konsolidovane finansijske izveštaje za ceo sektor. Svi podaci se mogu pronaći na sajtu „Agencije za privredne registre Srbije“ u okviru „Godišnjeg biltena finansijskih izveštaja”¹⁰. Analiza se odnosi na vremenski interval 2015-2020. godina, spram raspoloživih podataka u istoj formi. Kretanje broja MSP, kao i broja zaposlenih u sektoru, prikazano je u Tabeli 1. Tokom celog perioda je zabeležen trend rasta broja MSP na tržištu Republike Srbije. Sa rastom broja entiteta, rastao je i broj zaposlenih u sektoru.

Tabela 1: Prikaz ukupnog broja entiteta koji čine sektor MSP u Republici Srbiji u periodu 2015-2020. godina

Kategorija	2015.	2016.	2017.	2018.	2019.	2020.
Broj entiteta u MSP sektoru	9,906	10,420	10,895	11,774	12,533	13,432
Broj zaposlenih u MSP	477,127	506,396	525,247	546,426	575,267	589,362

Izvor: Agencija za privredne registre, 2023

Analiza podrazumeva sledeće korake:

- ➔ *Analiza dugoročne finansijske stabilnosti.* Kada je prisutna ravnoteža između dugoročnih sredstava i kapitala koji je uvećan za dugoročne obaveze, kaže se da postoji dugoročna finansijska stabilnost (Rodić i dr, 2024). Analiza dugoročne finansijske stabilnosti će biti sprovedena putem dugoročnog ACID testa.
- ➔ *Analiza kratkoročne finansijske stabilnosti,* koja predstavlja likvidnost kompanije, a u ovom slučaju likvidnost sektora, definiše se kao sposobnost plaćanja obaveza onda kada iste dospevaju. Likvidnost zavisi od novčanih tokova, ali i strukture obrtno imovine i kratkoročnih obaveza (Subramanyam & Wild, 2009). Testiranje ovog aspekta će biti izvršeno putem kratkoročnog ACID testa.
- ➔ *Analiza profitabilnosti,* koja će biti sprovedena kroz ispitivanje dva racio pokazatelja – ROA (*en. Return on Assets*) i ROE (*en. Return on Equity*). Pokazatelj ROA meri sposobnost da se upotrebe ukupna sredstva u cilju stvaranja profita (Gibson, 2000). Pokazatelj ROE meri koliko je produktivnost kapitala (Fridson i Alvarez, 2002), odnosno signalizira koliko je profitabilna kompanija u odnosu na kapital koji angažuje.

U Tabeli 2, prikazana je analiza dugoročne finansijske stabilnosti sa ACID testom. Dugoročno vezana sredstva u MSP sektoru pokazuju trend rasta kontinuirano od 2015. do 2020. godine. Dugoročne obaveze uvećane za kapital takođe imaju uzlaznu putanju do 2020. godine. Koeficijent dugoročne finansijske stabilnosti postepeno opada između godina, a raspon je od 1.13 do 1.05, što je posledica činjenice da dugoročno vezana

¹⁰ [www.apr.gov.rs](https://apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-bilten-finansijskih-izvestaja.2127.html) (Dostupno na: <https://apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-bilten-finansijskih-izvestaja.2127.html>. Datum pristupa: 18.10.2023.)

sredstva sporije rastu u dinamici poređeno sa dugoročnim obavezama uvećanim za kapital.

Tabela 2: Analiza dugoročne finansijske stabilnosti MSP i ACID test za vremenski period 2015-2020. godina

<i>ANALIZA DUGOROČNE FINANSIJSKE STABILNOSTI (U 000 RSD)</i>							
#	Pozicija	2015.	2016.	2017.	2018.	2019.	2020.
1	Stalna imovina	2,331,510,063	2,521,856,373	2,656,085,386	2,858,568,149	3,211,205,749	3,497,315,802
2	Zalihe	694,586,327	774,496,151	844,534,056	899,536,681	957,138,428	1,087,894,203
3	Odložena poreska sredstva	16,499,993	14,941,634	13,319,132	11,560,783	12,642,176	12,693,489
3	Dugoročno vezana sredstva	3,042,596,383	3,311,294,158	3,513,938,574	3,769,665,613	4,180,986,353	4,597,903,494
4	Dugoročne obaveze	761,630,883	868,736,465	939,049,655	1,058,161,932	1,176,797,977	1,332,893,537
5	Dugoročna rezervisanja	46,481,040	52,992,422	53,748,866	49,862,651	49,873,384	48,932,614
6	Odložene poreske obaveze	25,434,066	28,371,358	30,860,339	32,525,320	32,716,740	32,756,419
7	Kapital	1,864,781,121	2,054,333,925	2,208,771,331	2,365,328,853	2,629,954,263	2,972,663,154
8	Kapital i dugoročne obaveze	2,698,327,110	3,004,434,170	3,232,430,191	3,505,878,756	3,889,342,364	4,387,245,724
9	KOEF. DUGOROČNE FINANSIJSKE STABILNOSTI (3/8)	1.1276	1.1021	1.0871	1.0752	1.0750	1.0480
#	Pozicija	2015.	2016.	2017.	2018.	2019.	2020.
1	Dugoročno vezana sredstva	1	1	1	1	1	1
2	Koeficijent dugoročne finansijske stabilnosti	1.1276	1.1021	1.0871	1.0752	1.0750	1.0480
3	Dugoročne obaveze i kapital (1/2)	0.8869	0.9073	0.9199	0.9300	0.9302	0.9542


Izvor: Kalkulacija autora, MS Excel program

Donji deo Tabele 2 pokazuje rezultate ACID testa, a isti je prezentovan na Slici 9. ACID test signalizira da je dugoročna finansijska stabilnost narušena u odnosu na teorijski normativ (1:1). Svaki 100 dinara dugoročnih sredstava, pokriveno je sa:

- 89 dinara dugoročnih izvora sredstava u 2015. godini, dok je razlika od 11% finansirana iz kratkoročnih izvora;
- 91 dinar dugoročnih izvora sredstava u 2016. godini, dok je razlika od 9% finansirana iz kratkoročnih izvora;
- 92 dinara dugoročnih izvora sredstava u 2017. godini, dok je razlika od 8% finansirana iz kratkoročnih izvora;

- 93 dinara dugoročnih izvora sredstava u 2018. godini, dok je razlika od 7% finansirana iz kratkoročnih izvora;
- 93 dinara dugoročnih izvora sredstava u 2019. godini, dok je razlika od 7% finansirana iz kratkoročnih izvora;
- 95 dinara dugoročnih izvora sredstava u 2020. godini, dok je razlika od 5% finansirana iz kratkoročnih izvora;

Slika 9: Vizuelni prikaz ACID testa za analizu dugoročne finansijske (ne)stabilnosti MSP u Republici Srbiji u periodu 2015-2020. godina



Izvor: Ilustracija autora, MS Excel program

Činjenica da se jedan deo dugoročnih sredstava finansira iz kratkoročnih izvora ima negativan uticaj na likvidnost, kako kratkoročne obaveze na plaćanje dospevaju pre oslobađanja dugoročno vezanih sredstva. Situacija gde se kratkoročno vezana sredstva u potpunosti poklapaju sa vrednošću i dospećem kratkoročnih obaveza je veoma retka u praksi (Bhattacharya, 2011). Uzimajući prethodno prezentovane rezultate i činjenicu da je 1:1 odnos gotovo neostvariv u praksi, može se zaključiti da MSP sektor postiže da uspostavi dugoročnu finansijsku ravnotežu, jer manje od 15% dugoročnih sredstava finansira iz kratkoročnih izvora finansiranja (Kušter, 2021, str. 751). Posmatrano u dinamici, zaključuje se da MSP radi kontinuirano na poboljšanju svoje finansijske stabilnosti, kako od 2015. do 2020. godine dolazi do postepenog pada finansiranja dugoročnih sredstava iz kratkoročnih izvora sa 11% na 5%. Najslabija promena je prisutna na prelazu između 2018. i 2019. godine. Najbolji rezultat od 5% dugoročnih sredstava finansiranih iz kratkoročnih izvora, ostvaren je u poslednjoj posmatranoj godini.

Na Slici 10, prikazana je analiza kratkoročne finansijske stabilnosti sa ACID testom. Likvidna i kratkoročno vezana sredstva ostvaruju rast vrednosti kroz godine, a isto je slučaj i sa kratkoročnim obavezama ukoliko se izuzme 2017. godina kada su kratkoročne obaveze ostvarile pad vrednosti. Vrednost koeficijenta kratkoročne stabilnosti ima uzlaznu putanju u celom posmatranom intervalu 2015-2020. godina, usled značajnijeg rasta kratkoročno vezanih, likvidnih, sredstava.

Tabela 3: Analiza kratkoročne finansijske stabilnosti MSP i ACID test za vremenski period 2015-2020. godina


<i>ANALIZA KRATKOROČNE FINANSIJSKE STABILNOSTI (U 000 RSD)</i>							
#	Pozicija	2015.	2016.	2017.	2018.	2019.	2020.
1	Gotovina i ekvivalenti	207,234,780	258,317,788	286,200,082	336,130,626	405,605,882	526,347,580
2	Potraživanja po osnovu prodaje, iz specifičnih poslova i druga potraživanja	834,385,373	906,291,946	929,481,526	1,004,791,017	1,091,089,696	1,164,544,284
3	Kratkoročni finansijski plasmani	217,602,441	203,150,760	196,384,251	199,885,377	229,674,847	265,253,743
4	Porez na dodatu vrednost	30,962,922	41,173,829	48,126,403	43,307,863	48,305,007	53,541,656
5	Finansijska sredstva koja se vrednuju po fer vrednosti kroz bilans uspeha	2,748,522	2,920,743	3,343,747	2,682,648	2,918,833	5,869,257
6	Aktivna vremenska razgraničenja	52,539,441	63,495,668	69,403,492	70,019,516	72,252,522	93,226,208
7	Likvidna i kratkoročno vezana sredstva	1,345,473,479	1,475,350,734	1,532,939,501	1,656,817,047	1,849,846,787	2,108,782,728
6	Kratkoročne finansijske obaveze	664,038,239	678,182,315	636,098,853	671,302,664	747,955,046	772,885,000
7	Obaveze iz poslovanja	853,035,891	934,666,609	928,517,431	968,289,142	1,028,656,121	1,057,513,271
8	Ostale kratkoročne obaveze	241,686,391	239,031,516	204,564,492	199,035,376	253,829,390	287,921,159
9	Obaveze po osnovu poreza na dodatu vrednost, obaveze za ostale poreze i pasivna vremenska razgraničenja	170,937,048	185,957,168	188,016,429	201,408,194	212,086,799	260,224,832
10	Primljeni avansi, depoziti i kaucije	114,275,853	139,030,629	157,960,493	175,392,853	224,414,645	273,293,596
11	Kratkoročne obaveze	2,043,973,422	2,176,868,237	2,115,157,698	2,215,428,229	2,466,942,001	2,651,837,858
12	KOEF. KRATKOROČNE FINANSIJSKE STABILNOSTI (7/11)	0.6583	0.6777	0.7247	0.7479	0.7499	0.7952
#	Pozicija	2015.	2016.	2017.	2018.	2019.	2020.
1	Kratkoročno vezana sredstva	1	1	1	1	1	1
2	Koeficijent kratkoročne finansijske stabilnosti	0.6583	0.6777	0.7247	0.7479	0.7499	0.7952
3	Kratkoročne obaveze (1/2)	1.5191	1.4755	1.3798	1.3372	1.3336	1.2575

Izvor: Kalkulacija autora, MS Excel program

Donji deo Tabele 3 pokazuje rezultate kratkoročnog ACID testa, a isti je prezentovan i na Slici 10. ACID test signalizira da je kratkoročna finansijska stabilnost narušena uzimajući u obzir teorijski optimum 1:1. Svakih 100 dinara kratkoročnih sredstava, pokriveno je sa:

- 152 dinara kratkoročnih obaveza u 2015. Ovo signalizira da se likvidnost teže održava i da je potrebno kratkoročna sredstva mobilisati pre dospeća kratkoročnih obaveza, odnosno rokovi dospeća kratkoročnih obaveza bi trebalo da budu duži od rokova vezivanja kratkoročnih sredstava za 52%;
- 147 dinara kratkoročnih obaveza u 2016. Ovo signalizira da se likvidnost teže održava i da je potrebno kratkoročna sredstva mobilisati pre dospeća kratkoročnih obaveza, odnosno rokovi dospeća kratkoročnih obaveza bi trebalo da budu duži od rokova vezivanja kratkoročnih sredstava za 47%;
- 138 dinara kratkoročnih obaveza u 2017. Ovo signalizira da se likvidnost teže održava i da je potrebno kratkoročna sredstva mobilisati pre dospeća kratkoročnih obaveza, odnosno rokovi dospeća kratkoročnih obaveza bi trebalo da budu duži od rokova vezivanja kratkoročnih sredstava za 38%;
- 134 dinara kratkoročnih obaveza u 2018. Ovo signalizira da se likvidnost teže održava i da je potrebno kratkoročna sredstva mobilisati pre dospeća kratkoročnih obaveza, odnosno rokovi dospeća kratkoročnih obaveza bi trebalo da budu duži od rokova vezivanja kratkoročnih sredstava za 34%;
- 133 dinara kratkoročnih obaveza u 2019. Ovo signalizira da se likvidnost teže održava i da je potrebno kratkoročna sredstva mobilisati pre dospeća kratkoročnih obaveza, odnosno rokovi dospeća kratkoročnih obaveza bi trebalo da budu duži od rokova vezivanja kratkoročnih sredstava za 33%;
- 126 dinara kratkoročnih obaveza u 2020. Ovo signalizira da se likvidnost teže održava i da je potrebno kratkoročna sredstva mobilisati pre dospeća kratkoročnih obaveza, odnosno rokovi dospeća kratkoročnih obaveza bi trebalo da budu duži od rokova vezivanja kratkoročnih sredstava za 26%.

Slika 10: Vizuelni prikaz ACID testa za analizu kratkoročne finansijske (ne)stabilnosti MSP u Republici Srbiji u periodu 2015-2020. godina



Izvor: Ilustracija autora, MS Excel program

U celom posmatranom periodu, sektor ima poteškoće u ostvarivanju kratkoročne finansijske stabilnosti, kako konstantno preko 25% kratkoročnih obaveza nije finansirano iz kratkoročnih i likvidnih izvora sredstava. Prethodno rečeno pokazuje da je likvidnost ugrožena, jer je ravnoteža tokom celog posmatranog perioda značajnije okrenuta ka kratkoročnim obavezama. Značajno je napomenuti da se vidi pozitivan trend kratkoročne finansijske stabilnosti, pošto se disbalans sa 52% iz 2015. godine, pomerio na 26% u 2020. godini.

Povrat na aktivu MSP sektora pokazuje dinamično kretanje u vremenskom intervalu 2015-2019. godina, tako što do 2016. godine ostvaruje rast, nakon čega u 2017. godini blago opada, da bi od 2017. godine do kraja analiziranog intervala, vrednost ROA pokazatelja za MSP sektor rasla do nivoa 5.46% (Tabela 4). U teoriji, prihvaćena je tvrdnja da je dobar nivo profitabilnosti prisutan sa ROA indikatorom iznad 10% (Dakić i Mijić, 2020).

Tabela 4: Analiza povrata na aktivu (ROA) MSP u Republici Srbiji u intervalu 2015-2020. godina

ROA							
#	Pozicija	2015.	2016.	2017.	2018.	2019.	2020.
1	Poslovni rezultat	198,683,581	253,642,451	251,404,107	279,400,113	313,425,716	366,769,299
2	Ukupna aktiva	4,394,501,316	4,792,572,867	5,052,713,405	5,432,094,806	6,038,769,779	6,714,376,242
3	ROA [1/2]	4.52%	5.29%	4.98%	5.14%	5.19%	5.46%

Izvor: Obračun autora, MS Excel program

Indikator povrata na kapital (Tabela 5) ukazuje na to da MSP sektor ostvaruje relativno nizak do umeren nivo povrata na uloženi kapital u celom posmatranom periodu, s obzirom

da je referentna vrednost ovog racia oko 10-15%. Bitno je napomenuti da postoji pozitivna tendencija kod ROE pokazatelja, gde on raste sve do 2019. godine, a nakon blagog pada u 2019. godini, već naredne godine ostvaruje rast. Sektor bi trebalo da razmotri strategije za unapređivanje efikasnosti korišćenja kapitala kroz umanjeње troškova ili rast prihoda kroz povećanje cena proizvoda/usluga, te kroz bolje upravljanje imovinom.

Tabela 5: Analiza povrata na uloženi kapital (ROE) MSP u intervalu 2015-2020. godina

ROE							
#	Pozicija	2015.	2016.	2017.	2018.	2019.	2020.
1	Neto rezultat	88,823,275	140,876,765	188,633,179	207,277,772	211,208,464	279,298,462
2	Kapital	1,864,781,12 ₁	2,054,333,925	2,208,771,331	2,365,328,853	2,629,954,263	2,972,663,154
3	ROE [1/2]	4.76%	6.86%	8.54%	8.76%	8.03%	9.40%

Izvor: Obračun autora, MS Excel program

3.3. Statistika malih i srednjih preduzeća u likvidaciji i stečaju u Republici Srbiji

U poslednjih šest godina, stopa preduzeća u stečaju i likvidaciji se kreće u rasponu od 4-5%. U Tabeli 6 su prikupljeni podaci iz šest biltena sa sajta APR-a, a odnose se na *entitete svih veličina* u Srbiji koji su u *stečaju i likvidaciji*.

Tabela 6: Opšti prikaz srazmere stečaja i likvidacije u Republici Srbiji

Stavka / Godine	2017. ¹¹	2018. ¹²	2019. ¹³	2020. ¹⁴	2021. ¹⁵	2022. ¹⁶
Broj kompanija koje su aktivne	141,942	146,675	128,511	130,582	133,255	135,490
Broj kompanija u stečaju i likvidaciji	6,562	6,891	6,307	6,096	5,956	5,817
Stopa stečaja i likvidacije	4.62%	4.70%	4.91%	4.67%	4.47%	4.29%

Izvor: Autor na osnovu podataka sa APR-a (www.apr.gov.rs)

¹¹ www.apr.gov.rs (Dostupno na: [https://apr.gov.rs/upload/Portals/0/GFI 2018/Saopstenje 19062018.pdf](https://apr.gov.rs/upload/Portals/0/GFI%2018/Saopstenje%2019062018.pdf); datum pristupa: 01.12.2023, str. 9-32)

¹² www.apr.gov.rs (Dostupno na: [https://apr.gov.rs/upload/Portals/0/GFI%202019/Makroekonomska saopstenja/Godisnji izvestaj SI2018.pdf](https://apr.gov.rs/upload/Portals/0/GFI%202019/Makroekonomska_saopstenja/Godisnji_izvestaj_SI2018.pdf); datum pristupa: 01.12.2023, str. 9-32)

¹³ www.apr.gov.rs (Dostupno na: [https://apr.gov.rs/upload/Portals/0/GFI_2020/Makroekonomska saopstenja/Godisnji izvestaj o poslovanju privrede u 2019.pdf](https://apr.gov.rs/upload/Portals/0/GFI_2020/Makroekonomska_saopstenja/Godisnji_izvestaj_o_poslovanju_privrede_u_2019.pdf); datum pristupa: 01.12.2023, str. 9-33)

¹⁴ www.apr.gov.rs (Dostupno na: [https://apr.gov.rs/upload/Portals/0/GFI_2021/Makroekonomska saopstenja/Godisnji izvestaj o poslovanju privrede u 2020.pdf](https://apr.gov.rs/upload/Portals/0/GFI_2021/Makroekonomska_saopstenja/Godisnji_izvestaj_o_poslovanju_privrede_u_2020.pdf); datum pristupa: 01.12.2023, str. 8-33)

¹⁵ www.apr.gov.rs (Dostupno na: [https://apr.gov.rs/upload/Portals/0/GFI_2022/Publikacije/Godisnji izvestaj o poslovanju privrede 2021.pdf](https://apr.gov.rs/upload/Portals/0/GFI_2022/Publikacije/Godisnji_izvestaj_o_poslovanju_privrede_2021.pdf); datum pristupa: 01.12.2023, str. 8-35)

¹⁶ www.apr.gov.rs (Dostupno na: [https://apr.gov.rs/upload/Portals/0/GFI_2023/Godisnji izvestaj o poslovanju privrede u 2022.pdf](https://apr.gov.rs/upload/Portals/0/GFI_2023/Godisnji_izvestaj_o_poslovanju_privrede_u_2022.pdf); datum pristupa: 01.12.2023, str. 8-35)

Kada je reč o strukturi po veličini preduzeća, najveći broj subjekata u stečaju i likvidaciji pripadaju kategoriji mikro preduzeća u celokupnom periodu (preko 98%). Međutim, kada je reč o MSP sektoru, u 2017. godini je u statusu stečaja i likvidacije bilo 85 malih i 19 srednjih preduzeća. Obe kategorije beleže pad zaposlenih, i to sa 1.240 na 520 radnika kod malih preduzeća, dok je u srednjim preduzećima zaposleno 1.046 radnika. Tokom 2018. godine, u procesu likvidacije ili stečaja se našlo 61 malo i 5 srednjih preduzeća koja su zapošljavala 322 i 289 radnika respektivno.

U 2019. godini, u procesu stečaja i likvidacije se nalazilo 5 srednjih društava koja su zapošljavala 419 zaposlenih i 74 mala društva koja su zapošljavala 719 radnika. To je porast za 130 radnika u oblasti malih preduzeća, odnosno porast 348 radnika u segmentu srednjih preduzeća na nivou godine. Tokom 2020. godine, od ukupnog broja preduzeća sa finansijskim poteškoćama, bilo je 58 malih društava u stečaju i likvidaciji, a kod njih je bilo ukupno zaposleno 697 radnika. U srednjim preduzećima je bilo zaposleno 269 radnika, a ukupno se u stečaju i likvidaciji našlo 5 srednjih preduzeća.

U 2021. godini, 6 preduzeća u stečaju i likvidaciji srednje veličine zapošljavala su 435 radnika, a 38 malih preduzeća je angažovalo 285 zaposlenih. Za 2022. godinu, nisu dostupni podaci granularni za MSP.

Iako je stopa likvidacije i stečaja u Srbiji uravnotežena tokom prethodnih godina (4-5%), prethodno prikazana analiza sektora MSP je ukazala na to da postoji značajnija kratkoročna finansijska nestabilnost. Dodatno, ROA i ROE pokazatelji ne prate teorijska očekivanja. Sve prethodno rečeno signalizira da je potrebno staviti fokus na istraživanje malih i srednjih preduzeća.

Kada je reč o teritorijama mimo Srbije, prema poslednjim dostupnim podacima (Trading Economics, 2024), stečaj na teritoriji Evropske unije (EU) je na nivou 2,7%, dok je na evrozoni procenat nešto viši – 3,7%. Najveći broj stečaja je zabeležen u Švajcarskoj (15.447), a najmanji u Islandu (56). Na nivou Grupe 20 (G20), koju čine najrazvijenije zemlje sveta, zajedno sa EU, najveći broj stečaja je zabeležen u SAD-u (22.762), a najniži u Južnoj Koreji (13).

4. SISTEMATSKI PREGLED TEHNIKA I POSTOJEĆIH MODELA ZA PREDVIĐANJE STEČAJA

Kako će se modelovanje predikcije stečaja raditi upotrebom dve grupe tehnika (*statističke tehnike i mašinsko učenje*), neophodno je prvo osvrnuti se na teorijsko-metodološke osnove svake tehnike sa ciljem da se ustanove principi modelovanja, definišu osnovni termini, te kasnije generišu pouzdani modeli sa jakom sposobnošću generalizacije na novim (nepoznatim) podacima. Nakon teorijskih prikaza svake tehnike, biće izvršen pregled relevantne literature iz oblasti predikcije stečaja¹⁷ zarad sticanja svesti o trenutnom nivou znanja, kao i definisanja uzorka, varijabli i ostalih parametara istraživanja. U nastavku sledi opšti osvrt na tehnike analize i primenu tih tehnika u predikciji stečaja.

Statističke tehnike (logistička regresija i diskriminantna analiza), kao i metode mašinskog učenja (neuronske mreže, stabla odlučivanja i k-najbližih suseda) koje će biti fokusirane u istraživanju, spadaju u proces koji se jednom rečju naziva – **učenje**. Na setovima podataka, modeli uče obrasce u cilju predviđanja budućeg ishoda. Razlikuje se nekoliko kategorija učenja (Burkov, 2019):

- Nadgledano (*en. Supervised*) – kod ovog tipa učenja poznata je veza između inputa i outputa, odnosno, inputi se nazivaju nezavisnim varijablama (x), dok se outputi nazivaju zavisnim varijablama (y). Model teži da utvrdi skrivene obrasce između inputa i outputa.
- Nenadgledano (*en. Unsupervised*) – kod ovog tipa istraživanja outputi nisu obeleženi (*en. Labeled*) odnosno klasifikovani, tako da kombinacija inputa i outputa nije poznata. Ovaj vid učenja je usmeren na analizu međuzavisnosti između input parametara, a sa ciljem otkrivanja skrivenih obrazaca, strukture i značajnih karakteristika unutar samih podataka.
- Polunadgledano (*en. Semi-supervised*) – ovaj tip učenja funkcioniše tako što kombinuje manji skup podataka koji su označeni, odnosno klasifikovani sa velikim skupom neoznačenih podataka u cilju poboljšanja performansi modela. Podaci iz označenih podataka se koriste za početnu obuku, dok se neoznačeni podaci koriste za unapređivanje prediktivne sposobnosti modela.

¹⁷ Neki autori prilikom modelovanja koriste više tehnika, ali će prilikom pregleda literature biti akcentovana samo ona tehnika na koju se poglavlje odnosi.

Pojačano učenje (*en. Reinforcement*) – ovaj tip učenja je najnapredniji, a podrazumeva donošenje odluka kroz interakciju sa okruženjem tako što se povratne informacije dobijaju u vidu nagrada ili kazni, a cilj je da se kumulativne nagrade maksimiziraju. Na osnovu povratnih informacija se vrši prilagođavanje strategija zarad donošenja boljih odluka u budućnosti.

Dodatno, neki od termina koji važe za sve vidove učenja, a bitni su za razumevanje dalje analize su:

- Čišćenje ulaznih podataka (*en. Data Scrubbing*) koje podrazumeva pregledanje podataka u cilju uklanjanja grešaka i rešavanja pitanja nedostajućih vrednosti. Dodatno, može da podrazumeva uklanjanje duplih vrednosti, što je od suštinskog značaja za kvalitet modela.
- Normalizacija i standardizacija ulaznih podataka (*en. Normalization & Standardization*). Normalizacija podrazumeva da se podaci transformišu tako da sve vrednosti podataka padaju u isti opseg: od 0 do 1 ili od -1 do 1. Standardizacija je takođe deo pripreme podataka, a podrazumeva da se podaci transformišu tako da imaju normalnu distribuciju gde je srednja vrednost 1, a standardna devijacija¹⁸ 0. Kada su podaci normalno distribuirani, to znači da se oko 68% vrednosti nalazi u rangi $\pm 1\text{StDev}$ u odnosu na μ . Oko 95% opservacija posmatranog skupa se nalazi u intervalu $\pm 2\text{StDev}$, a u rangi $\pm 3\text{StDev}$ se nalazi oko 99.7% podataka.
- Pristrasnost i varijansa (*en. Bias & Variance*) – *Bias* se odnosi na pristrasnost modela, odnosno na sistematske greške koje isti pravi u odnosu na stvarne ishode. Prethodno rečeno znači da model može imati sklonost da na isti način netačno predviđa ishode, bez obzira na izmene u podacima. Sa druge strane *Variance* ukazuje na to kako se rezultati menjaju u odnosu na male izmene u skupu za treniranje modela. Visoke vrednosti varijanse mogu biti signal da model jako dobro pamti podatke iz trening skupa, sa sve šumom (*en. Noise*) u podacima što dovodi do generisanja modela loše predviđačke snage. Idealno, teži se što nižem *bias*-u i varijansi.
- Preterano prilagođavanje i nedovoljno prilagođavanje modela (*en. Overfitting & Underfitting*). *Overfitting* nastaje kada se model jako dobro prilagodi trening podacima, što rezultuje odličnim klasifikacionim rezultatima modela na trening skupu podataka, ali daleko lošijim rezultatima na test skupu (novim podacima koji nisu korišćeni za razvoj modela). Suprotno tome *underfitting* se odnosi na situaciju u kojoj model nije dovoljno kompleksan da shvati zakonitosti i šablone u podacima, jer nije dovoljno znanja prikupljeno u trening fazi. Ovakvi modeli imaju loše performanse i na trening i na test podacima.

Kada je reč o **primeni tehnika učenja u modelovanju predikcije stečaja**, Shi i Li (2019) su napravili sistematizovani pregled modela predikcije stečaja kroz analizu 321 relevantnog istraživačkog rada, nevezano za državu ili veličinu pravnog entiteta u uzorku. Rezultati su prikazani u Tabeli 7. Najčešće korišćena statistička tehnika je logistička regresija, dok su neuronske mreže najčešća tehnika mašinskog učenja.


¹⁸ Standardna devijacija (skraćeno: *StdDev* ili oznaka σ) se odnosi na apsolutnu meru disperzije u osnovnom skupu. Ovaj pokazatelj daje odgovor na pitanje koliko prosečno elementi nekog skupa odudaraju od aritmetičke sredine (μ) za taj skup.

Tabela 7: Sistematizovan pregled tehnika predikcije stečaja

KLASIČNI STATISTIČKI MODELI		
Rang	Metod	Broj istraživanja
1	Logistička regresija	123
2	Diskriminantna analiza	52
3	Multivarijantna diskriminantna analiza	33
4	Hazardni metod	19
5	Logit i Probit	7
6	Probit	6
MACHINE LEARNING AND ARTIFICIAL INTELLIGENCE MODELS		
Rang	Metod	Broj istraživanja
1	Neuronske mreže	56
2	Mašine sa podrškom vektora (<i>Support vector machine</i>)	32
3	Stabla odlučivanja	21
4	Generički algoritam	20
5	„Fuzzy“ metoda	17
6	„Rough set“ metoda	13
7	Rudarenje podataka	11

Izvor: Shi & Li, 2019

Cheraghali i Molnár (2023) su u studiji akcenat stavili na mala i srednja preduzeća (MSP), te analizirali 145 studija koje se bave stečajem MSP u periodu 1972-2023. godina. Na Slici 11, prikazana je distribucija naučnih radova na ovu temu. Oznaka “ABS” se odnosi na radove koji su publikovani u časopisima koji su na listi Asocijacije poslovnih škola (*en. Association of Business Schools*), dok Non-ABS ima suprotno značenje.

Slika 11: Distribucija istraživanja na temu predikcije stečaja MSP

Izvor: Cheraghali i Molnár, 2023, str. 8

Rezultati istraživanja pokazuju da do 2023. godine na teritoriji Republike Srbije ne postoji literatura koja se bavi predikcijom stečaja MSP. Najviše istraživanja na temu predikcije stečaja MSP je sprovedeno u Italiji (29), i Kini (17).

4.1. Statističke tehnike

Statističke tehnike se, u konkretnom istraživanju, odnose na logističku regresiju (*en. Logistic regression*) i diskriminantnu analizu (*en. Discriminant Analysis*) čija će teorijska polazišta biti predstavljena u nastavku.

4.1.1. Logistička regresija (LR)

4.1.1.1. Teorijsko-metodološka osnova logističke regresije

U svojoj srži, logistička regresija (log regresija) je slična višestrukoj regresiji. Međutim, glavna razlika je to što ishod može biti kategorička varijabla, dok prediktori (nezavisne varijable) mogu da budu ili kategoričke ili kontinuirane. Kada se predviđa pripadnost grupi za samo dva kategorička ishoda, onda se govori o *binarnoj* log regresiji. Sa druge strane, kada se predviđa ishod koji ima više od dve kategorije, onda se govori o *multinominalnoj* log regresiji (Field, 2009).

U cilju pojašnjenja principa log regresije, prvenstveno će biti urađen osvrt na linearnu i višestruku regresiju. Kada je reč o *linearnoj regresiji*, varijabla ishoda (Y) se predviđa kao rezultat sledeće jednačine:

$$Y_i = b_0 + b_1X_{1i} + \varepsilon_i$$

U kojoj je b_0 tačka preseka na Y-osi (*en. Intercept*), b_1 je nagib linije (*en. Gradient*), X_1 predstavlja vrednost prediktorske varijable, dok ε označava rezidualni član. Kod *višestruke regresije*, sa druge strane, glavna razlika je to što postoji više prediktora, a po uzoru na jednačinu linearne regresije, svaki prediktor ima svoj koeficijent koji ga množi. Vrednost Y se predviđa na bazi kombinacije više faktora. Jednačina se može zapisati ovako:

$$Y_i = b_0 + b_1X_{1i} + b_2X_{2i} + \dots + b_nX_{ni} + \varepsilon_i$$

Gde b_n predstavlja regresioni koeficijent za varijablu ispred koje stoji (X_n). Na kraju, *logistička regresija* se od prethodno pomenutih razlikuje po tome što se ne vrši predviđanje vrednosti Y na bazi prediktora (X_n), već se vrši predviđanje verovatnoće da se desi ishod Y putem poznatih prediktora. Računski, može se zapisati ovako:


$$P(Y) = \frac{1}{1 + e^{-(b_0 + b_1X_{1i})}}$$

Oznaka $P(Y)$ je verovatnoća da se desi događaj Y, e je prirodni logaritam, dok su ostali koeficijenti u zagradi imenioca slični linearnoj i višestrukoj regresiji. Oznaka b_0 stoji za konstantu u samom modelu, dok se oznaka b_1 odnosi na koeficijent (*en. Weight*) koji stoji uz prediktor varijablu – X_1 . Istom logikom kao i kod linearne regresije, i log regresija može da bude obogaćena dodatnim prediktorima, pa taj zapis izgleda ovako:

$$P(Y) = \frac{1}{1 + e^{-(b_0 + b_1 X_{1i} + b_2 X_{2i} + \dots + b_n X_{ni})}}$$

Logistička regresija je vid nadgledanog učenja i najčešće koristi sigmoidnu funkciju da bi pretvorila u verovatnoću linearnu kombinaciju ulaznih prediktora. Ova funkcija sve realne brojeve svodi na vrednosti od 0 do 1, što je veoma pogodno za binarne klasifikacije (npr. preduzeće je solventno ili preduzeće je u stečaju → dva ishoda). Verovatnoća da se događaj desi zavisi od toga koliko je rezultat transformacije bliži jedinici ili nuli, dok je prelomna vrednost 0.5 (*en. Cut-off*). Vizuelno to izgleda ovako:

Slika 12: Vizuelni prikaz sigmoidne funkcije



Izvor: Hair, 2010

Bitno je napomenuti da se ocena modela log regresije radi preko merila koje se zove log-verovatnoće (*en. Log-likelihood*):

$$\log - \text{likelihood} = \sum_{i=1}^N [Y_i \ln(P(Y_i)) + (1 - Y_i) \ln(1 - P(Y_i))]]$$

Ovo merilo je indikator koji ukazuje na to koliko neobjašnjenih informacija postoji nakon što je model uklopljen. Stoga, može se reći da visoke vrednosti ovog pokazatelja signaliziraju loše modele, jer što je veći log-likelihood, to je veći broj opservacija koje nisu objašnjene modelom.

Postavlja se pitanje kojim testovima se može uraditi dalja analiza kvaliteta uklopljenosti (*en. Goodness-of-fit*) kod log regresionog modela. Najčešće korišćeni su (Hosmer & Lemeshow, 1989; Cox & Snell, 1989; Nagelkerke, 1991):

→ *Hosmer & Lemeshow* R^2 koji se računa na sledeći način:

$$R^2_{H\&L} = \frac{-2L \text{ (of the model)}}{-2LL \text{ (initial)}}$$

Gde se -2LL odnosi na $-(2 * \log\text{-likelihood})$. U brojilac stavlja -2LL za razvijeni model, a u imenilac -2LL koji se odnosi na originalni model, onaj bez unetog ijednog prediktora. Rezultat jednačine varira od 0 do 1, a veći rezultat ukazuje na kvalitetniji model.

→ *Cox & Snell* R^2

$$R^2_{C\&S} = 1 - e^{\left[\frac{-2}{n} (LL \text{ new}) - (LL \text{ baseline}) \right]}$$

Gde se n odnosi na veličinu uzorka, “LL new” na log-likelihood novog modela, a “LL baseline” na log-likelihood originalnog modela bez unetih prediktora.

→ Nagelkerke R^2

$$R^2_N = \frac{R^2_{C\&S}}{1 - e^{\left[\frac{2(LL \text{ baseline})}{n} \right]}}$$

Za regresione modele nije samo bitno da li su dobro uklopljeni (*en. Goodness-of-fit*), već i koji je značaj, odnosno doprinos, pojedinih nezavisnih varijabli (prediktora) u predviđanju verovatnoće ishoda. Pokazatelj *Wald statistic* daje odgovor na to pitanje. Ovaj pokazatelj signalizira da li se b_n koeficijent koji stoji uz određeni prediktor (X_n) značajno razlikuje od nule. Ukoliko se koeficijent razlikuje značajno od nule, pretpostavlja se da prediktor koji stoji uz taj koeficijent ima značajan doprinos u predikciji verovatnoće ishoda. *Wald statistic* se računa na sledeći način:

$$\text{Wald} = \frac{b}{SE_b}$$

Gde se b odnosi na sam regresioni koeficijent, a SE_b je standardna greška (*en. Standard error*) za taj koeficijent.

Kod generisanja log regresionih modela, poznata su dva principa (Field, 2009):

- Direktan unos svih nezavisnih varijabli (*en. Enter method*) koji podrazumeva da se u startu u model uključuju svi prediktori istovremeno;

- Postepen unos nezavisnih varijabli (*en. Stepwise method*) gde se u model prvo uključuje samo konstanta, a prediktori se posle uključuju spram kriterijuma koji se zove “score statistic”. Varijabla sa najvišim prethodno pomenutim pokazateljem se uključuje u model, i tako svaka naredna dok nijedna preostala varijabla više nema značajan *score statistic* rezultat. Drugim rečima, *Stepwise* logistička regresija u model uključuje samo one nezavisne varijable koje su značajne za predviđanje događaja (Kušter, 2023b). *Stepwise* tehnika može uključivati varijable od napred (*en. Forward Stepwise*) ili od pozadi (*en. Backward Stepwise*). U oba slučaja, varijable se uvode u model korak po korak, sve dok ispunjavaju statističke kriterijume, ali isto tako svaka varijabla može da bude eliminisana u svakom narednom koraku ukoliko nadalje ne bude doprinosila dovoljno regresionom modelu (Ho, 2013, str. 295).

Kod log regresije treba obratiti pažnju da (Ho, 2013):

- Zavisna varijabla bude nominalna, odnosno kategorička, te se sastoji samo od dve grupe (npr. bankrotiralo preduzeće i solventno preduzeće);
- Nezavisne varijable mogu biti kontinuirane, dihotomne ili kombinacija prethodna dva;
- Pitanje distribucije prediktora (normalnost i linearnost) nisu obavezan zahtev za sprovođenje ove analize, ali je bitno rešiti pitanje multikolinearnosti (putem *Variance Inflation Factor* – VIF analize¹⁹)

Osnovna prednost ovog vida modelovanja, ogleda se u jednostavnosti implementacije, te lakom načinu interpretacije. Unošenjem vrednosti nezavisnih varijabli u razvijenu funkciju, dolazi se do verovatnoće nastanka događaja. S obzirom da je rezultat verovatnoća, pogodna je za donošenje svih odluka koje se zasnivaju na mogućnosti da se neki ishod desi. Dalje, modelovanje putem log regresije pokazuje veliku efikasnost, pogotovo kada je mnogo ulaznih varijabli. Na kraju, bitna karakteristika i prednost ovog vida modelovanja je to što nema potrebe da se radi skaliranje nezavisnih varijabli, odnosno normalizacija nezavisnih varijabli. Sa druge strane, slabost log regresije jeste to što postaje neefikasna za ekstremno velike skupove podataka, te činjenica da je predodređena za rešavanje samo klasifikacionih problema.

4.1.1.2. Pregled postojećih modela predikcije stečaja zasnovanih na logističkoj regresiji

Pionir modelovanja predikcije stečaja na bazi log regresije jeste Ohlson (1980). Istraživanje koje je on sproveo ukazuje da su odnos neto rezultata i ukupne aktive, kao i odnos ukupnog duga i aktive, najbolji prediktori stečaja. Luoma i Laitinen (1991) su u razvijenom modelu sa 7 faktora ostvarili tačnost predikcije 73.5% i 71% za preduzeća u stečaju i solventna preduzeća respektivno. Model predviđa stečaj godinu dana unapred, a baziran je na uzorku kompanija iz Finske. Fletcher i Gross (1993) u svom log modelu sa 3 faktora postižu klasifikacionu moć modela 71%.

Laitinen i Laitinen (2000), težili su u modelu predvideti verovatnoću pokretanja stečajnog postupka čak tri godine unapred. Primenjena je tehnika postepenog uključivanja varijabli

¹⁹ **VIF (Variance Inflation Factor)** analiza se koristi kod modelovanja u cilju identifikacije multikolinearnosti između nezavisnih varijabli, što u značajno može uticati na stabilnost i interpretaciju modela. Visoke VIF vrednosti signaliziraju prisustvo multikolinearnosti, što bi značilo da je varijabla u jakoj korelaciji sa jednom ili više drugih nezavisnih varijabli. Detaljnije će postupak VIF analize biti objašnjen prilikom pripreme podataka za modelovanje.

(*en. Stepwise*), a tačnost modela je 75%, 65% i 67% za predikciju stečaja godinu, dve i tri godine unapred respektivno. Hu i Ansell (2009) su, pored nekoliko drugih modela, razvili i model po metodi log regresije. Principom postepenog uključivanja su selektovane varijable, a konačan model obuhvata 10 internih i eksternih varijabli. Model ostvaruje tačnost od 90%, 87% i 82% predikcije stečaja godinu, dve i tri unapred.

Tseng i Hu (2010) su u svom istraživanju predložili predikciju upotrebom raznih principa, a jedan od njih jeste i log regresija. Istraživanje ukazuje na to su da su indikatori profitabilnosti, ali i oni koji se tiču upravljanja novčanim tokovima – ključni. Ukupna tačnost modela na trening skupu podataka iznosi 77%. Za razliku od većine autora, Cho i saradnici (2010), pored tehnike postepenog uključivanja varijabli u regresioni model, upotrebili su stablo odlučivanja da donesu odluku o tome koja varijabla je značajna za predikciju stečaja. Model je razvijen na uzorku od 1000 entiteta, a broj solventnih i preduzeća u stečaju je jednak (1:1). Najuspešniji model ima predviđačku snagu 72%, a oslanja se na 7 racio pokazatelja, u najvećoj meri vezanih za profitabilnost, likvidnost i aktivnost, dok su uključena i racia rasta (dinamike). Yoon i Kwon (2010) su na izbalansiranom uzorku od 10.000 preduzeća razvili model ukupne klasifikacione tačnosti 70%. Sa druge strane, Divsalar sa saradnicima (2012) opredelio se za upotrebu uzorka koji nije izbalansiran, a u totalu ima 136 firmi. Razvijeni model se oslanja na pokazatelje profitabilnosti, likvidnosti i solventnosti, a ima ukupnu predviđačku moć 76% za testni set podataka. Shie i koautori (2012) su na uzorku od 54 kompanije razvili model predviđačke snage 73% i to na bazi racia profitabilnosti, likvidnosti, novčane pozicije, te racia efikasnosti. Du Jardin i Severin (2011) su primenom postepenog uključivanja varijabli razvili nekoliko modela na uzorku od 2360 kompanija, među kojima je i log regresioni model sa klasifikacionom snagom 81.1%.

Tseng i saradnici (2014), metodom log regresije uz inicijalnu primenu 5 grupa racio pokazatelja (likvidnost, leveridž, obrt, profitabilnost i tržište) generisali su tri modela predikcije stečaja: godinu dana, dve godine i tri godine pre pokretanja postupka. Najuspešniji modeli imaju tačnost 79%, 79% i 75% za predikciju stečaja godinu, dve i tri unapred – respektivno. Tri modela predikcije stečaja i do tri godine unapred, razvijeni su od strane autora Gordini (2014) na uzorku 3.100 kompanija uz upotrebu varijabli profitabilnosti, likvidnosti, zaduženosti i novčanih tokova. Ključne varijable su selektovane putem VIF analize i metode postepenog uključivanja varijabli u model. Ukupna preciznost razvijenih modela predikcije stečaja za jednu, dve i tri godine je respektivno 69%, 68% i 67%. Du Jardin (2015) je u svojoj analizi odabrao samo nekoliko sektora prilikom modelovanja (trgovina, građevina i usluge), te koristio nekoliko test uzoraka. Najprecizniji univerzalni model za ova tri sektora beleži ukupnu tačnost od 81% za predikciju stečaja godinu dana unapred, 78.5% za predikciju dve godine unapred i 75.5% za predikciju stečaja tri godine unapred. Varijable koje su uključene u finalne modele su pretežno vezane za likvidnost, obrt potraživanja, te povrat na uloženi kapital.

Papana i Spyridou (2020) su razvili model predikcije stečaja log regresijom za grčka preduzeća. Za redukciju dimenzionalnosti je korišćen t-test, a nakon same redukcije, preostalo je 9 varijabli. Varijable su mahom vezane za profitabilnost, likvidnost, solventnost, kao i strukturu imovine. Model ima ukupnu tačnost 66% za predikciju stečaja godinu dana unapred, 62.5% za predikciju dve godine unapred i 68% kod predikcije stečaja tri godine unapred. Sricharoenchit and Hensawang (2021) su se u modelovanju osvrnuli samo na auto industriju Tajlanda, te razvili model ukupne tačnosti 75% uz upotrebu finansijskih racia, kao i varijabli korporativnog upravljanja. Na uzorku od 9.771

kompanije iz Slovačke, Papík i Papíková (2024), poredili su performanse log regresije sa algoritmima mašinskog učenja. Model logističke regresije je ostvario ukupnu tačnost 68.29% i imao je najlošije performanse poređeno sa ostalih 6 tehnika.

Kada je reč o modelima koji su razvijeni *na teritoriji Srbije*, važno je istaći da postoji nekolicina autora koji su metodom log regresije vršili modelovanje predikcije stečaja, ali fokus nije bio usmeren na MSP. Upotrebom “sirovih” varijabli vezane za broj zaposlenih i zaradu pre kamate, taksi i amortizacije (EBITDA), te upotrebom ratio pokazatelja obrta i zaduženosti, Stanišić i saradnici (2013) su razvili log regresioni model sa ukupnom tačnošću 75%. Model je razvijen na uzorku od 130 preduzeća koja se klasifikuju kao srednja i velika. Bešlić-Obradović i koautori (2018) su razvili model predikcije stečaja na uzorku od 126 srednjih i velikih kompanija. Uključene su samo finansijske varijable, a metodom postepenog uključivanja varijabli, za konačan model su selektovani pokazatelji vezani za radni kapital, samostalnost finansiranja, te efikasnost biznisa. Ukupna tačnost modela na trening skupu podataka iznosi 82.5%. Za MSP sa teritorije Srbije, razvijen je log regresioni model predikcije stečaja MSP na uzorku od 100 entiteta (Kušter, 2023b), ali sa fokusom samo na efikasnost upravljanja aktivom i radnim kapitalom (*Working Capital*).

4.1.2. Diskriminantna analiza (DA)

4.1.2.1. Teorijsko-metodološka osnova diskriminantne analize

Diskriminantna funkcija je statistička tehnika koja omogućava definisanje varijabli kojima se pravi razlika između dve ili više grupa. Ukoliko se govori o diskriminaciji između dve grupe, onda se analiza naziva samo “diskriminantna” (*en. Discriminant Analysis*). Sa druge strane, ukoliko je reč o diskriminaciji između više grupa, tehnika dobija prefiks “višestruka” (*en. Multiple Discriminant Analysis*), koja je poznatija i kao MDA (Ho, 2013, str. 335).

Diskriminantna analiza uključuje izvođenje varijante (*en. Variate deriving*). Diskriminantna varijanta podrazumeva linearnu kombinaciju dve ili više nezavisnih varijabli koje mogu da ostvare najbolju diskriminaciju između dva skupa podataka. (Hair, 2010). Diskriminacija se postiže kroz obračun težinskih koeficijenata (*en. Weights*) za svaku nezavisnu varijablu sa ciljem postizanja maksimalne diskriminacije između grupa. Varijanta u diskriminantnoj analizi se još naziva i *diskriminantnom funkcijom*, a ista se matematički može zapisati na sledeći način:


$$Z_{jk} = a + W_1X_{1k} + W_2X_{2k} + \dots + W_nX_{nk}$$

Gde se Z_{jk} odnosi na Z rezultat (*en. Z Score*) diskriminantne funkcije j za objekat k ; zatim, a je oznaka za konstantu (*en. Intercept*); dalje, W_n je oznaka za težišni koeficijent diskriminantne funkcije za nezavisnu varijablu n ; na kraju, X_{nk} je nezavisna varijabla n za objekat k .

Na Slici 13, dat je prikaz funkcije diskriminacije. DA je adekvatna tehnika za testiranje jednakosti srednjih vrednosti grupa (*en. Group Means Equality*). Izračunavanjem prosečnih vrednosti diskriminantnih rezultata za sve pojedinačne vrednosti u nekoj grupi, dolazi se do srednje vrednosti same grupe. Ova vrednost se još naziva i *centroid* i predstavlja “centar” grupe. Poređenje *centroida* grupa signalizira koliko su udaljene

grupe u kontekstu diskriminacije između istih. Test statističke značajnosti same diskriminantne funkcije predstavlja stepen udaljenosti između centroida grupe. Kada je nivo preklapanja mali (pogledati Sliku 13, gornji grafikon), to je signal da diskriminantna funkcija dobro vrši podelu (diskriminaciju) dve grupe. Sa druge strane, ukoliko je nivo preklapanja veliki, to znači da funkcija ima lošu tačnost, te da ne radi diskriminaciju dovoljno dobro. Na Slici 13, gornji grafikon prikazuje dobar klasifikator, odnosno jaku diskriminaciju, kako je osenčena površina mala, dok donji grafikon ukazuje na loše diskriminatorne performanse funkcije, kako je osenčena površina velika. Tačnije, osenčena površina ukazuje na sve situacije gde se može desiti da se neka jedinica posmatranja iz A grupe slučajno klasifikuje kao član B grupe i obrnuto.

Slika 13: Vizuelni prikaz diskriminantne funkcije



Izvor: Hair, 2010

Hair (2010) ističe da postoji nekoliko načina da se definiše jedinstvena (optimalna) *cut-off* vrednost kod diskriminantne funkcije:

$$Z_{CS} = \frac{N_A Z_B + N_B Z_A}{N_A + N_B}$$

Gde je Z_{CS} optimalan *cut-off* rezultat, N_A broj opservacija u grupi “A”, N_B broj opservacija u grupi “B”, Z_A je centroid za grupu “A”, dok je Z_B centroid za grupu “B”. Ukoliko su obe grupe jednakih veličina, onda se optimalan rezultat za klasifikaciju može izračunati na sledeći način:

$$Z_{CE} = \frac{Z_A + Z_B}{2}$$

Gde se Z_{CE} odnosi na optimalan *cut-off* rezultat, dok su Z_A i Z_B centroidi za grupu “A” i “B” respektivno.

Kod DA tehnike, važni su sledeći parametri:

- ➔ Log determinante (*en. Log Determinants*) koje služe za procenu homogenosti kovarijacionih matrica. Kada je ovaj pokazatelj za različite grupe sličan, to signalizira da je pretpostavka jednakosti kovarijacionih matrica ispunjena;
- ➔ Box-ov M test (*en. Box's M Test*) koji takođe proverava da li postoji homogenost kovarijacionih matrica među grupama. Visoke vrednosti ovog testa nisu dobar signal, te mogu ukazati na velike razlike u kovarijacionim matricama, što dalje može narušiti DA;
- ➔ Sopstvene vrednosti (*en. Eigenvalues*) se odnose na varijansu koja je objašnjena funkcijama diskriminacije. Što su veće sopstvene vrednosti, to je veća sposobnost diskriminatorne funkcije da razdvoji grupe;
- ➔ Vilkova lambda (*en. Wilk's lambda*) ukazuje na to koliko funkcija dobro diskriminiše vrednosti između grupa. Vrednosti bliže nuli ukazuju na dobru moć modela. Ovaj pokazatelj se kombinuje sa drugim, jer u uslovima malih uzoraka ili pak velikog broja varijabli – može biti nepouzdan.

Kod DA tehnike, važno je voditi računa o narednim pretpostavkama i zahtevima (Ho, 2013):

- Zavisna varijabla mora biti kategorička, a može da reprezentuje dve ili više grupa
- Važna je veličina uzorka, jer minimalno mora da postoji 5 opservacija po jednoj nezavisnoj varijabli. Iako su prihvatljive nesrazmerne veličine grupa između kojih se radi diskriminacija, ponekad velike razlike u broju opservacija po grupama – mogu biti problem;
- Potreban ali ne i presudan uslov je linearnost;
- Normalnost distribucije podataka je neophodna da bi rezultati analize bili upotrebljivi na novim podacima;
- Pretpostavlja se homogenost kovarijacionih matrica, a ista se testira putem Box-ovog M testa;
- Odsustvo multikolinearnosti je neophodno kako bi se obezbedilo generisanje stabilnih koeficijenata, te izbegla degeneracija kovarijacione matrice;
- Prisustvo ekstremnih vrednosti remeti DA.

Generisanje modela na bazi diskriminantne analize, kao i kod log regresije, može da se sprovede uključivanjem svih nezavisnih varijabli odjednom („enter“ metoda) ili pak postepenim uključivanjem parametara modela („stepwise“ metoda). Kao i svaka tehnika, tako i DA ima svoje prednosti, ali i nedostatke. Velika prednost ove tehnike jeste to što ima dobre performanse onda kada su uslovi normalnosti i homogenosti varijansi ispunjeni. Dodatno, može da se koristi za klasifikaciju između više od 2 grupe. Iako se interpretiraju modeli, a unošenjem nezavisnih varijabli u funkciju, lako se dolazi do samog rezultata diskriminacije. Međutim, ukoliko podaci nisu normalno distribuirani ili ako ne postoji jednakost kovarijacionih matrica, performanse značajno opadaju. Stoga, više vremena je potrebno utrošiti na pripremu podataka. Dodatno, kada se modeluje sa velikim brojem varijabli, DA može da postane nestabilna, pa je potrebno sa velikom pažnjom tumačiti testove koji potvrđuju stabilnost samog modela.

4.1.2.2. Pregled postojećih modela predikcije stečaja zasnovanih na diskriminantnoj analizi

Jedan od prvih autora koji se bavio predikcijom stečaja na bazi diskriminantne analize, bio je Altman (1968). Upotrebom racio pokazatelja na uzorku od 66 kompanija, razvio je model sa šest varijabli ukupne tačnosti 79%. Godinama kasnije, Altman je razvijao i unapređivao svoje modele diskriminantne analize kroz dodavanje ili oduzimanje faktora (Altman, 1983; Altman 2005). Deakin (1972) je upotrebom 14 varijabli razvio DA model predikcije stečaja koji je godinu dana unapred tačno klasifikovao 77% preduzeća u stečaju, te 82% solventnih preduzeća. Model se svrstava u generalne, što znači da nije fokusirao neku posebnu delatnost ili veličinu preduzeća. Jedan od značajnijih modela predikcije stečaja na teritoriji UK, razvio je Taffler (1983), a isti je ostvario tačnost klasifikacije 60% za preduzeća u stečaju. Keasey i Watson (1986), svoju analizu su usmerili ka malim preduzećima sa teritorije UK. Diskriminantnom funkcijom sa 5 faktora, postigli su ukupnu tačnosti klasifikacije 70% za preduzeća u stečaju, te 80% za preduzeća koja su solventna i to godinu dana unapred. Grover (2003) je objavio istraživanje u kojem je predstavljen generalni model predikcije stečaja putem DA funkcije sa 6 faktora. Testni uzorak je pokazao tačnost 72.4%. Dimitras i koautori (1999) su sa 12 faktora razvili model predikcije stečaja na uzorku 40 grčkih kompanija. Klasifikaciona moć za bankrotirala preduzeća iznosi 63.2%, dok za solventna iznosi 68.4%.

Slefendorfas (2016) je sproveo istraživanje na uzorku od 145 MSP sa teritorije Litvanije. Celokupan uzorak je podrazumevao privatna preduzeća, a nije izbalansiran, kako su 73 kompanije nesolventne, a 72 i dalje posluju. Upotrebljeno je čak 156 finansijskih racia, a modelovanje je izvršeno putem postepene (*en. Stepwise*) diskriminantne analize. Ukupna klasifikaciona snaga modela je 89%. Kim (2011) u analizi takođe koristi tehniku postepenog odabira varijabli, a na izbalansiranom uzorku od 56 entiteta, razvijen je model ukupne tačnosti 72.6%. Na nebalansiranom uzorku od 1775 preduzeća, autori Lee i Choi (2013) su razvili model tačnosti 82%.

Pervan i koautori (2011) su odabrali 78 insolventnih entiteta sa teritorije Hrvatske, i tom broju dodali isti broj entiteta koji i dalje posluju, te upotrebom diskriminantne analize razvili model predikcione snage 80%. Pored toga, izvršeno je modelovanje log regresionim principom i potvrđeno da taj model ima jaču klasifikacionu snagu od DA – 83%. Nije u pitanju generalni model, kako su svi entiteti iz uzorka deo prerađivačke i trgovinske grane privrede. Korišćeni su racio pokazatelji likvidnosti, aktivnosti, profitabilnosti, novčanih tokova i finansijske strukture. Nasuprot tome Kim i Gu (2006) u svojoj analizi dokazuju da diskriminantna analiza i log regresija imaju istu efektivnost kod predviđanja stečaja u ugostiteljstvu.

Abbas i Rashid (2011) su analizirali podatke u vremenskom intervalu 1996-2006. godina za ukupno 52 preduzeća (26 solventnih i 26 insolventnih), a po uzoru na Altmanovu DA funkciju, kreirali su model ukupne tačnosti 77%. Predloženi su racio pokazatelji finansijskog leveridža, profitabilnosti, likvidnosti, solventnosti, kao i aktivnosti. Lugovskaya (2010) fokus stavlja na sektor malih i srednjih entiteta, te na uzorku od 520 entiteta uz testiranje na odvojenom uzorku, postiže 79% tačnost klasifikacije. Istraživanje je uključivalo i finansijske i nefinansijske varijable, a ključni parametri modela su izabrani putem *PCA* i *Stepwise* tehnike. Još jedan rad koji je akcentovao MSP, objavljen je od strane autora Terdpaopong i Mihret (2011). Model je razvijen na uzorku od 266

entiteta, a ukupna tačnost istog je 97%. Korišćene su finansijske varijable. Putem analize korelacije su selektovane one ključne za modelovanje. Autori Kosmidis and Stavropoulos (2014) su na uzorku 58 MSP razvili model ukupne tačnosti 85.5%. Upotrebljene su samo finansijske varijable.

Khan (2018) u analizi se osvrće na kompanije koje su na teritoriji Pakistana, a čije se akcije kotiraju na *Karachi* berzi. Uzorak obuhvata podatke u vremenskom periodu 2009-2015. godina. Selektovano je 40 firmi. Model diskriminantne analize sa 6 faktora je postigao tačnost klasifikacije 81.5% na trening uzorku, što je lošije od log regresionog modela koji je razvijen na istom setu podataka. Sa druge strane, Szetela i dr. (2016) primenom diskriminantne analize za predikciju insolventnosti, zaključuju da je to najpovoljniji metod analize poređeno sa ostalim metodama kao što je log regresija. Zulkarnain i saradnici (2001), analizirali su podatke u vremenskom periodu 1980-1996. godina za preduzeća sa teritorije Malezije i generisali model diskriminantne analize upotrebom racia obaveza i ukupne aktive, prihoda od prodaje i obrtno imovine, novčanih sredstava i kratkoročnih obaveza, te tržišne vrednosti duga. Pindado i Rodrigues (2004) su na uzorku od 42 insolventne i 42 solventne male firme generisali model diskriminantne analize. Sva preduzeća su sa teritorije Portugalije, a pripadaju prerađivačkoj industriji. Klasifikaciona snaga modela je 77.95% za testni uzorak.

Na uzorku od 9.771 kompanije iz Slovačke, Papík i Papíková (2024), razvili su model diskriminantne analize zajedno sa drugim metodama, a sve sa ciljem da se izvrši poređenje sa algoritmima mašinskog učenja. Diskriminantna funkcija je ostvarila ukupnu tačnost 75%, dok je najuspešniji algoritam mašinskog učenja ostvario klasifikacionu snagu 84.52%. U skladu sa prethodno rečenim, u istraživanju koje su objavili Shetty i saradnici (2022) potvrđeno je da su tehnike mašinskog učenja nadjačale DA po performansama.

Na *teritoriji Republike Srbije*, Kušter (2023a) je razvio model predikcije stečaja godinu dana unapred na bazi diskriminantne analize. Model je razvijen na uzorku od 74 kompanije različitih veličina, a inicijalno je uključeno 12 nezavisnih varijabli. Model sa dva faktora je pokazao ukupnu tačnost predikcije stečaja godinu dana unapred 70.3% (kod unakrsne validacije).

4.2. Tehnike mašinskog učenja

Tehnike mašinskog učenja se, u konkretnom istraživanju, odnose na neuronske mreže (*Neural Networks*), stabla odlučivanja (*Decision Trees*) i k-najbližih suseda (*k-Nearest Neighbours*) čija će osnovna teorijska obeležja biti predstavljena u nastavku.

4.2.1. Neuronske mreže (NN)

4.2.1.1. Teorijsko-metodološka osnova neuronskih mreža

Neuronske mreže se sastoje od čvorova (neurona) koji komuniciraju putem sinapsi - veza između njih. Svaki neuron prima signale od drugih neurona ili spoljašnjih izvora, obrađuje ih kroz težinske koeficijente (*en. Weights*) i aktivacione funkcije (*en. Activation function*), i zatim šalje izlazne signale dalje.

Kod nadgledanog učenja, neuronske mreže se treniraju na setu podataka koji je označen (*en. Labeled*), odnosno postoji jasna veza između inputa i poznatog outputa. Neuronska mreža funkcioniše tako što vrši prilagođavanje težinskih koeficijenata (*en. Weights*) i *bias* vrednosti u cilju minimiziranja razlike između realnih outputa i onih koji su prediktovani modelom. Kod nenadgledanog učenja, treniranje se vrši na setu podataka koji nije označen kao u prethodnom slučaju, već je cilj da algoritam otkrije koji obrasci postoje u podacima.

Postoje tri najčešće korišćene vrste neuronskih mreža (Murray, 2023):

1. *Feedforward* neuronske mreže koje su poznate i pod imenom MLP (*en. Multilayer perception*). One su najprostije i najčešće korišćene mreže u praksi. Kod ovih mreža, informacije teku u jednom smeru, od input čvora, kroz skrivene slojeve, sve do krajnjeg - output čvora. Svi čvorovi u jednom sloju su povezani u potpunosti sa onim iz narednog sloja. Ovaj vid mreža je najkorisniji kada se rade klasifikacioni problemi. One funkcionišu tako što prvo input sloj prima podatke koji su standardizovani tako da budu na istoj skali. Svaki čvor u input sloju je jedna varijabla. Vrednosti varijabli se množe sa težišnim koeficijentima iz konekcije između input i prvog skrivenog sloja (*en. Hidden Layer*). Skriveni sloj radi niz transformacija na input podacima kako bi razumeo koji obrasci postoje u podacima. Poslednji korak je izlazni sloj koji proizvodi klasifikaciju. Bitno je napomenuti da MLP podrazumeva i prilagođavanje težišnih koeficijenata kako bi se minimizirala funkcija gubitka (*en. Loss function*). Ovo se obično radi uz pomoć *gradient descent* algoritma.
2. *Convolutional* neuronske mreže se koriste kod slika i videa, odnosno koriste se da prepoznaju obrasce koji postoje u njima putem konvolucionih slojeva. Svaki sloj primenjuje niz filtera u inputu i tako izvlači određene karakteristike.
3. *Recurrent* neuronske mreže se najviše koriste za procesiranje govora i teksta. One imaju rekurentne veze, tako da čuvaju u sebi informacije o prethodnim input i skrivenim stanjima. Ova neuronska mreža prilikom donošenja odluka o trenutnom izlazu, uzima u obzir kontekst prethodnih ulaza.

Pre početka modeliranja neuronskih mreža, potrebno je izvršiti normalizaciju, odnosno skaliranje nezavisnih varijabli, kako bi bile iste magnitude. Dodatno, potrebno je uraditi adekvatno kodiranje i redukciju dimenzionalnosti (*en. Feature engineering*). Najčešći

način na koji se radi odabir ključnih nezavisnih varijabli jeste PCA²⁰ (*en. Principal Components Analysis*). Kreiranje modela neuronske mreže podrazumeva i definisanje brojnih hiperparametara: stopa učenja (*en. Learning rate*), veličinu grupe (*en. Batch size*), broj epoha (*en. Epochs*), aktivacione funkcije (*en. Activation function*), broj skrivenih slojeva (*en. Hidden layers*) itd. Prema rečima autora Burkov-a (2023) onog momenta kada neuronska mreža ima više od dva sloja koja nisu output, reč je o dubokom učenju (*en. Deep Learning*).

- ➔ *Learning rate* je hiperparametar koji definiše koliko brzo ili sporo se model ažurira u kontekstu njegovih parametara tokom procesa optimizacije pomoću algoritama kao što je *gradient descent*. Kada je ovaj parameter viši, može da dovede do ubrzavanja konvergencije, što otežava postizanje vrednosti koje su optimalne. Sa druge strane, nizak *learning rate* može dovesti do usporavanja konvergencije. Stoga, balans između brzine konvergencije je ključ prilikom izbora ovog parametra.
- ➔ *Batch size* se odnosi na to koliko će uzoraka biti pušteno kroz neuronsku mrežu i to pri svakom koraku optimizacije. Veće vrednosti ovog parametra ukazuju na to da će se istovremeno obrađivati više uzoraka, što dovodi do brže konvergencije i *vice versa*.
- ➔ *Epochs*, odnosno epohe, odnose se na broj iteracija kroz celokupan set podataka tokom treninga. Jedna epoha je jedno prolaženje kroz sve opservacije skupa. Tokom jedne epohe, mreža radi ažuriranje parametara pomoću optimizirajućih algoritama, kao što je *gradient descent*, u cilju minimiziranja greške u predikciji.
- ➔ *Activation functions*, odnosno aktivacione funkcije, bitan su element koji uvodi nelinearnost u modele neuronskih mreža. Kroz izlaz, svaki neuron primenjuje aktivacionu funkciju i to modelu omogućava da uči složene šablone u podacima. Postoji nekoliko aktivacionih funkcija:
 - *ReLU* (aktivira neurone tako što negativne vrednosti svodi na nulu, a pozitivne vrednosti ostavlja nepromenjene, što ubrzava učenje),
 - *Tanh* (tangens hiperbolička koja vrednosti mapira na skalu od -1 do 1),
 - *Sigmoidna* (vrednosti mapira na skalu od 0 do 1, što je pogodno kod binarnih klasifikacija),
- ➔ *Hidden layers*, odnosno skriveni slojevi, nalaze se između ulaznog i izlaznog sloja, a u sebi sadrže skrivene jedinice i neurone. Veći broj skrivenih slojeva može da pojača snagu mreže, ali i da poveća njenu složenost što otežava rad u kontekstu računarskih resursa. Stoga, balans je neophodan, kao i kod drugih parametara.

Ukoliko su date vrednosti x_1 , x_2 i x_3 , neuron radi sledeći obračun (Bernard, 2021, str. 272):

$$y = f(w_1x_1 + w_2x_2 + w_3x_3 + b)$$

²⁰ **PCA (Principal Components Analysis)** funkcioniše tako što pronalazi komponente kod kojih podaci imaju najveću varijansu. Prva glavna komponenta predstavlja onu sa najvećom varijansom podataka, dok je druga glavna komponenta ona sa sledećom najvećom varijansom itd. Na ovaj način se smanjuje dimenzionalnost podataka, što olakšava analizu. Postupan prikaz PCA će biti izvršen prilikom same pripreme za treniranje neuronske mreže na konkretnim podacima.

Gde su w_1 , w_2 i w_3 *learning* parametri odnosno koeficijenti (*en. Weights*) koji se mogu interpretirati kao “snaga” konekcije između neurona. Oznaka b je još jedan parameter koji se uči, a zove se *bias*. Oznaka f stoji za aktivacionu funkciju. Prilikom treniranja, kao što je pomenuto, neuronska mreža uči tako što minimizira funkciju troška (*en. Cost function*), a ona je suma gubitaka pojedinačnih slučajeva, plus opcionalna regularizacija. To se može prikazati na sledeći način:


$$\text{cost}(w) = \frac{1}{m} \sum_{i=1}^m \text{loss}(f_{w(x_i)}, y_i) + \text{reg}(w)$$

Ovde su x_i i y_i input i autput, dok je f mreža, a w su parametri mreže. Kod klasifikacionih problema, tipično se javlja *cross-entropy loss*:

$$\text{loss}(f_{w(x_i)}, y_i) = -\log(P_w(y_i | x_i))$$

Pomenuti parametri neuronskih mreža, jasniji su ukoliko se prikažu vizuelno, stoga vizuelni prikaz sledi na Slici 14.

Slika 14: Vizuelni prikaz neuronske mreže



Izvor: Karimova i dr, 2024

Za razliku od tradicionalnih statističkih metoda, NN može da se koristi i sa inputima koji imaju šuma u sebi (*en. Noisy data*). Glavne prednosti ovog metoda modelovanja ogledaju se u sledećem:

- ✓ Mogućnost analiziranja obrazaca u podacima sa velikom preciznošću i to za kratak period (Shachmurove, 2002);
- ✓ Ne postoje restriktivne pretpostavke koje nezavisne varijable moraju da ostvare da bi se modelovalo (Callejón i dr, 2013; Shachmurove, 2002 i Cybinski, 2000);
- ✓ NN lako prevazilaze problem autokorelacije (Cybinski, 2000) i
- ✓ Nepotpuni podaci koji imaju šum nisu problematični za NN tokom uočavanja obrazaca u podacima (Shachmurove, 2002).

Međutim, glavni nedostatak je činjenica da NN ne mogu lako da objasne svoje ponašanje, te veze između varijabli (*en. Black Box Dilemma*). Glavni nedostaci NN metoda su sledeći (Roiger i Geatz, 2003):

- ✗ Nedostatak mogućnosti da se objasni ponašanje mreže i način na koji se odluke donose;
- ✗ Nije garantovano da će NN algoritam konvergirati ka optimalnom rešenju i
- ✗ Lako se može dogoditi da se NN pre-treniraju do te mere da imaju odlične performanse na trening setu podataka, ali loše performanse na test uzorku (*en. Overfitting*).

4.2.1.2. Pregled postojećih modela predikcije stečaja zasnovanih na neuronskim mrežama

Kada je reč o međunarodnoj literaturi, metoda neuronskih mreža je zastupljena među naučnicima. Altman i saradnici (2017) su na uzorku od 1000 entiteta sa teritorije Italije kreirali model predikcije stečaja na bazi neuronskih mreža sa ciljem predikcije stečaja godinu dana unapred. Korišćeni su racio pokazatelji finansijske strukture, zaduženosti, profitabilnosti, likvidnosti, kao i internog finansiranja. Rezultati istraživanja ukazuju na to da su neuronske mreže efikasno i efektivno sredstvo za klasifikaciju preduzeća. Upotrebom metode neuronskih mreža, Callejón i koautori (2013), razvili su model predikcije stečaja na izbalansiranom uzorku koji je sadržao 500 solventnih i 500 entiteta koji su u stečajnom postupku. Oslanjajući se na finansijske podatke od pre dve godine u odnosu na momenat pokretanja stečajnog postupka, razvijen je model jake klasifikacione snage – 92%. Charitou i saradnici (2004) su, takođe uz upotrebu neuronskih mreža, objavili istraživanje u kojem se predviđa stečaj entiteta godinu, dve i tri unapred. Istraživanje ističe široku primenu mreža pored predikcije stečaja: analiza kreditne sposobnosti, detekcija prevara i slično. Krajni ishod modelovanja je ukupna klasifikaciona snaga 83% kod predikcije stečaja godinu dana unapred, odnosno 78% za tri godine pre nego što nastupi insolventnost.

Autor Atiya (2001) je u istraživanju razvio model predikcije stečaja za kompanije sa teritorije SAD-a na bazi neuronskih mreža, te ukazao da korišćeni indikatori imaju značajan uticaj na predikciju stečaja poređeno sa klasičnim finansijskim racio pokazateljima. Rezultat istraživanja je model jake klasifikacione snage koja ide i do 85% za predikciju tri godine unapred. Blanco sa saradnicima (2013) u analizi se osvrnuo na 5500 entiteta koji su pozajmljivali sredstva od kompanija za mikrofinansiranje sa teritorije Perua, te upotrebom MLP neuronskih mreža, razvijen je model za procenu kreditne sposobnosti. Krajnji zaključak istraživanja jeste da metode neuronskih mreža imaju bolje performanse od tradicionalnih metoda ocene kreditne sposobnosti kao što su: logistička regresija, diskriminantna analiza itd. Eriki i Udegbumam (2013) su kroz analizu 44 kompanije iz Nigerije u vremenskom intervalu 1987-2006. godina, ukazali na to da neuronske mreže imaju veliki potencijal, te da su iste značajan alat koji menadžmentu može da pomogne u donošenju odluka. Takođe, rezultati istraživanja ukazuju i da mreže imaju jaču klasifikacionu snagu od diskriminantne analize.

Još jedan u nizu istraživanja koji svedoče o klasifikacionoj snazi neuronskih mreža u poređenju sa diskriminantnom analizom i logističkom regresijom, jeste i ono koje je sproveo Inam sa saradnicima (2019). Pogotovo se ističe činjenica da mreže ne zahtevaju mnogo uslova u smislu obrade nezavisnih varijabli. Razvijeni model se odnosi na sektor prerađivanja i usluga, a ima klasifikacionu snagu 88.9%. Chen i Du (2009) su u svojoj analizi koristili *backpropagation* neuronske mreže i na uzorku od 68 entiteta sa teritorije Tajvana, razvili model predikcije sa ukupnom tačnošću predikcije 82% dve godine pre pokretanja stečaja. Uzorak je bio izbalansiran, a podaci su prikupljeni u vremenskom

periodu 1999-2006. godina. Zaključak istraživanja je da neuronske mreže imaju nadmoć nad tradicionalnim metodama predikcije stečaja. Charalambous i saradnici su (2000) napravili komparativnu analizu logističke regresije i neuronskih mreža, te zaključili da su mreže imale jaču klasifikacionu snagu u sve tri godine pre pokretanja stečajnog postupka. Uzorak se sastojao od 139 kompanija, gde je odnos solventnih i insolventnih bio 1:1. Superiornost neuronskih mreža u predikciji stečaja, takođe je potvrđena i od strane brojnih drugih autora (Brockett, 2006; Kim, 2011; Sehgal, 2021; itd.). Sa ciljem kreiranja modela predikcije stečaja za evropske zemlje, u istraživanju autora Korol (2019), između ostalog, korišćene su neuronske mreže (MLP) sa preciznošću predikcije 93.4% godinu dana unapred i 87,4% dve godine unapred. Neuronske mreže su potvrđene kao odličan klasifikator i na duge staze, sa preciznošću od 80.8%.

Kod istraživanja koje je sproveo Alfaro (2008), izvršena je primena neuronskih mreža na uzorku od 1180 entiteta sa teritorije Španije i to u periodu od 2000. do 2003. godine. Za modelovanje su korišćeni finansijski indikatori, kao i druge varijable poput veličine, pravne forme entiteta itd. Zaključak je da su mreže dobar i pouzdan metod za predikciju stečaja. Sa druge strane, na uzorku američkih i kanadskih kompanija, Barboza i saradnici (2017) su upotrebom neuronskih mreža uz druge metode mašinskog učenja, analizirali faktore koji vode ka stečaju. Analiza se oslanjala na pokazatelje rasta, veličine, likvidnosti i profitabilnosti. Rezultati istraživanja ukazuju na to da su neuronske mreže imale oko 10% lošiju prediktivnu sposobnost poređeno sa drugim metodama mašinskog učenja.

Kod istraživanja koje je sprovedeno od strane autora Fedorova i dr (2013), na uzorku ruskih kompanija je demonstrirano da upotrebom metode neuronskih mreža može da se razvije model preciznosti čak 89%. Upotrebom *backpropagation multilayer* (MLP) mreža i *radial basis function* mreža (RBFN), utvrđeno je da MLP daje bolje rezultate. Nasuprot tome Cheng i saradnici (2006) su u rezultatima svog istraživanja pronašli da RBFN mreže imaju nadmoć nad MLP mrežama, ali i tradicionalnim metodama predikcije stečaja.


Kada je reč o predikciji stečaja upotrebom neuronskih mreža na **teritoriji Republike Srbije**, prisutni su minorni radovi na temu, a nijedan ne pokriva oblast MSP. Simić i saradnici (2012) su razvili MDA-SOM model koji podrazumeva primenu MDA analize i posebne vrste neuronskih mreža koje se zovu *self-organized maps*. U fokusu istraživanja su bila srednja i velika preduzeća sa teritorije Srbije, a klasifikaciona snaga razvijenog modela je 95% godinu dana pre stečaja. Upotrebom podataka iz izveštaja koji su objavljeni dve godine pre pokretanja postupka stečaja, Stanišić i saradnici (2013), razvili su, pored ostalih, i model MLP neuronskih mreža. Klasifikaciona snaga modela je 79.2% uz AUC 0.839. Svi entiteti iz uzorka pripadaju velikim i srednjim preduzećima i ukupno ih ima 130. Marinković i koautori (2014), na uzorku 52 kompanije različitih veličina sa teritorije Republike Srbije (26 solventnih i 26 u stečaju), razvili su dva modela neuronskih mreža. Korišćeno je samo pet racia po uzoru na Altmanovo (1968) istraživanje. *Pattern recognition* mreže su pokazale tačnost 82% na testnom uzorku, dok su *probabilistic* mreže nakon 10 treninga pokazale klasifikacionu snagu 90.7%. Pored nekolicine prethodno pomenutih radova, Kušter i dr. (2023), razvili su model predikcije stečaja godinu dana i dve unapred za Srbiju i to za preduzeća svih veličina i delatnosti. Model predikcije stečaja godinu dana unapred pokazuje ukupnu tačnost 80% na test uzorku, dok model predikcije stečaja dve godine unapred ostvaruje ukupnu tačnost 73.3% na testnom uzorku, takođe.

4.2.2. Stabla odlučivanja (DT)

4.2.2.1. Teorijsko-metodološka osnova stabala odlučivanja

Stabla odlučivanja predstavljaju neparametarski metod koji se koristi često za klasifikacione probleme. Prema rečima autora (Bernard, 2021), ova tehnika ne proizvodi odlične modele u kontekstu predikcije, ali je brza i za rezultat daje modele koji se lako interpretiraju (str. 227). Ovaj metod je osnova za naprednije metode kao što su nasumične šume (*en. Random Forests*) i pojačana stabla (*en. Gradient Boosted Trees*). Na slici 15, dat je primer stabla odlučivanja.

Slika 15: Primer stabla odlučivanja



Izvor: Gepp i Kumar, 2015, str. 398

Svaki čvor je pitanje na koje se može dati prost odgovor: da ili ne. Pitanja se kreću od “korena” drveta, preko grana, dok se ne dođe do samih listova. Prilikom generisanja stabala odlučivanja, težnja je da ista budu što manje kompleksna, jer se takva stabla lakše interpretiraju i manje su podložna *overfitting*-u. Theobald (2021) navodi da se umerena kompleksnost drveta postiže tako što se biraju samo varijable koje optimalno dele podatke u homogene grupe, tako da se umanjuje nivo entropije podataka (*Data Entropy*) naredne grane. Entropija (*Entropy*) je koncept koji ukazuje na visinu varijanse kod podataka između različitih klasa. Obračun entropije se vrši na sledeći način:

$$(-p_1 \log p_1 - p_2 \log p_2) / \log 2$$

Dva često korišćena algoritma su CRT/CART i CHAID:

- ➔ *CRT* ili *CART* (*Classification & Regression Trees*) algoritam generiše stablo u dva koraka. Prvi korak se naziva rastom (*en. Growing*), dok se drugi korak naziva

orezivanjem ili trimovanjem (*en. Pruning*). Tokom samog rasta (Elfar, 2009; Phelps and Merkle, 2008), stablo ima glavne čvorove, odnosno “roditelje” (*en. Parent nodes*), čvorove potomke (*en. Child nodes*) koji nastaju deljenjem ovih prvih, kao i krajnje čvorove (*en. Terminal nodes*). CRT algoritam koristi binarni kriterijum za podelu (*en. Binary splitting*). Glavni čvorovi se dele na čvorove potomke, koji i sami mogu postati glavni čvorovi u narednoj iteraciji, te se dalje deliti na čvorove potomke. Koncept trimovanja ili orezivanja počinje od terminalnih čvorova, gde se oni čvorovi koji ne povećavaju preciznost samog stabla – odstranjuju.

- CHAID (*en. Chi-squared Automatic Interaction Detector*) koristi χ^2 statistiku za donošenje odluka o kategorizaciji. Za razliku od ostalih metoda, CHAID ima mogućnost da kreira čvorove sa više grana, odnosno višestruke podele. Granjanje stabla se završava u onom momentu kada više nije moguće napraviti značajniji pomak (posmatra se p-vrednost). Kao i svako stablo, počinje sa osnovnim čvorom – korenom. Za svaku pojedinačnu nezavisnu varijablu (prediktor), vrši se procena χ^2 statistike za sve moguće podele. Ako prediktorske varijable nisu značajno drugačije u odnosu na zavisnu varijablu – spajaju se. Najviša statistička značajnost signalizira najbolju podelu. Kada je podela statistički značajna (najniža p-vrednost), čvor se deli na podčvorove.

Stabla odlučivanja imaju brojne prednosti (Vlaović Begović i Bonić, 2020, str. 131):

- *Transparentnost* – DT eksplicitno omogućavaju uvid u sve alternative i prikazuju svaku alternativu do krajnjeg ishoda, što omogućava da se alternative porede;
- *Specifičnost* – DT ima mogućnost da dodeli izvesne vrednosti svakoj odluci i rezultatu svake odluke, a time umanjuje nejasnoće u procesu donošenja odluka;
- *Uporedivost* – DT omogućava uporednu analizu posledica bilo koje odluke;
- *Lakoća upotrebe* – DT pružaju grafičku prezentaciju problema i alternative u formatu koji je jednostavan i lak za razumevanje, te ne zahteva dalja objašnjenja;
- *Fleksibilnost* – DT mogu da funkcionišu sa različitim tipovima podataka;
- *Rezilijentnost* – DT se fokusiraju na vezu između različitih događaja, ukazujući na prirodan tok događaja i
- *Potvrđivanje* – DT se koriste za kvantitativnu analizu problema, ali takođe mogu da se koriste za validaciju rezultata statističkih testova.

Međutim, nedostaci su sledeći (Vlaović Begović i Bonić, 2020, str. 132):

- *Nestabilnost* – pouzdanost informacija koje daje DT zavise od tačnosti inputa. Čak i mala promena u unetim podacima, može da rezultuje značajnim promenama u samom DT modelu.
- *Kompleksnost* – iako DT karakteriše lakoća upotrebe kada se poredi sa drugim tehnikama, stabla odlučivanja su ponekad velika i teška za prezentovanje i tumačenje;
- *Trošak* – u vezi sa prethodno rečenim, treniranje velikih stabala odlučivanja zahteva dosta ljudskog rada i ekspertize i
- *Preopterećenje informacijama* – iako je sposobnost stabala da rade sa velikom količinom podataka pozitivna stvar, može se desiti da se donosioci odluka

nekada suoče sa velikim brojem informacija koje model sa sobom nosi, te je neophodno dodatno vreme da se procesuiraju svi podaci.

4.2.2.2. Pregled postojećih modela predikcije stečaja zasnovanih na stablima odlučivanja

Chen (2011) predlaže upotrebu dva algoritma C5.0 i CART (CRT). Ideja je bila da se utvrdi koliko kvartala unapred mogu da se predvide finansijske poteškoće kompanija sa Tajvana. Uzorak je obuhvatio 200 kompanija čije se akcije kotiraju na berzi, a samo modelovanje je izvršeno upotrebom 42 ratio pokazatelja: 33 finansijska, 8 nefinansijskih i 1 kombinovano-makroekonomski. Za redukciju dimenzionalnosti je korišćena PCA tehnika. Model razvijen putem C5.0 algoritma je ostvario ukupnu tačnost 86.79% za predikciju 2 kvartala unapred, odnosno 78.75% za predikciju 8 kvartala unapred. DT razvijen putem CART algoritma, pokazuje niže performanse sa ukupnom tačnošću 84.91% i 76.87% za predikciju poteškoća 2 i 8 kvartala respektivno. Na kraju istraživanja, DT model je upoređen sa drugim metodama, kako mašinskog učenja, tako i statističkim, a zaključak je da ovaj model ima najlošije performanse. Sa druge strane, Shaw i Gentry (1990) zaključuju da su stabla odlučivanja imala bolje performanse od logističke regresije.

Wang i Yang (2014) koriste dva seta podataka, jedan od 240 kompanija i drugi od 132 kompanije, te razvijaju dva DT modela. Za generisanje prvog modela, korišćeno je inicijalno 30 finansijskih ratio varijabli, a ukupna tačnost modela je 71.63%. Kod drugog modela, uključeno je 24 finansijske varijable, a tačnost modela je 75.99%. Poređenjem raznih tehnika, utvrđeno je da DT algoritam nema najveću uspešnost predikcije. Hesari i Akkaya (2018) su poredili performanse DT modela sa drugim algoritmima na uzorku od 176 entiteta u vremenskom periodu 2009-2014, te utvrdili da su stabla odlučivanja ostvarila najbolje performanse, a slično istraživanje je sproveo Apan (2018) sa saradnicima.

Heo i Yang (2014) su razvili model predikcije stečaja na bazi *gradient boosting*²¹ algoritma stabala odlučivanja za Južnu Koreju i to na uzorku od 2762 entiteta. Ukupna tačnost pomenutog modela je 75.52%. Ghodselahi and Amirmadhi (2011) su na uzorku 1000 entiteta generisali stablo odlučivanja po *gradient boosting principu* za Nemačku, a ukupna klasifikaciona snaga jeste 72.77%. Kim i Kang (2010), takođe su koristili *gradient boosting* tehniku građenja DT modela. Analizirali su podatke 1458 entiteta sa prostora Koreje i to u vremenskom intervalu 2002-2005. godina. Ukupna tačnost razvijenog modela iznosi 75.1%. Ocal i saradnici (2015) su prediktovali stečaj upotrebom CHAID i C5.0 algoritma stabala odlučivanja za preduzeća prerađivačkog sektora iz Istanbula. Analizirani su podaci u vremenskom intervalu 2007-2013. godina za ukupno 206 entiteta. Algoritam C5.0 pokazuje ukupnu tačnost 85.13%, dok CHAID algoritam ostvaruje ukupnu tačnost klasifikacije 87.37%. Lin i McClean (2001) su u svojoj studiji primenili nekoliko tehnika, kako statističkih, tako i mašinskog učenja. Stablo odlučivanja je generisano putem C5.0 algoritma, a ostvaruje ukupnu tačnost klasifikacije 86.6-88.7% u zavisnosti od načina izbora nezavisnih varijabli. Zaključak je i da tehnike mašinskog učenja po performansama nadjačavaju statističke metode. Lee i dr (2020) razvijaju model stabla odlučivanja za MSP na uzorku od 4358 entiteta, a ukupna ostvarena tačnost je

²¹ *Gradient boosting* metoda kombinuje stabla odlučivanja jedno za drugim, a svako novo stablo ispravlja greške prethodnih stabala. Kombinacijom jednostavnih stabala odlučivanja teži se kreiranju snažnijeg modela.

82.7% za testni uzorak. Korišćene su nefinansijske varijable. Sa druge strane DiDonati i Nieddu (2015) na uzorku od 100 MSP, putem CRT algoritma stabla odlučivanja, razvijaju model ukupne tačnosti 91.6%, a unakrsna validacija je korišćena za testiranje modela. Prediktori su isključivo finansijske varijable.


Na *teritoriji Republike Srbije* metoda stabala odlučivanja je prisutna u dva istraživanja, od čega jedan koristi klasičan DT algoritam, a drugi tehniku nasumičnih šuma (*en. Random Forests*). Nijedan model se ne vezuje za mala i srednja preduzeća. Vlaović Begović i Bonić (2020) predlažu upotrebu *Random Forests* algoritma na uzorku od 204 velika i srednja preduzeća iz oblasti trgovine i prerađivačke industrije. Uzorak je izbalansiran, a ukupna tačnost modela je 98%. Stanišić i koautori (2012), na uzorku od 232 velike i srednje kompanije, razvijaju model ukupne tačnosti 75.4% za predikciju stečaja dve godine unapred na trening uzorku podataka, dok na testnom uzorku AUC za DT model iznosi 0.696.

4.2.3. K-najbližih suseda (kNN)

4.2.3.1. Teorijsko-metodološka osnova tehnike k-najbližih suseda

Ova metoda spada u kategoriju nadgledanog učenja. Klasifikacija novih jedinica posmatranja se vrši na osnovu pozicije u odnosu na obližnje jedinice posmatranja. Na Slici 16, prikazano je kako funkcioniše ovaj algoritam. Algoritmom k-NN (*en. k-Nearest Neighbors*) moguće je da se nova posmatrana vrednost „▲” klasifikuje u grupu na osnovu najbližih suseda „★” i „♥”. Osnovno je da se definiše parametar “k”, odnosno koliko najbližih suseda će biti uzeto u obzir. Ukoliko se za parametar odabere 3, onda se posmatra pozicija nove vrednosti „▲” u odnosu na najbliža 3 suseda. U ovom konkretnom primeru, nova jedinica posmatranja bi bila klasifikovana kao “★”, odnosno klasa B, pošto su 2/3 suseda u toj klasi.

Slika 16: Predikcija na bazi k-NN metode – primer



Izvor: Ilustracija autora putem MS Excel programa

Odabir “k” parametra u praksi je izazovna aktivnost, a značajno može da utiče na kvalitet i efikasnost modela. Kada se želi klasifikovati nova vrednost, algoritam računa udaljenost te nove vrednosti od svih tačaka u posmatranom skupu. Prvih “k” tačaka koje imaju najmanju udaljenost od nove posmatrane vrednosti su – “najbliži susedi”. Nova jedinica koja se posmatra, predstavlja klasu koja je najbrojnija među tih “k” suseda. Ako se parametar podesi jako nisko, dovešće do pogrešne klasifikacije; sa druge strane, ako se podesi previsoko, otežaće samo generisanje modela i zahtevati dosta resursa. Tačnije, mali parametar “k” može da dovede do prevelike osetljivosti modela, odnosno njegove jake osetljivosti na šum u inputima (*en. Noise*), što za posledicu ima *overfitting*. Sa druge strane, veliki parametar “k” dovodi do situacije gde model uključuje mnogo tačaka koje su udaljene dosta od nove vrednosti koja se treba klasifikovati, što na kraju dovodi do *underfitting-a*. Obično se testira nekoliko vrednosti “k” da bi se došlo do optimalne vrednosti koja daje najbolje rezultate.

Pored prethodno pomenutog parametra, bitno je napomenuti metričke distance koje koristi k-NN algoritam za merenje sličnosti između jedinica posmatranja. Dve su najčešće distance u upotrebi: *euclidean distance* i *cosine similarity*:

→ *Euclidean distance* za dve tačke x_i i x_k u D-dimenzionalnom prostoru se može prikazati putem sledeće jednačine:

$$d(x_i, x_k) \stackrel{\text{def}}{=} \sqrt{(x_i^{(1)} - x_k^{(1)})^2 + (x_i^{(2)} - x_k^{(2)})^2 + \dots + (x_i^{(D)} - x_k^{(D)})^2} =$$

$$\sqrt{\sum_{j=1}^D (x_i^{(j)} - x_k^{(j)})^2}$$

Gde su $x_i^{(1)}, x_i^{(2)}, x_i^{(D)}$ koordinate tačke x_i , a $x_k^{(1)}, x_k^{(2)}, x_k^{(D)}$ koordinate tačke x_k .

→ *Cosine similarity* za dve tačke x_i i x_k u D-dimenzionalnom prostoru se definiše na sledeći način:

$$s(x_i, x_k) \stackrel{\text{def}}{=} \cos(\angle(x_i, x_k)) = \frac{\sum_{j=1}^D x_i^{(j)} x_k^{(j)}}{\sqrt{\sum_{j=1}^D (x_i^{(j)})^2} \sqrt{\sum_{j=1}^D (x_k^{(j)})^2}}$$

- Gde:
 - $\sum_{j=1}^D x_i^{(j)} x_k^{(j)}$ predstavlja skalarni proizvod između vektora x_i i x_k ;
 - $\sqrt{\sum_{j=1}^D (x_i^{(j)})^2}$ je dužina vektora x_i ;
 - $\sqrt{\sum_{j=1}^D (x_k^{(j)})^2}$ je dužina vektora x_k .
- Rezultat jednačine je vrednost između -1, što ukazuje na potpunu suprotnost i 1, što ukazuje na potpunu sličnost. Ova vrednost meri ugao između dva vektora u prostoru.

Da bi se sproveda analiza ovom metodom, obično se vrši skaliranje, odnosno standardizacija nezavisnih varijabli (Theobald, 2021, str. 74). Ovo je bitno kako bi se obezbedilo da sve dimenzije podataka imaju jednak doprinos udaljenosti. Theobald (2021) ističe da je glavna prednost ovog metoda to što daje precizne rezultate, te lakoća implementacije, ali je nedostatak to što nije preporučljiv za velike setove podataka (str. 76).

4.2.3.2. Pregled postojećih modela predikcije stečaja zasnovanih na tehnici k-najbližih suseda

Algoritam kNN je slabije zastupljen u analizi predikcije stečaja poređeno sa drugim metodama, poput logističke regresije ili neuronskih mreža. Aker i Karavardar (2023) su u svojoj studiji koristili veći broj tehnika u cilju predikcije stečaja turskih kompanija, a jedna od njih je i k-NN. Na uzorku od 378, 380 i 385 MSP su razvijena tri kNN modela predikcionih snaga 87%, 89% i 92% za godinu, dve i tri unapred. Na uzorku od 244 entiteta koji su kotirani na Daka berzi, razvijeno je nekoliko modela predikcije insolventnosti od strane Abdullah (2021). Analizirani su podaci u vremenskom intervalu 2015-2019. godina, a razvijeni k-NN model pokazuje ukupnu tačnost 82% na trening setu, odnosno 85% na test grupi podataka.

Gracia i saradnici (2019) razvili su modele predikcije stečaja putem nekoliko algoritama i to upotrebom 14 finansijskih baza podataka. Broj varijabli u modelima varira od 12 do 64, dok se AUC (*en. Area Under the Curve*) za k-NN modele kreće u rang od 0.583 do 0.975.

Liang i koautori (2017) predlažu upotrebu nekoliko algoritama klasifikatora, od čega jedan jeste i k-NN. Uzorci obuhvataju više zemalja: Tajvan, Kinu, Australiju i Nemačku. Rezultati, izuzimajući napredne tehnike (*bagging i boosting*), su najbolji za set podataka Kine, gde je ukupna tačnost klasifikacije 90.37%, dok je najslabiji rezultat ukupne tačnosti ostvaren za Nemačku i iznosi 69.40%.

Doprinos tehnike prekomernog uzorkovanja²² (*en. Oversampling*) demonstriran je od strane autora Smiti i Soui (2020). Pre *oversampling*-a, k-NN model predikcije stečaja ima AUC 0.637-0.480 za predikciju stečaja od godinu dana do pet unapred. Nakon što je primenjena tehnika prekomernog uzorkovanja, AUC se značajno popravio, te za predikciju stečaja u vremenskom intervalu od jedne do pet godina iznosi 0.856-0.859. Na balansiranom uzorku od 912 preduzeća uz upotrebu 55 nezavisnih varijabli, Zelenkov i koautori (2017) su testirali algoritme za predikciju stečaja u Rusiji. Varijable su normalizovane tako da vrednosti budu u rang od -1 do 1. Klasifikator k-NN je u testnom setu podataka ostvario ukupnu tačnost predikcije 83.1%.

Le i Viviani (2018) su istraživanje orijentisali ka bankama sa teritorije SAD-a. Uzorak je obuhvatao 3000 jedinica, a analiza je rađena sa podacima za period 2002-2010. godina. Korišćeno je nekoliko algoritama, među kojima je i k-NN koji je pokazao klasifikacionu snagu 73,1%. Bian i saradnici (2003), predložili su u svom istraživanju upotrebu novijeg, hibridnog pristupa za predikciju finansijskih poteškoća - *fuzzy-rough-nearest neighbour*.

²² Prekomerno uzorkovanje (*Oversampling*) se radi u situacijama kada je uzorak nebalansiran, te postoji više pripadnika jedne klase u odnosu na drugu. Konkretno, kod predikcije stečaja, uvek je više zdravih preduzeća nego onih koja su pokrenula stečajni postupak. Ideja ove tehnike je da se poveća broj jedinica posmatranja manje zastupljene grupe.

Poredili su standardni k-NN i prethodno pomenuti napredniji pristup. *Fuzzy-rough* k-NN je ostvario bolje rezultate u identifikaciji poteškoća kod entiteta.

Pregledom postojeće literature u ovoj oblasti, na *teritoriji Republike Srbije* k-NN metoda još uvek nije korišćenja za predikciju stečaja.

5. OSNOVE MODELOVANJA PREDIKCIJE STEČAJA

Pre nego se pristupi kreiranju modela predikcije stečaja, nakon pregleda teorijskih osnova pojedinih statističkih tehnika i metoda mašinskog učenja, te pregleda vladajuće literature, neophodno je postaviti stabilnu osnovu za samo istraživanje i modelovanje. U ovom poglavlju, identifikovan je naučni problem, definisan je konceptualni okvir istraživanja sa osvrtom na proces i tehnike analize, definisan je uzorak istraživanja, te varijable istraživanja i način verifikacije dobijenih rezultata (testiranje preciznosti razvijenih modela).

5.1. Identifikacija naučnog problema

Naučni problem istraživanja je predikcija stečaja malih i srednjih entiteta u Srbiji godinu dana i dve godine pre pokretanja postupka stečaja. Poslovni ambijent koji je aktuelan, zahteva da se privredni subjekti velikom brzinom prilagođavaju kontinuiranim promenama u samom okruženju, paralelno sa blagovremenim izmirivanjem obavezama, a sve to u cilju opstanka u oštroj konkurentskoj trci. U tako neizvesnim uslovima poslovanja, rizici su visoki, a kada se preduzeće suoči sa krizom, ona se neretko završava finansijskim poteškoćama, pa čak i bankrotom. Insolventnost je stanje u kojem preduzeće ne može da plati svoje dugove u momentu dospeća, a situacija je dodatno otežana ukoliko je vrednost sredstava kompanije znatno manja od vrednosti njenih obaveza (Becerra i dr, 2005). Zakon o stečaju Republike Srbije ("Sl. glasnik RS", br. 104/2009, 99/2011 - dr. zakon, 71/2012 - odluka US, 83/2014, 113/2017, 44/2018 i 95/2018) navodi da se stečajni postupak može okončati na dva načina: *bankrotstvom* ili *reorganizacijom*. Prema pomenutom Zakonu, bankrotstvo označava isplatu poverilaca korišćenjem celokupne imovine stečajnog dužnika. Reorganizacija podrazumeva isplatu poverilaca u skladu sa odobrenim planom reorganizacije, kroz redefinisane odnose između dužnika i poverilaca, statusne promene dužnika ili drugim načinima predviđenim tim planom. Problematika predikcije stečaja intrigira naučnu zajednicu dugi niz godina. Neki autori smatraju da je predikcija stečaja svetski fenomen (Kovacova i dr, 2019), kao i da sam stečaj afektuje sve zemlje (Gordini, 2014).

MSE su od velikog značaja u ekonomijama (Civelek i dr, 2021; Kljuncinkov i dr, 2021). Ovi entiteti su pogotovo dominantni na tržištima u razvoju (Matenda i dr, 2021). MSE sektor u Srbiji učestvuje sa 35% u ukupnoj zaposlenosti, čini 36% bruto domaće vrednosti, te ima udeo 41% u ukupnom prometu, a ostvaruje 29% izvoza i 43% uvoza

(Republički zavod za statistiku Srbije, 2023). Važno je napomenuti da MSE imaju karakteristiku veće „ranjivosti“ (Peel i dr, 2000) u odnosu na velike kompanije, te su pod većim uticajem ekonomskih promena. Shodno tome, MSE su podložniji finansijskim krizama u poređenju sa velikim preduzećima (Brüdel i dr, 1992; Virglerova i dr, 2021). Jedna od osnovnih karakteristika MSE je ograničenost resursa. Ovi entiteti imaju ograničene finansijske resurse (Jenkins i Hines, 2003), pa je njihova moć adaptacije u kriznim situacijama limitirana. Donošenje odluka je često centralizovano u malim timovima, koji obuhvataju članove porodice, te se odlučivanje često zasniva i na intuiciji i ličnom iskustvu (Davig and Brown, 1992). Dodatno, MSE često imaju ograničen pristup dodatnim izvorima sredstava, kao što su krediti, u poređenju sa velikim entitetima, pa teže upravljaju svojom likvidnošću (Ganbold, 2008; Shabbir, 2012). Ovi entiteti su često zavisni od konkretnih klijenata, pa ukoliko neki od tih klijenata doživi krizu, ista se može preliti i na MSE (Nilsson, 2010). U poređenju sa velikim entitetima, MSE može imati problem u uspostavljanju konkurentskih prednosti, a vrlo su osetljivi na efekte monetarne politike i promene na tržištu (Ganbold, 2008; Shabbir, 2012). Za razliku od velikih entiteta, MSE često imaju neformalni način upravljanja sa jakim fokusom na prodaju, a neretko se suočavaju sa poteškoćama nalaženja kvalitetnog kadra (Nilsson, 2010). Računovodstvene kontrole su dosta uprošćene u ovim entitetima (Reid and Smith, 2000; Nayak and Greenfield, 1994).

Razvoj modela predikcije stečaja za MSP još uvek nije dovoljno istraženo područje (Sokka, 2020). Shodno prethodno rečenom, potreba za naučnim istraživanjem na temu predikcije stečaja proizilazi iz činjenice da postoje minorna prethodna istraživanja koja se bave ovom važnom temom na uzorku privrednih društava Republike Srbije (Simić i dr, 2012, Stanišić i dr, 2013; Marinković i dr, 2014; Bešlić-Obradović i dr, 2018; Vlaović-Begović i Bonić, 2020). Dodatno, kada se polje istraživanja suzi na male i srednje entitete, pokrivenost oblasti je vrlo oskudna, što potvrđuje i analiza drugih autora (Nikolić i dr, 2020, str. 3), a svodi se na nekolicinu istraživanja (Nikolić i dr, 2018 i Aleksić i dr, 2014) koja se ne oslanjaju na finansijske (računovodstvene) pokazatelje, već na karakteristike vlasnika i njihovo ponašanje. Konačno, uključivanjem komponente mašinskog učenja i kriterijuma vremenskog horizonta predviđanja (do 2 godine unapred) uz kriterijum veličine preduzeća (MSP), dolazi se do zaključka da je polje istraživanja potpuno nepokriveno u Republici Srbiji. Veliki broj autora u Srbiji (Muminović i dr, 2011, Alihodžić, 2013; Mizdraković i Bokić, 2017; Vlaović-Begović i dr, 2021; Milić i dr, 2021; itd) je bio angažovan na testiranju postojećih modela predikcije stečaja. Rezultati njihovih istraživanja ukazuju da preciznost postojećih modela nije na visokom nivou za preduzeća u Republici Srbiji.

Uzevši u obzir da postojeći modeli (razvijeni na uzorcima preduzeća iz drugih zemalja) nisu najpodesniji za primenu na uzorku kompanija u Republici Srbiji, javlja se potreba za razvojem novog modela koji je prilagođen zemljama u razvoju, uz uvažavanje specifičnosti privrednog ambijenta i ostalih eksternih i internih uslova poslovanja. Zatim, analizom dostupnih podataka u Biltenima APR-a²³, dolazi se do zaključka da sektor MSE u Srbiji ima poteškoće sa aspekta održavanja finansijske stabilnosti i likvidnosti, što eventualno može dovesti do stečaja (analiza prikazana u poglavlju 3). Nikolić i drugi (2018) navode da je jedan od najbitnijih problema u Srbiji veliki broj stečaja malih i srednjih entiteta, što dodatno ukazuje na potrebu za istraživanjem. Napredne analize i modeli koji mogu da predvide krizu su neophodni za prevenciju poslovnog neuspeha


²³ Agencija za privredne registre Srbije (<https://www.apr.gov.rs>)

(Krulicky, 2021). Polazeći od istraživanja postojećih modela, Du Jardin (2009) je sproveo analizu 190 studija koje se bave predikcijom stečaja, te došao do zaključka da se u najvećem broju istraživanje predikcija oslanja na racio pokazatelje: 28% radova uključuje statističke varijable, 14% radova uključuje varijable varijacija (evolucije varijabli kroz vreme), dok se 13% naučnih istraživanja zasniva na upotrebi nekih nefinansijskih varijabli o kompaniji. Ovde se takođe otvara prostor za doprinos, kako naučnoj zajednici, tako i privredi, kroz generisanje sveobuhvatnog modela, koji uključuje razne aspekte poslovanja malih i srednjih entiteta. Pored svega, prediktor varijable koje se koriste u predikciji stečaja (racio pokazatelji), često ne ispunjavaju pretpostavke poput normalnosti distribucije, nezavisnosti i sl. (Kyung-Shik i dr, 2005; Wang i dr, 2014). Svaka tehnika modelovanja ima svoja ograničenja, a često su iste od strane autora korišćene po inerciji, bez prethodnih provera (Sung i dr, 1999). U vezi sa prethodno rečenim, mnogi autori stavljaju po strani pomenute polazne osnove za primenu pojedinih tehnika modelovanja, što je pogotovo problematično kod diskriminantne analize. Ona ima najstrožije pretpostavke da bi bila uspešna, te sam model bio primenjiv na nove podatke (Balcaen & Ooghe, 2006; Pervan i dr, 2011; Alaka i dr, 2017). Pojedini autori (Du Jardin, 2011; Lin & Piesse, 2004; Chung i dr, 2008) su pokazali neophodnost ispunjavanja gore pomenutih restriktivnih pretpostavki kako bi razvijeni model imao moć da generalizuje, te posedovao optimalne performanse.

Sve prethodno rečeno ide u korist stavu da je modelovanje predikcije stečaja za MSE u Republici Srbiji neophodan korak da bi se vlasnicima preduzeća i menadžmentu pružila pouzdana i precizna osnova za poslovno odlučivanje i pravovremeno reagovanje na potencijalne krizne situacije, koje bi modeli mogli da predvide. Upotrebom modela predikcije stečaja, vlasnici mogu rano uočiti finansijske probleme, te preuzeti preventivne mere za opstanak. Pored vlasnika preduzeća i menadžmenta, razvoj modela predikcije stečaja može doneti korist i za: finansijske institucije, kreditore, investitore, dobavljače i partnere, akcionare, zaposlene, regulatore i Vladine organizacije.


5.2. Konceptualni okvir, proces i tehnike istraživanja

Na Šemi 1, prikazan je detaljno konceptualni okvir doktorske disertacije. Istraživanje je podeljeno u ukupno 5 faza. Prva faza se odnosi na upoznavanje sa postojećom literaturom te sistematizaciju iste sa ciljem definisanja naučnog problema, uzorka, hipoteza i varijabli istraživanja. U drugoj fazi se vrši prikupljanje podataka, kako finansijskih, tako i makroekonomskih i nefinansijskih o preduzećima koja su uključena u definisani uzorak. Podaci se čiste i dalje pripremaju za modelovanje. Treća faza se odnosi na dalje pripreme za samo modelovanje, kao što je selekcija ključnih varijabli za modelovanje, eliminisanje multikolinearnosti itd. Faze 4 i 5 su, zbog kompleksnosti, prikazane odvojeno na šemama 2 i 3, a odnose se na sam postupak modelovanja putem statističkih tehnika, kao i tehnika mašinskog učenja.

Šema 1: Konceptualni okvir doktorske disertacije (*en. Framework*)


Izvor: Ilustracija autora

Šema 2: Detaljni pregled faze 4 konceptualnog okvira doktorske disertacije



Izvor: Ilustracija autora

Šema 3: Detaljni pregled faze 5 konceptualnog okvira doktorske disertacije



Izvor: Ilustracija autora

5.3. Definisanje uzorka istraživanja

Kada je reč o predikcijama stečajna, osnovna karakteristika ovog tipa modelovanja jeste da je procenat preduzeća u stečajnom postupku dosta niži u odnosu na procenat preduzeća koja su solventna. To može dovesti do situacije gde modeli imaju ograničenu moć da predvide preduzeća koja će pokrenuti stečajni postupak (Masten and Masten, 2012). Kao rešenje ovog problema, mnoge studije su u uzorak uključivale jednak broj solventnih i preduzeća u stečaju. Dakle, solventna i preduzeća u stečaju su uparena po principu 1:1 u mnogim empirijskim istraživanjima, što za cilj ima obezbeđivanje veće preciznosti modela (Altman, 1968; Fletcher & Gross, 1993; McKee, 1995; Kwon i Yoon, 2010; Cho i dr, 2010; Bešlić Obradović i dr, 2018; Cheong and Ramasamy, 2019; itd.).


Uzorak istraživanja u doktorskoj disertaciji će se sastojati od **212 malih i srednjih preduzeća** sa teritorije Republike Srbije. Modeli kreirani kao opšti, na uzorku preduzeća svih veličina, mogu imati poteškoće u prepoznavanju poslovnih problema preduzeća iz sektora MSP, te je zato cilj razviti modele fokusirane isključivo na preduzeća MSP sektora, koji sa sobom nosi prethodno pomenute specifičnosti. Uzorak je izbalansiran po uzoru na postojeću literaturu, što znači da je u istom 106 zdravih (solventnih) preduzeća i 106 preduzeća koja su pokrenula stečajni postupak. Ovakva analiza/modelovanje zahteva dobro strukturiran uzorak, te isti nije samo izbalansiran po statusu preduzeća (solventno ili u stečaju), već i po drugim kriterijumima: broj zaposlenih, vrednost poslovnog prihoda, vrednost dugoročnih obaveza i delatnost. Medijana broja zaposlenih u aktivnim (solventnim) preduzećima ($\Sigma 106$) za 6 godina (2016-2022) je 40, dok je medijana broja zaposlenih u preduzećima koja su pokrenula stečajni postupak ($\Sigma 106$) za gore pomenuti vremenski period – 50. Prosečna vrednost dugoročnih obaveza za sve solventne entitete zajedno u periodu od 6 godina iznosi 15.713.362 hiljada dinara, dok prosečna vrednost dugoročnih obaveza u istom periodu za sve entitete koji su pokrenuli stečajni postupak iznosi 15.859.150 hiljada dinara. Prosečna vrednost poslovnih prihoda za sve solventne entitete zajedno u periodu od 6 godina iznosi 45.007.400 hiljada dinara, dok prosečna vrednost poslovnih prihoda u istom periodu za sve entitete koji su pokrenuli stečajni postupak iznosi 47.397.137 hiljada dinara. Detaljan pregled preduzeća iz uzorka sa prikazom delatnosti kojoj pripadaju, dostupan je u Prilogu 1.

Svi podaci iz finansijskih izveštaja su prikupljeni sa stranice APR-a²⁴. Putem stranice Agencije za licenciranje stečajnih upravnika²⁵ su prikupljeni podaci o preduzećima koja su pokrenula stečajni postupak. Detalji o formiranju uzorka se nalaze na Slici 17.

²⁴ <https://www.apr.gov.rs/> (Preuzeto sa <https://pretraga2.apr.gov.rs/unifiedentitysearch>; datum pristupa - 06.10.2023.)

²⁵ <https://alsu.gov.rs/> (Preuzeto sa: <https://alsu.gov.rs/stečaj/stečajevi/> ; datum pristupa - 06.10.2023.)

Slika 17: Vizuelni prikaz uzorka istraživanja za razvoj modela predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) unapred



Izvor: Ilustracija autora na osnovu Kušter i dr, 2023.

Dakle, u analizu i modelovanje su uključena MSP koja su pokrenula stečajni postupak ili bila solventna u sledećem vremenskom periodu: 2018-2023. godina, odnosno uključeni su finansijski izveštaji za period 2016-2022. godina, kako je cilj da se predvidi stečaj i do dve godine unapred. Za modelovanje predikcije stečaja godinu dana pre pokretanja samog postupka (Y-1), korišćeni su izveštaji iz 2022, 2021, 2020, 2019, 2018. i 2017. godine, dok su za modelovanje predikcije dve godine unapred (Y-2) korišćeni izveštaji iz 2021, 2020, 2019, 2018, 2017. i 2016. godine. Stoga kreiranje modela za predikciju stečaja godinu dana unapred je izvršeno na 212 opservacija, a isto važi i za model predikcije dve godine unapred. Način podele uzorka na testni i trening, vođen je aktuelnom literaturom, a detaljnije će biti obrazložen pojedinačno kod svake tehnike modelovanja.

5.4. Varijable istraživanja

Du Jardin (2009) je istraživanjem čak 190 studija, generisao sistematizovan pregled varijabli, koji ukazuje na to da se prilikom modelovanja predikcije stečaja autori najviše oslanjaju na finansijske ratio pokazatelje (u čak 93% slučajeva), dok su nefinansijske varijable zastupljene tek u 13% radova. Celokupna analiza je prikazana u Tabeli 8.

Tabela 8: Sistematizovani pregled nezavisnih varijabli u modelima predikcije stečaja

Varijable	Učestalost korišćenja u 190 studija
Finansijski ratio (odnos dve varijable)	93%
Statističke varijable (srednja vrednost, standardna devijacija, varijansa, logaritam, rezultati faktorske analize... izračunati sa racijima ili finansijskim varijablama)	28%
Varijabla trenda (evolucija nekog koeficijenta ili finansijske varijable tokom vremena)	14%
Nefinansijska varijabla (svaka karakteristika kompanije ili njenog okruženja osim onih koji se odnose na finansijsku situaciju)	13%
Tržišna varijabla (odnos ili varijabla u vezi sa cenom akcija, prinosom akcija)	6%
Varijabla finansijskog tržišta (podaci koji potiču iz bilansa stanja, bilansa uspeha ili bilo kojih finansijskih dokumenata)	5%

Izvor: Du Jardin, 2009

Na Slici 18, prikazani su rezultati istraživanja koji ukazuju na prosečan broj varijabli koje su modeli predikcije stečaja MSP po dekadama obuhvatali. Najveći broj varijabli je zabeležen u istraživanju iz 2020-ih godina i iznosi 79 varijabli u istraživanju koje nije na ABS listi.

Slika 18: Broj varijabli koji je korišćen u predikciji stečaja MSP po dekadama

	Minimum	Maximum	Average (rounded)
ABS (94 Studies)			
1970s	7	7	7
1980s	5	6	6
1990s	3	15	8
2000s	4	29	13
2010s	1	50	12
2020s	5	52	16
Overall	1	52	13
Non-ABS (51 Studies)			
1970s			
1980s	5	9	7
1990s			
2000s	16	16	16
2010s	3	24	11
2020s	1	79	12
Overall	1	79	12

Izvor: Cheraghali i Molnár, 2023, str. 14

Prethodno pomenuti pregledi ukazuju na značaj generisanja modela koji pored finansijskih varijabli, ipak obuhvataju i neke druge kategorije. U skladu sa prethodno rečenim, kao i vladajućom i relevantnom literaturom, definisane su varijable ove doktorske disertacije. Varijable istraživanja se svrstavaju u dve kategorije: zavisna i nezavisne (objašnjavajuće) varijable. Zavisna varijabla je binarna, što znači da ima dva moguća ishoda:

- 0 = preduzeće u stečaju i
- 1 = preduzeće koje je solventno.

Nezavisne varijable istraživanja obuhvataju 66 ratio pokazatelja – varijabli (52 statične-finansijske varijable, 2 nefinansijske interne varijable, 1 makroekonomska hibridna varijabla, 5 varijabli trenda/varijacije i 6 statističkih varijabli). Nezavisne varijable su prikazane u Tabeli 9. Ovim varijablama, teži se objasniti kretanje zavisne varijable. Finansijske varijable su prikupljene iz Bilansa uspeha, Bilansa stanja, kao i Izveštaja o novčanim tokovima MSP.

Tabela 9: Pregled nezavisnih varijabli istraživanja ($\Sigma 66$)

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
1	ROA	Finansijska (interna, statična)	$\frac{\text{Neto rezultat}}{\text{Ukupna aktiva}}$	Back et al. (1996), Atiya (2001), Charitou et al. (2004), Rafiei et al. (2011), Yim & Mitchell (2005), Neophytou & Molinero (2004), Virag & Kristof (2005), Ryu & Yue (2005), Chung et al. (2008), Chen & Du (2009), Simić et al. (2011), Lin (2009), Kim & Kang (2010), Blanco et al. (2013), Zebardast et al. (2014), Korol (2019), Callejón et al. (2013), Ravisankar et al. (2010), Sehgal et al. (2021), Chinedu et al. (2023)
2	CR	Finansijska (interna, statična)	$\frac{\text{Obrtna imovina}}{\text{Kratkoročne obaveze}}$	Back et al. (1996), Neophytou & Molinero (2004), Charitou et al. (2004), Virag & Kristof (2005), Ryu & Yue (2005), Yim & Mitchell (2005), Chung et al. (2008), Abdelwahed & Amir (2005), Alfaro (2008), Chen & Du (2009), Lin (2009), Kim & Kang (2010), Ravisankar et al. (2010), Kim (2011), Rafiei et al. (2011), Callejón et al. (2013), Zebardast et al. (2014), Bredart (2014), Inam et al. (2018), Bapat & Nagale (2014), Korol (2019), Sehgal et al. (2021), Chinedu et al. (2023)

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
3	WCTA	Finansijska (interna, statična)	$\frac{\text{Radni (obrotni) kapital}}{\text{Ukupna aktiva}}$	Back et al. (1996), Charitou et al. (2004), Neophytou & Molinero (2004), Abdelwahed & Amir (2005), Ryu & Yue (2005), Alfaro (2008), Simić et al. (2011), Ravisankar et al. (2010), Chung et al. (2008), Rafiei et al. (2011), Bapat & Nagale (2014), Eriki & Udegbumam (2013), Inam et al. (2018), Barboza et al. (2017), Sehgal et al. (2021)
4	RER	Finansijska (interna, statična)	$\frac{\text{Neraspoređeni dobitak}}{\text{Ukupna aktiva}}$	Back et al. (1996), Neophytou & Molinero (2004), Charitou et al. (2004), Ryu & Yue (2005), Lin (2009), Simić et al. (2011), Kim & Kang (2010), Chung et al. (2008), Ravisankar et al. (2010), Eriki & Udegbumam (2013), Bapat & Nagale (2014), Inam et al. (2018), Barboza et al. (2017), Sehgal et al. (2021), Chinedu et al. (2023)
5	EBITTA	Finansijska (interna, statična)	$\frac{\text{EBIT}}{\text{Ukupna aktiva}}$	Atiya (2001), , Neophytou & Molinero (2004), Charitou et al. (2004), Ryu & Yue (2005), Alfaro (2008), Chung et al. (2008), Callejón et al. (2013), Simić et al. (2011), Eriki & Udegbumam (2013), Bredart (2014), Bapat & Nagale (2014), Barboza et al. (2017), Korol (2019), Inam et al. (2018), Chinedu et al. (2023)

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
6	STA	Finansijska (interna, statična)	$\frac{\text{Prihodi od prodaje}}{\text{Ukupna aktiva}}$	Charitou et al. (2004), Neophytou & Molinero (2004), Ryu & Yue (2005), Chung et al. (2008), Alfaro (2008), Ravisankar et al. (2010), Rafiei et al. (2011), Eriki & Udegbumam (2013), Blanco et al. (2013), Bapat & Nagale (2014), , Inam et al. (2018), Chinedu et al. (2023)
7	QR	Finansijska (interna, statična)	$\frac{(\text{Obrtna imovina} - \text{Zalihe})}{\text{Kratkoročne obaveze}}$	Yim & Mitchell (2005), Virag & Kristof (2005), Chung et al. (2008), Lee & Choi (2013), Rafiei et al. (2011), Zebardast et al. (2014), Mselmi et la. (2017), Korol (2019), Inam et al. (2018), Chinedu et al. (2023)
8	TDTA	Finansijska (interna, statična)	$\frac{\text{Ukupni dug}}{\text{Ukupna aktiva}}$	Leshno & Spector, (1996), Back et al. (1996), Ryu & Yue (2005), Lin (2009), Chen & Du (2009), Kim & Kang (2010), Callejón et al. (2013), Ravisankar et al. (2010), Zebardast et al. (2014), Zhai, et al. (2014)
9	CATA	Finansijska (interna, statična)	$\frac{\text{Obrtna imovina}}{\text{Ukupna aktiva}}$	Back et al. (1996), Neophytou & Molinero (2004), Charitou et al. (2004), Ryu & Yue (2005), Virag & Kristof (2005), Chung et al. (2008), Alfaro (2008), Chen & Du (2009), Kim & Kang (2010), Ravisankar et al. (2010), Fedorova et al. (2013), Douglas (2014), Bapat & Nagale (2014), Inam et al. (2018), Sehgal et al. (2021), Chinedu et al. (2023)

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
10	OCFTA	Finansijska (interna, statična)	$\frac{\text{Operativni novčani tok}}{\text{Ukupna aktiva}}$	Back et al. (1996), Atiya (2001), Neophytou & Molinero (2004), Ryu & Yue (2005), Abdelwahed & Amir (2005), Charitou et al. (2004), Callejón et al. (2013), Bapat & Nagale (2014), Douglas (2014), Sehgal et al. (2021), Chinedu et al. (2023)
11	OCFTD	Finansijska (interna, statična)	$\frac{\text{Operativni novčani tok}}{\text{Ukupni dug}}$	Back et al. (1996), Ryu & Yue (2005), Alfaro (2008)
12	QATA	Finansijska (interna, statična)	$\frac{\text{Likvidna sredstva}}{\text{Ukupna aktiva}}$	Back et al. (1996), Charitou et al. (2004), Neophytou & Molinero (2004), Ryu & Yue (2005), Ravisankar et al. (2010), Kim & Kang (2010), Kim (2011), Bapat & Nagale (2014), Inam et al. (2018)
13	CAS	Finansijska (interna, statična)	$\frac{\text{Obrtna imovina}}{\text{Prihodi od prodaje}}$	Neophytou & Molinero (2004), Charitou et al. (2004), Ryu & Yue (2005), Chung et al. (2008), Simic et al. (2011), Bapat & Nagale (2014), Chinedu et al. (2023)
14	EBITInt	Finansijska (interna, statična)	$\frac{\text{EBIT}}{\text{Rashodi kamata}}$	Lee, et al. (1996), Back et al. (1996), Kim & Kang (2010), Chung et al. (2008), Kouki & Elkhaldi (2011), Korol (2019)
15	InvS	Finansijska (interna, statična)	$\frac{\text{Zalihe}}{\text{Prihodi od prodaje}}$	Back et al. (1996), Charitou et al. (2004), Neophytou & Molinero (2004), Ryu & Yue (2005), Chung et al. (2008), Chen & Du (2009), Simić et al. (2011), Ravisankar et al. (2010), Kim & Kang (2010), Kim (2011),

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
				Chinedu et al. (2023), Bapat & Nagale (2014),
16	OITA	Finansijska (interna, statična)	$\frac{\text{Poslovni (operativni) prihodi}}{\text{Ukupna aktiva}}$	Back et al. (1996), Atiya (2011), Ravisankar et al. (2010), Rafiei et al. (2011)
17	OCFS	Finansijska (interna, statična)	$\frac{\text{Operativni novčani tok}}{\text{Prihodi od prodaje}}$	Neophytou & Molinero (2004), Charitou et al. (2004), Bapat & Nagale (2014), Chinedu et al. (2023)
18	NIS	Finansijska (interna, statična)	$\frac{\text{Neto prihod}}{\text{Prihodi od prodaje}}$	Charitou et al. (2004), Chung et al. (2008), Kim & Kang (2010), Rafiei et al. (2011), Bapat & Nagale (2014)
19	LTDTA	Finansijska (interna, statična)	$\frac{\text{Dugoročni dug}}{\text{Ukupna aktiva}}$	Ravisankar et al. (2010), Mselmi et al. (2017), Sehgal et al. (2021), Chinedu et al. (2023)
20	CCL	Finansijska (interna)	$\frac{\text{Gotovina}}{\text{Kratkoročne obaveze}}$	Back et al. (1996), Ryu & Yue (2005), Alfaro (2008), Chung et al. (2008), Zebardast et al. (2014),), Fedorova et al. (2013), Inam et al. (2018)
21	OCFCL	Finansijska (interna, statična)	$\frac{\text{Operativni novčani tok}}{\text{Kratkoročne obaveze}}$	Back et al. (1996), Charitou et al. (2004), Neophytou & Molinero (2004), Bapat & Nagale (2014), Lin (2009), Chinedu et al. (2023)
22	WCS	Finansijska (interna, statična)	$\frac{\text{Radni (obrti) kapital}}{\text{Prihodi od prodaje}}$	Neophytou & Molinero (2004), Alfaro (2008), Simić et al. (2011)

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
23	CAPA	Finansijska (interna, statična)	$\frac{Kapital}{Ukupna\ aktivna}$	Yim & Mitchell (2005), Virag & Kristof (2005), Neophytou & Molinero (2004), Kim & Kang (2010), Lee & Choi (2013), Rafiei et al. (2011), Bapat & Nagale (2014), Douglas (2014), Inam et al. (2018)
24	NSTA	Finansijska (interna, statična)	$\frac{Neto\ prihod\ od\ prodaje}{Ukupna\ aktivna}$	Back et al. (1996), Virag & Kristof (2005), Lin (2009), Barboza et al. (2017), Bapat & Nagale (2014)
25	NCI	Finansijska (interna, statična)	<i>Bes kreditni interval</i>	Tinoco & Wilson (2013), Liang et al. (2016), Fedorova et al. (2013), Brenes, Johannssen & Chukhrova (2022)
26	Log_TA	Statistička (interna)	$Log(Ukupna\ aktivna)$	Leshno, & Spector (1996), Alfaro (2008), Callejón et al. (2013), Korol (2013), Douglas (2014), Mselmi et al. (2017), Mai, Tian, Lee & Ma (2019)
27	CFNID	Finansijska (interna, statična)	$\frac{Neto\ rezultat\ iz\ novčanih\ tokova}{Ukupan\ dug}$	Leshno & Spector (1996), Virag & Kristof (2005), Brockett et al. (2006), Chen & Du (2009), Ravisankar et al. (2010), Kouki & Elkhaldi (2011), Inam et al. (2018)
28	OCF	Finansijska (interna, statična)	<i>Operativni novčani tok</i>	Mossman et al. (1998), Anandarajan et al. (2001)
29	OEOI	Finansijska (interna, statična)	$\frac{Poslovni\ (operativni)\ rashodi}{Poslovni\ (operativni)\ prihodi}$	Douglas (2014), Africa (2016), Asyikin (2018)

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
30	QAS	Finansijska (interna, statična)	$\frac{\text{Likvidna sredstva}}{\text{Prihodi od prodaje}}$	Back et al. (1996), Neophytou & Molinero (2004), Charitou et al. (2004), Ryu & Yue (2005), Kouki & Elkhaldi (2011), Simić et al. (2011), Bapat & Nagale (2014)
31	SINV	Finansijska (interna, statična)	$\frac{\text{Prihodi od prodaje}}{\text{Zalihe}}$	Jo et al. (1997), Virag & Kristof (2005), Liang et al. (2016), Rafiei et al. (2011)
32	HC	Nefinansijska (interna, statična)	<i>Broj zaposlenih</i>	Leshno & Spector (1996), Yazdanfar (2011), Stanišić, et al. (2013), Stachova et al. (2015)
33	OY	Nefinansijska (interna, statična)	<i>Godine rada pre bankrotstva</i>	Dakovic et al. (2010), Yazdanfar (2011), Giordani, et al. (2014)
34	Log_SINV	Statistička (interna, statična)	$\text{Log}\left(\frac{\text{Prihodi od prodaje}}{\text{Zalihe}}\right)$	Karlsson & Dieden Sandell (2016)
35	IEBD	Finansijska (interna, statična)	<i>Rashodi kamata – Ukupan dug</i>	Liang, et al. (2016), Brenes, Johannssen & Chukhrova (2022), Rasolomanana (2022)
36	CRR	Finansijska (interna, dinamična)	$\frac{(\text{Promena u stalnoj imovini između dve godine} + \text{Promena u radnom kapitalu između dve godine})}{\text{Operativni novčani tok}}$	Lin et al. (2014), Liang, et al. (2016), Chiou, et al. (2017), Wen & Meng (2019), Brenes, et al. (2022)
37	IETR	Finansijska (interna, statična)	$\frac{\text{Rashodi kamata}}{\text{Ukupan prihod}}$	Liang, et al. (2016), Paraschiv et al. (2023)
38	QACL	Finansijska (interna, statična)	$\frac{\text{Likvidna sredstva}}{\text{Kratkoročne obaveze}}$	Back et al. (1996), Dimitras et al. (1999), Michael et al. (1999), Piramuthu et al. (1998), Ryu & Yue (2005), Liang, et al. (2016), Brenes, et al. (2022)

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
39	INVWC	Finansijska (interna, statična)	$\frac{Zalihe}{Radni kapital}$	Dimitras et al. (1999), Michael et al. (1999), Liang, et al. (2016), Paraschiv, et al. (2023), Brenes, et al. (2022),
40	INVCL	Finansijska (interna, statična)	$\frac{Zalihe}{Kratkoročne obaveze}$	Liang, et al. (2016), Paraschiv et al. (2023), Brenes, et al. (2022)
41	CLCA	Finansijska (interna, statična)	$\frac{Kratkoročne obaveze}{Obrtna imovina}$	Ohlson (1980), Liang, et al. (2016), Brenes, et al. (2022)
42	LTLEFA	Finansijska (interna, statična)	$\frac{(Dugoročne obaveze + Kapital)}{Stalna imovina}$	Liang, et al. (2016), Paraschiv et al. (2023)
43	FATA	Finansijska (interna, statična)	$\frac{Stalna imovina}{Ukupna aktiva}$	Koyuncugil & Ozgulbas (2012), Brenes, et al. (2022), Liang, et al. (2016), Paraschiv et al. (2023)
44	OENS	Finansijska (interna, statična)	$\frac{Poslovni rashodi}{Neto prihod od prodaje}$	Koyuncugil & Ozgulbas (2012), Liang, et al. (2016), Mohd Shafarin (2019)
45	SEE	Finansijska (interna, statična)	$\frac{Prihod od prodaje}{Broj zaposlenih}$	Mcgurr & Devaney (1998), Lin & McClean (2001), Michel et al. (2001), Yazdanfar (2011), Liang, et al. (2016), Chen & Jhuang (2018)
46	OIEE	Finansijska (interna, statična)	$\frac{Poslovni prihod}{Broj zaposlenih}$	Zhou & Elhag (2007), Liang, et al. (2016), Brenes, et al. (2018), Johannssen & Chukhrova (2022)
47	FAEE	Finansijska (interna, statična)	$\frac{Stalna imovina}{Broj zaposlenih}$	Lin, et al. (2014), Liang, et al. (2016), Chen & Jhuang (2018)
48	TITE	Finansijska (interna, statična)	$\frac{Ukupni prihod}{Ukupni rashod}$	Tam & Kiang (1992), Brenes, et al. (2022), Liang, et al. (2016),

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
49	TETA	Finansijska (interna, statična)	$\frac{\text{Ukupni rashod}}{\text{Ukupna aktiva}}$	Tam & Kiang (1992), Tay & Shen (2002), Brenes, et al. (2022), Liang, et al. (2016),
50	CS	Finansijska (interna, statična)	$\frac{\text{Gotovina}}{\text{Prihodi od prodaje}}$	Back i dr (1996), Lee, et al. (1996), Liang, et al. (2016), Brenes, et al. (2022), Ryu i Yue (2005), Ravisankar i dr. (2010)
51	OIG	Finansijska (interna, dinamična)	$\frac{\text{Poslovni prihod u posmatranoj godini} - \text{Poslovni prihod u prethodnoj godini}}{\text{Poslovni prihod u prethodnoj godini}}$	Zhai, et al (2015), Liang, et al. (2016), Rasolomanana (2022)
52	NIG	Finansijska (interna, dinamična)	$\frac{\text{Neto prihod u posmatranoj godini} - \text{Neto prihod u prethodnoj godini}}{\text{Neto prihod u prethodnoj godini}}$	Ohlson (1980), Dietrich & Kaplan (1982), Lee, et al. (1996), Lin et al. (2014), Zhai, et al (2015), Liang, et al. (2016), Rasolomanana (2022)
53	TAG	Finansijska (interna, dinamična)	$\frac{\text{Ukupna aktiva u posmatranoj godini} - \text{Ukupna aktiva u prethodnoj godini}}{\text{Ukupna aktiva u prethodnoj godini}}$	Lee, et al. (1996), Min & Jeong (2009), Yazdanfar (2011), Lee & Choi (2013), Zhai, et al. (2015), Lin et al. (2014), Liang, et al. (2016), Brenes, et al. (2022), Rasolomanana (2022)
54	TEG	Finansijska (interna, dinamična)	$\frac{\text{Kapital u posmatranoj godini} - \text{Kapital u prethodnoj godini}}{\text{Kapital u prethodnoj godini}}$	Lin (2009), Lin et al. (2014), Zhai, et al (2015), Liang, et al. (2016), Brenes, et al. (2022)
55	TAGNP	Makroekonomska (hibridna, statična)	$\frac{\text{Ukupna Aktiva}}{\text{Bruto nacionalni proizvod}}$	Bryant (1997), Brenes, et al. (2022)
56	Ln_S	Statistička (interna, statična)	$\ln(\text{Prihod od prodaje})$	Laitinen (1999), Chancharat (2010), Yazdanfar (2011), Situm (2014)
57	Ln_CACL	Statistička (interna, statična)	$\ln\left(\frac{\text{Obrtna imovina}}{\text{Kratkoročne obaveze}}\right)$	Gupta, et al. (2014), Gupta & Gregoriou

#	Oznaka	Kategorija varijable	Način izračunavanja varijable	Izvor literature
				(2018), Gupta, et al. (2018a)
58	CLTA	Finansijska (interna, statična)	$\frac{\text{Kratkoročne obaveze}}{\text{Ukupna aktiva}}$	Bryant (1997), Dimitras et al. (1999), Michael et al. (1999), Shin & Lee (2002), Brenes, et al. (2022)
59	LTLCA	Finansijska (interna, statična)	$\frac{\text{Dugoročne obaveze}}{\text{Obrtna imovina}}$	Elam (1975), Brenes, et al. (2022), Paraschiv et al. (2023)
60	CFTL	Finansijska (interna, statična)	$\frac{\text{Gotovina}}{\text{Ukupne obaveze}}$	Back, et al. (1996), Ahn, et al. (1996), Bryant (1997), Tung, et al. (2004), Brenes, et al. (2022)
61	SLC	Finansijska (interna, statična)	$\frac{\text{Izdaci za zaposlene}}{\text{Ukupni rashod}}$	Andres, et al. (2005), Manjrekar & Damani (2023)
62	Log_TA_GNP	Statistička (hibridna, statična)	$\text{Log}\left(\frac{\text{Ukupna aktiva}}{\text{Bruto nacionalni proizvod}}\right)$	Ohlson (1980), Oribel & Hanggraeni (2021), Nguyen (2023)
63	Ln_TA_GDP	Statistička (hibridna, statična)	$\text{Ln}\left(\frac{\text{Ukupna aktiva}}{\text{Bruto domaći proizvod}}\right)$	Barniv, et al. (1997), Kotsiantis et al. (2005), Kotsiantis et al. (2007), Kotsiantis & Kanellopoulos (2008)
64	OBSCTA	Finansijska (interna, statična)	$\frac{\text{Vanbilansna pasiva}}{\text{Ukupna aktiva}}$	Swicegood & Clark (2001), Cleary & Hebb (2015)
65	SATA	Finansijska (interna, statična)	$\frac{\text{Izdaci za zaposlene}}{\text{Ukupna aktiva}}$	Swicegood & Clark (2001), Alali & Romero (2013), Salina et al. (2021)
66	IETA	Finansijska (interna, statična)	$\frac{\text{Rashodi kamata}}{\text{Ukupna aktiva}}$	Swicegood & Clark (2001), Paraschiv et al. (2023)

Izvor: Ilustracija autora

5.5. Verifikacija modela

Verifikacija razvijenih modela će se raditi putem testnog skupa podataka ili putem unakrsne validacije u zavisnosti od metode koja je korišćena za modelovanje i mogućnosti SPSS programa²⁶. Pored toga, na samom kraju istraživanja, razvijeni modeli će biti upoređeni sa Altman-ovim Z' i EMS modelima u cilju testiranja performansi. Kod svih metoda modelovanja, za samo testiranje predviđačke moći, koristiće se matrica konfuzije (*Confusion Matrix*) koja je prikazana na Slici 19.

Slika 19: Teorijski prikaz matrice konfuzije (*Confusion Matrix*)

		True Classification	
		Positive	Negative
Predicted classification	Positive	TP	FP
	Negative	FN	TN

Izvor: Ilustracija autora, MS Excel program

Sledeći pokazatelji proizilaze iz matrice konfuzije (Murray, 2023; Kušter i dr, 2023):

- **Tačnost (*Accuracy*)**. Odličan je pokazatelj za balansirane setove podataka, što je slučaj u konkretnom istraživanju. Definiše se kao ukupan broj tačno klasifikovanih jedinica posmatranja u uzorku. Obračun sledi:

$$Accuracy = (True_{positive} + True_{negative}) / (True_{positive} + True_{negative} + False_{positive} + False_{negative})$$

- **Preciznost (*Precision*)** je koristan indikator i kada su setovi podataka nebalansirani. Ukazuje na broj ispravno-pozitivnih ishoda u ukupnom broju pozitivnih ishoda. U konkretnom slučaju, ukazuje na to koliko je model sposoban da identifikuje opservacije kao bankrotirale. Računa se na sledeći način:

$$Precision = (True_{positive}) / (True_{positive} + False_{positive})$$

²⁶ Napredne tehnike validacije (poput 10-fold ili unakrsne validacije) su dostupne samo kod nekih tehnika (DA i DT) u aktuелnoj verziji SPSS programa. Princip **10-fold** podrazumeva da se set podataka deli na 10 jednakih delova, gde se 9 koristi za treniranje modela, a jedan za testiranje; taj process se ponavlja 10x, a svaki put se drugi deo ukupnog skupa nalazi u ulozi test skupa. Ovo predstavlja rigorozniji metod testiranja jer se procenjuje predviđačka snaga modela na različitim delovima podataka.

- ➔ **Specifičnost (*Specificity*)** indikator meri broj korektno klasifikovanih solventnih MSP. Računa se na sledeći način:

$$Specificity = (True_{negative}) / (True_{negative} + False_{positive})$$

- ➔ **Senzitivnost (*Sensitivity ili Recall*)** meri sposobnost modela da identifikuje insolventne MSP. Računa se na sledeći način:

$$Sensitivity = (True_{positive}) / (True_{positive} + False_{negative})$$

- ➔ **F1-rezultat (*F1-Score*)** vrši balansiranje između pokazatelja preciznosti i senzitivnosti. Veće vrednosti ovog pokazatelja, ukazuju da je model snažniji. Računa se na sledeći način:

$$F1-Score = 2 * (Precision * Sensitivity) / (Precision + Sensitivity)$$

Pre testiranja predviđačke moći putem matrice konfuzije, svaki razvijeni model, u kontekstu njegovih parametara i kvaliteta (*Goodness-of-fit*), biće ispitan putem brojnih testova koji variraju u zavisnosti od tehnike modelovanja. Pomenuti testovi su već prikazani u tački 5.2 gde je definisan konceptualni okvir istraživanja.

6. GENERISANJE I TESTIRANJE MODELA PREDIKCIJE STEČAJA JEDNU I DVE GODINE PRE POKRETANJA STEČAJNOG POSTUPKA

U skladu sa prethodno pomenutim programom istraživanja, u šestom poglavlju su kreirani modeli predikcije stečaja MSP godinu dana i dve godine pre pokretanja stečajnog postupka. Pre kreiranja samih modela, izvršeno je testiranje, te selekcija ključnih nezavisnih varijabli. Prvi korak jeste testiranje normalnosti distribucije nezavisnih varijabli. Za sve varijable koje nisu pokazale normalnu distribuciju, izvršen je Men-Vitni test (*Mann-Whitney*), dok je *t-test* realizovan za one varijable koje ipak jesu pokazale normalnu distribuciju prilikom testiranja normalnosti. Oba testa pokazuju da li postoje statistički značajne razlike u vrednostima (nezavisnih) varijabli između grupa MSP: solventna i ona u stečaju. Sve varijable koje pokazuju statistički značajne razlike u vrednostima između dve grupe MSP, dalje su podvrgnute analizi multikolinearnosti, nakon koje je formiran konačni set nezavisnih varijabli koji se dalje koristio u modelovanju. Kao što je već pomenuto, ukupno je korišćeno pet tehnika:

- Dve statističke tehnike (logistička regresija i diskriminantna analiza) i
- Tri tehnike mašinskog učenja (neuronske mreže, stabla odlučivanja i k-najbližih suseda)

Razvijeno je ukupno deset modela, odnosno dva po svakoj tehnici analize (jedan za predikciju u periodu do godinu dana, a drugi za period do dve godine).

6.1. Identifikovanje ključnih varijabli za kreiranje modela

Redukcija dimenzionalnosti je ključna pre generisanja modela, uzevši u obzir da je broj nezavisnih varijabli čak 66. Prvi korak jeste analiza normalnosti distribucije, drugi korak je analiza statističke značajnosti razlika u varijablama između grupa, dok je poslednji korak analiza multikolinearnosti, nakon čega se pristupa modelovanju. Dodatne redukcije dimenzionalnosti će biti urađene spram potreba pojedinačnih tehnika modelovanja, dok se prethodno pomenute podrazumevaju kao deo *opšte pripreme za modelovanje*. Na Slici 20, prikazani su najčešće korišćeni načini za selekciju ključnih varijabli kod MSP. Najčešće korišćene metode su: korelacija (26/145 istraživačkih radova), *FW Stepwise*

selekcija (26/145 istraživačkih radova) i VIF analiza (13/145 istraživačkih radova). Te tehnike, između ostalih, biće korišćene i u pripremi podataka za ovo istraživanje.

Slika 20: Najčešće korišćene metode za selekciju ključnih varijabli

Variable Selection Method	ABS	Non-ABS	N
(Number of Studies)	(94)	(51)	(145)
Correlation Analysis	18	8	26
Forward Stepwise Selection	17	9	26
VIF	9	4	13
Backward Stepwise Elimination	4	5	9
Stepwise Method ^a	6	3	9
PCA	4	3	7
Univariate Analysis	4	2	6
Average Marginal Effect (AME)	4	0	4
Significance	3	1	4
Wrapper Method	2	2	4
LASSO	2	1	3
RF Feature Selection Method	3	0	3

VIF stands for variance inflation factor, which shows the multicollinearity between the features. PCA stands for principal component analysis. It is often used to find a subset of variables that explains most of the variation in the data. LASSO stands for least absolute shrinkage and Selection operator. Significance stands for keeping only (the most) significant variables in the model. RF in RF feature selection method stands for random forests.

^aIt is not specified if the method is forward or backward.

Izvor: Cheraghali i Molnár, 2023, str. 15

6.1.1. Testiranje normalnosti distribucije nezavisnih varijabli

Testiranje normalnosti je inicijalno izvršeno putem *Kolmogorov-Smirnov* (skraćeno: K-S) i Šapiro-Vilk (*Shapiro-Wilk*; *S-W*) testova. Prema tumačenju autora (Field, 2009), Šapiro-Vilk test je moćniji u detekciji devijacije od normalnosti u poređenju sa K-S testom. Gissane (2016) smatra da je Šapiro-Vilk test moćniji od K-S testa, a pogodan je za uzorke koji su manji od 300 jedinica posmatranja. Tumačenje autora Campbell (2017) je usaglašeno sa prethodno rečenim, te se u istraživanju takođe navodi da je Šapiro-Vilks test moćniji od K-S testa (str. 164). Istog stava su i brojni drugi autori (Mendes i Pala, 2003; Razzali i Wah, 2010; itd.). U skladu sa prethodnim istraživanjima, fokus u daljoj analizi normalnosti stavljen je isključivo na rezultate **Šapiro-Vilk** testa, dok je K-S apstrahovan. Testiranje normalnosti je izvršeno dva puta:

- Jednom za varijable koje se koriste za razvoj modela predikcije stečaja godinu dana pre pokretanja postupka (Y-1) - Tabela 10 i
- Drugi put za varijable koje se koriste za razvoj modela predikcije stečaja dve godine pre pokretanja postupka (Y-2) - Tabela 11.

Dakle, rezultati testa normalnosti za varijable koje se koriste u modelovanju predikcije stečaja godinu dana pre pokretanja postupka (Y-1), prikazani su u Tabeli 10. Rezultati testa ukazuju na to da nijedna varijabla *nema normalnu distribuciju*, kako je signifikantnost, odnosno “Sig.” pokazatelj, 0,000 i ispod vrednosti 0,05 (Field, 2009, str. 144; Pallant, 2009, str. 64; Ho, 2013, str. 54).

Tabela 10: Test normalnosti za varijable koje se koriste u modelovanju predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Tests of Normality						
Variable	Kolmogorov-Smirnov^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
ROA	0.317	212	0.000	0.465	212	0.000
CR	0.301	212	0.000	0.316	212	0.000
WCTA	0.341	212	0.000	0.232	212	0.000
RER	0.157	212	0.000	0.820	212	0.000
EBITTA	0.285	212	0.000	0.591	212	0.000
STA	0.276	212	0.000	0.430	212	0.000
QR	0.253	212	0.000	0.498	212	0.000
TDTA	0.358	212	0.000	0.233	212	0.000
CATA	0.105	212	0.000	0.932	212	0.000
OCFTA	0.495	212	0.000	0.045	212	0.000
OCFTD	0.495	212	0.000	0.045	212	0.000
QATA	0.073	212	0.008	0.963	212	0.000
CAS	0.462	212	0.000	0.092	212	0.000
EBITInt	0.458	212	0.000	0.122	212	0.000
INVS	0.458	212	0.000	0.102	212	0.000
OITA	0.261	212	0.000	0.456	212	0.000
OCFS	0.486	212	0.000	0.066	212	0.000
NIS	0.486	212	0.000	0.048	212	0.000
LTDTA	0.273	212	0.000	0.560	212	0.000
CCL	0.272	212	0.000	0.633	212	0.000
OCFCL	0.495	212	0.000	0.045	212	0.000
WCS	0.481	212	0.000	0.078	212	0.000
CAPA	0.151	212	0.000	0.882	212	0.000
NSTA	0.219	212	0.000	0.755	212	0.000
NCI	0.458	212	0.000	0.072	212	0.000
Log_TA	0.057	212	0.094	0.905	212	0.000
CFNID	0.239	212	0.000	0.544	212	0.000
OCF	0.332	212	0.000	0.347	212	0.000
OEOI	0.321	212	0.000	0.459	212	0.000
QAS	0.468	212	0.000	0.087	212	0.000
SINV	0.448	212	0.000	0.223	212	0.000
HC	0.271	212	0.000	0.591	212	0.000
OY	0.123	212	0.000	0.895	212	0.000
Log_SINV	0.123	212	0.000	0.887	212	0.000
IEBD	0.418	212	0.000	0.160	212	0.000
CRR	0.367	212	0.000	0.296	212	0.000
IETR	0.384	212	0.000	0.298	212	0.000
QACL	0.093	212	0.000	0.949	212	0.000
INVWC	0.393	212	0.000	0.189	212	0.000
INVCL	0.373	212	0.000	0.232	212	0.000
CLCA	0.387	212	0.000	0.203	212	0.000

Tests of Normality						
Variable	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
LTLEFA	0.456	212	0.000	0.153	212	0.000
FATA	0.105	212	0.000	0.932	212	0.000
OENS	0.358	212	0.000	0.291	212	0.000
SEE	0.367	212	0.000	0.322	212	0.000
OIEE	0.370	212	0.000	0.316	212	0.000
FAEE	0.424	212	0.000	0.136	212	0.000
TITE	0.222	212	0.000	0.824	212	0.000
TETA	0.256	212	0.000	0.464	212	0.000
CS	0.486	212	0.000	0.055	212	0.000
OIG	0.246	212	0.000	0.572	212	0.000
NIG	0.289	212	0.000	0.527	212	0.000
TAG	0.248	212	0.000	0.599	212	0.000
TEG	0.285	212	0.000	0.551	212	0.000
TAGNP	0.333	212	0.000	0.380	212	0.000
Ln_S	0.132	212	0.000	0.904	212	0.000
Ln_CACL	0.137	212	0.000	0.923	212	0.000
CLTA	0.353	212	0.000	0.225	212	0.000
LTLCA	0.405	212	0.000	0.208	212	0.000
CFTL	0.310	212	0.000	0.510	212	0.000
SLC	0.208	212	0.000	0.733	212	0.000
Log_TAGNP	0.069	212	0.017	0.900	212	0.000
Ln_TAGDP	0.070	212	0.014	0.900	212	0.000
OBSCTA	0.461	212	0.000	0.065	212	0.000
SATA	0.285	212	0.000	0.492	212	0.000
IETA	0.269	212	0.000	0.548	212	0.000
a. Lilliefors Significance Correction						

Izvor: Kalkulacija autora na osnovu SPSS-a

Zatim, rezultati testa normalnosti za varijable koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2), prikazani su u Tabeli 11. Rezultati testa ukazuju na to da svega tri nezavisne varijable imaju normalnu distribuciju (Log_TA, LOG_TAGNP i Ln_TAGDP), kako je signifikantnost, odnosno "Sig." pokazatelj, iznad vrednosti 0,05 ($p > 0,05$). Za sve ostale varijable, pretpostavka normalnosti raspodele nije potvrđena i mora se – odbaciti (Field, 2009, str. 144; Pallant, 2009, str. 64; Ho, 2013, str. 54).

Tabela 11: Test normalnosti za varijable koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Tests of Normality						
Variable	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
ROA	0.241	212	0.000	0.677	212	0.000
CR	0.402	212	0.000	0.147	212	0.000
WCTA	0.313	212	0.000	0.253	212	0.000
RER	0.146	212	0.000	0.861	212	0.000

Tests of Normality						
Variable	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
EBITTA	0.233	212	0.000	0.817	212	0.000
STA	0.162	212	0.000	0.751	212	0.000
QR	0.393	212	0.000	0.175	212	0.000
TDTA	0.350	212	0.000	0.210	212	0.000
CATA	0.103	212	0.000	0.927	212	0.000
OCFTA	0.143	212	0.000	0.866	212	0.000
OCFTD	0.399	212	0.000	0.105	212	0.000
QATA	0.069	212	0.015	0.964	212	0.000
CAS	0.421	212	0.000	0.158	212	0.000
EBITInt	0.430	212	0.000	0.212	212	0.000
INVS	0.397	212	0.000	0.227	212	0.000
OITA	0.160	212	0.000	0.760	212	0.000
OCFS	0.472	212	0.000	0.117	212	0.000
NIS	0.436	212	0.000	0.137	212	0.000
LTDTA	0.266	212	0.000	0.555	212	0.000
CCL	0.261	212	0.000	0.663	212	0.000
OCFCL	0.374	212	0.000	0.139	212	0.000
WCS	0.476	212	0.000	0.092	212	0.000
CAPA	0.114	212	0.000	0.919	212	0.000
NSTA	0.172	212	0.000	0.900	212	0.000
NCI	0.389	212	0.000	0.244	212	0.000
Log_TA	0.033	212	.200 [*]	0.990	212	0.149
CFNID	0.372	212	0.000	0.132	212	0.000
OCF	0.321	212	0.000	0.347	212	0.000
OEOI	0.372	212	0.000	0.237	212	0.000
QAS	0.429	212	0.000	0.146	212	0.000
SINV	0.458	212	0.000	0.093	212	0.000
HC	0.260	212	0.000	0.634	212	0.000
OY	0.124	212	0.000	0.896	212	0.000
Log_SINV	0.146	212	0.000	0.885	212	0.000
IEBD	0.416	212	0.000	0.163	212	0.000
CRR	0.452	212	0.000	0.117	212	0.000
IETR	0.421	212	0.000	0.171	212	0.000
QACL	0.075	212	0.006	0.960	212	0.000
INVWC	0.384	212	0.000	0.142	212	0.000
INVCL	0.416	212	0.000	0.145	212	0.000
CLCA	0.405	212	0.000	0.141	212	0.000
LTLEFA	0.472	212	0.000	0.119	212	0.000
FATA	0.104	212	0.000	0.927	212	0.000
OENS	0.411	212	0.000	0.132	212	0.000
SEE	0.422	212	0.000	0.141	212	0.000
OIEE	0.421	212	0.000	0.141	212	0.000
FAEE	0.441	212	0.000	0.110	212	0.000
TITE	0.260	212	0.000	0.565	212	0.000
TETA	0.172	212	0.000	0.755	212	0.000

Tests of Normality						
Variable	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
CS	0.354	212	0.000	0.348	212	0.000
OIG	0.348	212	0.000	0.217	212	0.000
NIG	0.464	212	0.000	0.079	212	0.000
TAG	0.311	212	0.000	0.452	212	0.000
TEG	0.321	212	0.000	0.481	212	0.000
TAGNP	0.316	212	0.000	0.417	212	0.000
Ln_S	0.068	212	0.019	0.979	212	0.003
Ln_CACL	0.129	212	0.000	0.886	212	0.000
CLTA	0.309	212	0.000	0.235	212	0.000
LTLCA	0.449	212	0.000	0.087	212	0.000
CFTL	0.299	212	0.000	0.549	212	0.000
SLC	0.203	212	0.000	0.719	212	0.000
Log_TAGNP	0.035	212	.200 [*]	0.987	212	0.058
Ln_TAGDP	0.035	212	.200 [*]	0.988	212	0.071
OBSCTA	0.463	212	0.000	0.061	212	0.000
SATA	0.333	212	0.000	0.350	212	0.000
IETA	0.288	212	0.000	0.475	212	0.000
*. This is a lower bound of the true significance.						
a. Lilliefors Significance Correction						

Izvor: Kalkulacija autora na osnovu SPSS-a

6.1.2. Testiranje statističke značajnosti razlika između vrednosti varijabli za solventna preduzeća i preduzeća u stečaju

Statistička značajnost razlike u vrednostima varijabli između dve grupe, najčešće se testira putem t-testa i Men-Vitni (*Mann-Whitney*) testa. Men-Vitni test se koristi da se identifikuju razlike između dve grupe posmatrano sa stanovišta neke varijable. On je neparametarska varijanta t-testa. (Mann i Whitney, 1947). Adekvatan izbor između ova dva testa je od velike važnosti, a uslovljen je prethodno prezentovanim rezultatima normalnosti distribucije (Tabela 10 i Tabela 11). Ukoliko serija podataka pokazuje normalnost raspodele, onda je preporuka mnogih autora (Pallant, 2009, str. 112; Rochon i dr, 2012; Ho, 2013, str. 518; Orcan, 2020, str. 255; Demir, 2022, str. 397; itd.) korišćenje parametarskih testova (u ovom slučaju t-test), dok se u suprotnom savetuje upotreba neparametarskih testova (u ovom slučaju Men-Vitni). Štaviše, prema rečima Field-a (2009) upotreba parametarskih testova u uslovima kada nije ispunjen kriterijum normalnosti, predstavlja veliki problem, te vodi do pogrešnih zaključaka (str. 132). Kada je vrednost Men-Vitni testa $p < 0,05$ (Asymp. Sig 2-tailed), onda se prihvata tvrdnja da postoje statistički značajne razlike u vrednostima varijabli među grupama. Isto pravilo važi i za tumačenje t-test pokazatelja (Field, 2009; Pallant, 2009). U suprotnom, kada je $p > 0,05$, ne postoje statistički značajne razlike među grupama po pitanju posmatranog pokazatelja.

U Tabeli 12, prikazani su rezultati Men-Vitni testa za varijable koje se koriste u modelovanju predikcije stečaja godinu dana pre pokretanja postupka (Y-1). S obzirom da su prilikom testa normalnosti, sve varijable za Y-1 modelovanje demonstrirale odsustvo

normalne distribucije, dovoljno je sprovesti za sve varijable samo Men-Vitni test. Sve varijable sa vrednostima $p < 0,05$ (*Asymp. Sig. 2 - tailed*), pokazale su statistički značajne razlike u vrednostima među grupama (MSP u stečaju vs. solventna MSP), te su se kvalifikovale za dalje modelovanje (ukupno 48 varijabli). Tako, na primer, postoji statistički značajna razlika u vrednostima prinosa na aktivu (ROA) između solventnih MSP i onih koja su pokrenula stečajni postupak; zatim, postoji statistički značajna razlika u likvidnosti (CR) između solventnih MSP i onih koja su pokrenula stečajni postupak, itd. Varijable sa vrednostima $p > 0,05$ (*Asymp. Sig. 2 - tailed*) su eliminisane iz daljeg modelovanja predikcije stečaja za period godinu dana pre pokretanja postupka (ukupno 18 varijabli), jer ne pokazuju statistički značajne razlike između dve grupe – likvidna i solventna MSP.

Tabela 12: Men-Vitni test za varijable koje se koriste u modelovanju predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Variable	Mann-Whitney U	Wilcoxon W	Z	Asymp. Sig. (2-tailed)
ROA	4289.000	9960.000	-2.976	0.003
CR	3556.000	9227.000	-4.617	0.000
WCTA	3205.000	8876.000	-5.403	0.000
RER	3882.000	9553.000	-3.888	0.000
EBITTA	1231.000	6902.000	-9.824	0.000
STA	4294.000	9965.000	-2.965	0.003
QR	3790.000	9461.000	-4.093	0.000
TDTA	2096.000	7767.000	-7.887	0.000
CATA	4866.000	10537.000	-1.684	0.092
OCFTA	3913.000	9584.000	-3.818	0.000
OCFTD	3691.000	9362.000	-4.315	0.000
QATA	4857.000	10528.000	-1.704	0.088
CAS	3461.000	9132.000	-4.831	0.000
EBITInt	2322.000	7993.000	-7.394	0.000
INVS	4406.000	10077.000	-2.715	0.007
OITA	4223.000	9894.000	-3.124	0.002
OCFS	5501.000	11172.000	-0.262	0.793
NIS	1265.000	6936.000	-9.749	0.000
LTDTA	4489.000	10160.000	-2.538	0.011
CCL	2669.000	8340.000	-6.606	0.000
OCFCL	3686.000	9357.000	-4.326	0.000
WCS	3449.000	9120.000	-4.858	0.000
CAPA	2436.500	8107.500	-7.184	0.000
NSTA	1889.000	7560.000	-8.350	0.000
NCI	4199.000	9870.000	-3.178	0.001
Log_TA	5509.000	11180.000	-0.244	0.807
CFNID	1504.000	7175.000	-9.212	0.000
OCF	4442.000	10113.000	-2.633	0.008
OEOI	2069.000	7740.000	-7.948	0.000
QAS	3383.000	9054.000	-5.006	0.000
SINV	5246.000	10917.000	-0.833	0.405

Variable	Mann-Whitney U	Wilcoxon W	Z	Asymp. Sig. (2-tailed)
HC	4339.500	10010.500	-2.865	0.004
OY	5012.000	10683.000	-1.358	0.174
Log_SINV	4910.000	10581.000	-1.586	0.113
IEBD	4657.000	10328.000	-2.152	0.031
CRR	4462.000	10133.000	-2.589	0.010
IETR	3040.000	8711.000	-5.776	0.000
QACL	4992.000	10663.000	-1.402	0.161
INVWC	4710.000	10381.000	-2.033	0.042
INVCL	3905.000	9576.000	-3.836	0.000
CLCA	3072.000	8743.000	-5.701	0.000
LTLEFA	5466.000	11137.000	-0.340	0.734
FATA	4872.000	10543.000	-1.671	0.095
OENS	3588.000	9259.000	-4.546	0.000
SEE	4969.000	10640.000	-1.454	0.146
OIEE	4948.000	10619.000	-1.501	0.133
FAEE	5269.000	10940.000	-0.782	0.434
TITE	1319.000	6990.000	-9.627	0.000
TETA	4987.000	10658.000	-1.413	0.158
CS	4291.000	9962.000	-2.973	0.003
OIG	2499.000	8170.000	-6.984	0.000
NIG	3818.000	9489.000	-4.031	0.000
TAG	2306.000	7977.000	-7.416	0.000
TEG	2040.000	7711.000	-8.023	0.000
TAGNP	5062.000	10733.000	-1.245	0.213
Ln_S	3885.000	9556.000	-3.881	0.000
Ln_CACL	3378.000	9049.000	-5.016	0.000
CLTA	2736.000	8407.000	-6.454	0.000
LTLCA	4541.000	10212.000	-2.421	0.015
CFTL	2866.000	8537.000	-6.164	0.000
SLC	5275.000	10946.000	-0.768	0.442
Log_TAGNP	5512.000	11183.000	-0.237	0.812
Ln_TAGDP	5519.000	11190.000	-0.222	0.825
OBSCTA	4729.000	10400.000	-2.391	0.017
SATA	4669.000	10340.000	-2.125	0.034
IETA	3854.000	9525.000	-3.953	0.000

Kalkulacija autora na osnovu SPSS-a

U Tabeli 13, prikazani su rezultati Men-Vitni testa za varijable koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2). S obzirom da kod testa normalnosti postoje varijable koje su pokazale normalnu distribuciju (ukupno njih 3), nije dovoljno sprovesti za sve varijable samo Men-Vitni test, već se t-test sprovodi za one varijable sa normalnom distribucijom (Log_TA, Log_TAGNP i Ln_TAGDP). Sve varijable sa vrednostima $p < 0,05$ (*Asymp. Sig. 2 - tailed*), pokazale su statistički značajne razlike u vrednostima među grupama (MSP u stečaju vs. solventna MSP) kod Men-Vitni testa, te su se kvalifikovale za dalje modelovanje (ukupno 37 varijabli).

Tabela 13: Men-Vitni test za varijable koje *nemaju normalnu distribuciju* i koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Variable	Mann-Whitney U	Wilcoxon W	Z	Asymp. Sig. (2-tailed)
ROA	4805.500	10476.500	-1.819	0.069
CR	4348.500	10019.500	-2.843	0.004
WCTA	4625.500	10296.500	-2.222	0.026
RER	3507.500	9178.500	-4.726	0.000
EBITTA	2988.500	8659.500	-5.888	0.000
STA	4758.500	10429.500	-1.925	0.054
QR	4428.500	10099.500	-2.664	0.008
TDTA	3297.500	8968.500	-5.196	0.000
CATA	4812.500	10483.500	-1.804	0.071
OCFTA	3933.500	9604.500	-3.772	0.000
OCFTD	3659.500	9330.500	-4.385	0.000
QATA	4950.500	10621.500	-1.495	0.135
CAS	4286.000	9957.000	-2.983	0.003
EBITInt	3480.000	9151.000	-4.790	0.000
INVS	4601.000	10272.000	-2.277	0.023
OITA	4830.500	10501.500	-1.763	0.078
OCFS	4432.000	10103.000	-2.656	0.008
NIS	3101.000	8772.000	-5.636	0.000
LTDTA	4821.500	10492.500	-1.789	0.074
CCL	3093.500	8764.500	-5.653	0.000
OCFCL	3583.500	9254.500	-4.556	0.000
WCS	4749.000	10420.000	-1.946	0.052
CAPA	3276.500	8947.500	-5.250	0.000
NSTA	3325.500	8996.500	-5.133	0.000
NCI	4814.000	10485.000	-1.800	0.072
CFNID	2640.500	8311.500	-6.667	0.000
OCF	4027.500	9698.500	-3.561	0.000
OEOI	3310.000	8981.000	-5.168	0.000
QAS	4483.000	10154.000	-2.542	0.011
SINV	4582.000	10253.000	-2.320	0.020
HC	5357.000	11028.000	-0.585	0.559
OY	5027.000	10698.000	-1.325	0.185
Log_SINV	4736.500	10407.500	-1.974	0.048
IEBD	3738.500	9409.500	-4.209	0.000
CRR	5047.000	10718.000	-1.279	0.201
IETR	3595.000	9266.000	-4.531	0.000
QACL	5522.500	11193.500	-0.214	0.831
INVWC	4992.500	10663.500	-1.401	0.161
INVCL	4593.500	10264.500	-2.294	0.022
CLCA	4357.500	10028.500	-2.823	0.005
LTLEFA	5525.000	11196.000	-0.208	0.835
FATA	4811.500	10482.500	-1.806	0.071

Variable	Mann-Whitney U	Wilcoxon W	Z	Asymp. Sig. (2-tailed)
OENS	5261.000	10932.000	-0.799	0.424
SEE	4764.500	10435.500	-1.911	0.056
OIEE	4850.500	10521.500	-1.719	0.086
FAEE	5462.500	11133.500	-0.348	0.728
TITE	3119.000	8790.000	-5.596	0.000
TETA	5227.500	10898.500	-0.874	0.382
CS	3776.000	9447.000	-4.125	0.000
OIG	3855.500	9526.500	-3.947	0.000
NIG	4411.500	10082.500	-2.702	0.007
TAG	5366.500	11037.500	-0.563	0.573
TEG	4100.000	9771.000	-3.401	0.001
TAGNP	4798.500	10469.500	-1.835	0.067
Ln S	5328.000	10999.000	-0.649	0.516
Ln_CACL	4346.500	10017.500	-2.847	0.004
CLTA	3669.500	9340.500	-4.363	0.000
LTLCA	5158.500	10829.500	-1.032	0.302
CFTL	3297.500	8968.500	-5.196	0.000
SLC	5453.000	11124.000	-0.369	0.712
OBSCTA	5079.500	10750.500	-1.462	0.144
SATA	4573.500	10244.500	-2.339	0.019
IETA	3867.000	9538.000	-3.923	0.000

Izvor: Kalkulacija autora na osnovu SPSS-a

Nijedna od tri varijable nije pokazala statističku značajnost na t-testu (Tabela 14, $p > 0,05$). Stoga, uzevši u obzir rezultate oba testa, kod generisanja modela za predikciju stečaja dve godine unapred u ovom koraku eliminiše ukupno 29 varijabli.

Tabela 14: T-test za varijable koje imaju normalnu distribuciju i koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Independent Samples Test						
Variables		Levene's Test for Equality of Variances		t-test for Equality of Means		
		F	Sig.	t	df	Sig. (2-tailed)
Log_TA	Equal variances assumed	0.046167	0.830082	1.732904	210.000000	0.084581
	Equal variances not assumed			1.732904	208.141695	0.084594
Log_TAGNP	Equal variances assumed	0.008112	0.928318	1.746540	210.000000	0.082179
	Equal variances not assumed			1.746540	208.847847	0.082187

Independent Samples Test						
Variables		Levene's Test for Equality of Variances		t-test for Equality of Means		
		F	Sig.	t	df	Sig. (2-tailed)
Ln_TAGD P	Equal variances assumed	0.012122	0.912434	1.746434	210.000000	0.082198
	Equal variances not assumed			1.746434	208.770578	0.082206

Izvor: Kalkulacija autora na osnovu SPSS-a

6.1.3. Analiza multikolinearnosti


Naredni korak koji je neophodan prilikom modelovanja, jeste analiza multikolinearnosti. U ovoj fazi je urađena dodatna redukcija dimenzionalnosti kroz eliminisanje suvišnih nezavisnih varijabli. Multikolinearnost se javlja kada su prediktor (nezavisne) varijable redundantne (Hair i dr, 1998). Prisustvo visoke multikolinearnosti u modelima implicira da bi zaključci analize mogli biti upitni zbog smanjene preciznosti prediktor varijabli, usled visoke varijanse samih estimatora, pa otkrivanje iste predstavlja prvi korak u samom modelovanju (Salmeron, 2018).

U skladu sa praksom koju navode autori (Field, 2009), prvenstveno je urađena **analiza korelacije**, pa je tek onda realizovana **VIF** (*Variance Inflation Factor*) analiza. Kao i kod prethodnog donošenja odluke vezano za izbor između parametarskog i neparametarskog testa za ispitivanje statističke značajnosti razlika između grupa (Men-Vitni test vs. t-test), tako je i kod izbora testa za korelaciju od krucijalnog značaja uzeti u obzir karakteristike seta podataka koji se koristi za modelovanje.

S obzirom da sve varijable koje su se kvalifikovale za dalje modelovanje karakteriše odsustvo normalne distribucije, doneta je odluka o upotrebi Spirman-ovog (**Spearman**) neparametarskog testa (Field, 2009, str. 179). Sve varijable koje su u korelaciji većoj od 0.9, eliminisane su pre pokretanja VIF analize kako za Y-1, tako i za Y-2 modelovanje (Field, 2009, str. 224). Celokupne matrice korelacije su dostupne u Prilogu 2 i Prilogu 3, a toplotna mapa (*Heatmap*) je zarad lakšeg sagledavanja prikazana na slikama 21 i 22 i to za predikciju stečaja godinu dana (Y-1) u dve (Y-2) unapred respektivno.


Izrazito **crvene** ćelije ukazuju na postojanje jake pozitivne korelacije, dok izrazito **zelene** ukazuju na postojanje jake negativne korelacije. Na primer, kod prikaza varijabli za modelovanje predikcije stečaja godinu dana unapred (Y-1), između varijabli WCTA (*Working Capital to Total Assets*) i CR (*Current Ratio*) postoji **jaka pozitivna korelacija**. Isto važi za pomenute varijable ako se pogleda dijagram za indikatore koji se koriste u predikciji stečaja dve godine unapred (Y-2). Zatim, kod varijabli CLCA & LnCACL postoji **jaka negativna korelacija** na oba dijagrama, i kod indikatora za predikciju stečaja godinu dana, i kod onih za predikciju stečaja dve godine unapred. Bitno je napomenuti da su dijagonale na oba prikaza crvene, jer svaka varijabla korelira savršeno sama sa sobom – to je očekivano. Stoga, kada se posmatra dijagram, *uvek se posmatra samo površina iznad ili ispod dijagonale*.

Slika 21: *Heatmap* prikaz korelacije varijabli iz modelovanja predikcije stečaja godinu dana unapred (Y-1)



Izvor: Ilustracija autora, MS Excel program

Slika 22: *Heatmap* prikaz korelacije varijabli iz modelovanja predikcije stečaja dve godine unapred (Y-2)



Izvor: Ilustracija autora, MS Excel

Nakon realizovanog testiranja korelacije, pokrenut je **VIF test**. U skladu sa teorijskim uporištem i brojnim empirijskim istraživanjima, visokim VIF rezultatom se smatra onaj koji je iznad 5 (Judge i dr., 1987; Menard, 2001; Caramanis i Spathis, 2006; Studenmund, 2006, Suleiman i Badamsi, 2019; itd.). Dakle, sve varijable koje imaju rezultat iznad prethodno pomenute granice, eliminisane su iz daljeg modelovanja, u cilju izbegavanja multikolinearnosti nezavisnih varijabli.

Rezultati VIF testa za varijable koje se koriste u modelovanju predikcije godinu dana pre pokretanja stečaja (Y-1), prikazani su ispod u Tabeli 15. Ukupno 28 varijabli je nakon VIF analize kvalifikovano za Y-1 modelovanje ($VIF < 5.0$).

Tabela 15: VIF test multikolinearnosti za varijable koje se koriste u modelovanju predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Variance Inflation Factor (Y-1)		
Variable	Collinearity Statistics	
	Tolerance	VIF
ROA	0.358	2.790
RER	0.575	1.738
QR	0.431	2.322
TDTA	0.241	4.150
EBITInt	0.944	1.059
OITA	0.417	2.397
OCFCL	0.985	1.015
NSTA	0.431	2.319
NCI	0.926	1.080
CFNID	0.547	1.829
OCF	0.501	1.996
OEOI	0.553	1.807
HC	0.644	1.552
CRR	0.781	1.281
IETR	0.391	2.559
INVWC	0.982	1.018
TITE	0.393	2.544
CS	0.711	1.406
NIG	0.553	1.808
TAG	0.529	1.889
TEG	0.357	2.803
Ln_S	0.440	2.275
Ln_CACL	0.329	3.036
LTLCA	0.447	2.239
CFTL	0.726	1.377
OBSCTA	0.642	1.557
SATA	0.501	1.995
IETA	0.434	2.305

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati VIF testa za varijable koje se koriste u modelovanju predikcije dve godine pre pokretanja stečaja (Y-2), prikazani su ispod u Tabeli 16. Ukupno 17 varijabli je nakon VIF analize kvalifikovano za Y-2 modelovanje ($VIF < 5.0$).

Tabela 16: VIF test multikolinearnosti za varijable koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Variance Inflation Factor (Y-2)		
Variable	Collinearity Statistics	
	Tolerance	VIF
RER	0.353	2.835
CAS	0.576	1.738
EBITInt	0.944	1.059
OCFS	0.427	2.344
CCL	0.447	2.237
CAPA	0.335	2.988
CFNID	0.790	1.266
OEOI	0.209	4.785
Log_SINV	0.634	1.576
IEBD	0.254	3.942
IETR	0.217	4.603
TITE	0.553	1.809
CS	0.265	3.775
TEG	0.772	1.295
Ln_CACL	0.437	2.291
SATA	0.844	1.185
IETA	0.234	4.279

Izvor: Kalkulacija autora na osnovu SPSS-a

Nakon sprovedenih koraka, **nezavisne (prediktor) varijable** su konačno spremne za modelovanje. Ukupno 28 nezavisnih varijabli je kvalifikovano za modelovanje predikcije stečaja godinu dana pre pokretanja postupka, dok je ukupno 17 varijabli kvalifikovano za modelovanje predikcije stečaja dve godine pre pokretanja postupka. Poslednje što je potrebno uraditi pre otpočinjanja modelovanja, jeste kodiranje **zavisne varijable**, što je prikazano u Tabeli 17. Sva MSP koja su pokrenula stečajni postupak su označena sa “0”, dok sva solventna preduzeća imaju oznaku “1”.

Tabela 17: Kodiranje zavisne varijable za modelovanje predikcije stečaja godinu dana (Y-1) i dve godine unapred (Y-2)

Dependent Variable Encoding	
Original Value	Internal Value
Bankrupt	0
Solvent	1

Izvor: SPSS program

6.2. Kreiranje modela na bazi statističkih metoda

Tradicionalne statističke tehnike se odnose na logističku regresiju (LR), kao i diskriminantnu analizu (DA). Kod svake tehnike je prvo izvršeno generisanje modela, pa zatim testiranje pouzdanosti istog.

6.2.1. Logistička regresija (LR)

Kreiranje modela logističke regresije (LR) izvršeno je prvenstveno kroz podelu uzorka u dve celine, $\approx 80\%$ za trening i $\approx 20\%$ za testiranje, u skladu sa teorijskim pravilom (Theobald, 2021, str. 47). Putem principa postepenog uključivanja nezavisnih varijabli (*Stepwise*), izvršena je selekcija relevantnih racio pokazatelja za modele predikcije stečaja. Testiranje modela obuhvata sledeće: “Omnibus” test, “Cox & Snell” i “Nagelkerke R Square”, “Hosmer & Lemeshow” i matricu konfuzije (*Confusion Matrix*), koja je poznata kao i klasifikaciona tablica.

6.2.1.1. Kreiranje modela

U Tabeli 18, prikazana je struktura uzorka koji je korišćen za kreiranje modela predikcije stečaja, kako godinu dana (Y-1), tako i dve godine (Y-2) pre pokretanja stečajnog postupka. Dakle, podaci za 166 MSP su iskorišćeni za generisanje modela, dok su podaci za 46 MSP upotrebljeni za testiranje razvijenog modela.

Tabela 18: Struktura uzorka za generisanje i testiranje modela Y-1 i Y-2 (trening i test skup)

Case Processing Summary			
		N	Percent
Selected Cases	Included in Analysis	166	78.3
	Missing Cases	0	0.0
	Total	166	78.3
Unselected Cases		46	21.7
Total		212	100.0

Izvor: Kalkulacija autora na osnovu SPSS-a

Selekcija ključnih varijabli je izvršena upotrebom *Stepwise* tehnike. Selekcija ključnih varijabli je urađena putem *Forward Stepwise* tehnike, što znači da je algoritam krenuo sa modelom koji uključuje samo konstantu, a onda je postepeno dodavao prediktor (nezavisne) varijable prema specifičnom kriterijumu. Kriterijum je vrednost statističkog skora – rezultata (*Score statistic*). Varijabla koja ima najznačajniji rezultat se dodaje u model. Algoritam nastavlja da dodaje varijable sve dok nijedna preostala nema statistički značajan skor (tačka preseka je 0,05 za statističku značajnost). Takođe, tokom modelovanja, razmatra se da li je neka od već uključenih varijabli postala od manjeg značaja, te da li ista treba da se ukloni (Field, 2009, str. 272).

Prikaz varijabli koje su ultimativno uključene u modele logističke regresije, dat je u Tabeli 19. Za model predikcije stečaja godinu dana (Y-1) pre pokretanja postupka,

algoritam je u četvrtom koraku kao poslednjem identifikovao kao značajne sledeće pokazatelje: TITE (ukupnih prihodi / ukupni rashodi), CS (gotovina / prihod od prodaje), TAG (rast ukupne aktive) i IETA (odnos rashoda kamata i ukupne aktive). Dakle, dinamika ukupnih prihoda, brzina naplate potraživanja, stepen u kojem se uvećavaju sredstva preduzeća, ali i stepen zaduženosti su bitne varijable za generisanje Y-1 modela.

Sa druge strane, za model predikcije stečaja dve godine (Y-2) pre pokretanja postupka, algoritam je u drugom koraku kao poslednjem identifikovao kao značajne sledeće pokazatelje: CCL (odnos gotovine i kratkoročnih obaveza) i CFNID (odnos neto rezultata iz izveštaja o novčanim tokovima i ukupnog duga). Može se zaključiti da pokazatelji koji govore o tome kako MSP upravlja svojim gotovinskim tokovima, presudni su za generisanje Y-2 modela.

Tabela 19: Varijable uključene u model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Variables in the Equation						
Observed		B	S.E.	Wald	df	Sig.
Y-1 MODEL						
Step 4	TITE	13.081793	3.054	18.345	1	0.000
	CS	0.107554	0.035	9.341	1	0.002
	TAG	0.000004	0.000	5.955	1	0.015
	IETA	-58.955100	24.746	5.676	1	0.017
	Constant	-12.148161	3.000	16.402	1	0.000
Y-2 MODEL						
Step 2	CCL	4.984282	1.900	6.883	1	0.009
	CFNID	6.758524	1.596	17.943	1	0.000
	Constant	-0.630804	0.227	7.708	1	0.005

Izvor: Kalkulacija autora na osnovu SPSS-a

Dva generisana modela predikcije stečaja se mogu zapisati matematički na sledeći način:

- **Y-1 (predikcija godinu dana unapred):**

$$P'(x) = \frac{1}{1 + e^{-(12.148161 - 58.955100 IETA + 0.000004 TAG + 0.107554 CS + 13.081793 TITE)}}$$

- **Y-2 (predikcija dve godine unapred):**

$$P''(x) = \frac{1}{1 + e^{-(-0.630804 + 6.758524 \text{ CFNID} + 4.984282 \text{ CCL})}}$$

U Tabeli 20, prikazani su efekti uklanjanja selektovanih varijabli iz modela. Kako je vrednost $p < 0,01$ (*Sig. of the Change*), zaključuje se da uklanjanje bilo koje od selektovanih varijabli nije opravdano, te da bi naškodilo preciznosti modela (Field, 2009, str. 289).

Tabela 20: Test značajnosti varijabli uključenih u model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Model if Term Removed					
Variable		Model Log Likelihood	Change in -2 Log Likelihood	df	Sig. of the Change
Y-1 MODEL					
Step 4	TITE	-91.260	54.489	1	0.000
	CS	-73.296	18.561	1	0.000
	TAG	-68.244	8.457	1	0.004
	IETA	-67.707	7.384	1	0.007
Y-2 MODEL					
Step 2	CCL	-94.897	8.284	1	0.004
	CFNID	-109.945	38.380	1	0.000

Izvor: Kalkulacija autora na osnovu SPSS-a

U Tabeli 21, prikazani su rezultati testa za ostale varijable koje nisu uključene u modele. Za rasio pokazatelje iz tabele, prikazan je statistički rezultat (*Score*), kao i statistička značajnost. Zaključuje se da kod svih rasio pokazatelja, vrednost koeficijenata se ne razlikuje statistički značajno od nule (kao što se može videti u koloni *Sig.*), te se dalje deduktivno zaključuje da nema osnova za uključivanje tih nezavisnih varijabli, kako u Y-1, tako ni u Y-2 model (Field, 2009, str. 289).

Tabela 21: Rezultati testa za varijable koje nisu uključene u model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Variables not in the Equation					
Step#	Label	Variable	Score	df	Sig.
Y-1 MODEL					
Step 4	Variables	ROA	0.220	1	0.639
		RER	0.555	1	0.456
		QR	1.528	1	0.216
		TDTA	1.990	1	0.158
		EBITInt	0.180	1	0.672
		OITA	2.280	1	0.131
		OCFCL	0.750	1	0.386
		NSTA	2.562	1	0.109
		NCI	0.750	1	0.386
		CFNID	0.658	1	0.417
		OCF	0.945	1	0.331
		OEOI	0.298	1	0.585
		HC	1.783	1	0.182
		CRR	1.029	1	0.310
		IETR	0.789	1	0.374
		INVWC	0.126	1	0.723
		NIG	1.742	1	0.187
		TEG	0.434	1	0.510
		Ln_S	3.561	1	0.059
		Ln_CACL	2.857	1	0.091
		LTLCA	0.000	1	0.998
		CFTL	1.532	1	0.216
		OBSCTA	0.407	1	0.524
		SATA	1.727	1	0.189
Y-2 MODEL					
Step 2	Variables	RER	0.073	1	0.787
		CAS	1.896	1	0.168
		EBITInt	2.985	1	0.084
		OCFS	0.966	1	0.326
		CAPA	1.726	1	0.189
		OEOI	1.224	1	0.269
		Log_SINV	1.389	1	0.239
		IEBD	0.542	1	0.462
		IETR	0.847	1	0.357
		TITE	0.007	1	0.931
		CS	1.420	1	0.233
		TEG	1.440	1	0.230
		Ln_CACL	0.037	1	0.847
		SATA	1.026	1	0.311
		IETA	2.273	1	0.132

Izvor: Kalkulacija autora na osnovu SPSS-a

6.2.1.2. Testiranje modela

Onog momenta kada se završi razvoj modela logističke regresije, vrši se testiranje kvaliteta istog, odnosno načina na koji su parametri uklopljeni (*Goodness-of-fit tests*) sa ciljem utvrđivanja da li je konačno razvijeni model adekvatan u predviđanju ishoda (Archer i Lemeshow, 2006, str. 97).

Prvi značajan test adekvatnosti modela jeste Vold-ov test (*Wald's test*) koji je prikazan iznad, u Tabeli 19. Kada je vrednost $p < 0,05$ kod ovog testa (Sig.), zaključuje se da varijabla ima značajan uticaj na klasifikacionu snagu generisanog modela (Field, 2009, str. 287; Pallant, 2009, str. 178.). Analizom rezultata iz pomenute tabele, donosi se zaključak da je kod svih varijabli signifikantnost (Sig.) ispod vrednosti 0,05, što ukazuje da selektovane varijable imaju značaj za generisane modele, kako za predikciju stečaja godinu dana unapred (Y-1), tako i za predikciju dve godine unapred (Y-2).

Naredni test kvaliteta razvijenih modela je *Omnibus* test. Ukoliko je pokazatelj signifikantnosti (Sig.) manji od 0.05, model je adekvatan u predikciji (Pallant, 2009, str. 176). Za sve varijable, kako u modelu predikcije stečaja godinu dana unapred (Y-1), tako i dve godine unapred (Y-2), pokazatelj signifikantnosti je manji od pomenute vrednosti, pa se zaključuje da su parametri modela dobro uklopljeni (Tabela 22).

Tabela 22: Omnibus test razvijenih modela predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Omnibus Tests of Model Coefficients				
Step#	Label	Chi-square	df	Sig.
Y-1 MODEL				
Step 4	Step	8.457	1	0.004
	Block	102.094	4	0.000
	Model	102.094	4	0.000
Y-2 MODEL				
Step 2	Step	8.284	1	0.004
	Block	48.615	2	0.000
	Model	48.615	2	0.000

Izvor: Kalkulacija autora na osnovu SPSS-a

Cox & Snell, kao i *Nagelkerke R Square*, dva su testa koja će pružiti dodatni uvid u kvalitet modela, odnosno adekvatnost uklapanja parametara istog (Tabela 23). *Cox & Snell* je koeficijent koji ukazuje na proporciju odnosno meru u kojoj je zavisna varijabla objašnjena kroz (nezavisne) prediktor varijable. Sam proces estimacije se bazira na poređenju logaritma verodostojnosti (*logarithm of likelihood*) za ceo model sa logaritmom verodostojnosti za bazični model (Cox i Snell, 1989). Nagelkerke je unapređena verzija prethodno pomenutog testa (Nagelkerke, 1991).

Prema rečima autora Bešlić-Obradović i dr. (2018), vrednost pseudo R^2 varira od 0, što je minimum, do maksimalnih 1, a vrednost koja je veća od 0.4 signalizira da je model dobro uklopljen (str. 143). Mišljenje autora (Braun i dr, 2013) je u skladu sa prethodno pomenutim, a to je da vrednost iznad 0.4 ukazuje na dobru uklopljenost modela. Dodatno, vrednosti ovih testova u rangu 0.24-0.32 se smatraju zadovoljavajućim (Mujkić i Poljašević, 2023, str. 136). Sa druge strane, neki autori navode da vrednosti *Cox & Snell* i *Nagelkerke* parametara moraju biti iznad 0.2 (Kanapickiene i Špicas, 2019). Konačno, bitno je napomenuti da ne postoji jedinstvena skala kod tumačenja vrednosti pseudo R^2 pokazatelja, pa upotreba istih treba da bude pažljiva, te je neophodno da se stave u kontekst sa ostalim indikatorima procene kvaliteta modela (Tušek i Gabrić, 2017).

Kod modela predikcije stečaja godinu dana pre pokretanja postupka (Y-1), vrednost za *Cox & Snell* test iznosi 0.46, dok je vrednost *Nagelkerke R Square* testa 0.61. Rezultati testova ukazuju da je razvijeni model dobro uklopljen, te da model može da objasni od 45 do 61% varijanse zavisne promenljive.

Kada je reč o modelu predikcije stečaja dve godine pre pokretanja postupka (Y-2), za *Cox & Snell* test iznosi 0.25, dok vrednost *Nagelkerke R Square* testa iznosi 0.34. Rezultati testova ukazuju da je razvijeni model dobro uklopljen, te da isti može da objasni od 25% do 34% varijanse zavisne promenljive.

Prethodno pomenuti rezultati su odlični (Kušter, 2023b, str. 64) i u skladu su sa gore pomenutim referentnim vrednostima (od 0.24 do 0.34). Model za predikciju stečaja godinu dana unapred čak pokazuje i izuzetno visoke vrednosti - iznad 0.40 (vidi Tabelu 23).

Tabela 23: “Cox & Snell” i “Nagelkerke R Square” testovi razvijenih modela predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Model Summary			
Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
Y-1 MODEL			
4	128.031	0.459	0.612
Y-2 MODEL			
2	181.51	0.254	0.339

Izvor: Kalkulacija autora na osnovu SPSS-a

Naredni korak u proveru kvaliteta i usklađenosti razvijenog modela jeste *Hosmer & Lemeshow (H&L) test*. Model se karakteriše kao dobro usklađen kada statistička značajnost ovog testa prelazi 0,05 (Sig.), odnosno manje vrednosti od 0,05 ukazuju na slabu predviđačku snagu modela (Zenzerovic & Perusko, 2009, str. 362; Pallant, 2009, str. 177; Ho, 2013, str. 391). U Tabeli 24, pokazatelj hi-kvadrat za H&S test iznosi 8.304 za model predikcije stečaja godinu dana unapred, uz statističku značajnost 0.404. Zatim, pokazatelj hi-kvadrat za H&S test iznosi 7.795 za model predikcije stečaja dve godine unapred, uz statističku značajnost 0.454. Statistička značajnost (Sig.) je iznad gore pomenutog nivoa, stoga se zaključuje da je model dobro uklopljen.

Tabela 24: “Hosmer & Lemeshow” test razvijenih modela predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Hosmer and Lemeshow Test			
Step	Chi-square	df	Sig.
Y-1 MODEL			
4	8.304	8	0.404
Y-2 MODEL			
2	7.795	8	0.454

Izvor: Kalkulacija autora na osnovu SPSS-a

Poslednji korak u testiranju modela jeste **matrica konfuzije** (*Confusion Matrix*), gde se direktno testira predviđačka snaga dva razvijena modela kroz parametre koji su pomenuti u samom okviru istraživanja: tačnost (*Accuracy*), preciznost (*Precision*), specifičnost (*Specificity*), senzitivnost (*Sensitivity*) i F1 rezultat (*F1 Score*). Rezultati su prikazani u Tabeli 25.

Tabela 25: Matrica konfuzije za modele predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Classification Table								
Observed		Predicted						
		Selected Cases			Unselected Cases			
		Status		% Correct	Status		% Correct	
0	1	0	1					
Y-1 MODEL								
Step 4	Status	0	62	21	74.7	17	6	73.9
		1	6	77	92.8	2	21	91.3
	Overall Percentage		83.7			82.6		
	Y-2 MODEL							
Step 2	Status	0	66	17	79.5	16	7	69.6
		1	28	55	66.3	9	14	60.9
	Overall Percentage		72.9			65.2		

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati matrice konfuzije za model predikcije stečaja godinu dana unapred (Y-1) pre pokretanja postupka, ukazuju na ukupnu tačnost (*Accuracy*) 83.7% za trening, odnosno 82.6% za test skup podataka. Pokazatelj Preciznost (*Precision*) iznosi 74.7 % za trening,

odnosno 73.9% za test skup podataka. Specifičnost (**Specificity**) modela je 78.6% za trening, odnosno 77.8% za test skup. Senzitivnost (**Sensitivity**) modela je 91.2% za trening, odnosno 89.5% za test skup. Na kraju, F1 rezultat (**F1-Score**) za model je 82.1% kod trening podataka, a 81.0% kod test uzorka.

Rezultati matrice konfuzije za model predikcije stečaja dve godine unapred (Y-2) pre pokretanja postupka, ukazuju na ukupnu tačnost (**Accuracy**) 72.9% za trening, odnosno 65.2% za test skup podataka. Pokazatelj Preciznost (**Precision**) iznosi 79.5% za trening, odnosno 69.6% za test skup podataka. Specifičnost (**Specificity**) modela je 76.4% za trening, odnosno 66.7% za test skup. Senzitivnost (**Sensitivity**) modela je 70.2% za trening, odnosno 64.0% za test skup. Na kraju, F1 rezultat (**F1-Score**) za model je 74.6% kod trening podataka, a 66.7% kod test uzorka.

6.2.2. Diskriminantna analiza (DA)

Kreiranje diskriminantnog modela (DA) izvršeno je upotrebom celog uzorka MSP, dok je trening urađen unakrsnom validacijom u skladu sa mogućnostima SPSS programa. Pre generisanja modela, urađena je normalizacija nezavisnih varijabli, kako je to ključni korak da bi DA bila ispravna. Putem principa postepenog uključivanja nezavisnih varijabli (*Stepwise*), izvršena je selekcija relevantnih ratio pokazatelja za modele predikcije stečaja. Testiranje modela obuhvata sledeće: Log determinante (*Log Determinants*), Boks-ov M test (*Box's M test*), sopstvene vrednosti (*Eigenvalues*), Vilkovu lambda (*Wilk's Lambda*), i matricu konfuzije (*Confusion Matrix*).

6.2.2.1. Kreiranje modela

Mimo standardnih procedura koje se sprovode u fazi prikupljanja i pripreme podataka za modelovanje, diskriminantna analiza ima dodatno ograničenje, a to je da zahteva da vrednosti za svaku prediktor varijablu imaju normalnu distribuciju. Kako je na samom početku potvrđeno da prediktor varijable nemaju normalnu distribuciju, ista mora da se obezbedi postupkom normalizacije. Normalizacija je izvršena u dva koraka po sledećem principu (Templeton, 2011, str. 44):

- Transformacija ka uniformnosti:
 - **Percentil Rang** = $1 - [\text{Rang}(X_i) / n]$
 Gde je:
 - $\text{Rang}(X_i)$ = rang vrednosti X_i ;
 - n = veličina uzorka
- Transformacija ka normalnosti (iz uniformnosti):
 - **$p = \mu + \sqrt{2} \sigma \text{erf}^{-1}(-1+2Pr)$**
 Gde je:
 - p = konačan rezultat normalizacije;
 - μ = srednja vrednost za p ;
 - σ = standardna devijacija od vrednosti p ;
 - erf^{-1} = inverzna funkcija greške;
 - Pr = rezultat prvog koraka

Tabela 26: Dodatni testovi normalnosti nakon normalizacije varijabli za generisanje modela predikcije stečaja godinu dana unapred (Y-1)

(Additional) Tests of Normality Y-1						
Variables	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
T_ROA	0.026	212	.200*	0.995	212	0.674
T_RER	0.041	212	.200*	0.983	212	0.013
T_QR	0.025	212	.200*	0.996	212	0.879
T_TDTA	0.027	212	.200*	0.997	212	0.933
T_EBITInt	0.080	212	0.002	0.988	212	0.061
T_OITA	0.027	212	.200*	0.995	212	0.786
T_OCFCL	0.021	212	.200*	0.995	212	0.660
T_NSTA	0.023	212	.200*	0.997	212	0.935
T_NCI	0.032	212	.200*	0.996	212	0.815
T_CFNID	0.025	212	.200*	0.997	212	0.936
T_OCF	0.020	212	.200*	0.997	212	0.938
T_OEOI	0.038	212	.200*	0.996	212	0.912
T_HC	0.046	212	.200*	0.981	212	0.005
T_CRR	0.022	212	.200*	0.997	212	0.938
T_IETR	0.049	212	.200*	0.980	212	0.004
T_INVWC	0.022	212	.200*	0.997	212	0.933
T_TITE	0.028	212	.200*	0.996	212	0.872
T_CS	0.040	212	.200*	0.981	212	0.005
T_NIG	0.010	212	.200*	0.997	212	0.940
T_TAG	0.012	212	.200*	0.997	212	0.939
T_TEG	0.075	212	0.006	0.995	212	0.748
T_Ln_S	0.042	212	.200*	0.997	212	0.919
T_Ln_CACL	0.026	212	.200*	0.997	212	0.936
T_LTLCA	0.111	212	0.000	0.952	212	0.000
T_CFTL	0.043	212	.200*	0.982	212	0.009
T_OBSCTA	0.410	212	0.000	0.677	212	0.000
T_SATA	0.027	212	.200*	0.993	212	0.354
T_IETA	0.060	212	0.062	0.976	212	0.001
*. This is a lower bound of the true significance.						
a. Lilliefors Significance Correction						

Izvor: Kalkulacija autora na osnovu SPSS-a

Kao što je pomenuto prilikom inicijalnog testiranja normalnosti u poglavlju 6, normalnost se pokazuje kroz *statistički neznačajno* odudaranje od normalnosti. Dakle, iznosom “Sig.” koji je veći od 0,05 (Pallant, 2009, str. 62).

Rezultati testa za one varijable koje se koriste u razvoju modela predikcije stečaja godinu dana unapred (Y-1), prikazani su u Tabeli 26. Sve varijable koje imaju statističku značajnost iznad 0,05 (kolona “Sig.”), kvalifikovale su se za modelovanje (ukupno 20 nezavisnih varijabli). Varijable koje i nakon normalizacije nemaju normalnu distribuciju, isključene su iz dalje analize.

Tabela 27: Dodatni testovi normalnosti nakon normalizacije varijabli za generisanje modela predikcije stečaja dve godine unapred (Y-2)

(Additional) Tests of Normality Y-2						
Variables	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	Df	Sig.	Statistic	df	Sig.
T_RER	0.031	212	.200*	0.987	212	0.057
T_CAS	0.015	212	.200*	0.997	212	0.937
T_EBITInt	0.052	212	.200*	0.994	212	0.630
T_OCFS	0.013	212	.200*	0.997	212	0.931
T_CCL	0.019	212	.200*	0.993	212	0.360
T_CAPA	0.074	212	0.007	0.970	212	0.000
T_CFNID	0.010	212	.200*	0.997	212	0.939
T_OEOI	0.016	212	.200*	0.997	212	0.938
T_Log_SINV	0.024	212	.200*	0.997	212	0.937
T_IEBD	0.008	212	.200*	0.997	212	0.939
T_IETR	0.043	212	.200*	0.982	212	0.009
T_TITE	0.012	212	.200*	0.997	212	0.939
T_CS	0.017	212	.200*	0.993	212	0.459
T_TEG	0.049	212	.200*	0.996	212	0.883
T_Ln_CACL	0.010	212	.200*	0.997	212	0.940
T_SATA	0.010	212	.200*	0.996	212	0.883
T_IETA	0.049	212	.200*	0.980	212	0.005
*. This is a lower bound of the true significance.						
a. Lilliefors Significance Correction						

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati testa za one varijable koje se koriste u razvoju modela predikcije stečaja dve godine unapred (Y-2), prikazani su u Tabeli 27. Sve varijable koje imaju statističku značajnost iznad 0,05 (kolona “Sig.”), kvalifikovale su se za modelovanje (ukupno nezavisnih 14 varijabli). Po istom principu kao i kod modelovanja predikcije godinu dana unapred, varijable koje i nakon postupka normalizacije nemaju normalnu distribuciju – isključene su.

Tabela 28: Struktura uzorka za generisanje i testiranje modela predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Analysis Case Processing Summary			
Unweighted Cases		N	Percent
Valid		212	100.0
Excluded	Missing or out-of-range group codes	0	0.0
	At least one missing discriminating variable	0	0.0
	Both missing or out-of-range group codes and at least one missing discriminating variable	0	0.0
	Total	0	0.0
Total		212	100.0

Izvor: SPSS program

U Tabeli 28, prikazana je struktura uzorka za modelovanje. Kao što je napomenuto na početku poglavlja, celokupan uzorak od 212 MSP je upotrebljen za razvoj modela, dok se testiranje radi putem unakrsne validacije (*Cross-Validation*).

Tabela 29: Analiza jednakosti srednjih vrednosti grupa za model predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tests of Equality of Group Means					
Variable	Wilks' Lambda	F	df1	df2	Sig.
Y-1					
T_ROA	0.962	8.229	1	210	0.005
T_QR	0.903	22.603	1	210	0.000
T_TDTA	0.729	77.917	1	210	0.000
T_EBITInt	0.789	56.261	1	210	0.000
T_OITA	0.947	11.718	1	210	0.001
T_OCFCL	0.912	20.347	1	210	0.000
T_NSTA	0.709	86.349	1	210	0.000
T_CFNID	0.641	117.615	1	210	0.000
T_OCF	0.979	4.550	1	210	0.034
T_OEOI	0.750	70.056	1	210	0.000
T_CRR	0.978	4.734	1	210	0.031
T_INVWC	0.992	1.683	1	210	0.196
T_TITE	0.614	131.991	1	210	0.000
T_NIG	0.942	12.953	1	210	0.000
T_TEG	0.725	79.726	1	210	0.000
T_Ln_S	0.943	12.645	1	210	0.000
T_Ln_CACL	0.866	32.574	1	210	0.000
T_SATA	0.976	5.209	1	210	0.023

Tests of Equality of Group Means					
Variable	Wilks' Lambda	F	df1	df2	Sig.
Y-2					
T_RER	0.892	25.427	1	210	0.000
T_CAS	0.952	10.502	1	210	0.001
T_EBITInt	0.897	24.058	1	210	0.000
T_OCFS	0.980	4.314	1	210	0.039
T_CCL	0.864	33.154	1	210	0.000
T_CFNID	0.788	56.661	1	210	0.000
T_OEOI	0.866	32.407	1	210	0.000
T_Log_SINV	0.983	3.566	1	210	0.060
T_TITE	0.860	34.231	1	210	0.000
T_CS	0.928	16.405	1	210	0.000
T_TEG	0.954	10.093	1	210	0.002
T_Ln_CACL	0.947	11.667	1	210	0.001
T_SATA	0.984	3.395	1	210	0.067

Izvor: Kalkulacija autora na osnovu SPSS-a

U Tabeli 29, prikazana je analiza jednakosti srednjih vrednosti između grupa za svaku varijablu i to za oba modelovanja, odnosno Vilkova lambda (*Wilks' Lambda*) i F test za period godinu dana (Y-1) i dve godine (Y-2) pre pokretanja stečajnog postupka. Varijable koje imaju rezultat signifikantnosti ("Sig.") manji od 0.05 ($p < .05$), potencijalno su značajne za modelovanje i mogu biti korisne u diskriminaciji između grupa (Ho, 2013, str. 363).

U cilju odabira samo relevantnih varijabli, kao i kod logističke regresije, korišćena je tehnika postepenog uključivanja varijabli (*Stepwise*) u DA model. Ova tehnika podrazumeva postepeno građenje modela korak-po-korak, a selektuju se samo one varijable koje mogu da doprinesu diskriminaciji između grupa. Rezultati su prikazani u Tabeli 30. Za predikciju stečaja godinu dana unapred (Y-1), algoritam je selektovao transformisane TITE, TDTA i CFNID varijable kao najznačajnije, dok je za predikciju stečaja dve godine unapred (Y-2), odabran sledeći par transformisanih varijabli: CFNID i CCL.

Tabela 30: Selektovane varijable po *Stepwise* principu za model predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Variables Entered/Removed ^{a,b,c,d}									
Step	Entered	Wilks' Lambda							
		Statistic	df1	df2	df3	Statistic	df1	df2	Sig.
Y-1									
1	T_TITE	0.614	1	1	210.000	131.991	1	210.000	0.000
2	T_TDTA	0.554	2	1	210.000	84.256	2	209.000	0.000
3	T_CFNID	0.538	3	1	210.000	59.505	3	208.000	0.000

Variables Entered/Removed ^{a,b,c,d}									
Step	Entered	Wilks' Lambda							
		Statistic	df1	df2	df3	Statistic	Exact F		Sig.
Y-2									
1	T_CFNID	0.788	1	1	210.000	56.661	1	210.000	0.000
2	T_CCL	0.741	2	1	210.000	36.536	2	209.000	0.000
At each step, the variable that minimizes the overall Wilks' Lambda is entered.									
a. Maximum number of steps is 28.									
b. Minimum partial F to enter is 3.84.									
c. Maximum partial F to remove is 2.71.									
d. F level, tolerance, or VIN insufficient for further computation.									

Izvor: Kalkulacija autora na osnovu SPSS-a

Pregled koeficijenata diskriminantne funkcije, dat je u Tabeli 31. Svaki koeficijent ukazuje na relativni značaj varijable uz koju stoji u modelu diskriminacije, tako da varijable sa većim koeficijentom imaju veći doprinos diskriminaciji i obrnuto (Ho, 2013, str. 363).

Tabela 31: Koeficijenti diskriminantne funkcije za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Canonical Discriminant Function Coefficients	
Variables	Function 1
Y-1	
T_TDTA	-0.207
T_CFNID	0.826
T_TITE	2.383
(Constant)	-1.999
Y-2	
T_CCL	3.759
T_CFNID	0.522
(Constant)	-0.456
Unstandardized coefficients	

Izvor: Kalkulacija autora na osnovu SPSS-a

Diskriminantna funkcija izgleda jasnije ukoliko se matematički zapiše na sledeći način:

→ Y-1 (predikcija godinu dana unapred):

$$D'_{MSP} = -1.999 + 2.383(T_TITE) + 0.826(T_CFNID) - 0.207(T_TDTA)$$

$$D'_{MSP} = -1.999 + 2.383\left(T \frac{\text{Ukupni prihod}}{\text{Ukupni rashod}}\right) + 0.826\left(T \frac{\text{Neto rezultat iz novčanih tokova}}{\text{Ukupan dug}}\right) - 0.207\left(T \frac{\text{Ukupni dug}}{\text{Ukupna aktiva}}\right)$$

➔ Y-2 (predikcija dve godine unapred):

$$D''_{MSP} = -0.456 + 3.759(T_CCL) + 0.522(T_CFNID)$$

$$D''_{MSP} = -0.456 + 3.759\left(T \frac{\text{Gotovina}}{\text{Kratkoročne obaveze}}\right) + 0.522\left(T \frac{\text{Neto rezultat iz novčanih tokova}}{\text{Ukupan dug}}\right)$$

Pored prethodno pomenutog, važno je napomenuti i koje su granične (*cut-off*) vrednosti za diskriminantnu funkciju. Rezultat je prikazan u Tabeli 32. Centroidi grupa (*Group centroids*) su standardizovane udružene srednje vrednosti bazirane na linearnoj kombinaciji prediktor varijabli za svaku grupu, a koriste se za interpretaciju razlika između grupa (Ho, 2013, str. 365).

Tabela 32: Centroidi grupa diskriminantne funkcije za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Functions at Group Centroids	
Status	Function 1
Y-1	
0	-0.922
1	0.922
Y-2	
0	-0.588
1	0.588
Unstandardized canonical discriminant functions evaluated at group means	


Izvor: Kalkulacija autora na osnovu SPSS-a

Za model predikcije stečaja godinu dana unapred (Y-1), zone diskriminacije su sledeće (Kušter, 2023a, str. 14) :

- $D \leq -0.922$ se interpretira kao da je preduzeće rizično, odnosno u zoni pokretanja stečajnog postupka;
- $-0.922 < D < 0.922$ se može interpretirati kao siva zona, gde je teško odrediti da li preduzeće ima ili nema finansijske poteškoće
- $D \geq 0.922$ se interpretira kao sigurna zona, odnosno zona u kojoj su male šanse da će preduzeće pokrenuti stečajni postupak.

Vizuelna reprezentacija prethodno pomenutih zona diskriminacije za Y-1 model, prikazana je na Slici 23, dok je isto za Y-2 model prikazano na Slici 24.

Slika 23: Vizuelni prikaz diskriminacionih zona (*Group centroids*) funkcije za predikciju stečaja godinu dana unapred (Y-1)




Izvor: Ilustracija autora na osnovu Kušter, 2023a, str.14

Za model predikcije stečaja dve godine unapred (Y-2), zone diskriminacije su sledeće (Kušter, 2023a, str. 14):

- $D \leq -0.588$ se interpretira kao da je preduzeće rizično, odnosno u zoni pokretanja stečajnog postupka;
- $-0.588 < D < 0.588$ se može interpretirati kao siva zona, gde je teško odrediti da li preduzeće ima ili nema finansijske poteškoće;
- $D \geq 0.588$ se interpretira kao sigurna zona, odnosno zona u kojoj su male šanse da će preduzeće pokrenuti stečajni postupak.

Slika 24: Vizuelni prikaz diskriminacionih zona (*Group centroids*) funkcije za predikciju stečaja dve godine unapred (Y-2)



Izvor: Ilustracija autora na osnovu: Kušter, 2023a, str. 14

6.2.2.2. Testiranje modela

Testiranje kvaliteta i predviđačke moći razvijenih modela, biće realizovano putem: Log determinanti, Boks-ovog M testa (*Box's M*), sopstvenih/pojedinačnih vrednosti (*Eigenvalues*), Vilkove lambde, kao i matrice konfuzije. U Tabeli 33, prikazane su log determinante (**Log determinants**). Variraju u rang od -4.032 do 4.180 za model predikcije godinu dana unapred, odnosno od -3.389 do -3.426 za model predikcije dve godine unapred. Pravilo je da vrednosti ovih determinanti treba da budu jednake (Shanthi, 2019, str. 265) ili približno jednake, što u konkretnoj analizi i jeste slučaj – za oba modela.

Tabela 33: Log determinante za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Log Determinants		
Status	Rank	Log Determinant
Y-1		
0	3	-4.032
1	3	-4.180
Pooled within-groups	3	-4.066
Y-2		
0	2	-3.389
1	2	-3.426
Pooled within-groups	2	-3.367
The ranks and natural logarithms of determinants printed are those of the group covariance matrices.		

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati Boks-ovog M testa (**Box's M** test), prikazani su u Tabeli 34. Rezultat testa za model predikcije stečaja godinu dana unapred (Y-1) iznosi 8.377 ($F=1.375$), što nije statistički signifikantno za $p = 0.221$ ($p > 0.001$), jer se niža p vrednost predlaže zbog velike osetljivosti testa (Ho, 2013, str. 362), te se zaključuje da pretpostavka jednakosti kovarijanse matrice nije prekršena. Do istog zaključka se dolazi za rezultate Boks-ovog testa za model predikcije stečaja dve godine unapred (Y-2), gde je rezultat testa 8.392 ($F=2.768$), uz $p = 0.040$ ($p > 0.001$). Sa druge strane, Hair (2010) sugerise da bi vrednost testa trebalo biti viša od 0.01; to je takođe zadovoljeno razvijenim modelom.

Tabela 34: Boks-ov M test (*Box's M*) za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Test Results		Y-1	Y-2
Box's M		8.377	8.392
F	Approx.	1.375	2.768
	df1	6	3
	df2	319516.981	7938000.000
	Sig.	0.221	0.040

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultat sopstvenih vrednosti (*Eigenvalues*) je prikazan u Tabeli 35. Pravilo je da što je veća pojedinačna vrednost, bolje je objašnjena varijansa zavisne varijable razvijenom diskriminantnom funkcijom. Kanonska korelacija (*Canonical Correlation*) za model predikcije stečaja godinu dana unapred iznosi 0.680, dok za model predikcije stečaja dve godine unapred iznosi 0.509, i u oba slučaja je veća od kriterijuma 0,5 koji signalizira jaku vezu (Meyers, Gamst i Guarino, 2006, str. 271). Rezultati sopstvenih vrednosti se mogu protumačiti i na sledeći način (Ho, 2013, str. 363): diskriminantna funkcija za predikciju stečaja godinu dana unapred objašnjava 46% varijanse zavisne varijable, dok diskriminantna funkcija za predikciju stečaja dve godine unapred objašnjava 26% varijanse zavisne varijable²⁷.

Tabela 35: Sopstvene vrednosti (*Eigenvalues*) za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Eigenvalues				
Function	Eigenvalue	% of Variance	Cumulative %	Canonical Correlation
Y-1				
1	.858 ^a	100.0	100.0	0.680
Y-2				
1	.350 ^a	100.0	100.0	0.509
a. First 1 canonical discriminant functions were used in the analysis.				

Izvor: Kalkulacija autora na osnovu SPSS-a

Indikator Vilksove lambde (*Wilks' Lambda*) je prikazan u Tabeli 36, a isti testira značaj sopstvenih vrednosti (*Eigenvalues*). Vrednost ovog indikatora je 0.538 i 0.741 za model predikcije stečaja godinu dana i dve godine pre pokretanja postupka respektivno, sa p

²⁷ Koeficijent determinacije se dobija kvadriranjem kanonske korelacije (r_c), tako da vrednost za Y-1 iznosi $0,680^2=0,4624$, što kada se pomnoži sa 100% daje rezultat 46,24%. Isti postupak važi i za Y-2 rezultat.

vrednošću 0,000 ($<0,05$), što dalje implicira da razvijena diskriminantna funkcija dobro objašnjava varijacije u zavisnoj varijabli.

Tabela 36: Vilksova Lambda (*Wilks' Lambda*) za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Wilks' Lambda				
Test of Function(s)	Wilks' Lambda	Chi-square	df	Sig.
Y-1				
1	0.538	129.193	3	0.000
Y-2				
1	0.741	62.664	2	0.000

Izvor: Kalkulacija autora na osnovu SPSS-a

Poslednji korak u testiranju preciznosti i predviđačke moći modela, jeste klasifikaciona matrica, odnosno matrica konfuzije (*Classification Matrix / Confusion Matrix*) i ona je prikazana u Tabeli 37.

Tabela 37: Matrica za modele predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Classification Results					
Status			Predicted Group Membership		Total
			0	1	
Y-1					
Original	Count	0	85	21	106
		1	19	87	106
	%	0	80.2	19.8	100.0
		1	17.9	82.1	100.0
Cross-validated	Count	0	83	23	106
		1	19	87	106
	%	0	78.3	21.7	100.0
		1	17.9	82.1	100.0
Y-2					
Status			Predicted Group Membership		Total
			0	1	
Original	Count	0	74	32	106
		1	30	76	106
	%	0	69.8	30.2	100.0
		1	28.3	71.7	100.0
Cross-validated	Count	0	74	32	106
		1	30	76	106
	%	0	69.8	30.2	100.0
		1	28.3	71.7	100.0

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati matrice konfuzije za model predikcije stečaja godinu dana unapred (Y-1) pre pokretanja postupka, ukazuju na ukupnu tačnost (**Accuracy**) 81.1% za trening, odnosno 80.2% za unakrsnu validaciju. Pokazatelj Preciznost (**Precision**) iznosi 80.2% za trening, odnosno 78.3% za unakrsnu validaciju. Specifičnost (**Specificity**) modela je 80.6% za trening, odnosno 79.1% za unakrsnu validaciju. Senzitivnost (**Sensitivity**) modela je 81.7% za trening, odnosno 81.4% za unakrsnu validaciju. Na kraju, F1 rezultat (**F1-Score**) za model je 81.0% kod trening podataka, a 79.8% kod unakrsne validacije.

Rezultati matrice konfuzije za model predikcije stečaja dve godine unapred (Y-2) pre pokretanja postupka, ukazuju na ukupnu tačnost (**Accuracy**) 70.8% za trening i 70.8% za unakrsnu validaciju. Pokazatelj Preciznost (**Precision**) iznosi 69.8% za trening i 69.8% za unakrsnu validaciju. Specifičnost (**Specificity**) modela je 70.4% za trening i 70.4% za unakrsnu validaciju. Senzitivnost (**Sensitivity**) modela je 71.2% za trening i 71.2% za unakrsnu validaciju. Na kraju, F1 rezultat (**F1-Score**) za model je 70.5% kod trening podataka i 70.5% kod unakrsne validacije.

6.3. Kreiranje modela na bazi tehnika mašinskog učenja

Modeli mašinskog učenja na osnovu kojih će se raditi predikcija stečaja su: neuronske mreže (NN), stabla odlučivanja (DT) i k-najbližih suseda (KNN).

6.3.1. Neuronska mreža (NN)

Kod neuronskih mreža, varijable će biti standardizovane, a pre samog modelovanja, biće izvršena dodatna redukcija dimenzionalnosti putem tehnike analize ključnih komponenti (*Principal Components Analysis*). Model će nakon generisanja biti testiran preko površine ispod krive - AUC (*Area Under the Curve*), ROC (*Receiver Operator Characteristic*) krive i klasifikacione matrice/matrice konfuzije (*Classification Matrix / Confusion Matrix*). Klasifikaciona matrica je već objašnjena u Poglavlju 5.5, kao opšti test koji se sprovodi kod svih tehnika. ROC kriva omogućava vizuelizaciju ponašanja modela. Najčešće se koristi kao alat za evaluaciju binarnih, klasifikacionih, problema, kako pokazuje odnos između specifičnosti i senzitivnosti modela (Klepáč & Hampel, 2018). Parametar AUC se odnosi na indeks koji objašnjava ROC krivu.

6.3.1.1. Kreiranje modela

Pre samog treniranja neuronske mreže, urađena je faktorska analiza, odnosno analiza ključnih komponenti – PCA (*Principal Components Analysis*). Ovo je jedna od najčešće korišćenih tehnika za umanjenje dimenzionalnosti (Burkov, 2019, str. 118). Da bi se proverilo jesu li su podaci adekvatni za PCA, sprovedena su dva testa: Kasier-Mejer-Olkin test adekvatnosti (*Kasier-Meyer-Olkin*, KMO), kao i Bartletov test sferičnosti (*Bartlet's Test of Sphericity*, BTS). KMO meri adekvatnost uzorkovanja za svaku varijablu u modelu, kao i za celokupni model. Rezultat ovog testa su vrednosti koje variraju u rang 0-1. Veće vrednosti ukazuju na veću prikladnost za PCA. Visoke vrednosti KMO testa ukazuju na to da su korelacije između parova varijabli objašnjene dobro drugim varijablama, dok niske vrednosti ovog testa signaliziraju da PCA nije dobra ideja, kako korelacije između varijabli nisu dobro objašnjene drugim varijablama

(Pallant, 2009, str. 184). BTS ukazuje na to da li postoji adekvatnost matrice korelacije, odnosno ovaj test procenjuje da li su varijable nenormativno međusobno nezavisne (Ho, 2013, str. 255). Podaci se smatraju pogodnim za PCA ukoliko KMO test prelazi ili je jednak vrednosti 0,6 (Pallant, 2009, str. 191), odnosno ukoliko BTS ima signifikantnost manju od 0,05 (Pallant, 2009, str. 191; Ho, 2013, str. 255). Dodatno, vrednosti KMO iznad 0,5 smatraju se adekvatnim (Hair, 1998).

Tabela 38: KMO i Bartlett-ov test za varijable koje se koriste u modelovanju predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka


KMO and Bartlett's Test			
		Y-1	Y-2
Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		0.607	0.659
Bartlett's Test of Sphericity	Approx. Chi-Square	1918.351	1612.235
	df	378	136
	Sig.	0.000	0.000

Izvor: *Kalkulacija autora na osnovu SPSS-a*

U Tabeli 38, prikazani su KMO i BTS testovi za Y-1 i Y-2 varijable modela. Rezultati analize podataka za generisanje modela predikcije stečaja godinu dana unapred, ukazuju na to da su podaci pogodni za PCA; vrednost KMO testa je 0,61 ($\geq 0,50$), dok je vrednost BTS 1918,351 uz signifikantnost (Sig.) $p = 0,000$ ($< 0,05$). Rezultati analize podataka za generisanje modela predikcije stečaja dve godine unapred, ukazuju na to da su podaci pogodni za PCA; vrednost KMO testa je 0,66 ($\geq 0,50$), dok je vrednost BTS 1612,235 uz signifikantnost (Sig.) $p = 0,000$ ($< 0,05$).

Na slikama 25 i 26, prikazan je dijagram prevoja (*Scree plot*) za modele predikcije stečaja godinu dana i dve godine unapred. Ovaj dijagram se koristi u cilju identifikovanja optimalnog broja faktora. Na x-osi se nalazi broj faktora, dok se sopstvene vrednosti (*Eigenvalues*) nalaze na y-osi. Pravilo je da se faktori izdvajaju sve dok je linija strma. Prema definiciji, samo faktori sa parametrom *eigenvalues* iznad 1 se tretiraju značajnim. Sopstvena vrednost iznad 1 ukazuje na to da komponenta, odnosno faktor, objašnjava više varijanse nego što bi jedna unikatna varijabla objašnjavala (Ho, 2013, str. 241; Hair i dr, 2010).


Slika 25: „Scree plot” grafikon za model predikcije stečaja godinu dana pre pokretanja postupka (Y-1)



Izvor: Vizuelizacija autora, SPSS program

Kod modela predikcije stečaja godinu dana unapred (Y-1), na bazi pravila sopstvenih vrednosti koje su veće od jedan (*Eigenvalues*), izdvojeno je 10 faktora, što se može uočiti na slici 25.

Slika 26: „Scree plot” grafikon za model predikcije stečaja dve godine pre pokretanja postupka (Y-2)



Izvor: Vizuelizacija autora, SPSS program

Kod modela predikcije stečaja dve godine unapred (Y-2), na bazi pravila sopstvenih vrednosti koje su veće od jedan (*Eigenvalues*), izdvojeno je 5 faktora, što se može uočiti na Slici 26. U nastavku, prikazani su rezultati analize sa faktorima i procentom u kojem objašnjavaju varijansu zavisne varijable.

Tabela 39: Faktorska analiza (PCA) za model predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Component	Total Variance Explained (Y-1)								
	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	4.146	14.807	14.807	4.146	14.807	14.807	2.919	10.427	10.427
2	2.791	9.970	24.776	2.791	9.970	24.776	2.610	9.320	19.746
3	2.216	7.913	32.689	2.216	7.913	32.689	2.202	7.865	27.611
4	1.883	6.724	39.413	1.883	6.724	39.413	2.033	7.261	34.872
5	1.531	5.470	44.883	1.531	5.470	44.883	2.003	7.153	42.025
6	1.456	5.201	50.084	1.456	5.201	50.084	1.765	6.303	48.328
7	1.341	4.791	54.875	1.341	4.791	54.875	1.596	5.698	54.027
8	1.115	3.983	58.858	1.115	3.983	58.858	1.220	4.357	58.384
9	1.084	3.872	62.730	1.084	3.872	62.730	1.182	4.222	62.606
10	1.014	3.621	66.351	1.014	3.621	66.351	1.049	3.745	66.351
11	0.991	3.540	69.891						
12	0.972	3.470	73.360						
13	0.922	3.292	76.652						
14	0.842	3.008	79.661						
15	0.811	2.896	82.557						
16	0.730	2.607	85.164						
17	0.614	2.195	87.358						
18	0.528	1.886	89.244						
19	0.495	1.768	91.011						
20	0.449	1.605	92.616						
21	0.395	1.410	94.026						
22	0.333	1.189	95.216						
23	0.317	1.133	96.349						
24	0.274	0.978	97.327						
25	0.233	0.833	98.160						
26	0.202	0.720	98.880						
27	0.191	0.683	99.563						
28	0.122	0.437	100.000						
Extraction Method: Principal Component Analysis.									

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati PCA za varijable koje se koriste u modelovanju predikcije stečaja godinu dana unapred, prikazani su u Tabeli 39. Ekstrakovanih 10 faktora objašnjava čak 66.35% varijanse zavisne varijable kumulativno gledano.

Tabela 40: Faktorska analiza (PCA) za model predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Component	Total Variance Explained (Y-2)								
	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	4.150	24.412	24.412	4.150	24.412	24.412	3.229	18.992	18.992
2	2.528	14.868	39.280	2.528	14.868	39.280	2.610	15.356	34.348
3	1.617	9.512	48.792	1.617	9.512	48.792	2.077	12.215	46.564
4	1.583	9.311	58.103	1.583	9.311	58.103	1.740	10.235	56.798
5	1.103	6.489	64.592	1.103	6.489	64.592	1.325	7.794	64.592
6	0.974	5.729	70.321						
7	0.913	5.372	75.694						
8	0.820	4.824	80.517						
9	0.727	4.279	84.796						
10	0.651	3.829	88.625						
11	0.639	3.758	92.383						
12	0.364	2.142	94.525						
13	0.306	1.798	96.324						
14	0.227	1.335	97.659						
15	0.148	0.872	98.530						
16	0.139	0.820	99.350						
17	0.110	0.650	100.000						

Extraction Method: Principal Component Analysis.

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati PCA za varijable koje se koriste u modelovanju predikcije stečaja dve godine unapred, prikazani su u Tabeli 40. Ekstrakovanih 5 faktora objašnjava čak 64.59% varijanse zavisne varijable kumulativno gledano.

Dalje, izvršena je **rotacija faktora**, jer je to neophodan korak za lakšu interpretaciju. Dok rotacija ne može da izmeni osnovne aspekte analize, ista značajno uprošćava i razjašnjava strukturu (Costello, 2009). Rotacija može biti ortogonalna, poznata i kao Varimaksova (*Varimax*) i ne-ortogonalna, poznata i kao oblično rotiranje (*Oblique*). Konvencionalno mišljenje je da, ukoliko je cilj istraživača da umani dimenzionalnost kod nezavisnih varijabli na upravljive mere, bez obzira na to koliko će smisleni biti sami faktori, preporučuje se upotreba *Varimax* principa (Ho, 2013, str. 243). Upravo prethodno pomenuto i jeste cilj: ekstrakovanje ključnih nezavisnih varijabli za modelovanje, a ne samih faktora koji bi krajnjim korisnicima rezultata istraživanja otežali tumačenje.

Rezultati rotacije za modelovanje predikcije godinu dana unapred se nalaze u Tabeli 41, dok se rezultati za modelovanje dve godine unapred nalaze u Tabeli 42. U skladu sa teorijskim stanovištem (Hair i dr, 2010), faktori iznad 0,5 smatraju se značajnim. Za uspešnu primenu, vrednost od 0,3 smatra se niskom, dok su vrednosti od 0,5 ili 0,6 mnogo korisnije u analizi (Rencher, 2002, str. 438). U skladu sa prethodno navedenim teorijskim uporištem, ali i brojnim drugim istraživačima koji su koristili PCA (Huang i dr, 2014; Bandara i dr, 2016, itd.), u rotiranoj matrici su zadržane sve varijable sa vrednostima > 0,6, odnosno isključene su one koje su ispod te vrednosti.

Tabela 41: Faktorska analiza (PCA) - rotirana matrica za model predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Rotated Component Matrix (Y-1) ^a										
Variables	Component									
	1	2	3	4	5	6	7	8	9	10
TEG	0.860									
NIG	0.745									
TAG	0.703									
IETA	-0.681									
QR		0.827								
RER		0.720								
Ln_CACL		0.687								
CFNID										
CFTL										
OITA			0.792							
TDTA			0.759							
ROA			0.685							
LTLCA				0.891						
IETR				0.882						
OEOI					-0.754					
OCF					0.743					
TITE										
CS						-0.782				
Ln_S						0.753				
OBSCTA							0.865			
SATA							0.865			
CRR								0.770		
NSTA										
EBITInt									-0.680	
HC										
OCFCL										
NCI										0.754
INVWC										
Extraction Method: Principal Component Analysis. Rotation Method: Varimax with Kaiser Normalization. ^a										
a. Rotation converged in 7 iterations.										

Izvor: Kalkulacija autora na osnovu SPSS-a

Kod predikcije stečaja godinu dana unapred, 21 varijabla se kvalifikovala za dalje modelovanje, što se može zaključiti po vrednostima faktora iz Tabele 41.

Tabela 42: Faktorska analiza (PCA) – rotirana matrica za model predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Rotated Component Matrix (Y-2)^a					
Variables	Component				
	1	2	3	4	5
OEOI	0.851				
OCFS	0.818				
IEBD	-0.808				
CS	0.793				
CAS					
CAPA		0.842			
Ln_CACL		0.813			
RER		0.801			
CFNID		0.606			
IETA			0.911		
IETR			0.879		
Log_SINV				0.728	
CCL				0.716	
SATA					
EBITInt					0.686
TITE					
TEG					
Extraction Method: Principal Component Analysis. Rotation Method: Varimax with Kaiser Normalization. ^a a. Rotation converged in 5 iterations.					

Izvor: *Kalkulacija autora na osnovu SPSS-a*

Kod predikcije stečaja dve godine unapred, 13 varijabli se kvalifikovalo za dalje modelovanje, što se može zaključiti po vrednostima faktora iz Tabele 42. Nakon što je izvršena redukcija dimenzionalnosti nezavisnih varijabli putem PCA tehnike, pristupa se daljem modelovanju, odnosno treniranju i testiranju neuronskih mreža. Osnovni podaci o podeli uzorka su dati u Tabeli 43.

Tabela 43: Osnovne informacije o podeli uzorka za NN modelovanje predikcije stečaja godinu i dve pre pokretanja postupka

Case Processing Summary (Y-1) & (Y-2)				
Items			N	Percent
Sample	Training		166	78.3%
	Testing		46	21.7%
Valid			212	100.0%
Excluded			0	
Total			212	

Izvor: *Autor, SPSS program*

Shodno teorijskim pretpostavkama (Theobald, 2021, str. 47), uzorak je podeljen po principu 80:20, što znači da se 80% podataka se koristi za treniranje neuronske mreže, dok se 20% koristi za testiranje performansi iste. Stoga, 166 MSP je korišćeno za

treniranje neuronske mreže, dok je 46 MSP korišćeno za testiranje. U Tabeli 44, date su osnovne **informacije o hiperparametrima** razvijenih neuronskih mreža za predikciju stečaja godinu dana unapred (levo – Y-1) i dve godine unapred (desno – Y-2).

Tabela 44: Osnovne informacije o postavkama neuronske mreže za model predikcije stečaja godinu dana unapred (levo) i dve godine unapred (desno)

Network Information (Y-1)			
Input Layer	Covariates	1	ROA
		2	RER
		3	QR
		4	TDTA
		5	EBITInt
		6	OITA
		7	NCI
		8	OCF
		9	OEOI
		10	CRR
		11	IETR
		12	CS
		13	NIG
		14	TAG
		15	TEG
		16	Ln_S
		17	Ln_CACL
		18	LTLCA
		19	OBSCTA
		20	SATA
		21	IETA
Number of Units ^a		21	
Rescaling Method for Covariates		Standardized	
Hidden Layer(s)	Number of Hidden Layers		2
	Number of Units in Hidden Layer 1 ^a		6
	Number of Units in Hidden Layer 2 ^a		5
	Activation Function		Sigmoid
Output Layer	Dependent Variables	1	Status
	Number of Units		2
	Activation Function		Softmax
	Error Function		Cross-entropy
a. Excluding the bias unit			

Network Information (Y-2)					
Input Layer	Covariates	1	RER		
		2	EBITInt		
		3	OCFS		
		4	CCL		
		5	CAPA		
		6	CFNID		
		7	OEOI		
		8	Log_SINV		
		9	IEBD		
		10	IETR		
		11	CS		
		12	Ln_CACL		
		13	IETA		
		Number of Units ^a		13	
		Rescaling Method for Covariates		Standardized	
Hidden Layer(s)	Number of Hidden Layers		2		
	Number of Units in Hidden Layer 1 ^a		8		
	Number of Units in Hidden Layer 2 ^a		6		
	Activation Function		Sigmoid		
Output Layer	Dependent Variables	1	Status		
	Number of Units		2		
	Activation Function		Softmax		
	Error Function		Cross-entropy		
a. Excluding the bias unit					

Izvor: Autor, SPSS program

Kao što je već pomenuto, sve varijable su pred modelovanje normalizovane po sledećem metodu (Murray, 2023):

$$[x - \text{srednja vrednost}(x)] / \text{standardna devijacija}(x)$$

Neuronske mreže za oba modela (Y-1 i Y-2) imaju dva skrivena sloja (*Hidden layers*) u skladu sa preporukama brojnih autora (Panchal i dr, 2011; Karsoliya, 2012; Gupta i Raza, 2020; itd). Kada je reč o aktivacionim funkcijama, ne postoji jasno pravilo koje bi ukazalo na to koja se i kada koristi. Međutim, u skladu sa činjenicom da su na treningu dale najbolje rezultate, kao i preporukama drugih autora, sledeće aktivacione funkcije su korišćene u oba modela (Y-1 i Y-2):

- Sigmoidna – u skrivenim (*Hidden layers*) slojevima (Naidu i Govinda, 2018; Anandarajan i dr, 2001) i
- Softmax – u izlaznim (*Output layers*) slojevima (Jencova i dr, 2021; Bhatia i Rangoonwala, 2020; Fialova i Folvarcna, 2020; Paule-Vianez, 2020).


Korišćen je algoritam spuštanja gradijenta (*gradient descent algorithm*) za optimizaciju (Bernard, 2021, str. 285) kao jedan od najčešće korišćenih koji parametre ažurira u model iterativno. Inicijalna stopa učenja (*Learning rate*), podešena je na 0,001 (Brenes i dr, 2022; Jan, 2021), dok je momenat (*Momentum*) podešen na nivo 0,9 (Lahmiri i Bekiros, 2019; Ahmadpour Kasgari i dr, 2013), u skladu sa postojećom literaturom, ali i kao posledica činjenice da su ovi parametri dali najbolje rezultate. Odabrana je tehnika (Iyer i Vinod, 2015; Chakraborty, 2005) treniranja u grupama (*Batch training*). Ovo je najpogodnija tehnika za male uzorke, jer minimizira ukupnu grešku. Trening je sproveden u 10.000 epoha (Back i dr, 1995). Sve prethodno pomenute postavke hiperparametara važe za oba modela: za predikciju stečaja godinu dana (Y-1) i dve godine unapred (Y-2). Osnovni rezultati treninga i testiranja neuronskih mreža su predstavljeni u Tabeli 45, a u nastavku će biti detaljno objašnjeni.

Tabela 45: Osnovne informacije o treniranju i testiranju neuronskih mreža za model predikcije stečaja godinu dana (Y-1) i dve godine unapred (Y-2)

Model Summary			
Sample	Parameters	Y-1	Y-2
Training	Cross Entropy Error	44.500	82.447
	Percent Incorrect Predictions	9.6%	24.1%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00.07	0:00:00.14
Testing	Cross Entropy Error	17.316	22.155
	Percent Incorrect Predictions	10.9%	26.1%
Dependent Variable: Status			
a. Error computations are based on the testing sample.			


Izvor: Autor, SPSS program

Slika 27: Vizuelni prikaz neuronske mreže za predikciju stečaja godinu dana pre pokretanja postupka (Y-1)



Izvor: Vizuelizacija autora, SPSS program

Slika 28: Vizuelni prikaz neuronske mreže za predikciju stečaja dve godine pre pokretanja postupka (Y-2)




Izvor: Vizuelizacija autora, SPSS program

Vizuelna prezentacija neuronskih mreža, dostupna je na slikama 27 i 28. Veze između neurona su prikazane u različitim bojama i debljinama samih linija. Plave veze ukazuju na to da su težišni koeficijenti (*Weights*) između datih varijabli manji od nule, dok konekcije u vidu sive linije ukazuju na to da su težišni koeficijenti (*Weights*) veći od nule. Ukoliko je veza (linija) deblja, vrednosti koeficijenata su brojevi udaljeniji od nule i obrnuto u slučaju tanjih veza (Kušter i dr, 2023, str. 11). Parametri obe neuronske mreže, dostupni su u Prilogu 4 i Prilogu 5.

Na slici 29, prikazan je normalizovan značaj varijabli u razvijenom modelu predikcije stečaja godinu dana unapred. Čak 7 varijabli ima značaj preko 80% u predikciji stečaja (TDTA, OEOI, NCI, OBSCTA, IETR, TEG i TAG).

Slika 29: Varijable od značaja za predikciju stečaja godinu dana pre pokretanja postupka (Y-1)



Izvor: Vizuelizacija autora, SPSS program

Dakle, rezultati ukazuju da kod predikcije stečaja godinu dana unapred, MSP treba da obrate pažnju na odnos duga i ukupne aktive (TDTA). Ovaj indikator pokazuje stepen u kojem se entitet oslanja na eksterne izvore finansiranja u svom poslovanju (Vuković i dr, 2020). Razvijeni NN model ukazuje na to da odluka MSP o stepenu u kojem će svoju aktivu da finansira zaduživanjem, u velikoj meri može da predodredi sudbinu samog entiteta. Ukoliko se MSP u velikoj meri zadužuju, srazmerno povećavaju rizik insolventnosti, jer se MSP često suočavaju sa ograničenim resursima i manjom fleksibilnošću u poređenju sa velikim preduzećima, koja lakše apsorbuju tržišne šokove. Sa druge strane, ukoliko se previše oslanja na sopstveni kapital, MSP ograničava svoj dalji napredak – razvoj i rast. Donošenje odluke o načinu i strukturi finansiranja ne utiče samo na finansijski položaj MSP, već i na njegovu rezilijentnost u dinamičnom okruženju.

Zatim, odnos poslovnih (operativnih) prihoda i rashoda (OEOI), takođe je značajan u predikciji stečaja godinu dana unapred. Efikasnost upravljanja poslovnim rashodima je

ključna za prosperitet i dalji održivi razvoj MSP. Ona preduzeća koja na vreme ne uspostave funkcije kontrole i praćenja troškova, postepeno gube finansijsku efikasnost, kontinuirano se susreću sa gubicima i iscrpljuju svoj kapital, a na kraju puta, mogu se naći u poziciji nemogućnosti servisiranja svojih obaveza. Finansijski efikasna MSP, sa druge strane, imaju veću otpornost na fluktuacije i izazove koje pred njih postavlja tržište, pa se verovatnoća finansijskog kolapsa, te stečaja, značajno umanjuje.

Bes kreditni interval (NCI) je od strane algoritma, takođe identifikovan kao značajni prediktor stečaja godinu dana unapred. Bes kreditni interval signalizira koliko dugo bi preduzeće moglo da opstane i vodi poslovne operacije ukoliko bude koristilo samo svoja likvidna sredstva, bez dodatnog finansiranja (Taffler, 1983). Preduzeća koja mogu da opstanu duže upotrebom samo svojih likvidnih sredstava, smatraju se finansijski otpornim. Zaključuje se da od odluke preduzeća o tome da li će kontrolisano i planski koristiti likvidna sredstva, te manje biti zavisno od eksternih izvora finansiranja, zavisi da li će samo preduzeće opstati u konkurentskoj trii ili će pak zapasti u finansijske poteškoće. Izazov održavanja likvidnosti je prisutan pogotovo kod MSP, jer ona nemaju adekvatan pristup povoljnim izvorima finansiranja. Kako MSP čine značajan deo privrede Srbije, mora se voditi računa o strateškom upravljanju likvidnim sredstvima sa ciljem obezbeđenja održivosti poslovanja u oštroj konkurenciji.


Odnos vanbilansne pasive i aktive (OBSCTA) je retko korišćen faktor među istraživačima, što se može zaključiti uvidom u Tabelu 9 (Poglavlje 5.4), gde je detaljnim pregledom literature na temu predikcije stečaja identifikovano samo dva autora (Swicegood & Clark, 2001; Cleary & Hebb, 2015). Međutim, kod MSP, algoritam neuronskih mreža je ukazao na to da odnos vanbilansne pasive i aktive preduzeća ima značaj za predikciju stečaja godinu dana unapred. Ovaj racio meri odnos obaveza koje nisu izražene u bilansu stanja naspram ukupne aktive (Swicegood & Clark, 2001; Cleary & Hebb, 2015). Visoki nivoi vanbilansne pasive mogu da signaliziraju da preduzeće ima bitne rizike koji su skriveni. Iako nisu iskazane u bilansu, ove obaveze mogu da imaju značajan uticaj na finansijsku stabilnost entiteta ukoliko se aktiviraju. Poslovnim partnerima visok nivo vanbilansne pasive naspram aktive može biti signal većeg poslovnog rizika MSP, te odluka o saradnji sa takvim preduzećima treba da se donese pažljivo, a poslovanje preduzeća treba dodatno ispitati analizom *Napomena uz finansijske izveštaje*. Sa druge strane, finansijska analiza koja obuhvata detaljnu procenu, te razumevanje vanbilansnih obaveza, ključna je za vlasnike MSP, jer ista pomaže da se razume skriveni rizik kojem je entitet izložen, te se posledično umanjuje mogućnost pokretanja stečajnog postupka. Dakle, visoki nivoi vanbilansne pasive, odnosno onih obaveza koje nisu prikazane u bilansu stanja (garancije, obaveze prema ugovorima...) su problematični kod MSP, jer predstavljaju skriveni rizik. Ovaj vid obaveza može značajno da ugrozi poslovanje i likvidnost MSP ukoliko se aktiviraju, a MSP za razliku od velikih kompanija nemaju pristup dodatnim izvorima finansiranja, stoga je važno posmatrati odnos vanbilansne pasive i ukupno raspoloživih sredstava.

Odnos rashoda kamata i ukupnog prihoda (IETR), takođe je pokazao veliki značaj u predikciji stečaja godinu dana unapred. Upravljanje rashodima kamata je od suštinskog značaja, jer usled naglog smanjenja prihoda, preduzeće može da se suoči sa problemom održavanja likvidnosti. Veliko opterećenje prihoda kamatama ukazuje da je preduzeće podložnije riziku. Kada se MSP suoči sa problemom da ne može pokriti rashode kamata upotrebom svojih prihoda, tada može biti prisiljeno da se dodatno eksterno zadužuje ili koristi rezerve. Sve prethodno rečeno značajno povećava šansu za nastanak finansijskih

problema, koji mogu odvesti MSP na prag stečaja. Adekvatna kontrola i praćenje zaduživanja, te kamata u ukupnom prihodu MSP, ključni su za razumevanje finansijskog zdravlja, te održiv rast i razvoj samog preduzeća.

Na kraju, od velikog značaja za predikciju stečaja jeste i trend, odnosno promene u kapitalu i ukupnoj aktivi (TEG i TAG). Racio rasta kapitala ukazuje kako se kreće kapital preduzeća u rasponu od dve godine; isto važi i za pokazatelj rasta aktive. Odnosno, ukazuju na brzinu ekspanzije pomenutih kategorija (Ming i dr, 2013; Iqbal i Saeed, 2023). Rast kapitala i aktive se može tumačiti različito, zavisno od toga da li se radi o pozitivnom ili negativnom trendu. Pozitivan rast aktive i kapitala može biti signal stabilnog poslovanja MSP, pogotovo kada je reč o održivom rastu kada preduzeće generiše dobit koju zadržava, te investira za svoj dalji rast i razvoj. Ukoliko MSP ima negativan rast kapitala i aktive, to može da bude prvi indikator poteškoća u poslovanju. Pad kapitala može da signalizira povlačenje samog kapitala ili gubitke, a sa druge strane pad aktive može biti posledica umanjenja poslovne efikasnosti ili pak prodaje same imovine. Kapital koji raste brže nego aktiva, ukazuje na to da postoji čvrsta finansijska kontrola i da se dobit u poslovanju zadržava. Prethodno rečeno je pozitivna karakteristika poslovanja MSP, jer entitet u tom slučaju povećava svoju bazu bez da se preterano zadužuje. Druga strana medalje jeste situacija gde aktiva MSP raste brže od kapitala preduzeća, jer to ukazuje da potencijalno preduzeće gravitira ka zaduživanju, a ako preduzeće ne upravlja dobro svojim dugovima, rezultat može da se ogleda u finansijskim poteškoćama. Kada se govori o kvalitetu rasta, bitno je da li je porast kapitala MSP uzrokovan ili emisijom akcija ili zadržanom dobiti. Zadržana dobit je uvek bolji pokazatelj zdravlja poslovanja. Takođe, ako je rast aktive vođen rastom potraživanja, daleko je manje održiv od rasta koji je nastao kao rezultat rasta gotovine. Pravovremeno praćenje rezultata vezano za rast kapitala i aktive, stejkholderima omogućava da donose prave odluke i bolje definišu strategije kojima će upravljati preduzećem.

Slika 30: Varijable od značaja za predikciju stečaja dve godine pre pokretanja postupka (Y-2)



Izvor: Vizuelizacija autora, SPSS program

Kod predikcije stečaja dve godine unapred (Y-2), varijable upravljanja novčanim tokovima su dominantne (CFNID, OCFS, CCL i CS), ali značaj pokazuje i odnos operativnih rashoda i prihoda (OEIO), što je bio slučaj i kod predikcije stečaja godinu dana unapred (vidi Sliku 30). Besprekoran normalizovan značaj ima varijabla koja meri odnos neto rezultata iz *Izveštaja o novčanim tokovima* i ukupnog duga (CFNID). Visok neto rezultat iz *Izveštaja o novčanim tokovima* ukazuje da preduzeće upravlja dobro prilivima i odlivima, što dalje ukazuje na to da ono lakše može da finansira svoje dugove. Praćenje ovog odnosa je ključno, kako za eksterne stejkholdere, tako i za same vlasnike MSP, jer omogućava da se uoče prvi signali koji bi ukazali na to da preduzeće možda neće imati dovoljno slobodnih novčanih sredstava da pokrije svoje dugove.

6.3.1.2. Testiranje modela

U Tabeli 46, prikazani su rezultati matrice konfuzije za razvijene modele neuronskih mreža, kako za predikciju stečaja godinu dana unapred, tako i za predikciju stečaja dve godine unapred.

Tabela 46: Matrica konfuzije za model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Classification				
Sample		Predicted		
		0	1	Percent Correct
Y-1				
Training	0	74	9	89.2%
	1	7	76	91.6%
	Overall Percent	48.8%	51.2%	90.4%
Testing	0	20	3	87.0%
	1	2	21	91.3%
	Overall Percent	47.8%	52.2%	89.1%
Y-2				
Training	0	71	12	85.5%
	1	28	55	66.3%
	Overall Percent	59.6%	40.4%	75.9%
Testing	0	19	4	82.6%
	1	8	15	65.2%
	Overall Percent	58.7%	41.3%	73.9%

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati matrice konfuzije za model predikcije stečaja godinu dana unapred (Y-1) pre pokretanja postupka, ukazuju na ukupnu tačnost (**Accuracy**) 90,4% za trening, odnosno 89,1% za test skup podataka. Pokazatelj Preciznost (**Precision**) iznosi 89,2% za trening, odnosno 87,0% za test skup podataka. Specifičnost (**Specificity**) modela je 89,4% za trening, odnosno 87,5% za test skup. Senzitivnost (**Sensitivity**) modela je 91,4% za trening, odnosno 90,9% za test skup. Na kraju, F1 rezultat (**F1-Score**) za model je 90,2% kod trening podataka, a 88,9% kod test uzorka.

Rezultati matrice konfuzije za model predikcije stečaja dve godine unapred (Y-2) pre pokretanja postupka, ukazuju na ukupnu tačnost (**Accuracy**) 75,9% za trening, odnosno 73,9% za test skup podataka. Pokazatelj Preciznost (**Precision**) iznosi 85,5% za trening, odnosno 82,6% za test skup podataka. Specifičnost (**Specificity**) modela je 82,1% za trening, odnosno 78,9% za test skup. Senzitivnost (**Sensitivity**) modela je 71,7% za trening, odnosno 70,4% za test skup. Na kraju, F1 rezultat (**F1-Score**) za model je 78,0% kod trening podataka, a 76,0% kod test uzorka.

U Tabeli 47, prikazani su rezultati za AUC (*Area Under the Curve*) pokazatelj, kako za model predikcije stečaja godinu dana (Y-1), tako i za model predikcije dve godine unapred (Y-2).

Tabela 47: Površina ispod krive za model predikcije stečaja godinu dana i dve godine pre pokretanja postupka


Area Under the Curve		
		Area
Y-1		
Status	0	0.945
	1	0.945
Y-2		
Status	0	0.835
	1	0.835

Izvor: Kalkulacija autora na osnovu SPSS-a


Kao što je pomenuto u teorijskom delu, AUC pokazuje površinu ispod ROC krive. Vrednost AUC-a 0.5 bi značila da je model nasumični klasifikator, dok vrednost 1 ukazuje na savršenu klasifikacionu snagu modela, premda ista u praksi nije moguća.

Rezultati predikcije stečaja godinu dana unapred pokazuju izuzetno visok nivo AUC od čak 0.945, dok su AUC rezultati za model predikcije stečaja dve godine unapred nešto niži, ali takođe na odličnom nivou – 0.835. Uzevši u obzir teorijske osnove za tumačenje AUC pokazatelja (Hosmer i dr, 2013; Trifonova i Lokhov, 2014; Al-Milli i dr, 2021) može se zaključiti da je AUC rezultat za model predikcije stečaja godinu dana unapred u kategoriji *odličnih/izuzetnih* rezultata, dok je rezultat za model predikcije stečaja dve godine unapred u kategoriji *veoma dobrih* rezultata.

ROC krive, kako za model predikcije stečaja godinu dana unapred, tako i za predikciju dve godine unapred, prikazane su na slikama 31 i 32.

Slika 31: ROC kriva za model predikcije stečaja godinu dana unapred (Y-1)

Izvor: Vizuelizacija autora, SPSS program

Slika 32: ROC kriva za model predikcije stečaja dve godine unapred (Y-2)

Izvor: Vizuelizacija autora, SPSS program

6.3.2. Stablo odlučivanja (DT)

Poput prethodnih modela, tako i kod stabla odlučivanja, prvo će biti izvršeno kreiranje samih stabala za predikciju stečaja godinu dana i dve unapred, a zatim će ista biti testirana. Prilikom kreiranja samih stabala, biće korišćen CRT algoritam, kako je od strane više autora potvrđeno da isti ima odlične performanse kod predikcije stečaja (Chen, 2011; Gepp i Kumar, 2015; Abdelrahman i Abdel-Hady, 2011; itd.).

6.3.2.1. Kreiranje modela

Osnovni podaci o samim modelima, dati su u Tabeli 48 i to za model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) unapred.

Tabela 48: Sumarni pregled postavki modela stabla odlučivanja za predikciju stečaja godinu dana (Y-1) i dve godine (Y-2) unapred

Model Summary					
Y-1			Y-2		
Specifications	Growing Method	CRT	Growing Method	CRT	
	Dependent Variable	Status	Dependent Variable	Status	
	Independent Variables		Independent Variables		
		ROA, RER, QR, TDTA, EBITInt, OITA, OCFCL, NSTA, NCI, CFNID, OCF, OEOI, HC, CRR, IETR, INVWC, TITE, CS, NIG, TAG, TEG, Ln_S, Ln_CACL, LTLCA, CFTL, OBSCTA, SATA, IETA		M.B., RER, CAS, EBITInt, OCFS, CCL, CAPA, CFNID, OEOI, Log_SINV, IEBD, IETR, TITE, CS, TEG, Ln_CACL, SATA, IETA	


Model Summary			
Y-1		Y-2	
Validation	Cross Validation	Validation	Cross Validation
Maximum Tree Depth	5	Maximum Tree Depth	5
Minimum Cases in Parent Node	100	Minimum Cases in Parent Node	100
Minimum Cases in Child Node	50	Minimum Cases in Child Node	50
Independent Variables Included	TITE	Independent Variables Included	CFNID
Number of Nodes	3	Number of Nodes	3
Number of Terminal Nodes	2	Number of Terminal Nodes	2
Depth	1	Depth	1

Izvor: Autor, SPSS program

Celokupan uzorak od 212 MSP je korišćen za kreiranje modela, dok je testiranje urađeno putem *10-fold* unakrsne validacije po preporukama drugih autora (Aktan, 2011, str. 60; Olson i dr, 2012, str. 465; Abdelrahman i Abdel-Hady, 2011, str. 434; itd.). Prema rečima Theobald (2021), stabla odlučivanja su podložna *overfitting*-u u procesu treniranja, što može dovesti do kasnijeg neuspeha u klasifikaciji novih podataka. Male promene u načinu kako je podeljen trening i test uzorak, mogu u velikoj meri izmeniti finalnu predikciju, te kreirati potpuno drugačije drvo (str. 123). U skladu sa prethodno rečenim, rađena je napredna validacija, bez izdvojenog trening skupa.

Dakle, set podataka je nasumično izdijeljen na 10 pod-uzorka, na kojima je testiran razvijeni model. Konačno stablo odlučivanja za predikciju stečaja godinu dana unapred koje je generisano putem CRT algoritma, prikazano je na Slici 33.

Slika 33: Vizuelni prikaz stabla odlučivanja za predikciju stečaja godinu dana pre pokretanja postupka (Y-1)




Izvor: Vizuelizacija autora, SPSS program

U predikciji stečaja godinu dana unapred (Y-1) je značajna varijabla odnosa ukupnih prihoda i ukupnih rashoda (TITE), što je slučaj i kod logističke regresije i diskriminantne analize. Sva MSP koja imaju vrednost ovog pokazatelja iznad 1, sa verovatnoćom 81.2%, klasifikovana su kao solventna. Sa druge strane, sva MSP koja imaju vrednost ovog indikatora manju ili jednaku 1, sa verovatnoćom 88.4%, klasifikovana su kao preduzeća koja su pokrenula stečajni postupak nakon godinu dana. Iz prethodno rečenog sledi da je od izuzetne važnosti pravovremena i detaljna analiza ukupnih prihoda, ukupnih rashoda, strukture istih, kao i njihovog odnosa. Tačnije, značajno je održavanje ekonomičnosti, kako bi se obezbedila održivost poslovanja MSP. Ona MSP koja uspevaju da ostvare pozitivan rezultat kroz veće ukupne prihode poređeno sa ukupnim rashodima, uspevaju da pokrivaju svoje obaveze, čak i da reinvestiraju u svoj biznis. To ukazuje na manje šanse za pokretanje stečajnog postupka. Sa druge strane, ona MSP koja u kontinuitetu posluju sa negativnim rezultatom, mogu imati poteškoće u izvršavanju svojih obaveza, a takvi uslovi mogu dovesti do pokretanja stečajnog postupka. Važno je napomenuti da se vrednost ovog racio pokazatelja stavi u kontekst prilikom same analize. Ukoliko iz perioda u period ovaj pokazatelj mnogo fluktuira, to može signalizirati da postoje neke stihijske komponente u poslovanju MSP i da entitet nije u stanju da na adekvatan način upravlja tim komponentama. Dodatno, rezultate analize ovog racio pokazatelja je uvek poželjno staviti u vezu sa drugim faktorima koje su prethodno razvijeni modeli istakli kao značajne, kako bi se sa većom sigurnošću mogla predvideti sudbina preduzeća.

Konačno stablo odlučivanja za predikciju stečaja dve godine unapred koje je generisano putem CRT algoritma, prikazano je na Slici 34.

Slika 34: Vizuelni prikaz stabla odlučivanja za predikciju stečaja dve godine pre pokretanja postupka (Y-2)



Izvor: Vizuelizacija autora, SPSS program

U predikciji stečaja dve godine unapred (Y-2) je značajan odnos neto rezultata iz Izveštaja o novčanim tokovima i ukupnog duga (CFNID), što je slučaj i kod svih prethodno razvijenih modela: logističke regresije, diskriminantne analize i neuronskih mreža. Sva MSP koja imaju vrednost ovog pokazatelja manju ili jednaku 0.05, sa verovatnoćom 67.2%, klasifikovana su kao ona koja će pokrenuti stečajni postupak za dve godine. Sa druge strane, sva MSP koja imaju vrednost ovog indikatora veću od 0.05, sa verovatnoćom 81.3%, klasifikovana su kao solventni entiteti. Stoga, još jednim algoritmom, potvrđeno je da MSP koji žele da obezbede održivo poslovanje, moraju da uspostave redovnu kontrolu novčanih tokova.

6.3.2.2. Testiranje modela

Testiranje razvijenih stabala odlučivanja, izvršeno je putem klasifikacione tablice, odnosno matrice konfuzije (*Confusion Matrix*), kao i napredne validacije.

Tabela 49: Matrica konfuzije za modele predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Classification Matrix			
Y-1			
CRT			
Observed	Predicted		Percent Correct
	0	1	
0	84	22	79.20%
1	11	95	89.60%
Overall Percentage	44.80%	55.20%	84.40%
Y-2			
CRT			
Observed	Predicted		Percent Correct
	0	1	
0	92	14	86.80%
1	45	61	57.50%
Overall Percentage	64.60%	35.40%	72.20%

Izvor: Kalkulacija autora na osnovu SPSS-a

Rezultati matrice konfuzije (Tabela 49) za model predikcije stečaja godinu dana unapred (Y-1) pre pokretanja postupka, ukazuju kod trening skupa podataka na ukupnu tačnost (**Accuracy**) 84.4%. Pokazatelj Preciznost (**Precision**) iznosi 79.2%. Specifičnost (**Specificity**) modela je 81.2%. Senzitivnost (**Sensitivity**) modela je 88.4%. Na kraju, F1 rezultat (**F1-Score**) za model je 83.6%.

Rezultati matrice konfuzije za model predikcije stečaja dve godine unapred (Y-2) pre pokretanja postupka, ukazuju kod trening skupa podataka na ukupnu tačnost (**Accuracy**) 72.2%. Pokazatelj Preciznost (**Precision**) iznosi 86.8%. Specifičnost (**Specificity**) modela je 81.3%. Senzitivnost (**Sensitivity**) modela je 67.2%. Na kraju, F1 rezultat (**F1-Score**) za model je 75.7%.

Kao što je već napomenuto, celokupan uzorak je korišćen za razvoj modela, tako da je rezultat testiranja dostupan u Tabeli 50 kao procenat rizika, odnosno procenat greške za 10-fold validaciju. Kod predikcije stečaja godinu dana unapred, on iznosi 16.51%, dok kod predikcije stečaja dve godine unapred iznosi 30.66%. Drugim rečima, ukupna tačnost modela (**Accuracy**) predikcije stečaja godinu dana unapred kod 10-fold validacije je 83.5%, dok je ukupna tačnost modela predikcije stečaja dve godine unapred kod 10-fold validacije 69.3%.

Tabela 50: Rezultati napredne validacije za modele predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Risk		
Y-1		
METHOD	CRT	
	Estimate	Std. Error
Resubstitution	0.1557	0.0249
Cross-Validation	0.1651	0.0255
Y-2		
METHOD	CRT	
	Estimate	Std. Error
Resubstitution	0.2783	0.0308
Cross-Validation	0.3066	0.0317

Izvor: Kalkulacija autora na osnovu SPSS-a

6.3.3. K-najbližih suseda (kNN)

Po uzoru na prethodna poglavlja, prva etapa kod modelovanja na bazi k-NN algoritma biće kreiranje modela, dok će matrica konfuzije biti obuhvaćena u fazi testiranja.

6.3.3.1. Kreiranje modela

U Tabeli 51, date su osnovne informacije o podeli uzorka za modelovanje. Uzorak je podeljen prema 80:20 principu (Theobald, 2021, str. 47), tako da je 166 MSP upotrebljeno za razvoj (treniranje) modela, a 46 MSP korišćeno za testiranje modela.

Tabela 51: Osnovne informacije o podeli uzorka za kNN modelovanje predikcije stečaja godinu (Y-1) i dve (Y-2) pre pokretanja postupka

Case Processing Summary (Y-1 & Y-2)			
		N	Percent
Sample	Training	166	78.3%
	Holdout	46	21.7%
Valid		212	100.0%
Excluded		0	
Total		212	


Izvor: Autor, izvoz iz SPSS programa

Sve varijable (za oba modela: Y-1 i Y-2) su normalizovane po sledećem principu (Murray, 2023):

$$X_{normalized} = [x - \min(x)] / [\max(x) - \min(x)]$$


Prediktorski prostor (*Predictor Space*) za oba razvijena modela, prikazan je na Slikama 35 i 36.

Slika 35: Prediktorski prostor za KNN model predikcije stečaja godinu dana unapred (Y-1)



Izvor: Vizuelizacija autora, SPSS program

Slika 36: Prediktorski prostor za KNN model predikcije stečaja dve godine unapred (Y-2)




Izvor: Vizuelizacija autora, SPSS program

Prilikom modelovanja, “k” parametar je automatski podešen od strane programa na 9 za model predikcije stečaja godinu dana unapred (Y-1), te na 5 za model predikcije stečaja dve godine unapred (Y-2), a ovaj raspon je usklađen sa brojnim drugim autorima (Zhang, 2017; Gracia i dr, 2019; itd). Dodatno, činjenica da je “k” parametar neparan broj, umanjuje šansu da se dobije pogrešan rezultat (Theobald, 2021; Derelioğlu & Gürgen, 2011).

Kod oba modela je korišćena euklidska udaljenost (*Euclidean distance*), po uzoru na postojeću literaturu u oblasti predikcije stečaja (Chen i dr, 2011; Marchesini, 2020; itd.), a i kao posledica činjenica da je ova udaljenost često korišćena u praksi (Burkov, 2019, str. 34). Na slikama 37 i 38, prikazan je značaj varijabli u predikciji stečaja. Zbir svih značajnosti daje total od 100%.

Slika 37: Značaj varijabli za predikciju stečaja godinu dana unapred (Y-1)




Izvor: Vizuelizacija autora, SPSS program

Najveći nivo značajnosti (0.13/1.00) u predikciji stečaja godinu dana unapred ima normalizovana varijabla rasta ukupne aktive (S_TAG). Ova varijabla je, takođe, značajan prediktor i za logističku regresiju, ali i za neuronske mreže. Algoritam k-NN potvrđuje da je upravljanje aktivom ključno kod MSP, jer direktno utiče na mogućnost efektivnog i efikasnog korišćenja samih resursa. Promene ukupne aktive treba sa velikom pažnjom balansirati sa kretanjem troškova i prihoda, a sve u cilju obezbeđivanja održivog poslovanja. Naravno, pokazatelj rasta aktive se mora staviti u širi kontekst prilikom analize poslovanja. Stejholderima nagli rast vrednosti aktive, koji nije ispraćen adekvatnim rastom na strani prihoda, prvi je signal da se MSP zadužuje ili da svojim resursima loše upravlja i neefikasno ih alokira. Sa druge strane, pad aktive može signalizirati da preduzeće pokušava prodajom sredstava da izvrši pokriće gubitaka. Međutim, neophodno je udubiti se u sam Bilans stanja, te uočiti koja komponenta aktive

dovodi do rasta ili pada: stalna imovina, gotovina, zalihe, itd. Tako, na primer, rast stalne imovine može biti signal da MSP radi na povećanju kapaciteta kroz dodatne investicije, sa idejom da se obezbedi dalji rast. Povećanje aktive koje je posledica povećanja gotovine ukazuje na to da MSP ima bolju likvidnost, te da je sposobnije da brzo i efikasno izvršava svoje kratkoročne obaveze i obratno. Rast aktive kao posledica rasta zaliha može da se tumači višestruko. Sa jedne strane, MSP možda nabavlja više sirovina ili gotovih proizvoda ukoliko očekuje rast tražnje; sa druge strane, ukoliko nije prisutan rast tražnje, ovaj trend može biti signal problema. Kontinuirana analiza aktive u bilansu, značajna je za uočavanje potencijalnih problema, koji na kraju puta mogu voditi otvaranju stečajnog postupka.

Slika 38: Značaj varijabli za predikciju stečaja dve godine unapred (Y-2)



Izvor: Vizuelizacija autora, SPSS program

Najveći nivo značajnosti (0.15/1.00) u predikciji stečaja dve godine unapred ima normalizovana varijabla odnosa poslovnih rashoda i poslovnih prihoda (S_OEOI). Ova varijabla je, takođe, značajan prediktor i za neuronske mreže. Algoritam k-NN potvrđuje da je uspostavljanje kontrole prihoda i rashoda značajan korak u poslovanju MSP. Nedovoljan nivo pokrivenosti poslovnih (operativnih) rashoda prihodima, prvi je signal da se preduzeće suočava sa finansijskim poteškoćama. U tom slučaju, neophodno je dodatno se udubiti u pozicije Bilansa uspeha, kako bi se utvrdilo koja tačno komponenta prihoda nedostaje, odnosno koja komponenta rashoda dominira u ukupnim rashodima: da li je to rashod koji se tiče redovnog poslovanja ili je pak u pitanju neki vanredni (ostali) rashod. Dok su rashodi iz redovnog poslovanja vezani za svakodnevnicu poslovanja MSP i isti su neophodni za obavljanje poslovnih operacija, vanredni su oni koji se odnose na nepredviđene situacije. Visok udeo vanrednih rashoda otežava predikciju stečaja kao i procenu stabilnosti poslovanja MSP, jer signalizira da postoji mogućnost da se dese neki neplanski gubici koji nisu u vezi sa redovnim operacijama.

6.3.3.2. Testiranje modela

Na slikama 39 i 40 prikazani su rezultati testiranja k-NN modela za predikciju stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja stečajnog postupka.

Slika 39: Matrica konfuzije za k-NN model predikcije stečaja godinu dana (Y-1) pre pokretanja postupka

Classification Table				
Partition	Observed	Predicted		
		0	1	Percent Correct
Training	0	67	16	80.7%
	1	7	76	91.6%
	Overall Percent	44.6%	55.4%	86.1%
Holdout	0	18	5	78.3%
	1	2	21	91.3%
	Missing	0	0	
	Overall Percent	43.5%	56.5%	84.8%

Izvor: Vizuelizacija autora, SPSS program

Rezultati matrice konfuzije za model predikcije stečaja godinu dana unapred (Y-1) pre pokretanja postupka, ukazuju na ukupnu tačnost (**Accuracy**) 86.1% za trening, odnosno 84.8% za test skup podataka. Pokazatelj Preciznost (**Precision**) iznosi 80.7% za trening, odnosno 78.3% za test skup podataka. Specifičnost (**Specificity**) modela je 82.6% za trening, odnosno 80.8% za test skup. Senzitivnost (**Sensitivity**) modela je 90.5% za trening, odnosno 90.0% za test skup. Na kraju, F1 rezultat (**F1-Score**) za model je 85.4% kod trening podataka, a 83.7% kod test uzorka.

Slika 40: Matrica konfuzije za k-NN model predikcije stečaja dve godine (Y-2) pre pokretanja postupka

Classification Table				
Partition	Observed	Predicted		
		0	1	Percent Correct
Training	0	57	26	68.7%
	1	21	62	74.7%
	Overall Percent	47.0%	53.0%	71.7%
Holdout	0	15	8	65.2%
	1	6	17	73.9%
	Missing	0	0	
	Overall Percent	45.7%	54.3%	69.6%

Izvor: Vizuelizacija autora, SPSS program

Rezultati matrice konfuzije za model predikcije stečaja dve godine unapred (Y-2) pre pokretanja postupka, ukazuju na ukupnu tačnost (***Accuracy***) 71.7% za trening, odnosno 69.6% za test skup podataka. Pokazatelj Preciznost (***Precision***) iznosi 68.7% za trening, odnosno 65.2% za test skup podataka. Specifičnost (***Specificity***) modela je 70.5% za trening, odnosno 68.0% za test skup. Senzitivnost (***Sensitivity***) modela je 73.1% za trening, odnosno 71.4% za test skup. Na kraju, F1 rezultat (***F1-Score***) za model je 70.8% kod trening podataka, a 68.2% kod test uzorka.

7. DISKUSIJA, PRAKTIČNE IMPLIKACIJE I OGRANIČENJA MODELA

Glavna uloga modela predikcije stečaja jeste obezbeđivanje znakova upozorenja kompanijama i investitorima da se stečaj može dogoditi, te da je neophodno preduzeti mere. Razvojem modela, smanjuje se rizik obavljanja samog biznisa. (Vuković i dr, 2020). Kompanije moraju da se adaptiraju na brze promene u poslovnom okruženju, kako ne bi bile potisnute od strane konkurencije. U nastavku će biti prikazana analiza svih razvijenih modela u ovom istraživanju, te biti ukazano na praktičan značaj i ograničenja samog istraživanja.

7.1. Analiza razvijenih modela i komparacija sa postojećim modelima

Kako je razvijeno po pet modela za predikciju stečaja na bazi različitih tehnika (LR, DA, NN, DT i KNN), i to u dva vremenska horizonta (Y-1 i Y-2), važno je napraviti sažeti prikaz rezultata. U tabelama 52 i 53 su prikazane varijable koje su selektovane po modelima za predikciju stečaja godinu dana i dve godine unapred – respektivno.

Tabela 52: Selektovane varijable²⁸ u modelima predikcije stečaja godinu dana unapred (Y-1)

Model / Varijabla	TITE	CS	TAG	IETA	TDTA	CFNID	OEOI
Logistička regresija (LR)	✓	✓	✓	✓			
Diskriminantna analiza (DA)	✓				✓	✓	
Neuronske Mreže (NN)					✓		✓
Stabla odlučivanja (DT)	✓						
K-najbližih suseda (KNN)			✓		✓		

Izvor: Vizuelizacija autora, MS Excel program

²⁸ Kod tehnika neuronskih mreža i k-najbližih suseda su selektovane dve varijable sa najboljim rezultatom

Od ukupno 66 varijabli raznih kategorija, kod predikcije stečaja godinu dana unapred po modelima je konačno selektovano ukupno 7 dominantnih prediktora stečaja (TITE, CS, TAG, IETA, TDTA, CFNID i OEOI). Racio ukupnih prihoda i ukupnih rashoda (**TITE**) je uključen kao prediktor u 3 modela: LR, DA i DT. Ovaj racio je pokazatelj ekonomičnosti poslovanja i visoke vrednosti istog (> 1.5) su poželjne. Sa druge strane, niže vrednosti ovog pokazatelja (< 1.0) mogu biti prvi signal da se MSP suočava sa finansijskih poteškoćama. U cilju izbegavanja finansijskih poteškoća koje eventualno mogu biti okončane stečajem, MSP moraju da usmere svoj fokus ka rashodima, odnosno ka optimizovanju istih, te podizanju efikasnosti i efektivnosti. Neophodno je eliminisati sve troškove koji ne stvaraju dodatnu vrednost i pregovarati bolje nabavne cene sa dobavljačima. Dodatno, ulaganjem u savremena tehnološka rešenja, moguće je povećati autput uz niže troškove poslovanja. Kada je reč o prihodnoj strani, potrebno je raditi na boljem ugovaranju prodajnih cena ka krajnjim kupcima, kao i na uvođenju šire lepeze proizvoda i usluga koji bi u najboljem slučaju bili komplementarni sa onim proizvodima ili uslugama koje klijenti već koriste. Kombinovanje proizvoda uz popuste koji motivišu kupce, može biti validna opcija za trgovinska preduzeća. Uslužna MSP dodatno mogu razmisliti o preformulaciji modela po kojem pružaju svoje usluge, te umesto ugovaranja i naplate po izvršenoj usluzi, mogu razmotriti mogućnosti za uvođenje fiksne godišnje pretplate na usluge (*Subscription*) i to po paketima usluga u zavisnosti od veličine klijenta. Izlazak preduzeća na nova tržišta je uvek dobra opcija za rast prihoda, ali ista nosi veće rizike. Ulaganjem u razvoj funkcije marketinga, dodatno se može doprineti rastu prodaje i samim tim ukupnih prihoda, pod uslovom adekvatne kontrole rashodne strane. Ukoliko je reč o MSP koji imaju skladišta, potrebno je obezbediti optimalne zalihe u cilju smanjenja pratećih troškova skladištenja, kao i vezivanja sredstva. Ovaj indikator, prepoznat je kao značajan u predikciji stečaja i od strane autora Brenes, et al. (2022).

Racio gotovine i prihoda od prodaje (**CS**) je selektovan kao ključna varijabla u jednom modelu – LR. Tumačenju ovog pokazatelja treba postupiti sa posebnom pažnjom, kako ekstremne vrednosti nisu dobre ni u jednom smeru. Preciznije rečeno, visoke vrednosti ovog pokazatelja mogu biti signal da MSP ima dovoljno gotovine da održi svoju likvidnost, te ispunji sve svoje obaveze. Međutim, previše slobodne gotovine je signal da preduzeće nema adekvatnu taktiku za ulaganje novca i razvoj biznisa. Na polju upravljanja gotovinom, MSP imaju na raspolaganju nekoliko opcija. Adekvatnim upravljanjem zalihama, može se osloboditi gotovina koja je vezana u istim. Smanjenjem operativnih troškova, dodatno se povećava raspoloživa gotovina, a ulaganjem u savremena tehnološka rešenja koja dižu efikasnost, utiče se na rast gotovinskih tokova u budućnosti. Dodatno, potrebno je veliku pažnju posvetiti ugovaranju povoljnih uslova plaćanja kod kupaca (kraći rokovi) i dobavljača (duži rokovi), tako da se maksimalno iskoriste benefiti ove opcije bez ugrožavanja poslovnih odnosa. Pored prethodno pomenutog, pokretanje budžetske kampanje može biti korisno, jer ovaj proces može malim i srednjim preduzećima pomoći da predvide kada se očekuju niski nivoi gotovine, te da proaktivno reaguju sa ciljem da se situacija prebrodi. Na strani prodaje, preporuke korespondiraju sa onim što je već pomenuto kod uticaja na rast prihoda, a to je: adekvatno formiranje cena, razvoji strategije prodaje, ulaganje u marketing, kao i uvođenje novog asortimana proizvoda/usluga. Pokazatelj odnosa gotovine i prihoda od prodaje je identifikovan kao značajan prediktor u finalnim modelima i od strane sledećih autora: Brenes i dr. (2022); Lee i dr. (1996), Back i dr (1996), Ryu i Yue (2005) i Ravisankar i dr. (2010).

Pokazatelj rasta ukupne aktive (**TAG**) je kao značajna nezavisna varijabla selektovan kod LR i KNN tehnika. Rast ovog indikatora signalizira da preduzeće teži investirati u nova sredstva, što dalje može odati utisak stabilnosti i jačanja kapaciteta biznisa. Međutim, potrebno je ovo ulaganje staviti u kontekst, te videti koji su izvori finansiranja istog i da li je prisutno prekomerno zaduživanje. Sa druge strane, kada pada vrednost imovine između perioda, to ne mora nužno da bude signal finansijskih problema, gde se redukcijom kapaciteta pokušava nastaviti poslovanje, već može biti signal da se teži optimizovati poslovanje kroz smanjenje zaliha ili imovine koja nema doprinos u poslovanju. Kada je u pitanju ovaj aspekt poslovanja MSP, prethodno pomenuto proširenje na nova tržišta ili pak rast asortimana proizvoda/usluga, može sa sobom povući dodatna kapitalna ulaganja u novu opremu i tehnologije, što direktno utiče na rast aktive. Međutim, potrebno je voditi računa o optimizacijama, kao i efikasnom i efektivnom korišćenju raspoložive imovine, te ukidanju neproduktivnog dela aktive (imovine), koji u sebi drži vezani kapital koji bi mogao profitabilnije da se investira. Lee & Choi (2013), Yazdanfar (2011), Min i Jeong (2009) i Rasolomanana (2022) takođe su prepoznali značaj ovog faktora u predikciji stečaja, kako je uključen u konačne modele.

Pokazatelj odnosa troškova kamata i ukupne aktive (**IETA**) je kao značajna nezavisna varijabla selektovan samo u LR modelu. Visoke vrednosti ovog pokazatelja mogu biti signal da preduzeće značajan deo svog poslovanja finansira kroz dugove, a to direktno utiče na solventnost i likvidnost. Međutim, važno je detaljnije razumeti kako se koriste pozajmljena sredstva, jer nekada visok trošak kamate poređeno sa aktivom može biti signal da se kroz pozajmljivanje sredstava, u stvari, finansiraju razvojne inicijative. U ovom scenariju je važno da MSP obezbedi da povrat investicije bude iznad troškova kamata kako bi akcija bila isplativa. Kroz otplaćivanje svojih dugova, MSP može da utiče na umanjenje troškova kamata. Ukoliko nema na raspolaganju dovoljne količine gotovine, putem rasprodaje neproduktivne aktive (imovine), mogu se obezbediti sredstva za finansiranje duga. Poslednja, najmanje povoljna, opcija kojoj MSP može da se okrene je korišćenje kredita za refinansiranje koji imaju manje kamate poređeno sa postojećim kreditima. Važno je da se zaduživanje koristi pametno kao mehanizam za rast aktive, kao i da se vrši ulaganje u projekte koji su visoko profitabilni i da se time direktno doprinese rastu biznisa. U celoj konstrukciji je značajna funkcija finansijske kontrole i praćenja, da bi se obezbedilo da investicija donese veće prilive u odnosu na inicijalna ulaganja.

Pokazatelj odnosa ukupnog duga i ukupne aktive (**TDTA**) selektovan je kao značajna prediktor varijabla u tri modela: DA, NN i KNN. To je u skladu sa istraživanjima Leshno i Spector (1996), Back i dr (1996), Zhai i dr (2014), Ryu i Yue (2005), Kim i Kang (2010) i Ravisankar i dr. (2010). Pokazatelj ima slične implikacije kao i prethodno pomenuti, s tim da se akcenat stavlja na ukupan dug, a ne samo troškove kamata. Ključno je da MSP stave u fokus namenu samog zaduživanja i isto uvek bude u funkciji razvoja poslovanja. Pozajmljivanje sredstava zarad pokrivanja operativnih troškova nije opravdano ukoliko se želi razviti održiv biznis, ali je ohrabrujuće da se pozajmljena sredstva usmere ka finansiranju neke velike marketinške kampanje ili pak na neke nove projekte koji će doneti prinos meren ROI ili drugim pokazateljima.

Odnos neto rezultata gotovine iz Izveštaja o novčanim tokovima i ukupnog duga (**CFNID**), selektovan je kao ključna prediktor varijabla u okviru DA modela. Visoke vrednosti ovog pokazatelja mogu biti signal da je preduzeće stabilno i da raspolaže sa velikom količinom slobodne gotovine kojom može da obezbedi likvidnost. Međutim, u slučaju izuzetno visokih vrednosti ovog pokazatelja, treba ispitati da li MSP ima program

razvoja biznisa, te da li planira ulaganje gotovine u dalji rast na duge staze. Niski nivoi ovog pokazatelja su opravdani onda kada je preduzeće mnogo investiralo u imovinu ili neke projekte kod kojih se očekuje donošenje značajnijih efekata u budućem periodu. Dakle, niski nivoi ovog pokazatelja, najčešće su signal da MSP ne generiše dovoljno gotovine kojom može da pokrije dugove i prihvatljivi su samo ukoliko je rast zabeležen na drugim pozicijama bilansa (poput imovine), a sve to sa ciljem daljeg razvoja biznisa i osvajanja novih projekata. Racio novčanih tokova i duga je identifikovan kao bitan faktor u modelovanju predikcije stečaja od strane sledećih autora: Leshno i Spector (1996), Virag i Kristof (2005), dok je recipročna vrednost ovog indikatora prepoznata kao značajna za konačni model u istraživanju koje su sprovedli Hu i dr (2021).

Pokazatelj odnosa operativnih (poslovnih) rashoda i operativnih prihoda (**OEOI**), selektovan je kao ključni prediktor putem algoritma neuronskih mreža što je u skladu sa istraživanjem Douglas (2014) i Asyikin (2018). Velike vrednosti ovog indikatora mogu biti signal da MSP troši više nego što generiše na strani prihoda, što direktno narušava profitabilnost. Međutim, to može biti i pozitivno ukoliko se MSP fokusira na ulaganje u neke inicijative koje će u budućnosti imati prinos. Niske vrednosti ovog pokazatelja, signal su da preduzeće dobro upravlja svojim poslovnim rashodima poređeno sa prihodima i da se ostvaruje dobar nivo ekonomičnosti. Međutim, druga strana medalje jeste to da izuzetno niske vrednosti racia mogu biti signal da MSP ne investira dovoljno u razvoj biznisa. Kroz rast efikasnosti i efektivnosti poslovanja, MSP može da vodi ka smanjenju poslovnih rashoda. Takođe, na komponentu operativnih rashoda se može direktno uticati kroz uspostavljanje funkcije kontrole troškova sa ciljem eliminacije nepotrebnih aktivnosti, koje uzrokuju nepotrebno trošenje. Ulaganjem u znanja zaposlenih, te automatizacijom nekih aktivnosti, može se postići dodatni prihod na bazi rasta efikasnosti. Takođe, na prihodnoj strani je bitno sve prethodno pomenuto što se tiče rasta funkcije marketinga sa ciljem razvoja prodaje uz adekvatno pregovaranje cena.

Tabela 53: Selektovane varijable u modelima predikcije stečaja dve godine unapred (Y-2)

Model / Varijabla	CCL	CFNID	OEOI	EBITInt
Logistička regresija (LR)	✓	✓		
Diskriminantna analiza (DA)	✓	✓		
Neuronske Mreže (NN)		✓	✓	
Stabla odlučivanja (DT)		✓		
K-najbližih suseda (KNN)			✓	✓

Izvor: Vizuelizacija autora, MS Excel program

Kada je reč o predikciji stečaja dve godine unapred (Y-2), ukupno je selektovano 4 varijable (CCL, CFNID, OEOI i EBITInt) od inicijalnih 66 (vidi tabelu 53). Sve varijable su finansijske prirode, a čak 2/4 su orijentisane ka upravljanju gotovinom. Odnos između stanja gotovine iz Bilansa stanja i kratkoročnih obaveza (CCL) je selektovan kao bitan prediktor kod 2 modela: LR i DA što je u skladu sa istraživanjima Back i dr (1996), Hu i

dr (2021), Brenes i dr. (2022), Ryu i Yue (2005). Niski nivoi ovog indikatora, signal su da MSP možda ima poteškoće da održavanjem likvidnosti, kao i da postoje nedostaci gotovine kojom bi se mogle pokriti kratkoročne obaveze. Prilikom analize, treba u kontekst uzeti i delatnost preduzeća, jer postoji mogućnost da je priroda delatnosti takva da se potraživanja prevode brzo u gotovinu, te da likvidnost nije nužno ugrožena. MSP treba da rade na poboljšanju priliva gotovog novca kroz unapređivanje prodajnih kanala, te razne promotivne i marketinške aktivnosti koje podstiču kupce. Dodatno, kao što je već pomenuto, potrebno je redovno analizirati novčane tokove u cilju identifikovanja kriznih perioda. Kada je reč o kratkoročnim obavezama, potrebno je efikasno upravljati istim, tako da se MSP postaraju za pregovaranje što povoljnijih uslova sa svojim dobavljačima, odnosno da zahtevaju razne popuste za prevremeno izvršavanje obaveza.

Pokazatelj odnosa neto rezultata gotovine iz Izveštaja o novčanim tokovima i ukupnog duga (**CFNID**), selektovan je od strane 4 modela (LR, DA, NN i DT), dok je odnos poslovnih rashoda i poslovnih prihoda (**OEOI**) odabran kao značajna prediktor varijabla u 2 modela (NN i KNN). Iste varijable su identifikovane kao značajne i kod predikcije stečaja godinu dana unapred, pa je u gore navedenom tekstu objašnjeno koje su ključne smernice za MSP, ali i ostale stejkholdere koji analiziraju poslovanje.

Odnos poslovnog rezultata i kamate (**EBITInt**) selektovan je kao ključna varijabla samo u KNN modelu. Racio pokrića kamate je identifikovan kao značajan i u istraživanjima sprovedenim od strane Leshno i Spector (1996), Brenes, i dr. (2022), Lee, i dr. (1996), Back i dr. (1996) i Kouki i Elkhaldi (2011). Prilikom analize ovog pokazatelja, važno je razumeti da ni suviše visoke ni suviše niske vrednosti nisu dobre. Visok racio je signal da MSP uspeva dovoljno da zaradi i pokrije troškove kamata, što dalje sugerise da postoji izvesni nivo finansijske stabilnosti. Međutim, previsoke vrednosti racia ukazuju da MSP ima nizak nivo zaduživanja, te da ne koristi dovoljno mogućnosti da dugom finansira svoju ekspanziju. Sa druge strane, niske vrednosti racia pokazuju da preduzeće ima poteškoće da generise dovoljno poslovnog rezultata da održi likvidnost i plati troškove kamata. Nizak nivo ovog racia, uz prisustvo investicija koje sa sobom nose budući povrat, može se smatrati opravdanim. Smernice za MSP su već sadržane u prethodnim objašnjenima, a svode se na strogu kontrolu i redukciju troškova, unapređenje efikasnosti poslovanja, rast EBIT-a putem rasta prodaje na bazi atraktivnih marketinških kampanja i dobrih pregovaračkih sposobnosti.

Kako je kod metoda mašinskog učenja prisutan problem „crne kutije“ (*black box*²⁹), u nastavku je dat prikaz deskriptivne statistike za najznačajnije varijable, što može biti dobra referenca prilikom analize poslovanja nekog MSP.

²⁹ *Black Box* kao problem u mašinskom učenju je objašnjen u okviru 4. poglavlja.

Tabela 54: Deskriptivna statistika za najznačajnije varijable predikcije stečaja godinu dana unapred (Y-1)

Descriptive Statistics: Y-1				
	N	Minimum	Maximum	Mean
BANKRUPT				
TITE	106	0.00	1.38	0.78
CS	106	0.00	8.44	0.28
TAG	106	-2,738,090.00	747,056.00	-154,318.08
IETA	106	0.00	0.18	0.02
TDTA	106	0.12	27.50	1.64
CFNID	106	- 0.99	0.74	- 0.14
OEOI	106	- 3.42	7.92	1.42
SOLVENT				
TITE	106	0.06	2.14	1.06
CS	106	0.00	147.22	1.46
TAG	106	- 496,440.00	715,067.00	54,679.97
IETA	106	0.00	0.03	0.01
TDTA	106	0.03	2.37	0.63
CFNID	106	- 1.30	5.17	0.22
OEOI	106	0.40	4.16	0.98

Izvor: Kalkulacija autora na osnovu SPSS-a

Tabela 54 predstavlja prikaz deksriptivne statistike za period Y-1, gde se gornji deo tabele odnosi na podatke za preduzeća u stečaju, a donji deo na solventna preduzeća. Tako je, na primer, prosečna ekonomičnost preduzeća u stečaju (TITE) 0.78, dok je prosečna ekonomičnost zdravih, odnosno, solventnih preduzeća 1.06. Kao što je prethodno pomenuto, vrednosti ovog pokazatelja ispod 1.0 su signal da preduzeće potencijalno ima finansijske poteškoće. Tabela 55 sadrži podatke istog logičkog sleda, samo se odnose na period Y-2. Tako, na primer, ratio pokrića kratkoročnih obaveza gotovinom iznosi 0.06 za preduzeća u stečaju, odnosno 0.12 za solventna preduzeća. Očekivano je da vrednost ovog indikatora bude što veća, jer isti demonstrira koliko puta MSP može da ispuni svoje kratkoročne obaveze upotrebom isključivo gotovine.

Tabela 55: Deskriptivna statistika za najznačajnije varijable predikcije stečaja dve godine unapred (Y-2)

Descriptive Statistics: Y-2				
	N	Minimum	Maximum	Mean
BANKRUPT				
CCL	106	0.00	0.78	0.06
CFNID	106	- 0.75	0.25	- 0.05
OEOI	106	0.41	11.99	1.28
EBITInt	106	- 9,469.67	182.93	-146.48
SOLVENT				
CCL	106	0.00	0.91	0.12
CFNID	106	- 0.44	23.11	0.42
OEOI	106	0.27	1.70	0.94
EBITInt	106	-22,763.00	8,110.50	-11.09

Izvor: Kalkulacija autora na osnovu SPSS-a

U Tabeli 56, prikazani su rezultati 5 klasifikacionih modela za predikciju stečaja godinu dana unapred (Y-1), kako za trening skup podataka, tako i za test podatke. Najviši ostvareni rezultat je kod neuronskih mreža i to ukupna tačnost 90% i 89% za trening i test skup respektivno. Najniži rezultat je ostvarila diskriminantna analiza sa ukupnom tačnošću 81% i 80% za trening i test skup podataka, s tim da je važno podsetiti se da je DA testirana po strogom kriterijumu unakrsne validacije u skladu sa drugim autorima koji su prethodno pomenuti, te mogućnostima SPSS alata.

Tabela 56: Uporedni prikaz klasifikacionih rezultata razvijenih modela predikcije stečaja godinu dana unapred (Y-1)

Kategorija/ Pokazatelj	TRENING SKUP				
	Tačnost (Accuracy)	Preciznost (Precision)	Specifičnost (Specificity)	Senzitivnost (Sensitivity)	F1 Rezultat (F1 Score)
Logistička regresija	83.7%	74.7%	78.6%	91.2%	82.1%
Diskriminantna analiza	81.1%	80.2%	80.6%	81.7%	81.0%
Neuronske Mreže	90.4%	89.2%	89.4%	91.4%	90.2%
Stabla odlučivanja	84.4%	79.2%	81.2%	88.4%	83.6%
K-najbližih suseda	86.1%	80.7%	82.6%	90.5%	85.4%
Kategorija/ Pokazatelj	TEST SKUP				
	Tačnost (Accuracy)	Preciznost (Precision)	Specifičnost (Specificity)	Senzitivnost (Sensitivity)	F1 Rezultat (F1 Score)
Logistička regresija	82.6%	73.9%	77.8%	89.5%	81.0%
Diskriminantna analiza	80.2%	78.3%	79.1%	81.4%	79.8%
Neuronske Mreže	89.1%	87.0%	87.5%	90.9%	88.9%
Stabla odlučivanja ³⁰	83.5%	n/a	n/a	n/a	n/a
K-najbližih suseda	84.8%	78.3%	80.8%	90.0%	83.7%

Izvor: Vizuelizacija autora, MS Excel program

U Tabeli 57, prikazani su rezultati 5 klasifikacionih modela za predikciju stečaja dve godine unapred (Y-2), kako za trening skup podataka, tako i za test podatke. Najbolji rezultat, kao i kod predikcije stečaja godinu dana unapred, ostvaruju neuronske mreže, sa ukupnom tačnošću 76% i 74% za trening i test uzorak. Kod trening uzorka, najlošije

³⁰ SPSS ne nudi klasifikacionu matricu kao rezultat pokretanja algoritma za 10-fold kod DT, već samo ukupnu tačnost

performanse merene ukupnom tačnošću ima diskriminantna analiza (71%), dok daleko najlošije performanse na test skupu ima logistička regresija sa ukupnom tačnošću 65%.

Tabela 57: Uporedni prikaz klasifikacionih rezultata razvijenih modela predikcije stečaja dve godine unapred (Y-2)

Kategorija/ Pokazatelj	TRENING SKUP				
	Tačnost (Accuracy)	Preciznost (Precision)	Specifičnost (Specificity)	Senzitivnost (Sensitivity)	F1 Rezultat (F1 Score)
Logistička regresija	72.9%	79.5%	76.4%	70.2%	74.6%
Diskriminantna analiza	70.8%	69.8%	70.4%	71.2%	70.5%
Neuronske Mreže	75.9%	85.5%	82.1%	71.7%	78.0%
Stabla odlučivanja	72.2%	86.8%	81.3%	67.2%	75.7%
K-najbližih suseda	71.7%	68.7%	70.5%	73.1%	70.8%
Kategorija/ Pokazatelj	TEST SKUP				
	Tačnost (Accuracy)	Preciznost (Precision)	Specifičnost (Specificity)	Senzitivnost (Sensitivity)	F1 Rezultat (F1 Score)
Logistička regresija	65.2%	69.6%	66.7%	64.0%	66.7%
Diskriminantna analiza	70.8%	69.8%	70.4%	71.2%	70.5%
Neuronske Mreže	73.9%	82.6%	78.9%	70.4%	76.0%
Stabla odlučivanja	69.3%	n/a	n/a	n/a	n/a
K-najbližih suseda	69.6%	65.2%	68.0%	71.4%	68.2%

Izvor: Vizuelizacija autora, MS Excel program

Iako modeli imaju dosta toga zajedničkog, što se najbolje vidi kroz varijable koje su algoritmi selektovali kao bitne, uvek je preporučljivo da se prilikom analize poslovanja MSP uradi svih 5 analiza po vremenskom horizontu, nevezano za prezentovane rezultate pojedinačnih modela, te da se uz uključivanje zdravorazumskog rasuđivanja, zajedno sa autputima modela – donese odluka. Uvidom u prethodno dati pregled literature, kao i brojne pregledne radove na temu predikcije stečaja u svetu (Bellovary i dr, 2007; Alaka i dr, 2018; Cheraghali i Molnár, 2023; itd), tačnost modela predikcije stečaja se najčešće kreće od 60% pa na dalje dok su oni sa tačnošću preko 90% zaista retki, iz čega sledi da se razvijeni modeli uklapaju u postojeću naučnu osnovu.

Razvoj specifičnih modela za MSP u Republici Srbiji zahteva velike napore za prikupljanje, ali i pripremu samih podataka. Poslovanje MSP sektora u Republici Srbiji ima regulativu koja je drugačija u poređenju sa drugim zemljama, a i sama kategorizacija

preduzeća po veličini se može razlikovati između zemalja. Dodatno, razlike na relaciji IFRS i GAAP metodologije mogu biti ograničavajući faktor za primenu međunarodnih modela na lokalna MSP.

Sve prethodno rečeno, jeste bio razlog razvoja specifičnih modela koji stejkholderima baš sa teritorije Republike Srbije mogu biti korisni za donošenje odluka. Sa ciljem potvrđivanja predviđačke snage razvijenih modela, te njihove adekvatnosti, urađeno je **poređenje** sa Altman-ovim poznatim i najkorišćenijim modelima: **Z' skorom**³¹ (Altman, 1983) i posebnim **EMS skorom**³² (Altman, 2005). Altman-ov prvi Z-skor model iz 1968. godine nije mogao biti korišćen kako se oslanja na tržišnu vrednost kapitala, a taj podatak nije moguće pribaviti za srpska MSP, tako da je umesto njega korišćen Z' skor, koji ima identične parametre kao i inicijalni Z, samo umesto tržišne vrednosti kapitala se koristi knjigovodstvena. Dodatno, primena Z' skora je adekvatnija kako je inicijalni Z skor iz 1968. bio fokusiran na preduzeća koja se nalaze na berzama. Pored ovog, sa namerom je iskorišćen EMS skor, kako Altman isti predlaže svim tržištima u razvoju (*Emerging Market Score*).

Oba prethodno pomenuta modela su primenjena na isti testni skup istraživanja (20% uzorka, 46 MSP), a rezultati su prezentovani u prilogima 6-9. Kako bi se izbegla klasifikacija u "sivoj zoni", prema preporuci autora (Hair, 2010), utvrđena je jedinstvena *cut-off* vrednost kao aritmetička sredina dva centroida³³. Kod predikcije stečaja godinu dana unapred (Y-1), EMS model je pokazao tačnost 67.4% uz ukupno tačno klasifikovanih 31/46 MSP. Sa druge strane Z' skor je pokazao nešto bolje performanse u pomenutom vremenskom horizontu sa ukupnom tačnošću 78.3%, odnosno 36/46 tačno klasifikovanih MSP. Svi razvijeni modeli u doktorskoj disertaciji pokazuju veći stepen tačnosti godinu dana unapred, koji ide i do 89% tačnosti na testiranju. Dodatno, DA i DT modeli su testirani i naprednijim softverskim tehnikama unakrsne validacije (*Cross Validation*). Kod predikcije stečaja dve godine unapred (Y-2), EMS model ostvaruje tačnost od 58.7%, uz tačnu klasifikaciju 27/46 MSP. Model Z' pokazuje ukupnu tačnost od 63.0% sa 29/46 ispravno klasifikovanih MSP. Takođe, i na ovom vremenskom horizontu, svi modeli koji su razvijeni u okviru disertacije, pokazuju bolju ukupnu tačnost.

Srpska privreda je specifična, a poslovanje MSP je veoma izazovno područje za istraživanje. Za razliku od velikih preduzeća, kod ovih entiteta postoji manja podrška, te manji broj lica koja bi se bavila analizom izveštaja i izvlačenjem raznih korisnih informacija za upravljanje i donošenje odluka.

³¹ Funkcija glasi: $Z' = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,42X_4 + 0,998X_5$

X₁ – odnos neto obrtnog kapitala i poslovne imovine (aktive),

X₂ – odnos zadržane dobiti i poslovne imovine,

X₃ – odnos dobiti pre kamata i poreza i poslovne imovine,

X₄ – odnos knjigovodstvene vrednosti kapitala i ukupnih obaveza i

X₅ – odnos poslovnih prihoda i poslovne imovine.

Granične vrednosti su: > 2,9 (solventno), 1.24-2.89 (siva zona) i < 1.23 (stečaj)

³² Funkcija glasi: $EMS = 6.56X_1 + 3.26X_2 + 6.72X_3 + 1.05X_4 + 3.25$

X₁ – odnos neto obrtnog kapitala i poslovne imovine,

X₂ – odnos zadržane dobiti i poslovne imovine,

X₃ – odnos dobiti pre kamata i poreza i poslovne imovine,

X₄ – odnos knjigovodstvene vrednosti kapitala i ukupnih obaveza

Granične vrednosti su: >2.6 (solventno), <2.60 i >1.10 (siva zona), <1.10 (stečaj)

³³ Princip je objašnjen kod teorijske osnove diskriminantne analize.

7.2. Praktične implikacije, ograničenja modela i smernice za buduća istraživanja

Modeli predikcije stečaja nesumnjivo mogu biti korisni u oceni finansijske budućnosti entiteta, te biti jedna od osnova za donošenje odluka. Naravno, s obzirom na pretpostavke istraživanja, počev od odnosa populacije i odabranog uzorka, pa do ostalih, važno je napomenuti da razvijeni modeli imaju ograničenja. Takođe, bitno je istaći i da samo područje ostavlja još prostora budućim istraživačima da nadgrade naučnu osnovu, pogotovo na teritoriji Republike Srbije, ali i šire.

→ Primena rezultata istraživanja, ogleda se u sledećem:

- [1] *Identifikacija ranih upozoravajućih znakova*: modeli identifikacije ranih znakova stečaja (i do 2 godine unapred), omogućili bi MSE i drugim zainteresovanim stranama (interni stejkholderi i vlasnici, kao i eksterni stejkholderi) da preduzmu proaktivne mere. Ovo je posebno ključno u ekonomskom okruženju poput Srbije, gde se preduzeća mogu suočiti sa različitim izazovima. Analizom sektora MSE na osnovu APR Biltene, identifikovan je problem sa likvidnošću. Međutim, pored toga, postoji čitav spektar problema sa kojima se MSE suočavaju, a isti se reflektuju kroz razne, ranije pomenute, pokazatelje: ograničenost finansijskih i ostalih resursa, limitirana moć adaptacije u kriznim situacijama, centralizovano donošenje odluka, velika zavisnost od pojedinačnih klijenata, itd. Modeli predikcije mogu ukazati na to da li je MSE u riziku izvestan vremenski period pre nego se eventualno pokrene stečajni postupak, identifikujući i kombinujući razne attribute (pokazatelje) na poseban način, koji nije karakterističan za klasičnu finansijsku analizu. Veze koje su uočene od strane statističkih modela i veštačke inteligencije, često nisu vidljive u procesu klasične finansijske analize, a mogu značajno doprineti očuvanju kontinuiteta poslovanja MSE.
- [2] *Vođenje preduzeća ka sigurnoj budućnosti*: preduzeće može pokrenuti proaktivne korake kako bi poboljšalo svoje finansijsko zdravlje. Adresiranjem problema koje bi model predikcije identifikovao, preduzeće osigurava svoju dugoročnu održivost, obezbeđuje poverenje investitora i doprinosi ukupnoj stabilnosti poslovnog okruženja. Jedna od pomenutih karakteristika MSE je ograničen pristup finansijskim resursima, te otežano zaduživanje (Jenkins & Hines, 2003, Ganbold, 2008; Shabbir, 2012). Model predikcije stečaja se fokusira na ključne parametre poslovanja MSE, te kao takav može da pomogne u identifikaciji potencijalnih finansijskih rizika. Ranom identifikacijom rizika, vlasnici MSE mogu na vreme da razmišljaju o alternativama za pojedine poslovne resurse, te o opcijama za osvežavanje novčanih tokova, pošto zaduživanje od banaka sa sobom nosi ograničenja za MSE. Dodatno, kod MSE je izražena zavisnost od manjeg broja poslovnih partnera (Radaš i Božić, 2009), pa vlasnici MSE ne moraju model da koriste samo za procenu sopstvenog rizika, već i za procenu rizika svojih poslovnih partnera, pod uslovom da i oni spadaju u kategoriju malih i srednjih entiteta. Ukoliko uoče da model ukazuje na rizik kontinuiteta poslovanja nekog od svojih partnera iz branše malih i srednjih entiteta, vlasnici mogu da reaguju i na vreme traže nove partnere, kako se kriza klijenta ne bi prelila i na same vlasnike biznisa. Dodatno, kao što je već pomenuto, MSE su često usmereni na praćenje pojedinih rezultata, a najčešće prodaje (Nilsson, 2010). Model predikcije stečaja

obežbeđuje da se ovi entiteti ne fokusiraju samo na jedan ratio pokazatelj ili grupu pokazatelja vezanih za prodaju, već kombinacijom raznih parametara omogućava da se sagleda celokupna slika poslovanja, te ukaže na poteškoće u poslovanju i to u ranim etapama, što se ne može videti posmatranjem jednog indikatora – poput prodaje.

- [3] *Unapređenje regulative*: informacija o ključnim faktorima koji vode ka stečaju MSE može biti podeljena sa regulatornim organima. To može dovesti do promena u politici ili do inicijativa usmerenih ka poboljšanju poslovnih uslova za MSE u cilju smanjenja stope stečaja (primera radi, povoljni krediti ili dodatne subvencije za mala i srednja preduzeća).
- [4] *Podrška finansijskim institucijama*: modeli predikcije stečaja mogu koristiti finansijskim institucijama, investitorima i kreditorima koji posluju u Srbiji. Precizne prognoze stečaja mogu pomoći ovim entitetima da efikasnije upravljaju svojim rizicima i donose odgovarajuće odluke o pozajmljivanju sredstava ili investiranju.

→ **Ograničenja razvijenih modela, ogledaju se u sledećem:**

- [1] *Veličina uzorka* uvek predstavlja ograničenje kada je reč o predikciji stečaja, kako je udeo onih preduzeća koja su u stečaju, poređeno sa solventnim – nizak. Problem se dodatno produbljuje kada je potrebno generisati uzorak samo za MSP. Međutim, upotrebom trening i test uzorka (80:20), te upotrebom naprednih tehnika unakrsne validacije kod algoritama koji su skloni prilagođavanju podataka, a u skladu sa mogućnostima SPSS programa, težilo se eliminaciji posledica manjeg uzorka.
- [2] *Kvalitet podataka u izveštajima* može biti kamen spoticanja kada su podaci nepotpuni ili nepouzđani. Neistiniti i neobjektivni podaci u izveštajima direktno utiču na mogućnost da se iz istih predvidi finansijska kriza.
- [3] *Heterogenost entiteta u MSP sektoru*, koja se ogleda u različitim poslovnim uslovima te sektorima, može dovesti do situacije da modeli koji su razvijeni na ovom uzorku ne budu adekvatni za predikciju stečaja nekog MSP ukoliko ono ima specifičnosti u odnosu na prosečne entitete (npr. deo je korporacije i sl.).
- [4] *Raspoloživost nefinansijskih podataka* na srpskom tržištu je ograničena. Javne baze podataka mimo APR-a, koje bi obelodanile nefinansijske informacije poput inovativnosti, konkurentske pozicije, broja menadžera, obrazovne strukture zaposlenih i slično – nisu dostupne. Ovaj nedostatak se težio nadomestiti onim nefinansijskim podacima koji jesu javno dostupni.
- [5] *Makroekonomski faktori* koji su korišćeni u modelu su hibridni, što znači da se vezuju za neke interne karakteristike MSP. Čiste makroekonomske varijable poput kretanja stope zaposlenosti, inflacije, i slično – nisu upotrebljene.
- [6] *Ograničenja IBM-ovog SPSS alata* koja se ogledaju u činjenici da, za razliku od programskih jezika kao što su *R* ili *Phyton*, ne postoji potpuna sloboda u sprovođenju analize. Na primer, napredne tehnike unakrsne validacije/*k-fold* su

dostupne samo kod nekih algoritama, a dodatna analitika nekada nije raspoloživa, što predstavlja problem kod tehnika mašinskog učenja koje po definiciji imaju *black box*³⁴ dilemu.

➔ **Preporuke za dalja istraživanja:**

- [1] *Razvoj modela predikcije stečaja* upotrebom naprednih tehnika mašinskog učenja, kao što je SVM (*Support Vector Machines*), RNN (*Recurrent Neural Networks*) ili nasumične šume (*Random Forests*).
- [2] *Generisanje hibridnih modela* upotrebom programskih jezika poput R-a ili Python-a. Hibridni modeli podrazumevaju da se kombinuju različite tehnike modelovanja, tako da se iskoriste snage različitih algoritama sa ciljem generisanja robusnih modela. Napredne tehnike poput *bagging*-a i *boosting*-a mogu doprineti razvoju modela sa većom preciznošću. Ovo je pogotovo važno na horizontu koji je duži od godinu dana, kako su modeli predikcije stečaja dve godine unapred pokazali pad tačnosti.
- [3] *Primena tehnika prekomernog uzorkovanja (Oversampling)* je korisna onda kada postoji disbalans između dve grupe, što jeste slučaj kod predikcije stečaja, gde je jedna grupa dosta manja (preduzeća u stečaju). Ova tehnika može da pomogne kroz povećanje prisutnosti manjinske klase prilikom treniranja modela, te omogućava da model bolje razume obrasce u podacima.
- [4] *Razvoj modela za posebne grane privrede* bi podrazumevao da se razvijaju pojedinačni modeli samo za određenu oblast MSP, na primer – prerađivačku industriju. Takav model bi mogao da na bolji način razume obrasce baš kod tih preduzeća i bude specijalizovan samo za njihovu predikciju stečaja.
- [5] *Uključivanje dodatnih faktora* može da doprinese preciznosti modela. Na primer, poželjno je uključivanje “čistih” makroekonomskih indikatora (inflacija, nezaposlenost, itd.) pored hibridno-makroekonomskih, kako mimo internih pokazatelja, eksterni uslovi imaju uticaj na poslovanje. Dodatno, u disertaciji su korišćeni Bilans uspeha, Bilans stanja i Izveštaj o novčanim tokovima, a bilo bi korisno da se uključe i Napomene uz finansijske izveštaje putem metoda rudarenja teksta.
- [6] *Sprovođenje panel analize* koja bi podrazumevala da se isti uzorak MSP posmatra u nekom vremenskom intervalu, sa ciljem boljeg razumevanja dinamike i obrazaca ponašanja koji vode do stečaja.

³⁴ *Black Box* kao problem u mašinskom učenju je objašnjen u okviru 4. poglavlja.

*“Zapamtite da je svaki model pogrešan;
praktično pitanje je koliko on mora da greši
da ne bude koristan.”*

- George Box

ZAKLJUČNA RAZMATRANJA

Stečaj je uvek aktuelna tema u svim privredama, bez obzira na to koliko su razvijene. Oskudna naučna istraživanja u oblasti predikcije stečaja na teritoriji Republike Srbije, te činjenica da problematika stečaja na uzorku malih i srednjih entiteta uopšte nije razmatrana, motivisali su ovaj rad. Mala i srednja preduzeća su nosioci razvoja svake ekonomije, što je potvrđeno brojim makroekonomskim pokazateljima. Ona čine čak 41% ukupnog prometa, kao i 43% ukupnog izvoza u Republici Srbiji prema podacima iz 2021. godine, a njihov značaj postoji i u brojnim drugim sferama privrede.

Savremeni uslovi poslovanja su zahtevni, a tržišna konkurencija je oštra. Na svakom koraku se nalaze novi rizici i stejholderima je potrebna pouzdana osnova za odlučivanje, pogotovo kada je reč o investiranju, upravljanju preduzećem i slično. Upravo modeli predikcije stečaja mogu da ukažu na potencijalne rizike dovoljno rano, kako bi se pravovremeno preduzele mere, biznis vodio u pravom smeru, te donele prave odluke. Eksterni stejholderi putem rane predikcije stečaja mogu da donesu pravovremene odluke o povlačenju investicija, odnosno, prekidu saradnje sa onim MSP koji su modelima kategorisani kao rizični za pokretanje stečaja. Interni stejholderi, sa druge strane, na bazi rezultata modela, mogu da menjaju poslovnu strategiju kako bi sprečili nastanak finansijske krize, kao i eventualno pokretanje stečajnog postupka. Iz svega prethodno rečenog je proizišao problem istraživanja.

Teorijski doprinos disertacije se ogleda u iscrpnom pregledu literature u vezi sa predikcijom stečaja. Za svaki od pet fokusiranih metoda, prezentovan je pregled vladajućih istraživačkih radova na lokalnom i svetskom tržištu. Ovakvi sistematizovani pregledi literature po tehnici koju primenjuju, retki su u zajednici koja se bavila ovom temom. Kako predikcija stečaja na teritoriji Srbije nije zastupljena, pogotovo ne za MSP, pregled postojeće literature je izuzetno važan za usmeravanje istraživanja. Pored pregleda literature iz oblasti predikcije stečaja, objašnjene su na jednom mestu sve tehnike, kako statističke, tako i one koje spadaju u oblast mašinskog učenja. Stoga, praktična analiza

ima uporište u pravilima i procedurama koje treba da se ispoštuju u zavisnosti od tehnike koja se primenjuje. Dodatno, kod svake tehnike su navedene prednosti i ograničenja iste.

Praktični doprinos disertacije je demonstriran kroz obračun ratio pokazatelja, te selektovanje najrelevantnijih za kreiranje modela predikcije stečaja. Svi podaci su sistematski obrađeni u skladu sa gore pomenutim pravilima statistike i mašinskog učenja i prikazan je svaki korak u procesu analize. Generisano je 10 modela predikcije stečaja putem 5 tehnika: logistička regresija, diskriminantna analiza, neuronske mreže, stabla odlučivanja i k-najbližih suseda. Dakle, 5 modela za predikciju stečaja godinu dana unapred i 5 modela za predikciju stečaja dve godine unapred. Ukupna tačnost modela predikcije stečaja godinu dana unapred (Y-1) se kreće u rasponu 81.1%-90.4%, za trening skup, odnosno 80.2%-89.1% za test skup podataka. Kod predikcije stečaja dve godine unapred (Y-2), ukupna tačnost se kreće u rasponu 70.8%-75.9% za trening skup podataka, odnosno 65.2%-73.9% za rezultate testiranja. Metode mašinskog učenja su pokazale veću sposobnost predikcije stečaja prilikom testiranja. Svi modeli su pokazali veći nivo preciznosti od tradicionalnih i najčešće korišćenih, Altmanovih Z' skor i EMS modela, čime je potvrđeno da je za tržište Srbije i MSP potrebno kreirati prilagođene modele. Upotrebom razvijenih modela se na vreme mogu prepoznati upozoravajući znakovi vezani za finansijsko zdravlje MSP, što je važno za razne stejkholdere, kako vlasnike MSP, tako i sve one koji sarađuju sa istima. Upotrebom ovih modela, kao i svih preporuka koje su date u disertaciji, MSP se usmeravaju ka sigurnoj budućnosti, tako da se proaktivnim koracima utiče na održivost poslovanja. Rezultati su korisni i za kreatore ekonomske politike, jer modeli sugerišu na aspekte u kojima MSP imaju najviše problema; tako je spram rezultata istraživanja evidentno da loše upravljanje novčanim tokovima, te nedostatak slobodnog novca, predstavljaju prvi signal da će za dve godine od momenta nastanka problema, uslediti finansijske poteškoće koje mogu dovesti do pokretanja stečajnog postupka. Obezbeđivanje podrške za MSP kroz razne podsticaje i povoljnije kredite, na primer, može biti prvi korak da se pomogne sektoru MSP. Dodatno, modeli mogu biti od koristi i finansijskim institucijama i investitorima, kako signaliziraju koji indikatori razlikuju solventna preduzeća od onih koja iskušavaju finansijske poteškoće koje se često završe stečajem. Preporuka za stejkholdere jeste da prilikom analize koriste sve razvijene modele, počevši od najpreciznijih – mašinskog učenja. Analizom tih varijabli uz uvažavanje smernica iz istraživanja, može se dijagnostifikovati stanje malog ili srednjeg entiteta. Međutim, kako metode mašinskog učenja imaju *black box* problem, i ne mogu da objasne način donošenja odluka, u narednom koraku je preporuka da se obračunaju verovatnoće putem log-regresione funkcije i diskriminantne funkcije, jer one daju jednoznačne klasifikacije spram rezultata funkcija i *cut-off* vrednosti, ali sa nešto manjom tačnošću kako ukazuju rezultati testiranja u istraživanju. Zato je važna kombinacija svih rezultata. Nevezano za sumnju o poslovanju MSP, svaki menadžer, vlasnik ili drugo lice koje upravlja preduzećem, trebalo bi da uradi ovakvu analizu, jer samo pravovremena dijagnoza stanja može biti ključ da se na vreme preduzmu eventualne mere za spasavanje biznisa, te vođenje istog u smeru održivosti i profitabilnosti.

Iz teorijskog i praktičnog doprinosa se može izvesti i sveobuhvatni **naučni doprinos** disertacije. Sistematizovani pregled literature i procedura za sprovođenje analize, korisni su naučnoj zajednici, čak i ako se ne radi nužno o predikciji stečaja, jer se pomenute metode mašinskog učenja i statistike mogu koristiti i za brojna druga istraživanja. Disertacija predstavlja okvir sa *korak-po-korak* metodom objašnjenja kako se sprovodi istraživanje putem raznih tehnika, što je pogotovo značajno za oblast društvenih nauka

gde još uvek veći deo ovih tehnika nije zastupljen, a i kada jeste, često nije objašnjen temeljno. Razvijeni modeli predstavljaju pionire predikcije stečaja MSP u Republici Srbiji, a sa sobom povlače nova pitanja i teme za istraživanje. Prema saznanjima autora, nijedan naučno-istraživački rad za sada na teritoriji Republike Srbije nije dizajniran za predikciju stečaja MSP i do dve godine unapred, čak ni u jednom istraživanju koje se zasniva na finansijskim indikatorima nisu ni fokusirana MSP, kako je generisanje takvog uzorka dosta zahtevno. Originalnosti istraživanja dodatno doprinosi činjenica da je korišćeno čak 5 metoda modelovanja, od čega su 3 vezane za mašinsko učenje koje nije zastupljeno u velikoj meri u društvenim naukama.

Samo istraživanje je struktuirano u 7 poglavlja. U prvom poglavlju je dat kratak osvrt na tradicionalne metode i tehnike ocene finansijskih performansi i boniteta preduzeća, koje se mahom zasnivaju na ratio analizi finansijskih izveštaja u cilju ocene finansijske, prinosne i imovinske pozicije entiteta. U drugom poglavlju je obrađen regulatorni okvir stečajnog postupka, te je dat kratak prikaz onoga što Zakon propisuje vezano za pokretanje, vođenje, načela i zatvaranje stečajnog postupka. Tačka tri je prva koja akcentuje mala i srednja preduzeća. U njoj je detaljno prikazano koji je značaj MSP za srpsku ekonomiju kroz analizu makroekonomskih pokazatelja, te uдела MSP u generisanju istih. Pored makroekonomskih pokazatelja poput uvoza, izvoza i slično, prikazan je udeo MSP u finansijsko-računovodstvenim parametrima kao što je ukupan prihod i vrednost imovine. U svim prethodno pomenutim parametrima, MSP imaju značajan udeo. Dodatno, u trećem poglavlju je dat originalan pristup analizi sektora MSP, primenom instrumentarijuma finansijske analize na čitav sektor upotrebom konsolidovanih izveštaja za sve MSP, koji su dostupni u vidu Biltena na sajtu Agencije za privredne registre Srbije. Na kraju samog poglavlja, dat je kratak prikaz statistike MSP u stečaju i likvidaciji, koji ukazuje da je stopa stečaja i likvidacije kod MSP poprilično uravnotežena na nivou 4-5%. Međutim, nedostatak kratkoročne finansijske stabilnosti koji pokazuje analiza MSP sektora, prvi je signal da je opravdano istraživati predikciju stečaja ove grupe entiteta, što je dalje potvrđeno kroz pregled raspoložive literature na ovu temu u Republici Srbiji u narednom poglavlju. U četvrtom poglavlju, dat je sistematizovan pregled 5 tehnika koje su korišćene u modelovanju predikcije stečaja. Za svaku tehniku je prvo prezentovana teorijska osnova za primenu iste, a zatim je urađen pregled raspoloživih radova koji koriste baš tu tehniku u predikciji stečaja. Po obrađivanju teorijskih uporišta predikcije stečaja, u petom poglavlju je definisana osnova za praktičan deo modelovanja predikcije stečaja MSP u Republici Srbiji. Definisan je najpre naučni problem, pa zatim okvir istraživanja, zajedno sa uzorkom, varijablama i načinom verifikacije razvijenih modela. U šestom poglavlju se pristupa razvijanju modela putem pet tehnika: logistička regresija, diskriminantna analiza, neuronske mreže, stabla odlučivanja i k-najbližih suseda. Prvo su razvijeni modeli za predikciju stečaja godinu dana i dve godine unapred, a zatim su testirani spram preporuka relevantne literature. U poslednjem, sedmom poglavlju, urađena je sinteza svega što je rečeno, kroz uporedni prikaz uspešnosti modela, te prikaz varijabli na kojima sa isti zasnivaju, a date su i preporuke za tumačenje stejkholderima kojima ovakvi modeli mogu biti od koristi. Od ukupno 66 nezavisnih varijabli, kod predikcije stečaja godinu dana unapred (Y-1), algoritmi su selektovali 7 varijabli: TITE (odnos ukupnog prihoda i ukupnih rashoda; 3/5 modela), CS (odnos gotovine i prihoda od prodaje 1/5 modela), TAG (rast ukupne aktive iz godine u godinu; 2/5 modela), IETA (odnos troškova kamata i ukupne aktive; 1/5 modela), TDTA (odnos ukupnog duga i ukupne aktive; 3/5 modela), CFNID (odnos neto rezultata iz novčanih tokova i ukupnog duga; 1/5 modela) i OEOI (odnos operativnih rashoda i operativnih prihoda; 1/5 modela). Kada je reč o predikciji stečaja dve godine

unapred (Y-2) od ukupno 66 nezavisnih varijabli, modeli su selektovali 4 i to: CCL (odnos gotovine i kratkoročnih obaveza; 2/5 modela), CFNID (odnos neto rezultata iz novčanih tokova i ukupnog duga; 4/5 modela), OEOI (odnos operativnih rashoda i prihoda; 2/5 modela) i EBITInt (odnos EBIT-a i rashoda kamata; 1/5 modela).

Potrebno je obraditi **hipoteze istraživanja**, te proveriti stepen njihove potvrđenosti. Istraživanje je zasnovano na 4 hipoteze, jednoj glavnoj i tri pomoćne. Stepenn potvrđenosti hipoteza je prikazan u Tabeli 58, nakon čega sledi objašnjenje.

Tabela 58: Uporedni prikaz istraživačkih hipoteza i stepen njihove potvrde

GLAVNA ISTRAŽIVAČKA HIPOTEZA		NIJE POTVRĐENA	DELIMIČNO POTVRĐENA	POTVRĐENA
X₁	Na bazi tehnika mašinskog učenja i statistike, moguće je kreirati pouzdane modele predikcije stečaja godinu dana i dve godine pre pokretanja stečajnog postupka za male i srednje entitete u Republici Srbiji.			✓
POMOĆNE ISTRAŽIVAČKE HIPOTEZE		NIJE POTVRĐENA	DELIMIČNO POTVRĐENA	POTVRĐENA
X₂	Finansijski racio pokazatelji (finansijske varijable – statičke) predstavljaju najznačajnije nezavisne varijable za predikciju stečaja godinu dana i dve godine unapred, dok nefinansijske, statističke, makroekonomska (hibridna), te varijable rasta dodatno doprinose performansama modela.			✓
X₃	Neuronske mreže su superiornije u predviđanju stečaja u poređenju sa logističkom regresijom i metodom k-najbližih suseda;			✓
X₄	Stabla odlučivanja su superiornija u predviđanju stečaja u poređenju sa diskriminantnom analizom.		✓	

Izvor: Autor po uzoru na rad Gašić, 2023, str. 343.

X₁: Na bazi tehnika mašinskog učenja i statistike, moguće je kreirati pouzdane modele predikcije stečaja godinu dana i dve godine pre pokretanja stečajnog postupka za male i srednje entitete u Republici Srbiji.

- ➔ Uzevši u obzir rezultate modela mašinskog učenja, čija tačnost kod NN modela za Y-1 period iznosi 90% na trening uzorku (89% na test uzorku), odnosno za Y-2 period 76% na trening uzorku (74% na test uzorku) zaključuje se da se mogu kreirati pouzdani modeli predikcije stečaja MSP na bazi naprednih tehnika modelovanja. Stoga, *prihvata se* prva hipoteza istraživanja.

X₂: Finansijski racio pokazatelji (finansijske varijable – statičke) predstavljaju najznačajnije nezavisne varijable za predikciju stečaja godinu dana i dve godine unapred, dok nefinansijske, statističke, makroekonomska (hibridna), te varijable rasta dodatno doprinose performansama modela.

- ➔ Mnogi modeli predikcije stečaja širom sveta su razvijani upotrebom samo računovodstvenih pokazatelja koji su dostupni u finansijskim izveštajima. Ideja disertacije je bila da u modelovanje pored prethodno pomenutih, uključi i druge varijable koje su nefinansijske prirode, a ukazuju na trend ili pak dovode u vezu kretanje internih parametara sa makroekonomskim kretanjima. Druga hipoteza istraživanja se *prihvata*, kako je rast ukupne aktive (TAG) iz kategorije varijabli rasta selektovan kao važan prediktor stečaja godinu dana unapred. Osim TAG varijable, sve ostale su finansijske – statičke, što je u skladu sa definisanom hipotezom koja navodi da su ove varijable najznačajnije.

X₃: Neuronske mreže su superiornije u predviđanju stečaja u poređenju sa logističkom regresijom i metodom k-najbližih suseda

- ➔ Kako su neuronske mreže pokazale bolje rezultate od metoda logističke regresije i k-najbližih suseda u oba horizonta predviđanja (Y-1 i Y-2) mereno ukupnom tačnošću (*Accuracy*), treća hipoteza se *prihvata u potpunosti*. Performanse NN modela su na zavidnom nivou, sa trening rezultatom tačnosti 90% za Y-1 horizont i 76% za Y-2 horizont, kao i test rezultatom tačnosti 89% za Y-1 horizont, odnosno 74% za Y-2 horizont. Bitno je napomenuti da je treniranje i testiranje ova tri algoritma izvršeno na isti način - 80:20 podelom uzorka.

X₄: Stabla odlučivanja su superiornija u predviđanju stečaja u poređenju sa diskriminantnom analizom.

- ➔ Stabla odlučivanja su ostvarila bolji rezultat ukupne tačnosti (*Accuracy*) od diskriminantne analize u Y-1 vremenskom horizontu i to 84% vs. 81% prilikom treniranja i 83.5% vs. 80% prilikom testiranja modela predikcije stečaja godinu dana unapred. Međutim, kada je reč o Y-2 horizontu predviđanja, stabla odlučivanja za trening podatke pokazuju bolje rezultate 72% vs. 71%, dok pokazuju lošiji rezultat od diskriminantne analize na testiranju 69% vs. 71%. Shodno prethodno rečenom, hipoteza se *delimično prihvata*. Takođe, i kod ove hipoteze je bitno napomenuti da je treniranje i testiranje izvršeno istovetno na oba algoritma, upotrebom celog uzorka za trening, a testiranjem putem napredne validacije (k-fold).

Na kraju, važno je osvrnuti se na to da predikcija stečaja ostaje vanvremenska tema u svim privredama, pa tako i u Republici Srbiji i od neprocenjivog je značaja kako za ekonomsku teoriju, tako i za praksu – biznis. Razvijeni modeli nisu samo naučna nadgradnja, već i alati za predviđanje izazova u praksi, kao i važni resursi za buduće generacije naučnih istraživača i praktičara. Stalnim unapređivanjem ovih modela, moguće je poboljšati dodatno sposobnosti za predikciju i sprečavanje stečaja MSP, čime se direktno utiče na održivo poslovanje MSP, te na prosperitet ekonomije kao celine. U svetu u kojem su samo promene izvesne, modeli predikcije stečaja su poput svetionika koji obezbeđuju sigurnost, vodeći ka predvidivijoj budućnosti u poslovnom svetu.

LITERATURA

- [1] Abdelrahman, A. I., & Abdel-Hady, D. H. (2011). Classification of insolvent small businesses in Egypt by some running cost variables: A decision tree approach. *Applied Mathematical Sciences*, 5(9), 421-440.
- [2] Abdelwahed, T., & Amir, E. M. (2005) New evolutionary bankruptcy forecasting model based on genetic algorithms and neural networks. *In Proceedings of the 17th IEEE International Conference on Tools with Artificial Intelligence, Hong Kong, China*, 14–16 November
- [3] Abdullah, M. (2021). The implication of machine learning for financial solvency prediction: an empirical analysis on public listed companies of Bangladesh. *Journal of Asian Business and Economic Studies*, 28(4), 303-320. DOI: <https://doi.org/10.1108/JABES-11-2020-0128>
- [4] Acs, Z., & Audretsch, D. (1990). The Determinants of Small-Firm Growth in U.S Manufacturing. *Applied Economics*, 22, 143-153.
- [5] Africa, L. (2016). Financial distress for bankruptcy early warning by the risk analysis on go-public banks in Indonesia. *Journal of Economics, Bussiness & Accountancy*, 19(2), 259–270. DOI: <http://dx.doi.org/10.14414/jebav.v19i2.542>
- [6] Agencija za licenciranje stečajnih upravnika (Dostupno na: <https://alsu.gov.rs/stecaj/stecajevi/> , datum pristupa 06.10.2023.)
- [7] Agencija za privredne registre Srbije (Dostupno na: <https://apr.gov.rs/registri/finansijski-izvestaji/publikacije/godisnji-bilten-finansijskih-izvestaja.2127.html> , datum pristupa: 18.10.2023.)
- [8] Ahmadpour Kasgari, A., Divsalar, M., Javid, M. R., & Ebrahimian, S. J. (2013). Prediction of bankruptcy Iranian corporations through artificial neural network

- p and Probit-based analyses.
- Neural Comput & Applic*
- 23(3-4), 927–936. DOI:
- <https://doi.org/10.1007/s00521-012-1017-z>
- [9] Ahn, B. A., Cho, S. S., & Kim, C. Y. (2000). The integrated methodology of rough set theory and artificial neural network for business failure prediction. *Expert Systems with Applications*, 18, 65–74.
- [10] Aker, Y., & Karavardar, A. (2023). Using machine learning methods in financial distress prediction: sample of small and medium sized enterprises operating in Turkey. *Ege Academic Review*, 23(2), 145-162. DOI: <https://doi.org/10.21121/eab.1027084>
- [11] Aktan, S. (2011). Application of machine learning algorithms for business failure Prediction. *Investment Management and Financial Innovations*, 8(2), 52-65
- [12] Alaka, H. A., Oyedele, L. O., Owolabi, H. A., Kumar, V., Ajayi, S. O., Akinade, O. O., & Bilal, M. (2018). Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert Systems with Applications*, 94, 164-184. DOI: <https://doi.org/10.1016/j.eswa.2017.10.040>
- [13] Alali, F., & Romero, S. (2013). Characteristics of failed US commercial banks: An exploratory study. *Accounting & Finance*, 53(4), 1149-1174. DOI: <https://doi.org/10.1111/j.1467-629x.2012.00491.x>
- [14] Aleksić, A., Stefanović, M., Tadić, D., & Arsovski, S. (2014). A fuzzy model for assessment of organization vulnerability. *Measurement*, 51, 214–223. DOI: <https://doi.org/10.1016/j.measurement.2014.02.003>
- [15] Alfaro, E., García, N., Gámez, M., & Elizondo, D. (2008). Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks. *Decision Support Systems*, 45(1), 110–122. DOI: <https://doi.org/10.1016/j.dss.2007.12.002>
- [16] Alihodžić, A. (2013). Testing the Kralicek DF indicator application on the Belgrade Stock Exchange. *Bankarstvo*, 42(3), 70-95. (Dostupno na: <https://scindeks.ceon.rs/article.aspx?artid=1451-43541303070A>; datum pristupa 05.09.2023.)
- [17] Al-Milli, N., Hudaib, A., & Obeid, N. (2021). Population Diversity Control of Genetic Algorithm Using a Novel Injection Method for Bankruptcy Prediction Problem. *Mathematics*, 9, 823. DOI: <https://doi.org/10.3390/math9080823>

- [18] Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, 23(4), 589–609. DOI: <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
- [19] Altman, E. I. (1983). *Corporate Financial Distress*, New York, Wiley InterScience.
- [20] Altman, E. I. (2005). An emerging market credit scoring system for corporate bonds. *Emerging Markets Review*, 6, 311–323.
- [21] Altman, E., Iwanicz-Drozdzowska, M., Laitinen, E., & Suvas, A. (2017). Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z-Score Model. *Journal of International Financial Management & Accounting*, 28(2), 131–171. DOI: <https://doi.org/10.1111/jifm.12053>.
- [22] Anandarajan, M., Lee, P., & Anandarajan, A. (2001). Bankruptcy Prediction of Financially Stressed Firms: An Examination of the Predictive Accuracy of Artificial Neural Networks. *Intelligent Systems in Accounting, Finance and Management*, 10(2), 69–81. DOI: <https://doi.org/10.1002/isaf.199>
- [23] Andres, J. D., Landajo, M., & Lorca, P. (2005). Forecasting business profitability by using classification techniques: A comparative analysis based on a Spanish case. *European Journal of Operational Research*, 167, 518–542.
- [24] Andrić, M., & Vuković, B. (2011). Analiza finansijskog izveštaja i ocena performansi. *Zbornik radova XV Kongresa Saveza računovođa i revizora Republike Srpske. Teslić: Savez računovođa i revizora Republike Srpske*, 509
- [25] Apan, M., Öztel, A., & İslamoğlu, M. (2018). Comparative Empirical Analysis of Financial Failures of Enterprises with Altman Z-Score and VIKOR Methods: BIST Food Sector Application. *Australasian Accounting, Business and Finance Journal*, 12(1), 77-101. DOI: <https://doi.org/10.14453/aabfj.v12i1.6>
- [26] Archer, K. J., & Lemeshow, S. (2006). Goodness-of-fit Test for a Logistic Regression Model Fitted using Survey Sample Data. *The Stata Journal: Promoting communications on statistics and Stata*, 6(1), 97–105. DOI: <https://doi.org/10.1177/1536867X0600600106>
- [27] Asyikin, J., Chandrarin, G., & Harmono, H. (2018). Analysis of financial performance to predict financial distress in sharia commercial banks in Indonesia. *Int. Journal of Account. Financ. Econ*, 1, 11–20.

- [28] Atiya, A. F. (2001). Bankruptcy Prediction For Credit Risk Using Neural Networks: A Survey And New Results, *IEEE Transactions on Neural Networks*, 12(4), 929-935. DOI: <https://doi.org/10.1109/72.935101>.
- [29] Back, B., Laitinen, T., & Sere, K.(1996). Neural network and genetic algorithm for bankruptcy prediction, *Expert Systems with Applications*, 11(4), 407–413. DOI: [https://doi.org/10.1016/S0957-4174\(96\)00055-3](https://doi.org/10.1016/S0957-4174(96)00055-3)
- [30] Back, B., Oosterom, G., Sere, K., & Wezel, M. (1995). Intelligent Information Systems Within Business: Bankruptcy Prediction Using Neural Networks. *Proceedings of the third European Conference of Information Systems, Athens, Greece, June 1-3*, 99-111.
- [31] Balcaen, S., & Ooghe, H. (2006). 35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems. *The British Accounting Review*, 38(1), 63-93. DOI: <https://doi.org/10.1016/j.bar.2005.09.001>
- [32] Bandara, Y. M., Nguyen, H.-O., & Chen, S.-L. (2016). Influential factors in the design of port infrastructure tariffs. *Maritime Policy & Management*, 43(7), 1-13.
- [33] Bapat, V., & Nagale, A. (2014). A. Comparison of bankruptcy prediction models: Evidence from India. *Accounting & Finance Research*, 3(4), 91–98. DOI: <https://doi.org/10.5430/afr.v3n4p91>
- [34] Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405–417. DOI: <https://doi.org/10.1016/j.eswa.2017.04.006>
- [35] Barniv, R., Anurag, A., & Leach, R. (1997). Predicting the out come following bankruptcy filing: A three state classification using NN. *International Journal of Intelligent Systems in Accounting, Finance and Management* 6, 177–194.
- [36] Becerra, V., Galvao, R., & Abou-Seada, M. (2005). Neural and wavelet network models for financial distress classification. *Data Mining and Knowledge Discovery*, 11(1), 35-55. DOI: <https://doi.org/10.1007/s10618-005-1360-0>
- [37] Bellovary, J., Giacomino, D., & Akers, M. (2007). A Review of Bankruptcy Prediction Studies: 1930 to Present. *Accounting Faculty Research and Publications*, 33, 1-42

- [38] Berkham, R., G., Gudgin, M. H., & Hanvey, E. (1996). *The Determinants of Small Firm Growth - An Inter-Regional Study in the U.K.: 1986-90*, London: Jessica Kingsley
- [39] Bernard, E. (2021). *Introduction to Machine Learning*. USA: WolframMedia
- [40] Bešlić-Obradović, D., Jakšić, D., Beslic Rupic, I., & Andric, M. (2018). Insolvency prediction model of the company: the case of the Republic of Serbia. *Economic Research-Ekonomska Istraživanja*, 31(1), 139–157. DOI: <https://doi.org/10.1080/1331677x.2017.1421990>
- [41] Bhattacharya, H. (2011). Liquidity Management and Assets-Liabilities Strategy. *Banking Strategy, Credit Appraisal, and Lending Decisions*, 32–64. DOI: <https://doi.org/10.1093/acprof:oso/9780198074106.003.0002>
- [42] Bian, H., & Lawrence, M. (2003), Fuzzy-Rough Nearest Neighbor Classification Approach, in: 22nd International Conference of the North American Fuzzy Information Processing Society (NAFIPS 2003) Proceedings Chicago, 500–505.
- [43] Blanco, A., Pino-Mejías, R., Lara, J., & Rayo, S.(2013) Credit scoring models for the microfinance industry using neural networks: Evidence from Peru. *Expert Systems with Applications*, 40(1), 356–364. DOI: <https://doi.org/10.1016/j.eswa.2012.07.051>
- [44] Braun, A., Muller, K., & Schmeise, H. (2013). What Drives Insurers' Demand for Cat Bond. *The Geneva Papers on Risk and Insurance - Issues and Practice*, 38(41288), 580-611. DOI: <https://doi.org/10.1057/gpp.2012.51>
- [45] Brédart, X. (2014). Financial Distress and Corporate Governance: The Impact of Board Configuration. *International Business Research*, 7(3), 72–80. DOI: <https://doi.org/10.5539/ibr.v7n3p72>
- [46] Brenes, F., R., Johannssen, A., & Chukhrova, N. (2022). An intelligent bankruptcy prediction model using a multilayer perceptron. *Intelligent Systems with Applications*, 16, 2-18. DOI: <https://doi.org/10.1016/j.iswa.2022.200136>
- [47] Brockett, P. L., Golden, L. L., Jang, J., & Yang, C. (2006) A comparison of neural network, statistical methods, and variable choice for life insurers' financial distress prediction. *Journal of Risk and Insurance*, 73(3), 397–419. DOI: <https://doi.org/10.1111/j.1539-6975.2006.00181.x>

- [48] Brüdel, J., Preisendörfer, P., & Ziegler, R. (1992). Survival chances of newly founded organizations. *American Sociological Review*, 57(2), 227–242.
- [49] Bryant, S. M. (1997). A case-based reasoning approach to bankruptcy prediction modelling. *Intelligent Systems in Accounting, Finance and Management*, 6, 195–214
- [50] Burkov, A. (2019). *The Hundred-Page Machine Learning Book*. USA, Middletown, DE
- [51] Callejón, A. M., Casado, A. M., Fernández, M. A., & Peláez, J. I. (2013). A System of Insolvency Prediction for industrial companies using a financial alternative model with Neural Networks. *International Journal of Computational Intelligence Systems*, 6(1), 29–37. DOI: <https://doi.org/10.1080/18756891.2013.754167>
- [52] Campbell, M. (2017). Assessing whether a variable has a Normal distribution: Methods. *African Journal of Midwifery and Women's Health*, 11(4), 162–168. DOI: <https://doi.org/10.12968/ajmw.2017.11.4.162>
- [53] Caramanis, C., & Spathis, C. (2006). Auditee and audit firm characteristics as determinants of audit qualifications: Evidence from the Athens stock exchange. *Managerial Auditing Journal*, 21(9), 905-920.
- [54] Carington, S., Tran, T. (2012). What Determines Investment in Australia: The Role of Stock Market, Uncertainty and Market Imperfections?. *Proceedings of the 41st Australian Conference of Economists-The Future of Economics: Research, Policy and Relevance*, 1-28
- [55] Chakraborty, S. (2005). Prediction of Corporate Failure Using Artificial Neural Network. *International Journal of Lateral Computing*, 2(1), 30-36
- [56] Chancharat, N., Tian, G., Davy, P., McCrae, M., & Lodh, S. (2010). Multiple states of financially distressed companies: Tests using a competing risk-model. *Australasian Accounting Business and Finance Journal*, 4(4), 27–44.
- [57] Charalambous, C., Charitou, A., & Kaourou, F. (2000). Comparative Analysis of Artificial Neural Network Models: Application in Bankruptcy Prediction. *Annals of Operations Research*, 99, 403–425. DOI: <https://doi.org/10.1023/A:1019292321322>
- [58] Charitou, A., Neophytou, E., & Charalambous, C. (2004). Predicting Corporate Failure: Empirical Evidence for the UK. *European Accounting Review*, 13(3), 465–497. DOI: <https://doi.org/10.1080/0963818042000216811>

- [59] Chen, H. L., Yang, B., Wang, G., Liu, J., Xu, X., Wang, S. J., & Liu, D. Y. (2011). A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest neighbor method. *Knowledge-Based Systems*, 24(8), 1348-1359.
- [60] Chen, M. Y. (2011). Bankruptcy prediction in firms with statistical and intelligent techniques and a comparison of evolutionary computation approaches. *Computers & Mathematics with Applications*, 62(12), 4514-4524. DOI: <https://doi.org/10.1016/j.camwa.2011.10.030>
- [61] Chen, S. D., & Jhuang, S. (2018). Financial distress prediction using data mining techniques. *ICIC Express Letters, Part B: Applications*, 9(2), 131-136. (Dostupno na: <http://www.icicelb.org/ellb/contents/2018/2/elb-09-02-07.pdf>, datum pristupa 01.07.2023.)
- [62] Chen, W. S., & Du, Y. K. (2009). Using neural networks and data mining techniques for the financial distress prediction model. *Expert Systems with Applications*, 36(2), 4075–4086. DOI: <https://doi.org/10.1016/j.eswa.2008.03.020>
- [63] Cheng, C. B., Chen, C. L., & Fu, C. J. (2006). Financial Distress Prediction by a Radial Basis Function Network with Logit Analysis Learning. *Computers & Mathematics with Applications*, 51(3-4), 579–588. DOI: <https://doi.org/10.1016/j.camwa.2005.07.016>
- [64] Cheong, C., & Ramasamy, S. (2019). Bank failure: A new approach to prediction and supervision. *Asian Journal of Finance & Accounting*, 11(1), 111-140. (Dostupno na: <https://doi.org/10.5296/ajfa.v11i1.14455>, datum pristupa 05.08.2023.)
- [65] Cheraghali, H., & Molnár, P. (2023). SME default prediction: A systematic methodology-focused review. *Journal of Small Business Management*, 1–59. DOI: <https://doi.org/10.1080/00472778.2023.2277426>
- [66] Chinedu, E. F., Kenneth, A. C., Nwaolisa, E. F., & Madubuko, U. C. (2023). A comparative study of genetic algorithm and neural network model in bankruptcy prediction of manufacturing firms in Nigeria. *Journal of Contemporary Issues in Accounting*, 4(2), 231–271. (Dostupno na: <https://journals.unizik.edu.ng/jocia>, datum pristupa 20.10.2022.)
- [67] Chiou, K. C., Lo, M. M., & Wu, G. W. (2017). The Minimizing Prediction Error on Corporate Financial Distress Forecasting Model: An Application of Dynamic Distress Threshold Value. *IEEE 2017 IEEE 8th International*

- Conference on Awareness Science and Technology (iCAST) –Taichung*, 514–517.
DOI: <https://doi.org/10.1109/ICAwST.2017.8256511>
- [68] Cho, S., Hong, H., & Ha, B. C. (2010). A hybrid approach based on the combination of variable selection using decision trees and case-based reasoning using the Mahalanobis distance: For bankruptcy prediction. *Expert Systems with Applications*, 37(4), 3482–3488. DOI: <https://doi.org/10.1016/j.eswa.2009.10.040>
- [69] Choundry, M. (2006). *An Introduction to Bond Markets*. New Jersey: John Wiley & Sons
- [70] Chung, K. C., Tan, S. S., & Holdsworth, D. K. (2008). Insolvency prediction model using multivariate discriminant analysis and artificial neural network for the finance industry in New Zealand. *International Journal of Business and Management*, 39 (1), 19-28 (Dostupno na: <https://ssrn.com/abstract=1080430> ; datum pristupa 01.09.2023.)
- [71] Civelek, M., Kljucnikov, A., Fialova, V., Folvarcna, A., & Stoch, M. (2021). How innovativeness of family-owned SMEs differ depending on their characteristics?. *Equilibrium. Quarterly Journal of Economics and Economic Policy*, 16(2), 413-428.
- [72] Cleary, S., & Hebb, G. (2015). An efficient and functional model for predicting bank distress: In and out of sample evidence. *Journal of Banking & Finance*, DOI: <https://doi.org/10.1016/j.jbankfin.2015.12.001>
- [73] Costello, A. B., & Osborne, J. W. (2005). Best practices in exploratory factor analysis: Four recommendations for getting the most from your analysis. *Practical Assessment Research & Evaluation*, 10(7), 1 – 9.
- [74] Cox, D. R., & Snell, D. J. (1989). *The analysis of binary data* (2nd ed.). London: Chapman & Hall. DOI: <https://doi.org/10.1201/9781315137391>
- [75] Cybinski, P. J. (2000). The path to failure: where are bankruptcy studies at now. *Journal of Business and management*, 7(1), 11-39.
- [76] Dakić, S., & Mijić, K. (2020). Regression analysis of the impact of internal factors on return on assets: a case of meat processing enterprises in Serbia. *STRATEGIC MANAGEMENT*, 25(1), 29-34
- [77] Dakovic, R., Czado, C., & Berg, D. (2010). Bankruptcy prediction in Norway: a comparison study. *Applied Economics Letters*, 17(17), 1739-1746. DOI: <https://doi.org/10.1080/13504850903299594>

- [78] Dauderis, H., & Annand, D. (2014). *Introduction to financial accounting*, Valley Educational Services Ltd.
- [79] David, L. O., Dursun, D., & Yanyan, M. (2012). Comparative analysis of data mining methods for bankruptcy prediction. *Decision Support Systems*, 52(2), 464-473. DOI: <https://doi.org/10.1016/j.dss.2011.10.007>.
- [80] Davig, W., & Steve B. (1992). Incremental decision making in small manufacturing firms. *Journal of Small Business Management*, 30(2), 53.
- [81] Deakin, E. B. (1972). A Discriminant Analysis of Predictors of Business Failure. *Journal of Accounting Research*, 10(1), 167–179. DOI: <https://doi.org/10.2307/2490225>
- [82] Demir, S. (2022). Comparison of Normality Tests in Terms of Sample Sizes under Different Skewness and Kurtosis Coefficients. *International Journal of Assessment Tools in Education*, 9(2), 397-409. DOI: <https://doi.org/10.21449/ijate.1101295>
- [83] Derelioğlu, G., & Gürgen, F. (2011). Knowledge discovery using neural approach for SME's credit risk analysis problem in Turkey. *Expert Systems with Applications*, 38(8), 9313–9318.
- [84] DiDonato, F., & Nieddu, L. (2015). The effects of performance ratios in predicting corporate bankruptcy: The Italian case. *Lecture Notes in Business Information Processing*, 216, 61–72. DOI: https://doi.org/10.1007/978-3-319-18533-0_6
- [85] Dietrich, J. R., & Kaplan, R. S. (1982). Empirical analysis of the loan classification decision. *The Accounting Review* 57, 18–38.
- [86] Dimitras, A. I., Slowinski, R., Susmaga, R., & Zopounidis, C. (1999). Business Failure prediction using rough sets. *European Journal of Operational Research*, 114, 263-280.
- [87] Douglas, E., Lont, D., & Scott, T. (2014) Finance company failure in New Zealand during 2006–2009: Predictable failures?. *Journal of Contemporary Accounting & Economics*, 10(3), 277–295. DOI: <https://doi.org/10.1016/j.jcae.2014.10.002>
- [88] Du Jardin, P. (2009). Bankruptcy prediction models: How to choose the most relevant variables?. *Bankers, Markets & Investors*, 98(1-2), 39–46.
- [89] Du Jardin, P. (2010). Predicting bankruptcy using neural networks and other classification methods: The influence of variable selection techniques on

- p model accuracy.
- Neurocomputing*
- , 73(10), 2047-2060. DOI:
- <https://doi.org/10.1016/j.neucom.2009.11.034>
- [90] Du Jardin, P. (2015). Bankruptcy prediction using terminal failure processes. *European Journal of Operational Research*, 242(1), 286–303. DOI: <https://doi.org/10.1016/j.ejor.2014.09.059>
- [91] Du Jardin, P., & Séverin, E. (2011). Predicting corporate bankruptcy using a self-organizing map: An empirical study to improve the forecasting horizon of a financial failure model. *Decision Support Systems*, 51(3), 701-711.
- [92] Elam, R. (1975). The Effect of Lease Data on the Predictive Ability of Financial Ratios. *The Accounting Review*, 50(1), 25-43.
- [93] Elfar, N. A. (2009). *Latent Class Regression Analysis in Commercial Banks*, Master Thesis, Faculty of Commerce, Mansoura University: Egypt
- [94] Eriki, P. O., & Udegbumam, R. (2013). Predicting corporate distress in the Nigerian stock market: Neural network versus multiple discriminant analysis. *African Journal of Business Management*, 7(38), 3856-3863. DOI: <https://doi.org/10.5897/AJBM09.152>
- [95] Fedorova, E., Gilenko, E., & Dovzhenko, S. (2013). Bankruptcy prediction for Russian companies: Application of combined classifiers. *Expert Systems with Applications*, 40(18), 7285–7293. DOI: <https://doi.org/10.1016/j.eswa.2013.07.032>
- [96] Fialova, V., & Folvarcna, A. (2020). Default prediction using neural networks for enterprises from the post-soviet country. *Ekonomicko-manazerske spektrum*, 14(1), 43–51. DOI: <https://dx.doi.org/10.26552/ems.2020.1.43-51>
- [97] Field, A. (2009). *Discovering Statistics using SPSS*. London: SAGE Publications Ltd
- [98] Fitzpatrick, P. (1932). A comparison of ratios of successful industrial enterprises with those of failed firms. *Certified Public Accountant*, 1(1), 598–605.
- [99] Fletcher, D., & Goss, E. (1993). Forecasting with neural networks: an application using bankruptcy data. *Information & Management*, 24(3), 159-167.
- [100] Fridson, M., & Alvarez, F. (2002). *Financial Statements Analysis*. John Wiley & Sons Inc., New York
- [101] Ganbold, B. (2008). Improving access to finance for SME: International good experiences and lessons for Mongolia. *Institute of Developing Economies*. (Vol. 438).

- [102] García, V., Marqués, A. I., & Sánchez, J. S. (2019). Exploring the synergetic effects of sample types on the performance of ensembles for credit risk and corporate bankruptcy prediction. *Information Fusion*, 47, 88–101. DOI: <https://doi.org/10.1016/j.inffus.2018.07.004>
- [103] Gašić, D. (2023). *Fleksibilni radni aranžmani u kontekstu savremenog poslovanja i uticaja na stavove i ponašanje zaposlenih u Republici Srbiji*. Doktorska disertacija. Subotica: Ekonomski fakultet
- [104] Gepp, A., & Kumar, K. (2015). Predicting financial distress: a comparison of survival analysis and decision tree techniques. *Procedia Computer Science*, 54, 396-404.
- [105] Ghodselahi, A., & Amirmadhi, A. (2011). Application of artificial intelligence techniques for credit risk evaluation. *Int. J. Model. Optim.* 1, 243–249
- [106] Gibson, H. C. (2000). *Financial Reporting & Analysis*. Cengage Learning, Boston
- [107] Giordani, P., Jacobson, T., Von Schedvin, E., & Villani, M. (2014). Taking the twists into account: Predicting firm bankruptcy risk with splines of financial ratios. *Journal of Financial and Quantitative Analysis*, 49(4), 1071-1099.
- [108] Gissane, C. (2016). Is the data normally distributed?. *Physiotherapy Practice and Research*, 37(1), 57-60. DOI: <http://dx.doi.org/10.3233/PPR-150069>
- [109] Gordini, N. (2014). A genetic algorithm approach for SMEs bankruptcy prediction: Empirical evidence from Italy. *Expert Systems with Applications*, 41(14), 6433–6445. DOI: <https://doi.org/10.1016/j.eswa.2014.04.026>
- [110] Grover, J. (2003). *Validation of a cash flow model: A non-bankruptcy approach*. PhD dissertation, Nova Southeastern University
- [111] Gupta, J., & Gregoriou, A. (2018). Impact of market-based finance on SMEs failure. *Economic Modelling*, 69, 13-25. DOI: <https://doi.org/10.1016/j.econmod.2017.09.004>
- [112] Gupta, J., Barzotto, M., & Khorasgani, A. (2018a). Does size matter in predicting SMEs failure?. *International Journal of Finance & Economics*, 23(4), 571-605. DOI: <https://doi.org/10.1002/ijfe.1638>
- [113] Gupta, J., Wilson, N., Gregoriou, A., & Healy, J. (2014). The effect of internationalisation on modelling credit risk for SMEs: Evidence from UK

- market. *Journal of International Financial Markets, Institutions and Money*, 31, 397–413. DOI:10.1016/j.intfin.2014.05.001
- [114] Gupta, T. K., & Raza, K. (2020). Optimizing Deep Feedforward Neural Network Architecture: A Tabu Search Based Approach. *Neural Process. Lett.*, 51, 2855–2870. DOI: <https://doi.org/10.1007/s11063-020-10234-7>
- [115] Hair, J. F., Anderson, R. E., Tatham, R. L., & Black, W. C., (1998), *Multivariate Data Analysis*, 5th edition. New Jersey: Prentice Hall.
- [116] Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate Data Analysis*. New Jersey: Prentice Hall, 7th Edition
- [117] Heo, J., & Yang, J., Y. (2014). Adaboost based bankruptcy forecasting of Korean construction companies. *Appl. Soft Comput*, 24, 494–499
- [118] Hesari, S., & Akkaya, G. C. (2018). *Financial failure prediction: a study on artificial neural network and decision tree methods*. Doctoral dissertation, University Institute of Social Sciences
- [119] Ho, R. (2013). *Handbook of Univariate and Multivariate Data Analysis with IBM SPSS*. Boca Raton, FL: CRC Press. <https://doi.org/10.1201/b15605>
- [120] Holmes, S., & Zimmer, I. (1994). The Nature of Small Firm: Understanding the Motivations of Growth and Non-growth Oriented Owners, *Australian Journal of Management*, (19)1, 97-120
- [121] Hosmer D. W. Jr, Lemeshow, S., & Sturdivant R. X. (2013). *Applied logistic regression*. 3rd ed. New Jersey: John Wiley & Sons
- [122] Hosmer, D. W., & Lemeshow, S. (1989). *Applied logistic regression*. New York: Wiley.
- [123] Hu, Y. C., Jiang, P., Jiang, H., & Tsai, J. F. (2021). Bankruptcy prediction using multivariate grey prediction models. *Grey Systems: Theory and Application*, 11(1), 46-62. DOI: <https://doi.org/10.1108/gs-12-2019-0067>
- [124] Hu, Y.C., & Ansell, J. (2007). Measuring retail company performance using credit scoring techniques. *European Journal of Operational Research*, 183(3), 1595-1606. DOI: <https://doi.org/10.1016/j.ejor.2006.09.101>
- [125] Huang, S. Y., Tsaih, R. H., & Lin W. Y. (2014). Feature Extraction Of Fraudulent Financial Reporting Through Unsupervised Neural Networks. *Neural Network World*, 5(14), 539-560, DOI: <https://doi.org/10.14311/NNW.2014.24.031>

- [126] Inam, F., Inam, A., Abbas Mian, M., Sheikh, A. A., & Awan, H. M. (2018). Forecasting Bankruptcy for organizational sustainability in Pakistan: Using artificial neural networks, logit regression, and discriminant analysis. *Journal of Economic and Administrative Sciences*, 35(3), 183–201. DOI: <https://doi.org/10.1108/JEAS-05-2018-0063>
- [127] Iqbal, J., & Saeed, A. (2023). Managerial sentiments, non-performing loans, and banks financial performance: A causal mediation approach. *Chaos, Solitons & Fractals*, 171, 113425. DOI: <https://doi.org/10.1016/j.chaos.2023.113425>
- [128] Iyer, E., & Vinod K., M. (2015). Comparison of logistic regression and artificial neural network based bankruptcy prediction models. *International Journal of Business Analytics and Intelligence*, 3(1), 23-31.
- [129] Jan C. I. (2021). Financial Information Asymmetry: Using Deep Learning Algorithms to Predict Financial Distress. *Symmetry*, 13(3): 443. DOI: <https://doi.org/10.3390/sym13030443>
- [130] Jelušić, D. Z., & Gligorić, Č. (2016). *Finansijska analiza i revizija*. Beograd: Beogradska poslovna škola
- [131] Jencova, S., Petruska, I., Lukacova, M. & Abu-Zaid, J. (2021) Prediction of Bankruptcy in Non-financial Corporations Using Neural Network. *Montenegrin Journal of Economics*, 17(4), 123–134.
- [132] Jenkins, H., & Hines, F. (2003). *Shouldering the burden of corporate social responsibility: what makes business get committed?*. UK: Cardiff University.
- [133] Jo, H., Han, I., & Lee, H. (1997). Bankruptcy prediction using case-based reasoning, neural networks, and discriminant analysis. *Expert Systems with Applications*, 13(2), 97–108. DOI: [https://doi.org/10.1016/S0957-4174\(97\)00011-0](https://doi.org/10.1016/S0957-4174(97)00011-0)
- [134] Judge, G. G., Hill, R. C., Griffiths, W. E., Lutkepohl, H., & Lee, T. (1987). *Theory and Practice of Econometrics* (2nd ed.). New York, NY: Wiley.
- [135] Kanapickiene, R., & Spicas, R. (2019). Credit Risk Assessment Model for Small and Micro-Enterprises: The Case of Lithuania. *Risks*, 7(2), 67. DOI: <https://doi.org/10.3390/risks7020067>

- [136] Karimova, N., Ochilov, U., Yakhshiev, S., & Egamberdiev, I. (2024). Predictive maintenance of cutting tools using artificial neural networks. *In E3S Web of Conferences* (Vol. 471, p. 02021)
- [137] Karlsson, M., & Dieden Sandell, S. (2016). Absolute & Relative Credit Quality Assessment. (Dostupno na: <https://lup.lub.lu.se/luur/download?func=downloadFile&recordId=8883825&fileId=8883828>, datum pristupa 09.09.2023.)
- [138] Karsoliya, S. (2012). Approximating Number of Hidden Layer Neurons in Multiple Hidden Layer BPNN Architecture. *Int. J. Eng. Trends Technol*, 3, 714–717
- [139] Keasey, K., & Watson, R. (1986). The prediction of small company failure: Some behavioral evidence for the UK. *Accounting and Business Research* 17, 49-57
- [140] Khan, U. E. (2018). Bankruptcy prediction for financial sector of Pakistan: Evaluation of logit and discriminant analysis approaches. *Pakistan Journal of Engineering, Technology & Science*, 6(2).
- [141] Kim, S. Y. (2011). Prediction of hotel bankruptcy using support vector machine, artificial neural network, logistic regression, and multivariate discriminant analysis. *The Service Industries Journal*, 31(3), 441–468. DOI: <https://doi.org/10.1080/02642060802712848>
- [142] Kim, H., & Zheng, G. (2006). Predicting restaurant bankruptcy: A logit model in comparison with a discriminant model. *Journal of Hospitality & Tourism Research* 30, 474–93.
- [143] Kim, M. J., & Kang, D. K. (2010). Ensemble with neural networks for bankruptcy prediction. *Expert Systems with Applications*, 37(4), 3373–3379. DOI: <https://doi.org/10.1016/j.eswa.2009.10.012>
- [144] Kim, S. Y. (2010). Prediction of hotel bankruptcy using support vector machine, artificial neural network, logistic regression, and multivariate discriminant analysis. *The Service Industries Journal*, 31(3), 441–468. DOI: <https://doi.org/10.1080/02642060802712848>
- [145] Klepáč, V., & Hampel, D. (2018). Predicting bankruptcy of manufacturing companies in EU, *E+M Ekonomie a Management = Economics and Management*, 159-173. DOI: <https://doi.org/10.15240/tul/001/2018-1-011>
- [146] Klikovac, A. (2009). *Financijsko izvestavanje u EU*. Zagreb: Mate

- [147] Kljucnikov, A., Civelek, M., Fialova, V., & Folvarcna, A. (2021). Organizational, local, and global innovativeness of family-owned SMEs depending on firm-individual level characteristics: Evidence from the Czech Republic. *Equilibrium. Quarterly Journal of Economics and Economic Policy*, 16(1), 169-184.
- [148] Korol, T. (2013). Early warning models against bankruptcy risk for Central European and Latin American enterprises. *Economic Modelling*, 31, 22-30. DOI: <https://doi.org/10.1016/j.econmod.2012.11.017>
- [149] Korol, T. (2019) Dynamic Bankruptcy Prediction Models for European Enterprises. *Journal of Risk and Financial Management* 12(4), 185. DOI: <https://doi.org/10.3390/jrfm12040185>
- [150] Kosmidis, K., & Stavropoulos, A. (2014). Corporate failure diagnosis in SMEs: A longitudinal analysis based on alternative prediction models. *International Journal of Accounting & Information Management*, 22, 49–67. DOI: <https://doi.org/10.1108/IJAIM-01-2013-0001>
- [151] Kotsiantis, S., & Kanellopoulos, D. (2008). Multi-Instance Learning for Bankruptcy Prediction. *IEEE 2008 Third International Conference on Convergence and Hybrid Information Technology (ICCIT) - Busan, Korea, ()*, 1007–1012. DOI: <https://doi.org/10.1109/iccit.2008.129>
- [152] Kotsiantis, S., Tzelepis, D., Koumanakos, E., & Tampakas, V. (2007). Selective costing voting for bankruptcy prediction. *International Journal of Knowledge-based and Intelligent Engineering Systems*, 11(2), 115–127. DOI: <https://doi.org/10.3233/KES-2007-11204>
- [153] Kotsiantis, S., Tzelepis, D., Koumanakos, E., & Tampakas, V. (2005). Efficiency of machine learning techniques in bankruptcy prediction. In *2nd International Conference on Enterprise Systems and Accounting*, 39-49
- [154] Kouki, M., & Elkhaldi, A. (2011). Toward a predicting model of firm bankruptcy: Evidence from the Tunisian context. *Middle East Financ.Econ*, 14, 26–43.
- [155] Kovacova, M., Kliestik, T., Valaskova, K., Durana, P., & Juhaszova, Z. (2019). Systematic review of variables applied in bankruptcy prediction models of Visegrad group countries. *Oeconomia Copernicana*, 10(4), 743–772. DOI: <https://doi.org/10.24136/oc.2019.034>

- [156] Koyuncugil, A. S., & Ozgulbas, N. (2012). Financial early warning system model and data mining application for risk detection. *Expert systems with Applications*, 39(6), 6238-6253. DOI: <https://doi.org/10.1016/j.eswa.2011.12.021>
- [157] Krulicky, T., & Horak, J. (2021). Business performance and financial health assessment through artificial intelligence. *Ekonomicko-manazerske spektrum*, 15(2), 38-51. DOI: <https://doi.org/10.26552/ems.2021.2.38-51>
- [158] Kušter, D. (2021). Financial stability of enterprises in Serbian agriculture, fishing and forestry sector. *Ekonomika poljoprivrede*. 68(3). 745-758. DOI: <https://doi.org/10.5937/ekoPolj2103745K>.
- [159] Kušter, D. (2023a). Construction of bankruptcy prediction model using discriminant analysis and financial ratios. *Ekonomija: teorija i praksa*, 16(1), 1-22. DOI: <https://doi.org/10.5937/etp2301001K>.
- [160] Kušter, D. (2023b). Efficiency of Working Capital & Assets Management in the Function of SMEs Bankruptcy Prediction. *Management: Journal Of Sustainable Business And Management Solutions In Emerging Economies*, 28(3), 57-70. DOI: <https://doi.org/10.7595/management.fon.2023.0007>
- [161] Kušter, D., Vuković, B., Milutinović, S., Peštović, K., Tica, T., & Jakšić, D. (2023). Early Insolvency Prediction as a Key for Sustainable Business Growth. *Sustainability*, 15(21): DOI: 15304. <https://doi.org/10.3390/su152115304>
- [162] Lahmiri, S., & Bekiros, S. (2019). Can machine learning approaches predict corporate bankruptcy? Evidence from a qualitative experimental design. *Quantitative Finance*, 19(9), 1569–1577. DOI: <https://doi.org/10.1080/14697688.2019.1588468>
- [163] Laitinen, E. K. (1999). Predicting a corporate credit analyst's risk estimate by logistic and linear models. *International Review of Financial Analysis*, 8(2), 97-121.
- [164] Laitinen, E. K., & Laitinen, T. (2000). Bankruptcy prediction. *International Review of Financial Analysis*, 9(4), 327–349. DOI: [https://doi.org/10.1016/s1057-5219\(00\)00039-9](https://doi.org/10.1016/s1057-5219(00)00039-9)
- [165] Le, H. H., & Viviani, J. L. (2018). Predicting bank failure: An improvement by implementing a machine-learning approach to classical financial ratios. *Research in International Business and Finance*, 44, 16-25.

- [166] Lee, K. C., Han, I., & Kwon, Y. (1996). Hybrid neural network models for bankruptcy predictions. *Decision Support Systems*, 18, 63–72
- [167] Lee, S., & Choi, W. S. (2013). A multi-industry bankruptcy prediction model using back-propagation neural network and multivariate discriminant analysis. *Expert Systems with Applications*, 40(8), 2941–2946. DOI: <https://doi.org/10.1016/j.eswa.2012.12.009>
- [168] Lee, S., Choi, K., & Yoo, D. (2020). Predicting the insolvency of SMEs using technological feasibility assessment information and data mining techniques. *Sustainability*, 12, 1–17. DOI: <https://doi.org/10.3390/su12239790>
- [169] Leshno, M., & Spector, Y. (1996). Neural network prediction analysis: The bankruptcy case. *Neurocomputing*, 10(2), 125–147. DOI: [https://doi.org/10.1016/0925-2312\(94\)00060-3](https://doi.org/10.1016/0925-2312(94)00060-3)
- [170] Liang, D., Lu, C. C., Tsai, C. F., & Shih, G. A. (2016). Financial Ratios and Corporate Governance Indicators in Bankruptcy Prediction: A Comprehensive Study. *European Journal of Operational Research*, 252(2), 561–572. DOI: <https://doi.org/10.1016/j.ejor.2016.01.012>
- [171] Liang, D., Tsai, C. F., Dai, A. J., & Eberle, W. (2017). A novel classifier ensemble approach for financial distress prediction. *Knowledge and Information Systems*, 54(2), 437–462. DOI: <https://doi.org/10.1007/s10115-017-1061-1>
- [172] Lin, F. Y., & McClean, S. (2001). A data mining approach to the prediction of corporate failure. *Knowledge-Based Systems*, 14(3-4), 189–195. DOI: [https://doi.org/10.1016/s0950-7051\(01\)00096-x](https://doi.org/10.1016/s0950-7051(01)00096-x)
- [173] Lin, F., Liang, D., Yeh, C. C., & Huang, J. C. (2014). Novel feature selection methods to financial distress prediction. *Expert Systems with Applications*, 41(5), 2472–2483. DOI: <https://doi.org/10.1016/j.eswa.2013.09.047>
- [174] Lin, L., & Piesse, J. (2004). Identification of corporate distress in UK industrials: a conditional probability analysis approach. *Applied Financial Economics*, 14 (2), 73–82. DOI: <https://doi.org/10.1080/0960310042000176344>
- [175] Lin, T. H. (2009). A cross model study of corporate financial distress prediction in Taiwan: Multiple discriminant analysis, logit, probit and neural networks models. *Neurocomputing*, 72(16-18), 3507–3516. DOI: <https://doi.org/10.1016/j.neucom.2009.02.018>

- [176] Lugovskaya, L. (2010). Predicting default of Russian SMEs on the basis of financial and nonfinancial variables. *Journal of Financial Services Marketing*, 14, 301–313. DOI: <https://doi.org/10.1057/fsm.2009.28>
- [177] Luoma, M., & Laitinen, E. (1991). Survival Analysis As A Tool For Company Failure Prediction. *OMEGA* 19(6), 673–678.
- [178] Mai, F., Tian, S., Lee, C., & Ma, L. (2019). Deep learning models for bankruptcy prediction using textual disclosures. *European Journal of Operational Research*, 274(2), 743-758. <https://doi.org/10.1016/j.ejor.2018.10.024>
- [179] Malinić, D., Milićević, V. & Stevanović, N. (2013). *Upravljačko računovodstvo*. Beograd: Ekonomski fakultet.
- [180] Mann, H. B., & Whitney, D. R. (1947). On a test of whether one of two random variables is stochastically larger than the other. *Annals of Mathematical Statistics*, 18, 50–60
- [181] Manjrekar, J., & Damani, A. D. (2023). Identifying Representative Financial Ratios of The Indian Tyre Industry: A Principal Component Analysis Approach. *The Indonesian Journal of Accounting Research*, 26(1), 125-150. DOI: <https://doi.org/10.33312/ijar.632>
- [182] Marchesini, L. (2020) *Data analysis for bankruptcy prediction: the wholesale and retail sector in Italy*. Master thesis. Italy: Università Degli Studi Di Padova
- [183] Marinković, D., Nikolić, B., & Dragović, I. (2014). Predicting Bankruptcy Of Companies Using Neural Networks And Regression Models. *Business Intelligence And Decision Making In Management*, 37, 157.
- [184] Masten, A. B., & Masten, I. (2012). Predicting bankruptcy with semi-parametric single-index model. *Economic Research*, 25(1), 121–133. DOI: <https://doi.org/10.1080/1331677X.2012.11517497>
- [185] McGurr, P. T., & Devaney, S. A. (1998). A retail failure prediction model. *The International Review of Retail, Distribution and Consumer Research*, 8(3), 259–276. DOI: <https://doi.org/10.1080/095939698342779>
- [186] McKee, T. E. (1995). Predicting bankruptcy via induction. *Journal of Information Technology*, 10(1), 26-36.
- [187] Mendes, M., & Pala, A. (2003). Type I Error Rate and Power of Three Normality Tests. *Pakistan Journal of Information and Technology* 2(2): 135-139.
- Dostupno na: <https://www.researchgate.net/profile/Akin->

- [Pala/publication/26556526_Type_I_Error_Rate_and_Power_of_Three_Normality_Tests/links/0046352d4e5f57e58d000000/Type-I-Error-Rate-and-Power-of-Three-Normality-Tests.pdf](#), datum pristupa 12.12.2022.)
- [188] Meyers, L. S., Gamst, G., & Guarino, A. J. (2006). *Applied Multivariate Research – design and interpretation*. London: SAGE Publications
- [189] Michael, S., Georgios, D., Nikolaos, M., & Constantin, Z. (1999). A fuzzy knowledge-based decision aiding method for the assessment of financial risk: The case of corporate bankruptcy prediction, in: *European Symposium on Intelligent Techniques, Crete, Greece*.
- [190] Michel C., Dan G., & Robert M. (2001). Prototype risk rating system. *Journal of Banking & Finance*, 25(1), 47–95. DOI: [https://doi.org/10.1016/s0378-4266\(00\)00117-5](https://doi.org/10.1016/s0378-4266(00)00117-5)
- [191] Milic, D., Tekic, D., Zekic, V., Novakovic, T., Popov, M., & Mihajlov, Z. (2021). Bankruptcy prediction models for large agribusiness companies in AP Vojvodina. *Economics of Agriculture*, 68(3), 805-822. DOI: <https://doi.org/10.5937/ekoPolj2103805M>
- [192] Min J. H., Jeong, C. (2009). A binary classification method for bankruptcy prediction. *Expert Systems with Applications*, 36, 5256– 5263
- [193] Ming, W., Yu-ru, Q., & Xing-chen, L. (2013). Empirical research of financial performance on the convergence of informatization and industrialization based on listed companies in Shaanxi province. In *2013 International Conference on Management Science and Engineering 20th Annual Conference Proceedings, IEEE*. 1764-1769. DOI: <https://doi.org/10.1109/icmse.2013.6586505>
- [194] Mizdrakovic, V., & Bokic, M. (2017). Reassessment of corporate bankruptcy prediction models efficiency: evidence from Serbia. *Teme*, 40(4), 1368-1382. DOI: <https://doi.org/1367.10.22190/TEME1604367M>
- [195] Mohd Shafarin, N. A. (2019). A Study of Relationship between Liquidity Risk with External and Internal Factors. (Dostupno na: https://mpra.ub.uni-muenchen.de/97203/1/MPRA_paper_97203.pdf, datum pristupa 14.12.2020)
- [196] Mossman, C. E., Bell, G. G., Swartz, L. M., & Turtle, H. (1998). An empirical comparison of bankruptcy models. *The Financial Review*, 33(2), 35– 54. DOI: <https://doi.org/10.1111/j.1540-6288.1998.tb01367.x>
- [197] Mselmi, N., Lahiani, A., & Hamza, T. (2017). Financial distress prediction: The case of French small and medium-sized firms. *International*

- Review of Financial Analysis*, 50, 67–80. DOI: <https://doi.org/10.1016/j.irfa.2017.02.004>
- [198] Mu, Y., C. (2011). Bankruptcy prediction in firms with statistical and intelligent techniques and a comparison of evolutionary computation approaches. *Computers & Mathematics with Applications*, Volume 62(12), 4514-4524. DOI: <https://doi.org/10.1016/j.camwa.2011.10.030>.
- [199] Mujkić, E. & Poljašević, J. (2023). Prediction of insolvency using logistic regression: The case of the Republic of Srpska. *Ekonomski vjesnik*, 36(1), 127-141. DOI: <https://doi.org/10.51680/ev.36.1.10>
- [200] Muminović, S., Pavlović, V., & Cvijanović, J. M. (2011). Predictive ability of various bankruptcy prediction z-score models for Serbian publicly listed companies. *Industrija*, 39(3), 1-12. (Dostupno na: <https://scindeks.ceon.rs/article.aspx?artid=0350-03731103001M>; datum pristupa: 24.08.2023.)
- [201] Murray, B. (2023). *Neural Networks for Beginners*. Monee, IL, USA: Virtued Press
- [202] Nagelkerke, N. J. D. (1991). A note on a general definition of the coefficient of determination. *Biometrika* 78, 691–692. DOI: <https://doi.org/10.1093/biomet/78.3.691>
- [203] Naidu, G. P., & Govinda, K. (2018). Bankruptcy prediction using neural networks. In *IEEE - 2018 2nd International conference on inventive systems and control (ICISC)*, 248-251. DOI: <https://doi.org/10.1109/icisc.2018.8399072>
- [204] Nayak, A., & Greenfield, S. (1994). The use of management accounting information for managing micro businesses. *Finance and the Small Firm*, 182-231.
- [205] Neely, A. (1998). *Measuring Business Performance: Why, What and How*. London: The Economist and Profile Books Ltd
- [206] Nelson, T. (2003). The Persistence of Founder Influence: Management, Ownership, and Performance Effects at Initial Public Offering. *Strategic Management Journal*, 24(8), 707-724. Preuzeto sa <http://onlinelibrary.wiley.com/doi/10.1002/smj.328/pdf>, datum pristupa 01.06.2023.)

- [207] Neophytou, E., & Molinero, C. M. (2004). Predicting Corporate Failure in the UK: A Multidimensional Scaling Approach. *J. Bus. Financ. Account.*, 31, 677–710. DOI: <https://doi.org/10.1111/j.0306-686X.2004.00553.x>
- [208] Nguyen, M., Nguyen, B., & Lieu, M. L. (2023). Corporate financial distress prediction in a transition economy. DOI: <http://dx.doi.org/10.2139/ssrn.4552384>
- [209] Nikolić, N., Jovanović, I., Nikolić, Đ., Mihajlović, I., & Schulte, P. (2018). Investigation of the Factors Influencing SME Failure as a Function of Its Prevention and Fast Recovery after Failure. *Entrepreneurship Research Journal*, 9(3), 20170030. DOI: <https://doi.org/10.1515/erj-2017-0030>
- [210] Nikolić, N., Nikolić, D., Marinkovic, S., & Mihajlovic, I. (2020). Application of FAHP–PROMETHEE Hybrid Model for Prioritizing SMEs Failure Factors. *Engineering Management Journal*, 33(3), 202–219. DOI: <https://doi.org/10.1080/10429247.2020.1788332>
- [211] Nilsson, A. (2010). Balancing the management control package of small, rapidly growing firms in turbulent environments. *International Journal of Entrepreneurship and Small Business*, 11(1), 3–24. DOI: <https://doi.org/10.1504/IJESB.2010.03442>
- [212] Nuryani, Y., & Sunarsi, D. (2020). The Effect of Current Ratio and Debt to Equity ratio on Dividing Growth. *JASa*, 4(2), 304-312
- [213] Ocal, N., Ercan, M. K., & Kadioglu, E. (2015). Predicting Financial Failure Using Decision Tree Algorithms: An Empirical Test on the Manufacturing Industry at Borsa Istanbul. *International Journal of Economics and Finance*, 7(7). DOI: <https://doi.org/10.5539/ijef.v7n7p189>
- [214] Ohlson, J. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109–131. DOI: <https://doi.org/10.2307/2490395>
- [215] Orcan, F. (2020). Parametric or Non-parametric: Skewness to Test Normality for Mean Comparison. *International Journal of Assessment Tools in Education*, 7(2), 255-265. DOI: <https://doi.org/10.21449/ijate.656077>
- [216] Oribel, T., & Hanggraeni, D. (2021). An Application of Machine Learning in Financial Distress Prediction Cases in Indonesia. *International Journal of Business and Technology Management*, 3(2), 98-110.

- [217] Pallant, J. (2009). *SPSS survival manual: A step by step guide to data analysis using IBM SPSS*. Routledge
- [218] Panchal, G., Ganatra, A., Kosta, Y. P., & Panchal, D. (2011) Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers. *Int. J. Comput. Theory Eng.* 2011, 3, 332–337. DOI: <https://doi.org/10.7763/IJCTE.2011.V3.328>
- [219] Papan, A., & Spyridou, A. (2020). Bankruptcy Prediction: *The Case of the Greek Market. Forecasting*, 2(4), 505–525. DOI: <https://doi.org/10.3390/forecast2040027>
- [220] Papík, M., & Papíková, L. (2024). Automated Machine Learning in Bankruptcy Prediction of Manufacturing Companies. *Procedia Computer Science*, 232, 1428-1436.
- [221] Paramasivan, C., & Subramanian, T. (2009). *Financial Management*. New age international publishers
- [222] Paraschiv, F., Schmid, M., & Wahlstrøm, R. R. (2023). Bankruptcy prediction of privately held SMEs using feature selection methods. (Dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3911490 , datum pristupa 01.05.2024.)
- [223] Paule-Vianez, J., Gómez-Martínez, R., & Prado-Román, C. (2020). A bibliometric analysis of behavioural finance with mapping analysis tools. *European Research on Management and Business Economics*, 26, 71–77. DOI: <https://doi.org/10.1016/j.iemeen.2020.01.001>
- [224] Peel, M. J., Wilson, N., & Howorth, C. A. (2000). Late payment and credit management in the small firm sector: some empirical evidence. *International Small Business Journal*, 18(2), 17–37
- [225] Pervan, I., Pervan, M., & Vukoja, B. (2011). Prediction of company bankruptcy using statistical techniques—Case of Croatia. *Croatian Operational Research Review*, 2(1), 158-167. (Dostupno na: <https://hrcak.srce.hr/96660>; datum pristupa: 01.09.2023.)
- [226] Phelps, M., C., & Merkle, E., C. (2008). Classification and Regression Trees as Alternatives to Regression, *Proceedings of the 4th Annual GRASP Symposium*, 77-78.
- [227] Pindado, J., & Rodrigues, L., F. (2004). Parsimonious Models of Financial insolvency in Small Companies. *Small Business Economics*, 22, 51-66

- [228] Piramuthu, S., Ragavan, H., & Shaw, M., J. (1998). Using feature construction to improve the performance of the neural networks, *Management Science* 44(3)
- [229] Raffael F. B., Arne J., & Nataliya C. (2022). An intelligent bankruptcy prediction model using a multilayer perceptron. *Intelligent Systems with Applications*, 16, 200136. DOI: <https://doi.org/10.1016/j.iswa.2022.200136>.
- [230] Rafiei, F. M., Manzari, S. M., Bostanian, S. (2011). Financial health prediction models using artificial neural networks, genetic algorithm and multivariate discriminant analysis: Iranian evidence. *Expert Systems with Applications*, 38(8), 10210–10217. DOI: <https://doi.org/10.1016/j.eswa.2011.02.082>
- [231] Rangoonwala, N., & Bhatia, H. (2020). Application of Artificial Neural Network to Predict Wilful Default for Commercial Banks in India. *Int. J. Bus. Anal. Intell*, 8, 13–22
- [232] Ranković, J. (1995) *Upravljanje finansijama preduzeća*. Beograd: Ekonomski fakultet.
- [233] Rashid, A., & Abbas, Q. (2011). Predicting Bankruptcy in Pakistan. *Theoretical & Applied Economics*, 18(9), 103-128
- [234] Rasolomanana, O. M. (2022), Bankruptcy Prediction Model Using Machine Learning. PhD Thesis, University of Hokkaido, Japan. DOI: <https://doi.org/10.14943/doctoral.k14923>
- [235] Ravisankar, P., Ravi, V., & Bose, I. (2010). Failure prediction of dotcom companies using neural network–genetic programming hybrids. *Inf. Sci.*, 180(8), 1257–1267. DOI: <https://doi.org/10.1016/j.ins.2009.12.022>
- [236] Razali, N. M., & Wah, Y. B. (2010). Power comparisons of some selected normality tests. *In proceedings of the regional conference on statistical sciences*, 126-138. (Dostupno na lokaciji: https://www.researchgate.net/profile/Bee-Yap/publication/228457917_Power_comparisons_of_some_selected_normality_tests/links/5477245b0cf245eb43729e37/Power-comparisons-of-some-selected-normality-tests.pdf, datum pristupa 01.03.2020.)
- [237] Reid, G. C., & Smith, J. A. (2000). The impact of contingencies on management accounting system development. *Management Accounting Research*, 11(4), 427-450.

- [238] Rencher, A. (2002). *Methods of Multivariate Analysis*. New York: John Wiley & Sons, 2nd Edition
- [239] Republički zavod za statistiku. (2023). *Preduzeća po veličini i preduzetnici u Republici Srbiji, 2020-2022*. (Preuzeto sa <https://stat.gov.rs/sr-Latn/vesti/20240725-preduzeca-po-velicini-i-preduzetnici-2020-2022/?a=0&s=1803> dana 16. jun 2024. godine
- [240] Robinson, A. P. (1989). *Essential Accounting for Managers*. Cassel Publishers Ltd, London
- [241] Robinson, T., Greuning, H., Henry, E., & Broihahn, M. (2009). *International Financial Statements Analysis*, John Wiley & Sons, Inc., New Jersey
- [242] Rochon, J., Gondan, M. & Kieser, M. (2012). To test or not to test: Preliminary assessment of normality when comparing two independent samples. *BMC Med Res Methodol* 12(81), DOI: <https://doi.org/10.1186/1471-2288-12-81>
- [243] Rodić, J., Andrić, M., Vuković, B., & Jakšić, D. (2024). *Analiza finansijskih izveštaja*. Subotica: Ekonomski fakultet
- [244] Roiger, R. J., & Geatz, M. (2003). *Data Mining: A Tutorial-Based Primer*; Addison Wesley: Boston, MA, USA.
- [245] Ryu, Y. U., & Yue, W. T. (2005). Firm bankruptcy prediction: Experimental comparison of isotonic separation and other classification approaches. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 35(5), 727–737. DOI: <https://doi.org/10.1109/TSMCA.2005.843393>
- [246] Salina, A. P., Zhang, X., & Hassan, O., A., G. (2021). An assessment of the financial soundness of the Kazakh banks. *Asian Journal of Accounting Research*, 6(1), 23-37. DOI: <https://doi.org/10.1108/AJAR-03-2019-0022>
- [247] Sehgal, S., Mishra, R. K., Deisting, F., & Vashisht, R. (2021). On the determinants and prediction of corporate financial distress in India. *Managerial Finance*, 47(10), 1428-1447. DOI: <https://doi.org/10.1108/MF-06-2020-0332>
- [248] Shabbir, S. (2012). Monetary Transmission in Pakistan: The Balance Sheet Channel. MPRA Paper. (Dostupno na: <https://mpra.ub.uni-muenchen.de/37862/> , datum prisutpa 04.02.2021)
- [249] Shachmurove, Y. (2002). Applying Artificial Neural Networks to Business, Economics and Finance, Working Paper 02–08; Center for *Analytic*

- Research in Economics and the Social Sciences*, University of Pennsylvania: Philadelphia, PA, USA, 1–47.
- [250] Shanthi, R. (2019). *Multivariate Data Analysis Using SPSS and AMOS*. New Delhi: MJP Publishers
- [251] Shaw, M. J., & Gentry, J. A. (1990). Inductive learning for risk classification. *IEEE Expert*, 5, 47–53
- [252] Shetty, S., Musa, M., & Brédart, X. (2022). Bankruptcy Prediction Using Machine Learning Techniques. *Journal of Risk and Financial Management*, 15(1), 35. DOI: <https://doi.org/10.3390/jrfm15010035>
- [253] Shi, Y., & Li, X. (2019). An overview of bankruptcy prediction models for corporate firms: A systematic literature review. *Intangible Capital*, 15(2), 114–127. DOI: <https://doi.org/10.3926/ic.1354>
- [254] Shie, F. S., Chen, M. Y., & Liu, Y. S. (2012). Prediction of corporate financial distress: an application of the America banking industry. *Neural Computing and Applications*, 21(7), 1687–1696. DOI: <https://doi.org/10.1007/s00521-011-0765-5>
- [255] Shin, K. S., & Lee, Y.-J. (2002). A genetic algorithm application in bankruptcy prediction modelling. *Expert Systems with Applications*, 23(3), 321–328.
- [256] Shin, K. S., Lee, T. S., & Kim, H. J. (2005). An application of support vector machines in bankruptcy prediction model. *Expert systems with applications*, 28(1), 127–135. DOI: <https://doi.org/10.1016/j.eswa.2004.08.009>
- [257] Simić, D., Kovačević, I., & Simić, S. (2012). Insolvency prediction for assessing corporate financial health. *Logic Journal of the IGPL*, 20(3), 536–549, DOI: <https://doi.org/10.1093/jigpal/jzr009>
- [258] Situm, M. (2014). The age and the size of the firm as relevant predictors for bankruptcy. *Journal of Applied Economics and Business*, 2(1), 5 – 30.
- [259] Slefendorfas, G. (2016) Bankruptcy prediction model for private limited companies of Lithuania. *Ekonomika* 95(1), 134–152
- [260] Smiti, S., & Soui, M. (2020). Bankruptcy prediction using deep learning approach based on borderline SMOTE. *Information Systems Frontiers*, 22(5), 1067–1083. DOI: <https://doi.org/10.1007/s10796-020-10031>

- [261] Sokka, I. (2020). *Constructing a predictive model for assessing the bankruptcy risk of Finnish SMEs*. Master thesis. Netherlands: Aalto University
- [262] Sricharoenchit, N., & Hensawang, S. (2021). Bankruptcy Prediction Model using Logit Regression in the Automotive Sector. *Conference: 1st International Conference on Sustainable Management and Innovation, ICoSMI 2020*, 250-270
- [263] Stachova, M., Kral, P., Sobisek, L., & Kakascik, M. (2015). Analysis of financial distress of Slovak companies using repeated measurements. *Applications of Mathematics and Statistics in Economics*. (Dostupno na: https://amse-conference.eu/history/amse2015/doc/Stachova_Kral_Sobisek_Kakascik.pdf, datum pristupa 08.05.2022.)
- [264] Stanišić, N., Mizdraković, V., & Knežević, G. (2013). Corporate Bankruptcy Prediction in the Republic of Serbia. *Industrija*, 41(4), 145-159. DOI: <https://doi.org/10.5937/industrija41-4024>
- [265] Studenmund, A. H. (2006). *Using econometrics, a practical guide (fifth edition)*. New York: Addison-Wesley.
- [266] Subramanyam, R., K., & Wild, J. J. (2009). *Financial Statement Analysis*. New York: McGraw-Hill.
- [267] Suleiman, S., & Badamsi, S. (2019). Effect of Multicollinearity in Predicting Diabetes Mellitus Using Statistical Neural Network. *European Journal of Advances in Engineering and Technology*, 6(6), 30-38. (Dostupno na: https://www.researchgate.net/profile/Shamsuddeen-Suleiman/publication/355368142_Effect_of_Multicollinearity_in_Predicting_Diabetes_Mellitus_Using_Statistical_Neural_Network/links/616d08c6951b3574c65dcd73/Effect-of-Multicollinearity-in-Predicting-Diabetes-Mellitus-Using-Statistical-Neural-Network.pdf , datum pristupa 01.06.2022.)
- [268] Sung, T. K., Chang, N., & Lee, G. (1999). Dynamics of modeling in data mining: interpretive approach to bankruptcy prediction. *Journal of management information systems*, 16(1), 63-85. DOI: <https://doi.org/10.1080/07421222.1999.11518234>
- [269] Swicegood, P., & Clark, J. A. (2001). Off-site monitoring for predicting bank under performance: A comparison of neural networks, discriminant analysis

- and professional human judgment. *International Journal of Intelligent Systems in Accounting, Finance and Management*, 10, 169–186
- [270] Szetela, B., Mentel, G., & Brożyna, J. (2016). In search of insolvency among European countries. *Economic Research-Ekonomska Istraživanja*, 29(1), 839–856. <https://doi.org/10.1080/1331677X.2016.1237301>
- [271] Taffler, R. J. (1983). The Assessment of Company Solvency and Performance Using a Statistical Model. *Accounting and Business Research*, 13(52), 295–308. DOI: <https://doi.org/10.1080/00014788.1983.9729767>
- [272] Tam, K. Y., & Kiang, M. (1992). Predicting bank failures: A neural network approach. *Decision Sciences*, 23, 926–947
- [273] Tay, F. E. H., & Shen, L. (2002). Economic and financial prediction using rough set model. *European Journal of Operational Research*, 141, 641–659.
- [274] Terdpaopong, K., & Mihret, D. G. (2011). Modelling SME credit risk: Thai empirical evidence. *Small Enterprise Research*, 18, 63–79. DOI: <https://doi.org/10.5172/ser.18.1.63>
- [275] Theobald, O. (2021). *Machine Learning for Absolute Beginners*. Monee, IL, USA: Scatterplot Press, 2nd Edition
- [276] Tinoco, M. H. & Wilson, N. (2013). Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables. *International Review of Financial Analysis*, 30, 394–419. DOI: <https://doi.org/10.1016/j.irfa.2013.02.013>
- [277] Todorović, M. (2010). *Poslovno i finansijsko restrukturiranje preduzeća*. Beograd: Ekonomski fakultet
- [278] Trading Economics (Dostupno na: <https://tradingeconomics.com/country-list/bankruptcies?continent=europe> , datum pristupa 16.11.2024)
- [279] Trifonova, O., Lokhov, P., & Archakov, A. I. (2014). Metabolic profiling of human blood. *Biomeditsinskaya Khimiya*, 60, 281-294. DOI: <https://doi.org/10.18097/pbmc20146003281>
- [280] Tseng, F. M., & Hu, Y.C. (2010). Comparing four bankruptcy prediction models: Logit, quadratic interval logit, neural and fuzzy neural networks. *Expert Systems with Applications*, 37(3), 1846–1853. DOI: <https://doi.org/10.1016/j.eswa.2009.07.081>
- [281] Tseng, H. P., Chen, P. C., Huang, W. H., Lei, M. C., & Tran, Q. H. (2014). Prediction of default probability for construction firms using the logit model.

- Journal of civil engineering and management*, 20(2), 247–255. DOI: <https://doi.org/10.3846/13923730.2013.801886>
- [282] Tung, W. L., Quek, C., & Cheng, P. (2004). GenSo-EWS: A novel neural-fuzzy based early warning system for predicting bank failures, *Neural Networks* 17(), 567–587.
- [283] Tušek, B., & Gabrić, D. (2017). Analiza novčanih pokazatelja kvalitete dobiti u funkciji utvrđivanja računovodstvenih manipulacija u finansijskim izvještajima kotirajućih preduzeća u Federaciji BIH. *Proceedings of the Faculty of Economics and Business in Zagreb*, 15(2), 85-103. <https://doi.org/10.22598/zefzg.2017.2.85>
- [284] Virag, M., & Kristof, T. (2005). Neural networks in bankruptcy prediction- a comparative study on the basis of the first Hungarian bankruptcy model. *Acta Oeconomica*, 55(4), 403–426. DOI: <https://doi.org/10.1556/aoecon.55.2005.4.2>
- [285] Virglerova, Z., Ivanova, E., Dvorsky, J., Belas, J., & Krulicky, T. (2021). Selected factors of internationalisation and their impact on the SME perception of the market risk. *Oeconomia Copernicana*, 12 (4), 1011–1032. DOI: <https://doi.org/10.24136/oc.2021.033>
- [286] Vlaovic-Begovic, S., Bonic, Lj., & Jovin, S. (2021). A comparison of the bankruptcy prediction models on a sample of Serbian companies. *Teme*, 44(2), 503-518. DOI: <https://doi.org/10.22190/TEME180619036V>
- [287] Vlaović-Begović, S., & Bonić, Lj. (2020). Developing A Model To Predict Corporate Bankruptcy Using Decision Tree In The Republic Of Serbia. *Facta Universitatis: Economics and Organization*, 17(2), 127-139. DOI: <https://doi.org/10.22190/FUEO191118010V>
- [288] Vuković, B., Milutinovic, S., Milićević, N., & Jakšić, D. (2020). Corporate bankruptcy prediction: evidence from wholesale companies in the Western European countries. *Ekonomicky casopis*, 68(5), 477-498. (Dostupno na: https://www.researchgate.net/publication/340917901_Corporate_Bankruptcy_Prediction_Evidence_from_Wholesale_Companies_in_the_Western_European_Countries, datum pristupa: 17.06.2023.)
- [289] Wang, G., Ma, J., & Yang, S. (2014). An improved boosting based on feature selection for corporate bankruptcy prediction. *Expert Systems with Applications*, 41(5), 2353-2361. DOI: <https://doi.org/10.1016/j.eswa.2013.09.033>

- [290] Wen, M., & Meng, L. (2019). Research on Financial Early Warning of Private Listed Companies Based on Z-score. *Advances in Economics, Business and Management Research* 94, 360-363. DOI: <https://doi.org/10.2991/jahp-19.2019.76>
- [291] www.paragraf.rs (Preuzeto sa: <https://www.paragraf.rs/propisi/zakon-o-racunovodstvu-2020.html>, datum pristupa 02.04.2021.)
- [292] Yazdanfar, D. (2011). Predicting bankruptcy among SMEs: evidence from Swedish firm-level data. *International Journal of Entrepreneurship and Small Business*, 14(4), 551. DOI: <https://doi.org/10.1504/ijesb.2011.043475>
- [293] Yim, J., & Mitchell, H. (2005). A Comparison of Corporate Distress Prediction Models in Brazil: Hybrid Neural Networks, Logit Models and Discriminant Analysis. *Nova Econ.*, 15, 73–93.
- [294] Yoon, J. S., & Kwon, Y. S. (2010). A practical approach to bankruptcy prediction for small businesses: Substituting the unavailable financial data for credit card sales information. *Expert Systems with Applications*, 37(5), 3624–3629. DOI: <https://doi.org/10.1016/j.eswa.2009.10.029>
- [295] Zakon o računovodstvu ("Sl. glasnik RS", br. 73/2019 i 44/2021 - dr. zakon)
- [296] Zakon o stečaju Republike Srbije ("Sl. glasnik RS", br. 104/2009, 99/2011 - dr. zakon, 71/2012 - odluka US, 83/2014, 113/2017, 44/2018 i 95/2018)
- [297] Zebardast, M., Javid, D., & Taherinia, M. (2014). The use of artificial neural network in predicting bankruptcy and its comparison with genetic algorithm in firms accepted in Tehran Stock Exchange. *J. Nov. Appl. Sci.*, 3, 151–160.
- [298] Zelenkov, Y., Fedorova, E., & Chekrizov, D. (2017). Two-step classification method based on genetic algorithm for bankruptcy forecasting. *Expert Systems with Applications*, 88, 393–401. DOI: <https://doi.org/10.1016/j.eswa.2017.07.025>
- [299] Zenzerovic, R., & Perusko, T. (2009). Evaluating the assumption of going concern in a transitionaleenvironment – Empirical findings in Croatia. *Ekonomski Pregled*, 60(7–8), 348–368. (Dostupno na: <https://hrcak.srce.hr/40482>, datum pristupa 23.09.2022.)

- [300] Zhai, S. S., Choi, J. G., & Kwansa, F. (2015). A financial ratio-based predicting model for hotel business failure. *Global Business & Finance Review (GBFR)*, 20(1), 71-86. DOI: <https://doi.org/10.17549/gbfr.2015.20.1.71>
- [301] Zhang, W. (2017) Machine Learning Approaches to Predicting Company Bankruptcy. *Journal of Financial Risk Management*, 6(4), 364-374. DOI: <https://doi.org/10.4236/jfrm.2017.64026>.
- [302] Zhou, Y., & Elhag, T. M. (2007). Apply logit analysis in bankruptcy prediction. *Proceedings of the 7th WSEAS International Conference on Simulation, Modelling and Optimization*, 302-308.
- [303] Zulkarnain, M. S., Mohamad Ali, A. H., Annuar, M. N., & Zainal Abidin, M. (2001). Forecasting corporate failure in Malaysian industrial sector firms. *Asian Academy of Management Journal*, 6(1), 15-30.

SPISAK TABELA, SLIKA I ŠEMATSKIH PRIKAZA

PREGLED TABELA, SLIKA I ŠEMA:

Tabela 1: Prikaz ukupnog broja entiteta koji čine sektor MSP u Republici Srbiji u periodu 2015-2020. godina

Tabela 2: Analiza dugoročne finansijske stabilnosti MSP i ACID test za vremenski period 2015-2020. godina

Tabela 3: Analiza kratkoročne finansijske stabilnosti MSP i ACID test za vremenski period 2015-2020. godina

Tabela 4: Analiza povrata na aktivu (ROA) MSP u Republici Srbiji u vremenskom intervalu 2015-2020. godina

Tabela 5: Analiza povrata na uloženi kapital (ROE) MSP u vremenskom intervalu 2015-2020. godina

Tabela 6: Opšti prikaz srazmere stečaja i likvidacije u Republici Srbiji

Tabela 7: Sistematizovan pregled tehnika predikcije stečaja

PREGLED TABELA, SLIKA I ŠEMA:

Tabela 8: Sistematizovani pregled nezavisnih varijabli u modelima predikcije stečaja

Tabela 9: Pregled nezavisnih varijabli istraživanja ($\Sigma 66$)

Tabela 10: Test normalnosti za varijable koje se koriste u modelovanju predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Tabela 11: Test normalnosti za varijable koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Tabela 12: Men-Vitni test za varijable koje se koriste u modelovanju predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Tabela 13: Men-Vitni test za varijable koje *nemaju normalnu distribuciju* i koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Tabela 14: T-test za varijable koje *imaju normalnu distribuciju* i koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Tabela 15: VIF test multikolinearnosti za varijable koje se koriste u modelovanju predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Tabela 16: VIF test multikolinearnosti za varijable koje se koriste u modelovanju predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Tabela 17: Kodiranje zavisne varijable za modelovanje predikcije stečaja godinu dana (Y-1) i dve godine unapred (Y-2)

Tabela 18: Struktura uzorka za generisanje i testiranje modela Y-1 i Y-2 (trening i test skup)

Tabela 19: Varijable uključene u model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

PREGLED TABELA, SLIKA I ŠEMA:

Tabela 20: Test značajnosti varijabli uključenih u model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 21: Rezultati testa za varijable koje nisu uključene u model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 22: Omnibus test razvijenih modela predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 23: “Cox & Snell” i “Nagelkerke R Square” testovi razvijenih modela predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 24: “Hosmer & Lemeshow” test razvijenih modela predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 25: Matrica za modele predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 26: Dodatni testovi normalnosti nakon normalizacije varijabli za generisanje modela predikcije stečaja godinu dana unapred (Y-1)

Tabela 27: Dodatni testovi normalnosti nakon normalizacije varijabli za generisanje modela predikcije stečaja dve godine unapred (Y-2)

Tabela 28: Struktura uzorka za generisanje i testiranje modela predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tabela 29: Analiza jednakosti srednjih vrednosti grupa za model predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tabela 30: Selektovane varijable po *Stepwise* principu za model predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tabela 31: Koeficijenti diskriminantne funkcije za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

PREGLED TABELA, SLIKA I ŠEMA:

Tabela 32: Centroidi grupa diskriminantne funkcije za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tabela 33: Log determinante za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tabela 34: Boks-ov M test (*Box's M*) za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tabela 35: Sopstvene vrednosti (*Eigenvalues*) za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tabela 36: Vilksova Lambda (Wilks' Lambda) za modele predikcije stečaja godinu dana unapred (Y-1) i dve godine unapred (Y-2)

Tabela 37: Matrica za modele predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 38: KMO i Bartlet-ov test za varijable koje se koriste u modelovanju predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 39: Faktorska analiza – PCA - za model predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Tabela 40: Faktorska analiza – PCA - za model predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Tabela 41: Faktorska analiza – PCA – rotirana matrica za model predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Tabela 42: Faktorska analiza – PCA – rotirana matrica za model predikcije stečaja dve godine pre pokretanja postupka (Y-1)

Tabela 43: Osnovne informacije o podeli uzorka za NN modelovanje predikcije stečaja godinu i dve pre pokretanja postupka

PREGLED TABELA, SLIKA I ŠEMA:

Tabela 44: Osnovne informacije o postavkama neuronske mreže za model predikcije stečaja godinu dana unapred (levo) i dve godine unapred (desno)

Tabela 45: Osnovne informacije o treniranju i testiranju neuronskih mreža za model predikcije stečaja godinu dana (Y-1) i dve godine unapred (Y-2)

Tabela 46: Matrica konfuzije za model predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 47: Površina ispod krive za model predikcije stečaja godinu dana i dve godine pre pokretanja postupka

Tabela 48: Sumarni pregled postavki modela stabla odlučivanja za predikciju stečaja godinu dana (Y-1) i dve godine (Y-2) unapred

Tabela 49: Matrica konfuzije za modele predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 50: Rezultati unakrsne validacije za modele predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) pre pokretanja postupka

Tabela 51: Osnovne informacije o podeli uzorka za kNN modelovanje predikcije stečaja godinu (Y-1) i dve (Y-2) pre pokretanja postupka

Tabela 52: Selektovane varijable u modelima predikcije stečaja godinu dana unapred (Y-1)

Tabela 53: Selektovane varijable u modelima predikcije stečaja dve godine unapred (Y-2)

Tabela 54: Deskriptivna statistika za najznačajnije varijable predikcije stečaja godinu dana unapred (Y-1)

Tabela 55: Deskriptivna statistika za najznačajnije varijable predikcije stečaja dve godine unapred (Y-2)

PREGLED TABELA, SLIKA I ŠEMA:

Tabela 56: Uporedni prikaz klasifikacionih rezultata razvijenih modela predikcije stečaja godinu dana unapred (Y-1)

Tabela 57: Uporedni prikaz klasifikacionih rezultata razvijenih modela predikcije stečaja dve godine unapred (Y-2)

Tabela 58: Uporedni prikaz istraživačkih hipoteza i stepen njihove potvrde

Slika 1: Promet po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021 godina (mil. RSD)

Slika 2: Bruto dodata vrednost po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina (mil. RSD)

Slika 3: Broj izvoznika po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina

Slika 4: Izvoz robe po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina

Slika 5: Broj uvoznika po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina

Slika 6: Vrednost uvoza robe po veličini preduzeća (i preduzetnici) u Republici Srbiji za period 2019-2021. godina

Slika 7: Ukupni prihodi privrednih društava prema veličini u 2022. godini

Slika 8: Poslovna imovina privrednih društava prema veličini u 2022. godini

Slika 9: Vizuelni prikaz ACID testa za analizu dugoročne finansijske (ne)stabilnosti MSP u Republici Srbiji u vremenskom periodu 2015-2020. godina

PREGLED TABELA, SLIKA I ŠEMA:

Slika 10: Vizuelni prikaz ACID testa za analizu kratkoročne finansijske (ne)stabilnosti MSP u Republici Srbiji u vremenskom periodu 2015-2020. godina

Slika 11: Distribucija istraživanja na temu predikcije stečaja MSP

Slika 12: Vizuelni prikaz sigmoidne funkcije

Slika 13: Vizuelni prikaz diskriminantne funkcije

Slika 14: Vizuelni prikaz neuronske mreže

Slika 15: Primer stabla odlučivanja

Slika 16: Predikcija na bazi k-NN metode – primer

Slika 17: Vizuelni prikaz uzorka istraživanja za razvoj modela predikcije stečaja godinu dana (Y-1) i dve godine (Y-2) unapred

Slika 18: Broj varijabli koji je korišćen u predikciji stečaja MSP po dekadama

Slika 19: Teorijski prikaz matrice konfuzije (*Confusion Matrix*)

Slika 20: Najčešće korišćene metode za selekciju ključnih varijabli

Slika 21: *Heatmap* prikaz korelacije varijabli iz modelovanja predikcije stečaja godinu dana unapred (Y-1)

PREGLED TABELA, SLIKA I ŠEMA:

Slika 22: *Heatmap* prikaz korelacije varijabli iz modelovanja predikcije stečaja dve godine unapred (Y-2)

Slika 23: Vizuelni prikaz diskriminacionih zona (*Group centroids*) funkcije za predikciju stečaja godinu dana unapred (Y-1)

Slika 24: Vizuelni prikaz diskriminacionih zona (*Group centroids*) funkcije za predikciju stečaja dve godine unapred (Y-2)

Slika 25: „Scree plot” grafikon za model predikcije stečaja godinu dana pre pokretanja postupka (Y-1)

Slika 26: „Scree plot” grafikon za model predikcije stečaja dve godine pre pokretanja postupka (Y-2)

Slika 27: Vizuelni prikaz neuronske mreže za predikciju stečaja godinu dana pre pokretanja postupka (Y-1)

Slika 28: Vizuelni prikaz neuronske mreže za predikciju stečaja dve godine pre pokretanja postupka (Y-2)

Slika 29: Varijable od značaja za predikciju stečaja godinu dana pre pokretanja postupka (Y-1)

Slika 30: Varijable od značaja za predikciju stečaja dve godine pre pokretanja postupka (Y-2)

Slika 31: ROC kriva za model predikcije stečaja godinu dana unapred (Y-1)

Slika 32: ROC kriva za model predikcije stečaja dve godine unapred (Y-2)

Slika 33: Vizuelni prikaz stabla odlučivanja za predikciju stečaja godinu dana pre pokretanja postupka (Y-1)

PREGLED TABELA, SLIKA I ŠEMA:

Slika 34: Vizuelni prikaz stabla odlučivanja za predikciju stečaja dve godine pre pokretanja postupka (Y-2)

Slika 35: Prediktorski prostor za KNN model predikcije stečaja godinu dana unapred (Y-1)

Slika 36: Prediktorski prostor za KNN model predikcije stečaja dve godine unapred (Y-2)

Slika 37: Značaj varijabli za predikciju stečaja godinu dana unapred (Y-1)

Slika 38: Značaj varijabli za predikciju stečaja dve godine unapred (Y-2)

Slika 39: Matrica konfuzije za k-NN model predikcije stečaja godinu dana (Y-1) pre pokretanja postupka

Slika 40: Matrica konfuzije za k-NN model predikcije stečaja dve godine (Y-2) pre pokretanja postupka

Šema 1: Konceptualni okvir doktorske disertacije (*en. Framework*)

Šema 2: Detaljni pregled faze 4 konceptualnog okvira doktorske disertacije

Šema 3: Detaljni pregled faze 5 konceptualnog okvira doktorske disertacije

PRILOZI

Prilog 1: Tabelarni prikaz malih i srednjih preduzeća u uzorku

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
07099983	B	2018	2017	2016	AD ŽUPLJANKA ALEKSANDROV AC	PRERAĐIVAČKA INDUSTRIJA
07574851	B	2019	2018	2017	M.D. NINI DOO NIŠ, VAZDUHOPLOV ACA BB	PRERAĐIVAČKA INDUSTRIJA
08254699	B	2018	2017	2016	MAJEVICA- POLJOOPREMA AD BAČKA PALANKA	PRERAĐIVAČKA INDUSTRIJA
08254672	B	2018	2017	2016	MAJEVICA- PUMPE I CISTERNE AD BAČKA PALANKA	PRERAĐIVAČKA INDUSTRIJA
20236698	A	2019	2018	2017	AMBALAŽERKA DOO BEOGRAD, BEGALJICA	PRERAĐIVAČKA INDUSTRIJA

³⁵ A = aktivno preduzeće / B = preduzeće u stečaju

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
20387742	A	2019	2018	2017	BELARUS- AGROPANONKA DOO NOVI SAD	PRERAĐIVAČKA INDUSTRIJA
20876565	A	2019	2018	2017	BOSS CONSTRUCTION	SNABDEVANJE ELEKTRIČNOM ENERGIJOM, GASOM, PAROM I KLIMATIZACIJA
08092427	A	2019	2018	2017	DTD RIBARSTVO	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20286768	A	2019	2018	2017	FAMOZO STYLE DOO IVANJICU	PRERAĐIVAČKA INDUSTRIJA
06326943	A	2019	2018	2017	GRAKOM SN DOO BEOGRAD	PRERAĐIVAČKA INDUSTRIJA
17151517	A	2019	2018	2017	HOLLAND ANGRO DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21211834	A	2019	2018	2017	JAVNO PREDUZEĆE ŠUME	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
17518216	A	2019	2018	2017	KTD DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
21129631	A	2019	2018	2017	LANISI	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20406984	A	2019	2018	2017	MAG CREATIVE	PRERAĐIVAČKA INDUSTRIJA
20175877	A	2019	2018	2017	MELPO DOO DOBANOVCI	PRERAĐIVAČKA INDUSTRIJA
20988959	A	2019	2018	2017	TIM INDUSTRIEL STEEL D.O.O. NIŠ	PRERAĐIVAČKA INDUSTRIJA
20466316	A	2019	2018	2017	TRENČ DOO ZRENJANIN	GRAĐEVINARSTVO
21031194	B	2019	2018	2017	AGRAR KVATRO DOO SMEDEREVO	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20497564	B	2019	2018	2017	AUDIO PLANETA DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20423200	B	2019	2018	2017	DECOTRA POWER DOO LOZNICA	SNABDEVANJE ELEKTRIČNOM ENERGIJOM, GASOM, PAROM I KLIMATIZACIJA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
08657432	B	2019	2018	2017	DOO VITALIS TRADE NOVI SAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21072435	B	2019	2018	2017	FRAD PRODUCTION D.O.O. ALEKSINAC	PRERAĐIVAČKA INDUSTRIJA
07207786	B	2019	2018	2017	GUMOPLASTIKA DOO BUJANOVAC	PRERAĐIVAČKA INDUSTRIJA
20230274	B	2020	2019	2018	HOME PLUS DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20036613	B	2019	2018	2017	HOSANA DOO POŽEGA	PRERAĐIVAČKA INDUSTRIJA
06347673	B	2019	2018	2017	INTER-KOP DOO ŠABAC	GRAĐEVINARST VO
21122866	B	2019	2018	2017	NECA-TTPP D.O.O. PROKUPLJE	PRERAĐIVAČKA INDUSTRIJA
20994398	B	2019	2018	2017	NEODOLJIVO BILJE DOO SUBOTICA	PRERAĐIVAČKA INDUSTRIJA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
07185090	B	2019	2018	2017	NISSAL DOO SREMSKA MITROVICA	PRERAĐIVAČKA INDUSTRIJA
06881980	B	2019	2018	2017	PKB IMES DOO BEOGRAD- PADINSKA SKELA	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
07342691	B	2019	2018	2017	ŽELEZARA DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20263229	A	2020	2019	2018	AB CONSTRUCT TEAM DOO BEOGRAD	GRAĐEVINARST VO
08648166	A	2020	2019	2018	DOO BEL CAR NOVI SAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20332271	A	2020	2019	2018	DOO JOVISTE PALIĆ	PRERAĐIVAČKA INDUSTRIJA
17611143	A	2020	2019	2018	FILI DOO SVILAJNAC	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
17546660	A	2020	2019	2018	JP LEBANE	GRAĐEVINARSTVO
21161128	A	2020	2019	2018	JS&O AD	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
61198733	A	2020	2019	2018	LJUBENKOVIĆ	PRERAĐIVAČKA INDUSTRIJA
20561653	A	2020	2019	2018	PANAPAC D.O.O. BAJINA BAŠTA	PRERAĐIVAČKA INDUSTRIJA
20393742	A	2020	2019	2018	SIB INVEST DOO NIŠ	GRAĐEVINARSTVO
21102687	A	2020	2019	2018	SWISS PAPIER	PRERAĐIVAČKA INDUSTRIJA
08762074	A	2020	2019	2018	ZZ AGROSOJ NEUZINA	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
21031658	B	2021	2020	2019	AGROHOMA DOO RUSKI KRSTUR	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
06076831	B	2020	2019	2018	ANTIĆ I SIN DOO NIŠ-MEDIJANA	PRERAĐIVAČKA INDUSTRIJA
20045426	B	2020	2019	2018	BALKAN STRATEGIC GROUP DOO NOVI SAD	GRAĐEVINARSTVO

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
20421762	B	2020	2019	2018	DAROV PRIRODE	PRERAĐIVAČKA INDUSTRIJA
17449486	B	2020	2019	2018	DUGA FRUIT DOO KRUŠEVAC	PRERAĐIVAČKA INDUSTRIJA
20818883	B	2020	2019	2018	LUČIĆ PRODUKT DM DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
07042612	B	2020	2019	2018	MAKOVICA AD MLADENOVAC	PRERAĐIVAČKA INDUSTRIJA
17187384	B	2020	2019	2018	NEIMAR PROJEKT DOO NIŠ	GRAĐEVINARST VO
21042137	B	2020	2019	2018	NIKAM 2014	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20076852	B	2020	2019	2018	URBAN 018 DOO NIŠ	GRAĐEVINARST VO
08562016	B	2020	2019	2018	ZZ BAĆO VRBAS	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20019565	A	2021	2020	2019	AGROSTOJ DOO GLOGONJ	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20051515	A	2021	2020	2019	AKO MED DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO;

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21041122	A	2021	2020	2019	AL RAWAFED SRBIJA D.O.O	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
08709645	A	2021	2020	2019	D & B COMPANY DOO STARI BANOVCI	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20134615	A	2021	2020	2019	DECORAMA DOO ŠABAC	SAOBRAĆAJ I SKLADIŠTENJE
20498005	A	2021	2020	2019	ENERGY STAR INTERNATIONA L	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20905956	A	2021	2020	2019	ESM D.O.O	PRERAĐIVAČKA INDUSTRIJA
21273791	A	2021	2020	2019	GEBI LOGISTIKA DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
20966645	A	2021	2020	2019	GREEN POWER TURBINE SYSTEMS D.O.O. BEOGRAD	PRERAĐIVAČKA INDUSTRIJA
17182226	A	2021	2020	2019	KOŽAR DOO	PRERAĐIVAČKA INDUSTRIJA
20959436	A	2021	2020	2019	MAJDAN LUKS D.O.O. BEOGRAD	USLUGE SMEŠTAJA I ISHRANE
17541447	A	2021	2020	2019	MDS INFORMATIČKI INŽENJERING DOO BEOGRAD	PRERAĐIVAČKA INDUSTRIJA
20179171	A	2021	2020	2019	O&M INŽENJERING GROUP DOO ZRENJANIN	PRERAĐIVAČKA INDUSTRIJA
56060561	A	2021	2020	2019	OROLOGIO I	PRERAĐIVAČKA INDUSTRIJA
17481665	A	2021	2020	2019	OXYGEN DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
08718407	A	2021	2020	2019	OZZ ŽUNJI- SILAK TEMERIN	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
08065888	A	2021	2020	2019	SAVA KOVAČEVIĆ DOO VRBAS	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
17539680	A	2021	2020	2019	SKY TECHNOLOGIES DOO BEOGRAD	ADMINISTRATIVNE I POMOĆNE USLUŽNE DELATNOSTI
17618768	A	2021	2020	2019	SMAJ PRODUKT DOO LAZAREVO SELO	PRERAĐIVAČKA INDUSTRIJA
21103233	A	2021	2020	2019	SMRČAK-BBS	PRERAĐIVAČKA INDUSTRIJA
21015008	A	2021	2020	2019	THERMO TEC FLEX DOO	GRAĐEVINARSTVO
20518863	A	2021	2020	2019	VIZURA SPORT DOO BEOGRAD, ZEMUN	USLUGE SMEŠTAJA I ISHRANE
06636110	B	2021	2020	2019	AGRO - MIL DOO POJATE	PRERAĐIVAČKA INDUSTRIJA
07411618	B	2021	2020	2019	AGROMAČVANI N DOO ŠABAC	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20359340	B	2021	2020	2019	AGROOFFICE DOO NOVI SAD	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20084740	B	2021	2020	2019	AGROPROM COM DOO	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
20666706	B	2021	2020	2019	B&J VAJAGIĆ AUTOBUSI	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
17614029	B	2021	2020	2019	BELLA 9 DOO ŠABAC	PRERAĐIVAČKA INDUSTRIJA
20043873	B	2021	2020	2019	BOFOR KGD DOO LOZNICA	PRERAĐIVAČKA INDUSTRIJA
20570288	B	2021	2020	2019	DECOR LIFE DOO BEOGRAD- STARI GRAD	GRAĐEVINARST VO
08349169	B	2021	2020	2019	DOO GRAFIČAR NOVI SAD	PRERAĐIVAČKA INDUSTRIJA
17045156	B	2021	2020	2019	EKOFARM DOO BEOGRAD	PRERAĐIVAČKA INDUSTRIJA
20458844	B	2021	2020	2019	FRUIT INTERNATIONA L DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21032760	B	2021	2020	2019	GRIL	PRERAĐIVAČKA INDUSTRIJA
08656908	B	2021	2020	2019	IM MATIĆ DOO NOVI SAD	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
08218838	B	2021	2020	2019	KOMPAS TOURISM &TRAVEL DOO NOVI SAD	ADMINISTRATIV NE I POMOĆNE USLUŽNE DELATNOSTI
07866518	B	2021	2020	2019	LAGERMAX ELITTE DOO SIBNICA- REKOVAC	SAOBRAĆAJ I SKLADIŠTENJE
06670938	B	2021	2020	2019	MIDO COMMERCE DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20957328	B	2021	2020	2019	MITA MD D.O.O. VRANJE	PRERAĐIVAČKA INDUSTRIJA
08040443	B	2021	2020	2019	MITEKS AD STARA MORAVICA	PRERAĐIVAČKA INDUSTRIJA
21356948	B	2021	2020	2019	PIZZA LAB D.O.O.	USLUGE SMEŠTAJA I ISHRANE
20245310	B	2021	2020	2019	RETAIL COFFEE DOO BEOGRAD	USLUGE SMEŠTAJA I ISHRANE
08695202	B	2021	2020	2019	TEPKOS DOO ČONOPLJA	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20244488	A	2022	2021	2020	AGRO RAVANGRAD DOO SOMBOR	TRGOVINA NA VELIKO I TRGOVINA NA MALO;

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21224227	A	2022	2021	2020	AGROSIMSA DOO SRBOBRAN	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20950269	A	2022	2021	2020	ALFA KOZMETIK GROUP D.O.O. BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
17581538	A	2022	2021	2020	APOTEKARSKA USTANOVA ADONIS	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20249552	A	2022	2021	2020	ARMONT DOO STARA PAZOVA	GRAĐEVINARST VO
20534141	A	2022	2021	2020	ARTEMOBILI DOO VETERNIK	ADMINISTRATIV NE I POMOĆNE USLUŽNE DELATNOSTI
20040297	A	2022	2021	2020	BANIJA-PAL	PRERAĐIVAČKA INDUSTRIJA
20860162	A	2022	2021	2020	BRICO S	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						VOZILA I MOTOCIKALA
21186511	A	2022	2021	2020	CASH & CARRY PLUS DOO KULA	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
17443151	A	2022	2021	2020	COMPLEX VIDIKOVAC NIŠ	USLUGE SMEŠTAJA I ISHRANE
20164654	A	2022	2021	2020	DELTAPLAST DOO MAČKAT	PRERAĐIVAČKA INDUSTRIJA
20072512	A	2022	2021	2020	DIPLOD DOO BEOGRAD, ZEMUN	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
08596182	A	2022	2021	2020	DOO FARM COMMERC ČANTAVIR	PRERAĐIVAČKA INDUSTRIJA
21199150	A	2022	2021	2020	ENERGY DELIVERY SOLUTIONS D.O.O. BEOGRAD	SNABDEVANJE ELEKTRIČNOM ENERGIJOM, GASOM, PAROM I KLIMATIZACIJA
20491515	A	2022	2021	2020	EPCG DOO BEOGRAD	SNABDEVANJE ELEKTRIČNOM ENERGIJOM, GASOM, PAROM

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						I KLIMATIZACIJA
17546961	A	2022	2021	2020	GOLD SALT DOO NIŠ, ULICA BRANKA KRSMANOVIĆA 57	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20941537	A	2022	2021	2020	IP PROMET 2010 DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20505800	A	2022	2021	2020	J&M CORN DOO CREPAJA	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
21025372	A	2022	2021	2020	JKP RAVNO 2014 ČUPRIJA	SNABDEVANJE VODOM; UPRAVLJANJE OTPADNIM VODAMA, KONTROLISANJ E PROCESA UKLANJANJA OTPADA I SLIČNE AKTIVNOSTI
21062383	A	2022	2021	2020	JP VODOVOD MAJDANPEK	SNABDEVANJE VODOM; UPRAVLJANJE OTPADNIM VODAMA, KONTROLISANJ E PROCESA UKLANJANJA OTPADA I

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						SLIČNE AKTIVNOSTI
20048140	A	2022	2021	2020	KINGSPAN DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21269883	A	2022	2021	2020	MAB GMBH DOO	GRAĐEVINARST VO
20392126	A	2022	2021	2020	MK-FINTEL WIND AD	SNABDEVANJE ELEKTRIČNOM ENERGIJOM, GASOM, PAROM I KLIMATIZACIJA
50634043	A	2022	2021	2020	NEDELJKOVIĆ	PRERAĐIVAČKA INDUSTRIJA
06651747	A	2022	2021	2020	OLI KOOP DOO VRNJAČKA BANJA	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20173289	A	2022	2021	2020	PDTPU IBS- TRADE DOO NOVI PAZAR	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						VOZILA I MOTOCIKALA
17475061	A	2022	2021	2020	PERKOM KLEK DOO KLEK	SAOBRAĆAJ I SKLADIŠTENJE
21159140	A	2022	2021	2020	PESAK SREM DOO	SAOBRAĆAJ I SKLADIŠTENJE
07360479	A	2022	2021	2020	PROGRES DOO MALI ZVORNIK	PRERAĐIVAČKA INDUSTRIJA
20200472	A	2022	2021	2020	S I B ŠPED-TRANS DOO LUŽANE, ŽITKOVAC	SAOBRAĆAJ I SKLADIŠTENJE
06703151	A	2022	2021	2020	SB TRADE DOO BEOGRAD	PRERAĐIVAČKA INDUSTRIJA
21298930	A	2022	2021	2020	SD VISOKOGRADNJA DOO NIŠ	GRAĐEVINARSTVO
20993898	A	2022	2021	2020	SISTEMI BAND DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20349883	A	2022	2021	2020	SPLENDID FUTURE DOO ARILJE	PRERAĐIVAČKA INDUSTRIJA
21104990	A	2022	2021	2020	SYNERGY TECH D.O.O. BEOGRAD	PRERAĐIVAČKA INDUSTRIJA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
21235873	A	2022	2021	2020	T - NAFTA TRGOVINA D.O.O. BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20158077	A	2022	2021	2020	TEHNO VG TRADE DOO NOVI SAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20480912	A	2022	2021	2020	TS STORK GROUP DOO KULA	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21168696	A	2022	2021	2020	VIGORTIM D.O.O. NIŠ	ADMINISTRATIVNE I POMOĆNE USLUŽNE DELATNOSTI
20254173	A	2022	2021	2020	VULE - MARKET DOO BEOGRAD, SREMČICA	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20479850	A	2022	2021	2020	WORTS TEAM DOO ŠIMANOVCI	TRGOVINA NA VELIKO I TRGOVINA NA MALO;

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20142952	A	2022	2021	2020	ZZ GREEN- GROUP ŠID	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20048425	B	2022	2021	2020	AD APETIT NIŠ	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20600381	B	2022	2021	2020	AGH INŽENJERING & MARKETING DOO NIŠ	PRERAĐIVAČKA INDUSTRIJA
17028685	B	2022	2021	2020	AGROLAZAREVI Ć PARAĆIN	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
08709793	B	2022	2021	2020	AGROLEK DOO VRŠAC	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20319399	B	2022	2021	2020	AGROOMEGA DOO ŽABALJ	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
21362263	B	2022	2021	2020	ALLEN DOO	PRERAĐIVAČKA INDUSTRIJA
21203912	B	2022	2021	2020	ALU HOLDING	PRERAĐIVAČKA INDUSTRIJA
17154001	B	2022	2021	2020	ANDRAX NK DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20801077	B	2022	2021	2020	BIG BULL FOODS DOO ĐURĐIN	PRERAĐIVAČKA INDUSTRIJA
20750677	B	2022	2021	2020	C&A MODA RS DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20917385	B	2022	2021	2020	DOBAR DOMAĆIN DOO POŽAREVAC	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
17577603	B	2022	2021	2020	DOO AGRIKOL KRUŠEVAC	GRAĐEVINARSTVO

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
21408069	B	2022	2021	2020	ECOLUX RECYCLING SEE DOO POŽAREVAC	SNABDEVANJE VODOM; UPRAVLJANJE OTPADNIM VODAMA, KONTROLISANJ E PROCESA UKLANJANJA OTPADA I SLIČNE AKTIVNOSTI
20482672	B	2022	2021	2020	ENAL-ELEKTRO	GRAĐEVINARST VO
20948914	B	2022	2021	2020	ENERGIA GAS AND POWER	SNABDEVANJE ELEKTRIČNOM ENERGIJOM, GASOM, PAROM I KLIMATIZACIJA
21088927	B	2022	2021	2020	ENERGY STRONG DOO NOVI SAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21450740	B	2022	2021	2020	ERSOLL SOLUTIONS DOO	PRERAĐIVAČKA INDUSTRIJA
21058823	B	2022	2021	2020	FABRIKA VODE DOO	SNABDEVANJE VODOM; UPRAVLJANJE OTPADNIM VODAMA, KONTROLISANJ E PROCESA UKLANJANJA OTPADA I

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						SLIČNE AKTIVNOSTI
21153443	B	2022	2021	2020	FARMA GAKOVO D.O.O.	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
21019771	B	2022	2021	2020	FINEST BREADS DOO	PRERAĐIVAČKA INDUSTRIJA
08285730	B	2022	2021	2020	HV PARTNER DOO MALA BOSNA	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
08823146	B	2022	2021	2020	INSERT DOO, RUMA	PRERAĐIVAČKA INDUSTRIJA
20931418	B	2022	2021	2020	LARIX INVEST D.O.O. BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20488182	B	2022	2021	2020	LUNIMAX DOO BEOGRAD-NOVI BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20721723	B	2022	2021	2020	MIROTIN-ENERGO	SNABDEVANJE ELEKTRIČNOM ENERGIJOM, GASOM, PAROM

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
						I KLIMATIZACIJA
21005339	B	2022	2021	2020	NETWORK FOR TRADING	SNABDEVANJE ELEKTRIČNOM ENERGIJOM, GASOM, PAROM I KLIMATIZACIJA
17402196	B	2022	2021	2020	NEW LOG DOO	SAOBRAĆAJ I SKLADIŠTENJE
20728973	B	2022	2021	2020	NIK PRO DOO	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20951206	B	2022	2021	2020	ORDISER D.O.O.	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20748397	B	2022	2021	2020	PEMY FAMILY DOO NOVI SAD	PRERAĐIVAČKA INDUSTRIJA
17363310	B	2022	2021	2020	PREDUZEĆE AEROFRUTI DOO SEVOJNO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21001287	B	2022	2021	2020	PRIMUS GROUP HRM D.O.O.	ADMINISTRATIV NE I POMOĆNE USLUŽNE DELATNOSTI

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
20813067	B	2022	2021	2020	RTI	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
08415587	B	2022	2021	2020	SABA TRADE DOO SREMSKA MITROVICA	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
07483031	B	2022	2021	2020	SAMEX GROUP DOO BEOGRAD	GRAĐEVINARSTVO
20317043	B	2022	2021	2020	SMART PLUS	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20806192	B	2022	2021	2020	SUNČEV KRUG OBEZBEĐENJA D.O.O. BEOGRAD	ADMINISTRATIVNE I POMOĆNE USLUŽNE DELATNOSTI
06334377	B	2022	2021	2020	TP NAJKOM DOO BELA PALANKA	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
21470368	B	2022	2021	2020	TRUCK-MTM DOO	SAOBRAĆAJ I SKLADIŠTENJE
21520357	B	2022	2021	2020	UNIPARK D.O.O. RUMA	USLUGE SMEŠTAJA I ISHRANE
20561955	B	2022	2021	2020	VIZ CONNECTION DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
08041784	B	2022	2021	2020	VOJVODINAŠPE D AD NOVI SAD	SAOBRAĆAJ I SKLADIŠTENJE
21137049	A	2023	2022	2021	A SPORT DD D.O.O. BEOGRAD-NOVI BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20040220	A	2023	2022	2021	AGENA TECHNOLOGY DOO ŠIMANOVCI	PRERAĐIVAČKA INDUSTRIJA
21075043	A	2023	2022	2021	AGNS INVEST	GRAĐEVINARSTVO
21160962	A	2023	2022	2021	ALFANOVA DOO LAPOVO	PRERAĐIVAČKA INDUSTRIJA
20971240	A	2023	2022	2021	ALUMINUM SYSTEMS AND CONSTRUCTION	PRERAĐIVAČKA INDUSTRIJA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
					S D.O.O. BEOGRAD	
20265574	A	2023	2022	2021	DOO VELIKI BRACA VLAJKOVAC	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
17318519	A	2023	2022	2021	EURO RP DOO BEOGRAD	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20527145	A	2023	2022	2021	EUROGUMA PLUS D.O.O	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20917610	A	2023	2022	2021	IVANA-PLUS DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20054140	A	2023	2022	2021	LEGI-SGS DOO BEOGRAD- RUŠANJ	PRERAĐIVAČKA INDUSTRIJA
07643659	A	2023	2022	2021	PREDUZEĆE STRELA DOO KLAJIĆ	PRERAĐIVAČKA INDUSTRIJA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
20434783	A	2023	2022	2021	REALITY PRODUCTS DOO STARA PAZOVA	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
29501483	A	2023	2022	2021	STRABAG AG	GRAĐEVINARSTVO
21473065	A	2023	2022	2021	TELEGRA FORTE TRGOVINE DOO NIŠ	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
21352250	B	2023	2022	2021	A-NET MCMXCII	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20042877	B	2023	2022	2021	BANKOVIĆ	GRAĐEVINARSTVO
20824824	B	2023	2022	2021	BELLA DORMO DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
21291471	B	2023	2022	2021	BIOENERGY POWER DOO	POLJOPRIVRED A, ŠUMARSTVO I RIBARSTVO
20825588	B	2023	2022	2021	MAMISA DOO	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
20707810	B	2023	2022	2021	MKS-PETROL DOO KONJUH	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
17275208	B	2023	2022	2021	MORAVA IN DOO KRUŠEVAC	GRAĐEVINARST VO
21094978	B	2023	2022	2021	MOTOIL D.O.O. NOVI SAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
08036004	B	2023	2022	2021	PODUNAVLJE-BEOČIN AD BEOČIN	PRERAĐIVAČKA INDUSTRIJA
17498185	B	2023	2022	2021	SIMPEN DOO BUJANOVAC	PRERAĐIVAČKA INDUSTRIJA

Matični broj	Status ³⁵	Godina statusa	Y-1	Y-2	Ime preduzeća	Privredna grana
21039918	B	2023	2022	2021	TMS BGD DOO LOVČENAC	PRERAĐIVAČKA INDUSTRIJA
20361581	B	2023	2022	2021	WELTEX DOO ČAČAK	PRERAĐIVAČKA INDUSTRIJA
20079215	B	2023	2022	2021	ZRNEX CO.05 DOO BEOGRAD	TRGOVINA NA VELIKO I TRGOVINA NA MALO; POPRAVKA MOTORNIH VOZILA I MOTOCIKALA
08014558	B	2023	2022	2021	ŽITOPROMET- RUMA DOO RUMA	PRERAĐIVAČKA INDUSTRIJA
17268775	A	2018	2017	2016	ALTERNATIVA MEDICA DOO LOZNICA	PRERAĐIVAČKA INDUSTRIJA
08813787	A	2018	2017	2016	ARMSTEEL DOO RUMENKA	PRERAĐIVAČKA INDUSTRIJA
21116785	A	2018	2017	2016	BIASIOTTO	PRERAĐIVAČKA INDUSTRIJA

Prilog 2: Spearman-ov koeficijent korelacije kod varijabli korišćenih za predikciju stečaja godinu dana unapred (Y-1)

NIS	OTIA	INVS	EBITInt	CAS	OCETID	OCETA	TDTA	OR	STA	EBITTA	RER	WCTA	CR	ROA	Variable Label
Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	
-0.136	0.352	-0.250	-0.167	-0.208	0.081	0.064	0.286	-0.037	0.361	-0.255	0.227	-0.240	-0.142	1.000	ROA
0.392	0.110	0.086	0.262	0.061	0.029	-0.022	-0.663	0.810	0.120	0.409	0.451	0.900	1.000	-0.142	CR
0.497	0.082	-0.032	0.363	-0.059	0.134	0.083	-0.737	0.732	0.092	0.487	0.418	1.000	0.900	-0.240	WCTA
0.372	0.217	-0.194	0.261	-0.117	0.280	0.195	-0.481	0.415	0.223	0.324	1.000	0.418	0.451	0.227	RER
0.869	0.260	-0.125	0.715	-0.326	0.322	0.269	-0.615	0.300	0.251	1.000	0.324	0.487	0.409	-0.255	EBITTA
0.283	0.993	-0.492	0.199	-0.764	0.167	0.153	-0.008	0.152	1.000	0.251	0.223	0.092	0.120	0.361	STA
0.322	0.140	-0.216	0.157	0.018	0.092	0.041	-0.491	1.000	0.152	0.300	0.415	0.732	0.810	-0.037	OR
-0.601	-0.008	0.074	-0.463	0.186	-0.260	-0.165	1.000	-0.491	-0.008	-0.615	-0.481	-0.737	-0.663	0.286	TDTA
0.297	0.169	-0.307	0.266	-0.364	0.936	1.000	-0.165	0.041	0.153	0.269	0.195	0.083	-0.022	0.064	OCETA
0.338	0.180	-0.283	0.304	-0.359	1.000	0.936	-0.260	0.092	0.167	0.322	0.280	0.134	0.029	0.081	OCETID
-0.429	-0.765	0.655	-0.338	1.000	-0.359	-0.364	0.186	0.018	-0.764	-0.326	-0.117	-0.059	0.061	-0.208	CAS
0.737	0.208	-0.122	1.000	-0.338	0.304	0.266	-0.463	0.157	0.199	0.715	0.261	0.363	0.262	-0.167	EBITInt
-0.273	-0.503	1.000	-0.122	0.655	-0.283	-0.307	0.074	-0.216	-0.492	-0.125	-0.194	-0.032	0.086	-0.250	INVS
0.290	1.000	-0.503	0.208	-0.765	0.180	0.169	-0.008	0.140	0.993	0.260	0.217	0.082	0.110	0.352	OTIA
0.290	0.290	-0.273	0.737	-0.429	0.338	0.297	-0.601	0.322	0.283	0.869	0.372	0.497	0.392	-0.136	NIS
-0.135	-0.112	0.075	-0.029	-0.014	-0.099	-0.054	0.174	0.014	-0.095	-0.166	-0.116	0.014	0.046	0.049	1.000
0.327	0.366	-0.290	0.243	-0.310	0.239	0.172	-0.333	0.338	0.374	0.346	0.308	0.240	0.294	0.075	CCL
0.339	0.140	-0.278	0.299	-0.343	0.980	0.922	-0.247	0.107	0.128	0.312	0.258	0.143	0.040	0.056	OCFCL
0.529	-0.002	-0.058	0.364	-0.045	0.080	0.049	-0.676	0.611	0.004	0.394	0.351	0.882	0.785	-0.268	WCS
0.527	0.052	0.002	0.403	-0.111	0.219	0.100	-0.952	0.509	0.054	0.569	0.556	0.668	0.691	-0.187	CAPA
0.763	0.312	-0.147	0.641	-0.330	0.313	0.271	-0.506	0.264	0.285	0.887	0.289	0.420	0.361	-0.197	NSTA
-0.251	-0.733	0.621	-0.275	0.934	-0.288	-0.301	0.066	0.108	-0.728	-0.170	-0.070	0.071	0.161	-0.278	NCI
0.788	0.307	-0.046	0.629	-0.259	0.281	0.205	-0.539	0.343	0.301	0.925	0.380	0.408	0.442	-0.150	CFNID
0.162	0.110	-0.110	0.183	-0.180	0.828	0.815	-0.125	0.056	0.107	0.174	0.193	0.008	0.021	0.045	OCF
-0.824	-0.254	0.187	-0.636	0.335	-0.310	-0.277	0.486	-0.257	-0.737	-0.761	-0.307	-0.389	-0.323	0.150	OEI
-0.455	-0.664	0.393	-0.395	0.899	-0.284	-0.293	0.254	0.170	-0.662	-0.362	-0.077	-0.122	-0.004	-0.106	OAS
0.226	0.120	-0.111	0.282	-0.364	0.177	0.171	-0.200	-0.165	0.112	0.111	-0.077	0.011	-0.071	0.080	HC
0.150	0.255	-0.082	0.089	-0.046	0.030	-0.021	-0.275	0.360	0.245	0.214	0.397	0.287	0.430	0.097	IEDD
0.069	-0.075	0.046	0.099	0.045	-0.065	-0.108	-0.102	0.063	-0.080	0.094	0.045	0.004	-0.001	0.053	CRR
-0.362	-0.350	0.259	-0.070	0.312	-0.165	-0.153	0.214	-0.248	-0.346	-0.335	-0.170	-0.256	-0.192	0.038	IEIR
0.269	0.022	0.124	0.242	-0.007	-0.013	-0.044	-0.430	0.235	0.017	0.259	0.210	0.585	0.512	-0.256	INXWC
0.313	0.116	0.496	0.290	-0.013	-0.034	-0.061	-0.445	0.192	0.123	0.339	0.215	0.516	0.626	-0.188	INXCL
-0.515	-0.071	0.032	-0.368	0.062	-0.155	-0.100	0.228	-0.740	-0.077	-0.472	-0.404	-0.968	-0.914	0.226	CLCA
0.282	0.194	0.083	0.262	-0.043	-0.040	-0.056	-0.270	0.183	0.182	0.463	0.136	0.262	0.328	-0.459	OENS
0.962	0.294	-0.194	0.707	-0.355	0.311	0.270	-0.581	0.329	0.289	0.903	0.392	0.462	0.422	-0.185	TITE
-0.021	-0.115	0.159	-0.042	0.267	0.060	0.010	-0.155	0.229	-0.106	0.131	0.132	0.100	0.228	-0.098	CS
0.437	0.282	-0.205	0.316	-0.418	0.204	0.176	-0.322	0.067	0.264	0.509	0.020	0.231	0.131	-0.081	OIG
0.277	0.086	0.034	0.197	-0.070	0.028	-0.008	-0.166	0.011	0.080	0.442	0.022	0.024	0.061	-0.164	NIG
0.549	0.019	-0.038	0.368	-0.119	-0.032	-0.034	-0.396	0.138	0.002	0.542	0.005	0.302	0.195	-0.425	TAG
0.728	0.181	-0.083	0.615	-0.275	0.165	0.138	-0.484	0.154	0.165	0.770	0.188	0.361	0.275	-0.269	TEG
0.312	0.515	-0.260	0.209	-0.494	0.151	0.118	-0.155	0.098	0.533	0.255	0.040	0.117	0.091	0.065	In_S
0.445	0.097	0.044	0.309	0.020	0.096	0.021	-0.703	0.783	0.106	0.440	0.444	0.117	0.951	-0.178	In_CAC
-0.484	0.081	0.046	-0.370	0.185	-0.251	-0.183	0.837	-0.507	0.075	-0.458	-0.377	-0.739	-0.682	0.248	CLTA
-0.191	-0.157	0.139	-0.069	0.015	-0.110	-0.090	0.142	-0.075	-0.140	-0.177	-0.137	-0.120	-0.030	0.048	ITLCA
0.329	0.435	-0.276	0.237	-0.285	0.212	0.153	-0.289	0.380	0.446	0.345	0.334	0.284	0.343	0.106	CETI
-0.250	-0.016	0.139	-0.128	0.157	-0.135	-0.153	0.145	-0.103	-0.002	-0.196	-0.089	-0.222	-0.095	-0.002	OBSCA
0.162	0.531	-0.271	0.143	-0.479	0.140	0.100	-0.067	0.001	0.525	0.093	0.184	-0.066	0.020	0.345	SATA
-0.164	0.108	-0.056	0.112	-0.115	-0.101	-0.057	0.264	-0.216	0.106	-0.231	-0.062	-0.246	-0.204	0.239	IEFA

INVC1	INXWC	IEIR	CRR	IEBD	HC	OAS	OEI	OCF	CENID	NCI	NSTA	CAPA	WCS	OCFCL	CCI	LTDTA	Variable Label
-0.188	-0.256	0.038	0.053	0.097	0.080	-0.106	0.150	0.045	-0.150	-0.278	-0.197	-0.187	-0.268	0.056	0.075	0.049	ROA
0.626	0.517	-0.192	-0.001	0.430	-0.071	-0.004	-0.323	0.021	0.442	0.161	0.361	0.691	0.785	0.040	0.294	0.046	CR
-0.516	0.585	-0.256	0.004	0.287	0.011	-0.122	-0.389	0.008	0.408	0.071	0.420	0.668	0.882	0.143	0.240	0.014	WCTA
0.215	0.210	-0.170	0.045	0.397	-0.077	-0.077	-0.307	0.193	0.380	-0.070	0.289	0.556	0.351	0.258	0.308	-0.116	RER
0.339	0.259	-0.335	0.094	0.214	0.111	-0.362	-0.761	0.174	0.925	-0.170	0.887	0.569	0.394	0.312	0.346	-0.166	FRITTA
0.123	0.017	-0.346	-0.080	0.245	0.112	-0.662	-0.237	0.107	0.301	-0.728	0.285	0.054	0.004	0.128	0.374	-0.095	STA
0.192	0.235	-0.248	0.063	0.360	-0.165	0.170	-0.257	0.056	0.343	0.108	0.764	0.509	0.611	0.107	0.338	0.014	OR
-0.445	-0.430	0.214	-0.102	-0.275	-0.200	0.254	0.486	-0.125	-0.539	0.066	-0.506	-0.952	-0.676	-0.247	-0.333	0.174	TDTA
-0.061	-0.044	-0.153	-0.108	-0.021	0.171	-0.293	-0.277	0.815	0.205	-0.301	0.271	0.100	0.049	0.972	0.172	-0.054	OCETA
-0.034	-0.013	-0.165	-0.065	0.030	0.177	-0.284	-0.310	0.828	0.281	-0.288	0.313	0.219	0.080	0.980	0.239	-0.099	OCETD
-0.013	-0.007	0.312	0.045	-0.046	-0.364	0.899	0.335	-0.180	-0.259	0.934	-0.330	-0.111	-0.045	-0.343	-0.310	-0.014	CAS
0.290	0.242	-0.070	0.099	0.089	0.282	-0.395	-0.636	0.183	0.629	-0.225	0.641	0.403	0.364	0.299	0.243	-0.029	FRITInt
0.496	0.124	0.259	0.046	-0.082	-0.111	0.393	0.187	-0.110	-0.046	0.621	-0.147	0.002	-0.058	-0.278	-0.290	0.075	INVS
0.116	0.022	-0.350	-0.075	0.255	0.120	-0.664	-0.254	0.110	0.307	-0.733	0.312	0.052	-0.002	0.140	0.366	-0.112	DTA
0.313	0.269	-0.362	0.069	0.150	0.226	-0.455	-0.824	0.162	0.788	-0.251	0.763	0.527	0.529	0.339	0.327	-0.135	NIS
0.058	0.056	0.399	-0.034	-0.140	-0.002	-0.021	0.061	0.011	-0.146	-0.030	-0.104	-0.145	0.028	-0.034	-0.043	1.000	LTDTA
0.092	0.047	-0.211	0.054	0.261	0.114	-0.234	-0.242	0.197	0.391	-0.260	0.298	0.397	0.141	0.224	1.000	-0.043	CCL
-0.038	-0.020	-0.118	-0.053	0.002	0.173	-0.271	-0.315	0.826	0.272	-0.264	0.301	0.201	0.094	1.000	0.224	-0.034	OCFCL
0.460	0.596	-0.249	-0.007	0.183	0.041	-0.123	-0.391	-0.045	0.287	0.087	0.330	0.590	1.000	0.094	0.141	0.028	WCS
0.473	0.396	-0.168	0.091	0.385	0.106	-0.177	-0.443	0.159	0.571	-0.013	0.474	1.000	0.590	0.201	0.397	-0.145	CAPA
0.314	0.240	-0.261	0.076	0.201	0.039	-0.348	-0.861	0.177	0.839	-0.168	1.000	0.474	0.330	0.301	0.298	-0.104	NSTA
0.059	0.052	0.295	0.087	-0.044	-0.348	0.828	0.175	-0.149	-0.126	1.000	-0.168	-0.013	0.087	-0.264	-0.260	-0.030	NCI
0.388	0.195	-0.303	0.097	0.300	0.045	-0.284	-0.714	0.217	1.000	-0.126	0.839	0.571	0.287	0.277	0.391	-0.146	CENID
0.039	-0.094	-0.077	-0.172	-0.055	0.105	-0.128	-0.193	1.000	0.217	-0.149	0.177	0.159	-0.045	0.826	0.197	0.011	OCF
-0.286	-0.225	0.261	-0.071	-0.109	-0.132	0.354	1.000	-0.193	-0.193	0.175	-0.861	-0.443	-0.391	-0.315	-0.242	0.061	OEI
-0.264	-0.144	0.254	0.043	-0.019	-0.424	1.000	0.354	-0.128	-0.284	0.828	-0.348	-0.177	-0.123	-0.271	-0.234	-0.021	OAS
0.166	0.020	-0.111	0.105	-0.263	1.000	-0.424	-0.132	0.105	0.045	-0.348	0.039	0.106	0.041	0.173	0.114	-0.002	HC
0.232	0.064	-0.156	0.021	1.000	-0.263	-0.019	-0.109	-0.055	0.300	-0.044	0.201	0.385	0.183	0.002	0.261	-0.140	IEBD
-0.012	-0.064	0.000	1.000	0.021	0.105	0.043	-0.071	-0.172	0.097	0.087	0.076	0.091	-0.007	-0.053	0.054	-0.034	CRR
-0.057	-0.121	1.000	0.000	-0.156	-0.111	0.254	0.261	-0.027	-0.303	0.295	-0.261	-0.168	-0.249	-0.118	-0.211	0.399	IEIR
0.439	1.000	-0.121	-0.064	0.064	0.020	-0.144	-0.275	-0.094	0.195	0.052	0.240	0.396	0.596	-0.020	0.047	0.056	INXWC
1.000	0.439	-0.057	-0.012	0.232	0.166	-0.264	-0.286	0.039	0.388	0.059	0.314	0.473	0.460	-0.038	0.092	0.058	INVC1
-0.547	-0.579	0.258	0.004	-0.287	-0.060	0.123	0.396	-0.016	-0.394	-0.075	-0.408	-0.653	-0.898	-0.166	-0.233	-0.004	CLCA
0.330	0.232	-0.127	0.027	0.258	-0.171	-0.101	-0.342	-0.018	0.490	0.000	0.510	0.312	0.167	-0.036	0.238	-0.068	OENS
0.369	0.258	-0.344	0.064	0.221	0.141	-0.386	-0.837	0.200	0.871	-0.186	0.808	0.550	0.445	0.310	0.360	-0.144	TITE
0.051	-0.014	-0.003	-0.011	0.178	-0.116	0.289	0.032	0.150	0.224	0.264	0.073	0.255	-0.065	0.052	0.724	-0.031	CS
0.155	0.127	-0.306	0.048	0.045	0.307	-0.439	-0.366	0.099	0.453	-0.348	0.428	0.261	0.150	0.207	0.230	-0.064	OIG
0.111	-0.016	-0.126	0.114	0.139	-0.020	-0.084	-0.271	0.012	0.458	-0.004	0.370	0.171	-0.045	0.023	0.142	-0.194	NIG
0.217	0.236	-0.339	0.183	-0.066	0.201	-0.177	-0.439	-0.106	0.448	-0.020	0.437	0.299	0.329	-0.019	0.241	-0.171	TAG
0.284	0.247	-0.293	0.151	0.107	0.205	-0.348	-0.602	0.031	0.715	-0.161	0.665	0.436	0.320	0.161	0.330	-0.144	TEG
0.169	0.056	-0.234	-0.035	-0.432	0.359	-0.476	-0.279	0.226	0.255	-0.420	0.240	0.122	0.067	0.154	0.286	-0.096	In_S
0.590	0.576	-0.217	-0.010	0.379	-0.029	-0.046	-0.358	0.029	0.427	0.137	0.387	0.694	0.851	0.107	0.276	0.035	In_CAC
-0.461	-0.409	0.041	-0.033	-0.207	-0.187	0.251	0.415	-0.172	-0.397	0.076	-0.394	-0.782	-0.677	-0.288	-0.275	-0.270	CITA
0.038	-0.016	0.440	-0.020	-0.118	0.003	-0.005	0.081	0.050	-0.114	-0.036	-0.124	-0.074	-0.106	-0.046	-0.023	0.937	LTICA
0.128	0.078	-0.251	0.026	0.288	0.066	-0.212	-0.239	0.170	0.398	-0.232	0.298	0.361	0.174	0.190	0.972	-0.100	CETI
-0.016	-0.033	0.219	-0.088	-0.162	-0.015	0.151	0.187	0.061	-0.115	0.110	-0.147	-0.053	-0.200	-0.148	-0.007	-0.045	OBSCITA
0.101	-0.096	-0.224	0.025	0.429	0.476	-0.445	-0.055	0.079	0.162	-0.501	0.039	0.136	-0.094	0.106	0.354	-0.086	SATA
-0.075	-0.129	0.751	-0.042	-0.122	0.021	-0.133	0.107	0.000	-0.211	-0.163	-0.126	-0.227	-0.196	-0.054	-0.069	0.438	ETA

Variable	Variable Label	CI CA	OENS	TITE	CS	OIG	NIG	TAG	TEG	In S	In CACL	CITA	LTICA	CETI	OBSCA	SATA	IFETA
Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio	Correlatio
ROA	ROA	0.226	-0.459	-0.185	-0.098	-0.081	-0.164	-0.425	-0.269	0.065	-0.178	0.248	0.048	0.106	-0.002	0.345	0.239
CR	CR	-0.914	0.328	0.422	0.228	0.131	0.061	0.195	0.275	0.091	-0.975	-0.682	-0.030	0.343	-0.095	0.020	-0.204
WCTA	WCTA	-0.968	0.262	0.462	0.100	0.231	0.024	0.302	0.361	0.117	-0.951	-0.739	-0.120	0.284	-0.222	-0.066	-0.246
RER	RER	-0.404	0.136	0.392	0.132	0.070	0.022	0.005	0.188	0.040	0.444	-0.377	-0.137	0.334	-0.089	0.184	-0.062
FRITTA	FRITTA	-0.472	0.463	0.903	0.131	0.509	0.442	0.542	0.770	0.255	0.440	-0.458	-0.177	0.345	-0.196	0.093	-0.231
STA	STA	-0.077	0.182	0.289	-0.106	0.264	0.080	0.002	0.165	0.533	0.106	0.075	-0.140	0.446	-0.002	0.525	0.106
OR	OR	-0.740	0.183	0.329	0.239	0.067	0.011	0.138	0.154	0.098	0.783	-0.507	-0.075	0.380	-0.103	0.001	-0.216
TDTA	TDTA	0.278	-0.270	-0.581	-0.155	-0.322	-0.166	-0.396	-0.484	-0.155	-0.703	0.837	0.142	-0.289	0.145	-0.067	0.264
OCETA	OCETA	-0.100	-0.056	0.270	0.010	0.176	-0.008	-0.034	0.138	0.118	0.021	-0.183	-0.090	0.153	-0.153	0.100	-0.057
OCETD	OCETD	-0.155	-0.040	0.311	0.060	0.204	0.028	-0.032	0.165	0.151	0.096	-0.251	-0.110	0.212	-0.135	0.140	-0.101
CAS	CAS	0.062	-0.043	-0.355	0.267	-0.418	-0.070	-0.119	-0.275	-0.494	0.020	0.185	0.015	-0.285	0.157	-0.429	-0.115
FRITInt	FRITInt	-0.368	0.262	0.707	-0.042	0.316	0.197	0.368	0.615	0.209	0.309	-0.370	-0.069	0.237	-0.128	0.143	-0.112
INVS	INVS	0.032	0.083	-0.194	0.159	-0.205	0.034	-0.038	-0.083	-0.260	0.044	0.046	0.139	-0.276	0.139	-0.094	-0.056
OTTA	OTTA	-0.071	0.194	0.294	-0.115	0.282	0.086	0.019	0.181	0.515	0.097	0.081	-0.157	0.435	-0.016	0.531	0.108
NIS	NIS	-0.515	0.282	0.962	-0.021	0.437	0.277	0.549	0.728	0.312	0.445	-0.484	-0.191	0.329	-0.250	0.162	-0.164
TDTA	TDTA	-0.004	-0.068	-0.144	-0.031	-0.064	-0.194	-0.171	-0.144	-0.096	0.035	-0.270	0.937	-0.100	0.045	-0.086	0.438
CCL	CCL	-0.233	0.238	0.360	0.724	0.230	0.142	0.241	0.330	0.286	0.276	-0.275	-0.023	0.977	-0.007	0.354	-0.069
OCCL	OCCL	-0.166	-0.036	0.310	0.052	0.207	0.023	-0.019	0.161	0.154	0.107	-0.288	-0.046	0.190	-0.148	0.106	-0.054
WCS	WCS	-0.898	0.167	0.445	-0.065	0.150	-0.045	0.329	0.320	0.067	0.851	-0.677	-0.106	0.174	-0.200	-0.094	-0.196
CAPA	CAPA	-0.653	0.312	0.550	0.255	0.261	0.171	0.299	0.436	0.122	0.694	-0.782	-0.074	0.361	-0.053	0.136	-0.227
NSTA	NSTA	-0.408	0.510	0.808	0.073	0.428	0.370	0.437	0.665	0.240	0.387	-0.394	-0.124	0.298	-0.147	0.039	-0.126
NCI	NCI	-0.075	0.000	-0.186	0.264	-0.348	-0.004	-0.020	-0.161	-0.420	0.137	0.076	-0.036	-0.232	0.110	-0.501	-0.163
CFND	CFND	-0.394	0.490	0.871	0.224	0.453	0.458	0.448	0.715	0.255	0.427	-0.397	-0.114	0.398	-0.115	0.162	-0.211
OCF	OCF	-0.016	-0.018	0.200	0.150	0.099	0.012	-0.106	0.031	0.226	0.029	-0.172	0.050	0.170	0.061	0.079	0.000
OEOL	OEOL	0.396	-0.342	-0.837	0.032	-0.366	-0.271	-0.439	-0.602	-0.279	-0.358	0.415	0.081	-0.239	0.187	-0.055	0.107
OAS	OAS	0.123	-0.101	-0.386	0.289	-0.439	-0.084	-0.177	-0.348	-0.476	-0.046	0.251	-0.005	-0.212	0.151	-0.445	-0.133
HC	HC	-0.060	-0.171	0.141	-0.116	0.307	-0.020	0.201	0.205	0.359	-0.029	-0.187	0.003	0.066	-0.015	0.476	0.021
IEBD	IEBD	-0.287	0.258	0.221	0.178	0.045	0.139	-0.066	0.107	-0.432	0.379	-0.207	-0.118	0.288	-0.162	0.429	-0.122
CRR	CRR	0.004	0.027	0.064	-0.011	0.048	0.114	0.183	0.151	-0.035	-0.010	-0.033	-0.020	0.026	-0.088	0.025	-0.042
IEIR	IEIR	0.258	-0.127	-0.344	-0.003	-0.306	-0.126	-0.339	-0.293	-0.234	-0.217	0.041	0.440	-0.251	0.219	-0.224	0.751
INXWC	INXWC	-0.579	0.232	0.258	-0.014	0.127	-0.016	0.236	0.247	0.056	0.576	-0.409	-0.016	0.078	0.033	-0.096	-0.129
INXCI	INXCI	-0.547	0.330	0.369	0.051	0.155	0.111	0.217	0.284	0.169	0.590	-0.461	0.038	0.128	-0.016	0.101	-0.075
CI CA	CI CA	1.000	-0.251	-0.467	-0.095	-0.220	-0.017	-0.308	-0.352	-0.116	-0.969	0.737	0.132	-0.279	0.217	0.036	0.236
OENS	OENS	-0.251	1.000	0.394	0.223	0.174	0.278	0.297	0.378	0.133	0.299	-0.183	-0.046	0.272	0.074	-0.006	-0.113
TITE	TITE	-0.467	0.394	1.000	0.083	0.419	0.349	0.534	0.739	0.317	0.439	-0.453	-0.170	0.363	-0.180	0.160	-0.202
CS	CS	-0.095	0.273	0.083	1.000	-0.017	0.108	0.098	0.119	0.027	0.182	-0.106	0.047	0.711	0.071	0.010	-0.188
OIG	OIG	-0.270	0.174	0.419	-0.017	1.000	0.368	0.475	0.482	0.270	1.000	-0.083	-0.093	0.199	-0.255	0.081	-0.145
NIG	NIG	-0.017	0.278	0.349	0.108	0.368	1.000	0.318	0.392	0.066	0.100	-0.268	-0.156	0.122	-0.196	0.098	-0.184
TAG	TAG	-0.308	0.297	0.534	0.098	0.475	0.318	1.000	0.676	0.263	0.305	-0.341	-0.161	0.224	-0.195	0.191	0.077
TEG	TEG	-0.352	0.378	0.739	0.119	0.482	0.392	0.676	1.000	0.229	0.305	-0.341	-0.161	0.326	-0.196	0.159	0.077
In S	In S	-0.116	0.133	0.317	0.027	0.270	0.066	0.263	0.229	1.000	0.100	-0.083	-0.093	0.303	0.159	0.081	-0.184
In CACL	In CACL	-0.969	0.299	0.439	0.182	-0.017	0.031	0.240	0.305	0.100	1.000	-0.717	-0.065	0.326	-0.137	-0.004	-0.221
CITA	CITA	0.737	-0.183	-0.453	-0.106	1.000	-0.073	-0.277	0.326	-0.083	-0.717	1.000	-0.268	-0.195	-0.137	-0.011	0.077
LTICA	LTICA	0.132	-0.046	-0.170	-0.072	-0.156	1.000	-0.182	0.224	-0.113	-0.268	-0.268	1.000	-0.113	-0.113	-0.046	0.424
CETI	CETI	-0.279	0.272	0.221	0.071	0.224	0.326	0.224	0.326	0.303	0.326	-0.195	-0.113	1.000	0.001	0.352	-0.075
OBSCA	OBSCA	0.001	1.000	0.001	1.000	0.001	1.000	0.001	1.000	0.001	1.000	0.001	1.000	1.000	1.000	1.000	1.000
SATA	SATA	0.046	-0.009	0.046	0.046	0.046	0.046	0.046	0.046	0.046	0.046	0.046	0.046	0.046	0.046	0.046	0.046
IFETA	IFETA	0.236	-0.113	-0.202	-0.188	-0.145	-0.189	-0.288	-0.184	-0.010	-0.221	0.077	0.424	-0.075	0.149	0.046	1.000

Prilog 3: Spearman-ov koeficijent korelacije kod varijabli korišćenih za predikciju stečaja dve godine unapred (Y-2)

EBITInt Correlation	CAS Correlation	OCFTD Correlation	OCFTA Correlation	TDTA Correlation	OR Correlation	EBITTA Correlation	RER Correlation	WCFTA Correlation	CR Correlation	Variable Label
0.345	0.097	0.095	-0.001	-0.613	0.773	0.399	0.490	0.947	1.000	CR
0.370	0.048	0.051	-0.022	-0.592	0.751	0.421	0.499	1.000	0.947	WCTA
0.403	-0.149	0.235	0.136	-0.653	0.481	0.546	1.000	0.499	0.490	RER
0.207	-0.229	0.297	0.257	-0.398	0.331	1.000	0.546	0.421	0.399	EBITTA
0.239	0.043	0.083	-0.015	-0.468	1.000	0.331	0.481	0.751	0.773	OR
-0.317	0.083	-0.230	-0.144	1.000	-0.468	-0.398	-0.653	-0.592	-0.613	TDTA
0.183	-0.192	0.958	1.000	-0.144	-0.015	0.257	0.136	-0.072	-0.001	OCETA
0.245	-0.193	1.000	0.958	-0.230	0.083	0.297	0.235	0.051	0.095	OCETD
-0.229	1.000	-0.193	-0.192	0.083	0.043	-0.229	-0.149	0.048	0.097	CAS
1.000	-0.229	0.245	0.183	-0.317	0.239	0.707	0.403	0.370	0.345	EBITInt
-0.090	0.650	-0.057	-0.055	0.071	-0.293	-0.165	-0.217	0.013	0.080	INVS
0.113	-0.003	0.840	0.862	-0.075	-0.019	0.174	0.062	-0.045	0.000	OCES
0.666	-0.078	0.279	0.249	-0.411	0.287	0.907	0.496	0.408	0.391	NIS
0.257	-0.341	0.292	0.261	-0.330	0.294	0.334	0.355	0.323	0.303	CCL
0.241	-0.173	0.979	0.939	-0.209	0.078	0.284	0.208	0.032	0.087	OCFCL
0.310	-0.067	0.243	0.148	-0.993	0.476	0.398	0.657	0.583	0.623	CAPA
0.589	-0.268	0.282	0.253	-0.369	0.257	0.854	0.413	0.356	0.336	NSTA
0.697	-0.178	0.347	0.264	-0.475	0.418	0.955	0.601	0.484	0.500	CFEND
0.183	-0.128	0.871	0.889	-0.081	-0.012	0.208	0.071	-0.021	0.002	OCF
-0.562	0.108	-0.274	-0.245	0.384	-0.246	-0.768	-0.373	-0.374	-0.351	OEOL
-0.235	0.802	-0.170	-0.178	0.089	0.342	-0.184	-0.032	0.039	0.062	OAS
0.061	-0.610	0.088	0.058	-0.051	0.323	0.158	0.229	-0.027	-0.040	SINV
0.043	-0.610	0.050	0.034	-0.042	0.318	0.134	0.204	-0.020	-0.056	Log SINV
0.127	-0.240	0.070	0.026	-0.362	0.324	0.263	0.382	0.328	0.313	IEBD
-0.127	0.236	-0.201	-0.191	0.108	-0.158	-0.208	-0.167	-0.110	-0.077	IEIR
0.303	0.051	0.128	0.044	-0.328	0.094	0.259	0.200	0.497	0.586	INVCL
-0.374	-0.061	-0.065	0.004	0.627	-0.745	-0.407	-0.479	-0.962	-0.967	CI CA
0.657	-0.059	0.288	0.246	-0.393	0.303	0.922	0.520	0.394	0.396	TITE
0.123	0.094	0.220	0.201	-0.262	0.286	0.197	0.244	0.325	0.325	CS
0.277	-0.161	0.080	0.081	0.021	-0.080	0.366	-0.002	0.049	0.017	OIG
0.322	-0.010	0.193	0.207	0.007	-0.029	0.481	-0.010	0.056	0.084	NIG
0.595	-0.141	0.135	0.110	-0.308	0.169	0.722	0.314	0.322	0.294	TEG
0.360	0.082	0.083	-0.002	-0.624	0.766	0.406	0.490	0.961	0.994	Ln CACL
-0.265	0.022	-0.174	-0.105	0.273	-0.458	-0.289	-0.443	-0.589	-0.641	CLTA
0.306	-0.287	0.269	0.235	-0.281	0.382	0.393	0.383	0.427	0.411	CFIL
0.114	-0.371	0.144	0.116	-0.091	0.030	0.050	0.165	-0.003	0.032	SATA
-0.016	-0.101	-0.181	-0.159	0.196	-0.172	-0.076	-0.092	-0.092	-0.089	IEFA

OAS	OEOI	OCF	CFNID	NSTA	CAPA	OCFCL	CCL	NIS	OCFS	INVS	Variable Label
Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	
0.062	-0.351	0.002	0.500	0.336	0.623	0.087	0.303	0.391	0.000	0.080	CR
0.039	-0.374	-0.021	0.484	0.356	0.583	0.032	0.323	0.408	-0.045	0.013	WCTA
-0.032	-0.373	0.071	0.601	0.413	0.657	0.208	0.355	0.496	0.062	-0.217	RER
-0.184	-0.768	0.208	0.955	0.854	0.398	0.284	0.334	0.907	0.174	-0.165	FBTTA
0.342	-0.246	-0.012	0.418	0.257	0.476	0.078	0.294	0.287	-0.019	-0.293	OR
0.089	0.384	-0.081	-0.475	-0.369	-0.993	-0.209	-0.330	-0.411	-0.075	0.071	TDTA
-0.178	-0.245	0.889	0.264	0.253	0.148	0.939	0.261	0.249	0.862	-0.055	OCETA
-0.170	-0.274	0.871	0.347	0.282	0.243	0.979	0.292	0.279	0.840	-0.057	OCETD
0.802	0.108	-0.128	-0.178	-0.268	-0.067	-0.173	-0.341	-0.078	-0.003	0.650	CAS
-0.235	-0.562	0.183	0.697	0.589	0.310	0.241	0.257	0.666	0.113	-0.090	FBTInt
0.208	0.051	0.017	-0.119	-0.160	-0.055	-0.043	-0.274	-0.054	0.087	1.000	INVS
-0.009	-0.204	0.850	0.204	0.157	0.094	0.855	0.161	0.209	1.000	0.087	OCFS
-0.086	-0.840	0.232	0.864	0.757	0.402	0.291	0.242	1.000	0.209	-0.054	NIS
-0.218	-0.252	0.240	0.386	0.318	0.338	0.254	1.000	0.242	0.161	-0.274	CCL
-0.146	-0.278	0.877	0.331	0.267	0.220	1.000	0.254	0.291	0.855	-0.043	OCFCL
-0.074	-0.373	0.091	0.489	0.367	1.000	0.220	0.338	0.402	0.094	-0.055	CAPA
-0.244	-0.888	0.193	0.820	1.000	0.367	0.267	0.318	0.757	0.157	-0.160	NSTA
-0.145	-0.746	0.231	1.000	0.820	0.489	0.331	0.386	0.864	0.204	-0.119	CENID
-0.121	-0.204	1.000	0.231	0.193	0.091	0.877	0.240	0.232	0.850	0.017	OCF
0.138	1.000	-0.204	-0.746	-0.888	-0.373	-0.278	-0.252	-0.840	-0.204	0.051	OEOI
1.000	0.138	-0.121	-0.145	-0.244	-0.074	-0.146	-0.218	-0.086	-0.009	0.208	OAS
-0.172	-0.019	0.001	0.151	0.153	0.061	0.069	0.294	0.020	-0.054	-0.958	SINV
-0.156	0.006	-0.018	0.110	0.125	0.040	0.033	0.269	-0.007	-0.036	-0.953	Loe SINV
-0.163	-0.180	-0.102	0.269	0.200	0.357	0.052	0.313	0.215	-0.050	-0.288	IEBD
0.183	0.072	-0.130	-0.219	-0.120	-0.105	-0.182	-0.252	-0.143	-0.078	0.243	IEFR
-0.315	-0.271	0.098	0.336	0.244	0.337	0.120	0.117	0.285	0.046	0.557	INVCL
-0.026	0.383	0.015	-0.471	-0.342	-0.613	-0.062	-0.286	-0.427	0.040	-0.045	CI CA
-0.061	-0.829	0.233	0.896	0.771	0.398	0.294	0.260	0.979	0.241	-0.037	TITE
0.146	-0.172	0.218	0.271	0.167	0.276	0.192	0.849	0.165	0.216	0.056	CS
-0.215	-0.326	0.083	0.335	0.406	-0.029	0.112	0.057	0.317	0.049	0.006	OIG
-0.082	-0.301	0.249	0.473	0.395	0.015	0.225	0.066	0.410	0.244	0.056	NIG
-0.184	-0.657	0.102	0.712	0.670	0.302	0.133	0.171	0.706	0.101	-0.042	TEG
0.047	-0.367	-0.005	0.492	0.341	0.624	0.078	0.298	0.409	-0.017	0.065	Int CACL
0.046	0.312	-0.113	-0.368	-0.248	-0.762	-0.200	-0.312	-0.354	-0.093	-0.041	CLTA
-0.182	-0.293	0.211	0.444	0.361	0.295	0.223	0.946	0.290	0.148	-0.226	CFTL
-0.319	0.034	0.080	0.063	0.010	0.108	0.117	0.281	-0.004	0.000	-0.248	SATA
-0.099	-0.008	-0.112	-0.112	0.016	-0.198	-0.164	-0.137	-0.057	-0.159	0.020	IFTA

TEG	NIG	OIG	CS	TITE	CLCA	INVCL	IETR	IEBD	Loe SINV	SINV	Variable Label
Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	Correlation	
0.294	0.084	0.017	0.325	0.396	-0.967	0.586	-0.077	0.313	-0.056	-0.040	CR
0.322	0.056	0.049	0.325	0.394	-0.962	0.497	-0.110	0.328	-0.020	-0.027	WCTA
0.314	-0.010	-0.002	0.244	0.520	-0.479	0.200	-0.167	0.382	0.204	0.229	RER
0.722	0.481	0.366	0.197	0.922	-0.407	0.259	-0.208	0.263	0.134	0.158	FBTTA
0.169	-0.029	-0.080	0.286	0.303	-0.745	0.094	-0.158	0.324	0.318	0.323	OR
-0.308	0.007	0.021	-0.262	-0.393	0.627	-0.328	0.108	-0.362	-0.042	-0.051	TDTA
0.110	0.207	0.081	0.201	0.246	0.004	0.044	-0.191	0.026	0.034	0.058	OCETA
0.135	0.193	0.080	0.220	0.288	-0.065	0.128	-0.201	0.070	0.050	0.088	OCETD
-0.141	-0.010	-0.161	0.094	-0.059	-0.061	0.051	0.236	-0.240	-0.610	-0.610	CAS
0.595	0.322	0.277	0.123	0.657	-0.374	0.303	-0.127	0.127	0.043	0.061	FBTInt
-0.042	0.056	0.006	0.056	-0.037	-0.045	0.557	0.243	-0.288	-0.953	-0.958	INVS
0.101	0.244	0.049	0.216	0.241	0.040	0.046	-0.078	-0.050	-0.036	-0.054	OCFS
0.706	0.410	0.317	0.165	0.979	-0.427	0.285	-0.143	0.215	-0.007	0.020	NIS
0.171	0.066	0.057	0.849	0.260	-0.286	0.117	-0.252	0.313	0.269	0.294	CCL
0.133	0.225	0.112	0.192	0.294	-0.062	0.120	-0.182	0.052	0.033	0.069	OCFCL
0.302	0.015	-0.029	0.276	0.398	-0.613	0.337	-0.105	0.357	0.040	0.061	CAPA
0.670	0.395	0.406	0.167	0.771	-0.342	0.244	-0.120	0.200	0.125	0.153	NSTA
0.712	0.473	0.335	0.271	0.896	-0.471	0.336	-0.219	0.269	0.110	0.151	CEND
0.102	0.249	0.083	0.218	0.233	0.015	0.098	-0.130	-0.102	-0.018	0.001	OCF
-0.657	-0.301	-0.326	-0.172	-0.829	0.383	-0.271	0.072	-0.180	0.006	-0.019	OEOL
-0.184	-0.082	-0.215	0.146	-0.061	-0.076	-0.315	0.183	-0.163	-0.156	-0.172	OAS
0.009	-0.014	-0.033	-0.030	0.040	0.078	-0.515	-0.207	0.250	0.951	1.000	SINV
0.024	-0.039	-0.031	-0.006	0.008	0.061	-0.546	-0.234	0.228	1.000	0.951	Loe SINV
0.047	-0.075	-0.001	0.162	0.196	-0.346	0.104	-0.338	1.000	0.228	0.250	IEBD
-0.130	-0.073	-0.166	-0.138	-0.128	0.112	0.033	1.000	-0.338	-0.234	-0.207	IETR
0.272	0.130	0.165	0.122	0.294	-0.553	1.000	0.033	0.104	-0.546	-0.515	INVCL
-0.322	-0.046	-0.042	-0.298	-0.396	1.000	-0.553	0.112	-0.346	0.061	0.078	CLCA
0.717	0.434	0.302	0.189	1.000	-0.396	0.294	-0.128	0.196	0.008	0.040	TITE
0.083	0.071	-0.014	1.000	0.189	-0.298	0.122	-0.138	0.162	-0.006	-0.030	CS
0.400	0.466	1.000	-0.014	0.302	-0.042	0.165	-0.166	-0.001	-0.031	-0.033	OIG
0.436	1.000	0.466	0.071	0.434	-0.046	0.130	-0.073	-0.075	-0.039	-0.014	NIG
1.000	0.436	0.400	0.083	0.717	-0.322	0.272	-0.130	0.047	0.024	0.009	TEG
0.308	0.068	0.027	0.316	0.399	-0.989	0.575	-0.091	0.330	-0.059	-0.057	Lo CACL
-0.205	-0.042	-0.033	-0.291	-0.332	0.649	-0.422	-0.106	-0.233	0.069	0.052	CLTA
0.233	0.091	0.062	0.827	0.311	-0.392	0.193	-0.309	0.339	0.234	0.251	CFTL
-0.094	-0.056	-0.031	0.062	-0.002	-0.010	0.055	-0.259	0.441	0.272	0.275	SATA
-0.033	-0.039	-0.058	-0.188	-0.067	0.101	0.075	0.828	-0.212	-0.051	0.001	IETA

IETA	SATA	CFTL	CLTA	Ln CACL	Variable Label
Correlation	Correlation	Correlation	Correlation	Correlation	
-0.089	0.032	0.411	-0.641	0.994	CR
-0.092	-0.003	0.427	-0.589	0.961	WCTA
-0.092	0.165	0.383	-0.443	0.490	RER
-0.076	0.050	0.393	-0.289	0.406	FBTIA
-0.172	0.030	0.382	-0.458	0.766	OR
0.196	-0.091	-0.281	0.773	-0.624	TDTA
-0.159	0.116	0.235	-0.105	-0.002	OCETA
-0.181	0.144	0.269	-0.174	0.083	OCETD
-0.101	-0.371	-0.287	0.022	0.082	CAS
-0.016	0.114	0.306	-0.265	0.360	FBTInt
0.020	-0.248	-0.226	-0.041	0.065	INVS
-0.159	0.000	0.148	-0.093	-0.017	OCFS
-0.057	-0.004	0.290	-0.354	0.409	NIS
-0.137	0.281	0.946	-0.312	0.298	CCL
-0.164	0.117	0.223	-0.200	0.078	OCFCL
-0.198	0.108	0.295	-0.762	0.624	CAPA
0.016	0.010	0.361	-0.248	0.341	NSTA
-0.112	0.063	0.444	-0.368	0.492	CEND
-0.112	0.080	0.211	-0.113	-0.005	OCF
-0.008	0.034	-0.293	0.312	-0.367	OEOL
-0.099	-0.319	-0.182	0.046	0.047	OAS
0.001	0.275	0.251	0.052	-0.057	SINV
-0.051	0.222	0.234	0.069	-0.059	Log SINV
-0.212	0.441	0.339	-0.233	0.330	IEBD
0.828	-0.259	-0.309	-0.106	-0.091	IEIR
0.075	0.055	0.193	-0.422	0.575	INVCL
0.101	-0.010	-0.392	0.649	-0.989	CI CA
-0.067	-0.002	0.311	-0.332	0.399	TITE
-0.188	0.062	0.827	-0.291	0.316	CS
-0.058	-0.031	0.062	-0.033	0.027	OIG
-0.039	-0.056	0.091	-0.042	0.068	NIG
-0.033	-0.094	0.233	-0.205	0.308	TEG
-0.093	0.024	0.405	-0.650	1.000	Ln CACL
0.014	-0.009	-0.206	1.000	-0.650	CLTA
-0.143	0.287	1.000	-0.206	0.405	CFTL
-0.076	1.000	0.287	-0.009	0.024	SATA
1.000	-0.076	-0.143	0.014	-0.093	IETA

Prilog 4: Parametri neuronske mreže za predikciju stečaja godinu dana unapred (Y-1)

Parameter Estimates (Y-1)													
Predictor	Predicted												
	Hidden Layer 1						Hidden Layer 2					Output Layer	
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(2:1)	H(2:2)	H(2:3)	H(2:4)	H(2:5)	[Status=0]	[Status=1]
Input Layer	(Bias)	0.140	0.767	-0.642	-1.151	0.377	-0.435						
	ROA	-0.816	0.839	-0.066	-0.195	0.770	0.695						
	RER	-0.195	0.182	-0.587	1.812	-0.451	0.547						
	QR	0.236	1.055	-0.684	2.407	-0.846	-0.067						
	TDTA	-1.155	1.351	-0.905	-1.125	1.303	0.686						
	EBITInt	-0.033	0.099	0.032	-0.415	-0.888	-0.215						
	OITA	0.759	-0.687	-0.191	0.359	-0.385	-0.103						
	NCI	-1.488	0.600	-0.537	-0.315	1.343	0.852						
	OCF	0.793	-0.071	1.153	-0.321	-0.432	-0.065						
	OEOI	-0.865	0.588	-0.886	0.920	0.898	0.334						
	CRR	-0.137	-1.228	1.355	-0.252	0.239	0.272						
	IETR	-1.543	0.217	-0.305	-0.634	1.315	0.601						
	CS	-0.449	-0.353	0.359	1.604	-1.216	0.355						
	NIG	1.235	0.555	-0.746	-0.414	-0.167	-0.593						
	TAG	0.262	-0.976	-0.579	2.061	-0.432	-0.011						
	TEG	0.706	-0.436	-0.289	1.212	-0.720	-0.731						
	Ln S	0.294	0.293	0.652	0.809	0.007	-0.477						
	Ln CACL	0.306	0.251	-2.271	2.287	-0.570	0.359						
	LTICA	-0.828	-1.282	-0.016	0.856	0.334	-0.033						
	OBSCTA	0.506	-0.431	0.747	0.694	-1.137	-0.484						
	SATA	0.163	0.420	-0.594	2.003	-0.125	0.380						
	IETA	-2.606	-0.286	-0.267	1.461	1.103	0.847						
Hidden Layer 1	(Bias)						-0.106	0.046	-0.317	-0.736	0.894		
	H(1:1)						0.279	0.038	0.739	0.938	-1.552		
	H(1:2)						0.336	0.385	-0.662	-1.676	1.152		
	H(1:3)						-0.981	-0.877	1.601	1.080	-1.105		
	H(1:4)						-0.120	-0.876	0.777	3.309	-1.896		
	H(1:5)						-0.443	0.645	-0.433	-1.624	1.585		
	H(1:6)						0.366	0.144	-0.292	-0.730	0.654		
Hidden Layer 2	(Bias)											0.119	-0.549
	H(2:1)											1.012	-0.961
	H(2:2)											0.533	-1.453
	H(2:3)											-1.853	1.046
	H(2:4)											-2.850	2.517
	H(2:5)											2.023	-2.191

Prilog 5: Parametri neuronske mreže za predikciju stečaja dve godine unapred (Y-2)

Parameter Estimates																
Predictor	Predicted															
	Hidden Layer 1								Hidden Layer 2					Output Layer		
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(2:1)	H(2:2)	H(2:3)	H(2:4)	H(2:5)	H(2:6)	[Status =0]	[Status =1]
Input Layer	(Bias)	0.054	-0.361	0.604	0.010	0.230	-0.304	0.140	-0.861							
	RER	0.429	0.656	-0.353	0.921	-0.285	-0.556	-0.007	-0.578							
	EBITInt	-0.408	1.074	-0.266	-0.037	0.745	1.184	0.429	0.491							
	OCFS	0.509	-0.006	0.404	0.534	0.500	0.285	0.327	0.009							
	CCL	-0.772	0.891	-0.277	0.599	-0.044	-1.455	0.546	0.285							
	CAPA	-0.534	0.661	-0.465	0.668	-0.218	-0.535	-0.041	0.052							
	CFNID	-1.442	1.809	0.893	0.163	-2.396	-0.921	0.232	1.479							
	OEOI	0.869	-0.195	-0.575	0.319	0.968	0.146	0.000	-0.881							
	Log_SI NV	0.365	0.839	-0.264	-0.190	0.710	-0.779	0.622	0.256							
	IEBD	0.267	-0.268	-0.519	-0.579	-0.747	0.078	0.135	-0.396							
	IETR	0.382	-0.386	-0.317	-0.376	0.557	0.141	0.415	0.311							
	CS	-0.090	-0.489	-0.632	0.596	0.391	0.426	0.587	0.010							
	Ln CA CL	0.986	0.254	0.294	0.241	-0.157	0.287	0.607	0.126							
	IETA	0.233	0.455	0.119	-0.001	1.263	-0.544	0.228	-0.388							
Hidden Layer 1	(Bias)								0.099	0.180	0.140	-0.492	0.137	0.336		
	H(1:1)								-0.168	-0.059	0.903	0.549	0.155	-0.105		
	H(1:2)								0.455	0.449	-1.268	-0.370	-0.141	0.848		
	H(1:3)								-0.169	0.070	-0.582	-0.509	0.042	-0.116		
	H(1:4)								-0.870	-0.311	0.375	0.293	-0.006	-0.123		
	H(1:5)								-0.114	-1.668	1.807	0.953	0.573	-0.605		
	H(1:6)								-0.714	-0.453	1.105	0.740	-0.524	-0.811		
	H(1:7)								0.192	-0.426	0.883	0.397	-0.104	-0.067		
	H(1:8)								0.512	1.087	-0.835	-0.612	-0.762	0.396		
Hidden Layer 2	(Bias)														-1.172	0.709
	H(2:1)														-0.750	0.309
	H(2:2)														-1.668	1.766
	H(2:3)														1.976	-1.859
	H(2:4)														0.846	-0.283
	H(2:5)														0.143	-0.740
	H(2:6)														-1.083	0.359

Prilog 6 : Rezultati Altman-ovog EMS modela za preduzeća iz test uzorka za predikciju stečaja godinu dana unapred (Y-1)

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-1) ³⁶	ALTMAN-OV EMS REZULTAT
06076831	0	6.72
06347673	0	0.21
06636110	0	7.19
07360479	1	11.17
07411618	0	7.19
08036004	0	(5.81)
08041784	0	(1.61)
08254672	0	1.67
08415587	0	4.59
08648166	1	16.49
17151517	1	18.74
17443151	1	7.00
17481665	1	45.01
17546961	1	9.11
17577603	0	(6.45)
17581538	1	6.38
20043873	0	6.64
20048140	1	11.97
20054140	1	4.46
20134615	1	9.24
20249552	1	5.67

³⁶ 0 = preduzeće u stečaju i 1 = solventno preduzeće

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-1) ³⁶	ALTMAN-OV EMS REZULTAT
20319399	0	5.15
20332271	1	6.74
20534141	1	6.07
20600381	0	3.70
20707810	0	5.46
20728973	0	2.46
20806192	0	5.14
20818883	0	(0.23)
20876565	1	12.64
20917385	0	7.58
20966645	1	5.02
20971240	1	9.35
21005339	0	3.74
21025372	1	7.27
21041122	1	3.27
21058823	0	0.95
21088927	0	6.27
21103233	1	7.06
21122866	0	2.17
21153443	0	(4.86)
21161128	1	5.54
21298930	1	7.56
21473065	1	8.60
21520357	0	3.24
56060561	1	4.53

Prilog 7: Rezultati Altman-ovog EMS modela za preduzeća iz test uzorka za predikciju stečaja dve godine unapred (Y-2)

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-2)	ALTMAN-OV EMS REZULTAT
06076831	0	6.87
06347673	0	1.03
06636110	0	0.69
07360479	1	10.68
07411618	0	4.09
08036004	0	7.49
08041784	0	(1.76)
08254672	0	2.34
08415587	0	5.25
08648166	1	20.20
17151517	1	185.82
17443151	1	6.42
17481665	1	23.31
17546961	1	9.58
17577603	0	5.61
17581538	1	6.37
20043873	0	4.95
20048140	1	10.46
20054140	1	5.28
20134615	1	10.26

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-2)	ALTMAN-OV EMS REZULTAT
20249552	1	10.66
20319399	0	5.46
20332271	1	7.44
20534141	1	4.61
20600381	0	3.72
20707810	0	7.40
20728973	0	3.43
20806192	0	3.80
20818883	0	8.33
20876565	1	11.79
20917385	0	6.69
20966645	1	5.41
20971240	1	8.26
21005339	0	5.34
21025372	1	5.56
21041122	1	2.86
21058823	0	0.73
21088927	0	7.66
21103233	1	6.01
21122866	0	3.10
21153443	0	4.92
21161128	1	5.82
21298930	1	10.36
21473065	1	10.65

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-2)	ALTMAN-OV EMS REZULTAT
21520357	0	4.50
56060561	1	2.93

Prilog 8: Rezultati Altman-ovog Z' modela za preduzeća iz test uzorka za predikciju stečaja godinu dana unapred (Y-1)

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-1)	ALTMAN-OV Z' REZULTAT
20600381	0	1.57
06636110	0	1.91
07411618	0	1.91
20319399	0	0.95
21041122	1	0.24
20971240	1	3.06
06076831	0	1.34
17581538	1	3.85
20249552	1	1.47
20534141	1	1.82
20043873	0	1.46
20876565	1	3.57
17443151	1	1.68
20134615	1	2.26
20917385	0	1.42

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-1)	ALTMAN-OV Z' REZULTAT
17577603	0	(1.47)
08648166	1	4.46
20332271	1	2.18
21088927	0	0.75
21058823	0	(0.25)
21153443	0	(1.75)
17546961	1	2.97
20966645	1	3.41
17151517	1	5.58
06347673	0	(0.33)
21025372	1	2.00
21161128	1	0.63
20048140	1	3.58
20054140	1	1.47
20818883	0	(1.32)
08254672	0	(0.37)
20707810	0	1.24
21122866	0	2.47
21005339	0	1.92
20728973	0	0.88
56060561	1	1.50
17481665	1	16.11
08036004	0	(0.01)

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-1)	ALTMAN-OV Z' REZULTAT
07360479	1	2.57
08415587	0	1.61
21298930	1	1.77
21103233	1	2.14
20806192	0	1.57
21473065	1	4.62
21520357	0	0.29
08041784	0	(0.42)

Prilog 9: Rezultati Altman-ovog Z' modela za preduzeća iz test uzorka za predikciju stečaja dve godine unapred (Y-2)

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-2)	ALTMAN-OV Z' REZULTAT
20600381	0	0.10
06636110	0	(1.09)
07411618	0	0.16
20319399	0	0.48
21041122	1	(0.07)
20971240	1	1.41
06076831	0	1.05
17581538	1	0.70
20249552	1	2.11
20534141	1	0.26

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-2)	ALTMAN-OV Z' REZULTAT
20043873	0	0.38
20876565	1	2.30
17443151	1	1.34
20134615	1	1.86
20917385	0	0.66
17577603	0	0.50
08648166	1	4.99
20332271	1	1.20
21088927	0	0.72
21058823	0	(0.36)
21153443	0	0.59
17546961	1	1.33
20966645	1	0.76
17151517	1	70.83
06347673	0	(0.05)
21025372	1	0.80
21161128	1	0.51
20048140	1	1.65
20054140	1	0.40
20818883	0	1.08
08254672	0	(0.25)
20707810	0	0.67
21122866	0	0.04
21005339	0	0.42

MATIČNI BROJ PREDUZEĆA	STVARNI STATUS (Y-2)	ALTMAN-OV Z' REZULTAT
20728973	0	0.09
56060561	1	0.22
17481665	1	6.17
08036004	0	0.78
07360479	1	1.91
08415587	0	(0.01)
21298930	1	2.29
21103233	1	0.67
20806192	0	(0.50)
21473065	1	1.90
21520357	0	0.51
08041784	0	(0.54)

Prilog 10 – Plan tretmana podataka

Назив пројекта/истраживања
„Predikcija stečaja malih i srednjih entiteta u Republici Srbiji“
Назив институције/институција у оквиру којих се спроводи истраживање
Univerzitet u Novom Sadu, Ekonomski fakultet u Subotici
Назив програма у оквиру ког се реализује истраживање
Doktorske studije Studijski program: Poslovna ekonomija i menadžment Studijski modul: Poslovne finansije, računovodstvo i revizija
1. Опис података
1.1 Врста студије <i>Укратко описати тип студије у оквиру које се подаци прикупљају</i> <u>Istraživanje podrazumeva generisanje modela predikcije stečaja MSE u Republici Srbiji upotrebom statističkih metoda i tehnika mašinskog učenja. Svi podaci koji su korišćeni u istraživanju, javno su dostupni na Internetu (stranica APR-a).</u> 1.2 Врсте података а) квантитативни б) квалитативни 1.3. Начин прикупљања података а) анкете, упитници, тестови б) клиничке процене, медицински записи, електронски здравствени записи в) генотипови: навести врсту _____ г) административни подаци: навести врсту <u>Podaci sa Interneta (APR)</u> _____ д) узорци ткива: навести врсту _____ ђ) снимци, фотографије: навести врсту _____ е) текст, навести врсту _____ ж) мапа, навести врсту _____ з) остало: описати _____ 1.3 Формат података, употребљене скале, количина података 1.3.1 Употребљени софтвер и формат датотеке: а) Excel фајл, датотека 1 б) SPSS фајл, датотека 2 с) PDF фајл, датотека 3 д) Текст фајл, датотека _____ е) JPG фајл, датотека _____ ф) Остало, датотека _____

1.3.2. Број записа (код квантитативних података)

- а) број варијабли 66 nezavisnih i 1 zavisna
 б) број мерења (испитаника, процена, снимака и сл.) 212 preduzeća

1.3.3. Поновљена мерења

- а) да
 б) **не**

Уколико је одговор да, одговорити на следећа питања:

- а) временски размак измедју поновљених мера је _____
 б) варијабле које се више пута мере односе се на _____
 в) нове верзије фајлова који садрже поновљена мерења су именоване као _____

Напомене: _____

Да ли формати и софтвер омогућавају дељење и дугорочну валидност података?

- а) Да**
 б) Не

Ако је одговор не, образложити _____

2. Прикупљање података

2.1 Методологија за прикупљање/генерисање података

- Podaci su preuzeti sa sajta APR-a, u MS Excel programu je izvršen obračun finansijskih racio pokazatelja koji su korišćeni u daljem modelovanju.

2.1.1. У оквиру ког истраживачког нацрта су подаци прикупљени?

- а) експеримент, навести тип _____
 б) корелационо истраживање, навести тип _____
 ц) анализа текста, навести тип _____
 д) **остало, навести шта** statističke metode (logistička regresija, diskriminantna analiza) i metode mašinskog učenja (neuronske mreže, stabla odlučivanja i k-najbližih suseda)

2.1.2 Навести врсте мерних инструмената или стандарде података специфичних за одређену научну дисциплину (ако постоје).

Excel Program (Microsoft)
SPSS Program (IBM)

2.2 Квалитет података и стандарди

2.2.1. Третман недостајућих података

- а) Да ли матрица садржи недостајуће податке? Да **Не**

Ако је одговор да, одговорити на следећа питања:

- а) Колики је број недостајућих података? _____
 б) Да ли се кориснику матрице препоручује замена недостајућих података? Да **Не**
 в) Ако је одговор да, навести сугестије за третман замене недостајућих података _____

2.2.2. На који начин је контролисан квалитет података? Описати

Putem SPSS programa je izvršeno testiranje varijabli (Mann Whitney & t-test) kako bi se ustanovilo koja od 66 nezavisnih varijabli doprinosi predikciji stečaja. Konačni modeli su testirani kroz goodness of fit testove i matricu konfuzije.

2.2.3. На који начин је извршена контрола уноса података у матрицу?

Kontrola je vršena naprednim funkcijama, kao i PowerPivot i Query opcijama u MS Excel-u.

3. Третман података и пратећа документација

3.1. Третман и чување података

3.1.1. Подаци ће бити депоновани у _____ репозиторијум.

3.1.2. URL адреса _____

3.1.3. DOI _____

3.1.4. Да ли ће подаци бити у отвореном приступу?

- a) Да
 б) Да, али после ембарга који ће трајати до _____
 в) Не

Ако је одговор не, навести разлог _____

3.1.5. Подаци неће бити депоновани у репозиторијум, али ће бити чувани.

Образложење

3.2 Метаподаци и документација података

3.2.1. Који стандард за метаподатке ће бити примењен? _____

3.2.1. Навести метаподатке на основу којих су подаци депоновани у репозиторијум.

Ако је потребно, навести методе које се користе за преузимање података, аналитичке и процедуралне информације, њихово кодирање, детаљне описе варијабли, записа итд.

3.3 Стратегија и стандарди за чување података

3.3.1. До ког периода ће подаци бити чувани у репозиторијуму? _____

3.3.2. Да ли ће подаци бити депоновани под шифром? Да Не

3.3.3. Да ли ће шифра бити доступна одређеном кругу истраживача? Да Не

3.3.4. Да ли се подаци морају уклонити из отвореног приступа после извесног времена?

Да Не

Образложити

4. Безбедност података и заштита поверљивих информација

Овај одељак МОРА бити попуњен ако ваши подаци укључују личне податке који се односе на учеснике у истраживању. За друга истраживања треба такође размотрити заштиту и сигурност података.

4.1 Формални стандарди за сигурност информација/података

Истраживачи који спроводе испитивања с људима морају да се придржавају Закона о заштити података о личности (https://www.paragraf.rs/propisi/zakon_o_zastiti_podataka_o_licnosti.html) и одговарајућег институционалног кодекса о академском интегритету.

4.1.2. Да ли је истраживање одобрено од стране етичке комисије? Да **Не**

Ако је одговор Да, навести датум и назив етичке комисије која је одобрила истраживање

4.1.2. Да ли подаци укључују личне податке учесника у истраживању? Да **Не**

Ако је одговор да, наведите на који начин сте осигурали поверљивост и сигурност информација везаних за испитанике:

- а) Подаци нису у отвореном приступу
- б) Подаци су анонимизирани
- ц) Остало, навести шта

5. Доступност података

5.1. Подаци ће бити

а) **јавно доступни**

б) доступни само уском кругу истраживача у одређеној научној области

ц) затворени

Ако су подаци доступни само уском кругу истраживача, навести под којим условима могу да их користе:

Ако су подаци доступни само уском кругу истраживача, навести на који начин могу приступити подацима:

5.4. Навести лиценцу под којом ће прикупљени подаци бити архивирани.

6. Улоге и одговорност

6.1. Навести име и презиме и мејл адресу власника (аутора) података

Denis Kušter, kuschter@yahoo.com

6.2. Навести име и презиме и мејл адресу особе која одржава матрицу с подацима

Denis Kušter, kuschter@yahoo.com

6.3. Навести име и презиме и мејл адресу особе која омогућује приступ подацима другим истраживачима

Denis Kušter, kuschter@yahoo.com

BIOGRAFIJA AUTORA

Denis (Željko) Kušter je rođen 25.08.1996. godine u Novom Sadu, Republika Srbija. Odrastao je u Indiji gde je stekao osnovno i srednje obrazovanje. **Osnovnu školu** „Dušan Jerković“ je završio školske 2010/2011. godine sa ukupnom prosečnom ocenom 5.00, kao nosilac *Vukove diplome*. Tokom osnovnog obrazovanja, pokazao je interesovanje za razne oblasti i učestvovao je na mnogim takmičenjima, a na završnoj godini je bio vicešampion republičkog takmičenja iz *Tehničkog i informatičkog obrazovanja*.

Školske 2011/2012. godine, upisuje **srednju ekonomsku školu** „Dr Đorđe Natošević“ kao jedan od najboljih učenika u Srbiji, sa ostvarenih 101/100 poena na prijemnom ispitu. Tokom srednje škole, učestvovao je na takmičenjima iz maternjeg jezika i poslovne ekonomije. Bio je dobitnik stipendije Republike Srbije za srednjoškolce. Srednju školu završava 2015. godine sa ukupnom prosečnom ocenom 5.00, kao nosilac *Vukove diplome*.

Akadske 2015/2016. godine, sa maksimalnim brojem poena prijemnom ispitu, upisuje **osnovne akademske studije** prvog stepena na Ekonomskom fakultetu u Subotici, Univerziteta u Novom Sadu, na studijskom programu *Finansije, bankarstvo i osiguranje*. Tokom trajanja studija, stručno se usavršavao mimo redovnog nastavnog plana i programa, pohađajući mnoge kurseve, seminare i obuke, a učestvovao je i u izradi studije slučaja za kompaniju „Coca Cola HBC“. Za vreme osnovnih studija, bio je stipendista raznih fondova: *stipendija Republike Srbije* (Akademska 2016/2017, stipendija obezbeđena za sve studente sa ukupnom prosečnom ocenom iznad 9.00), *stipendija Fonda za stipendiranje i podsticanje napredovanja darovitih studenata i mladih naučnih radnika i umetnika Univerziteta u Novom Sadu* (akademska 2017/2018. godina, stipendija obezbeđena za 62 najbolja studenta sa novosadskog univerziteta), *stipendija fondacije Carlsberg and Dunderski* (akademska 2017/2018. godina, stipendija obezbeđena za najbolje studente Ekonomskog fakulteta) i *stipendija Fonda za mlade talente – Dositeja* (akademska 2018/2019. godina, stipendija obezbeđena za 950 najboljih studenata osnovnih studija u Republici Srbiji). Za vreme osnovnih studija, nagrađen je sa nekoliko priznanja, od čega izdvaja sledeće: *Izuzetna nagrada Univerziteta u Novom Sadu* (akademska 2018/2019. godina, nagrada za ostvarenu ukupnu prosečnu ocenu 10.00), *Plaketa Saveza ekonomista Srbije* (akademska 2018/2019. godina, nagrada za izuzetne rezultate iz oblasti ekonomije, koju dobija ukupno 5 najboljih studenata sa svih ekonomskih fakulteta u Republici Srbiji), *Nagrada za naučni i stručni rad Univerziteta u Novom Sadu* (akademska 2018/2019. godina, nagrada koju dobijaju studenti za stručne istraživačke radove) i *Nagrada iz zadužbinskih fondova Matice Srpske* (akademska 2018/2019. godina, nagrada najboljem studentu sa *Departmana za finansije i računovodstvo* Ekonomskog fakulteta). Tokom osnovnih studija, na trećoj godini, napisao je prvi naučni rad na temu finansijskog izveštavanja i oporezivanja preduzetnika u Srbiji, za koji je dobio gore navedenu nagradu Univerziteta u Novom Sadu. Pored

pomenutog naučnog rada, tokom osnovnih studija je objavio još jedan rad u studentskom časopisu *Politeuma*, u izdavaštvu Fakulteta političkih nauka, Univerziteta u Beogradu. Zvanje *Diplomirani ekonomista*, kao jedan od najboljih studenata Ekonomskog fakulteta, stekao je u julu mesecu 2019. godine, položivši sve ispite predviđene nastavnim planom i programom sa ukupnom prosečnom ocenom 10.00, te odbranivši diplomski rad sa temom *Uticaj privatizacije na prinostne, imovinske i finansijske performanse kompanije „NIS AD Novi Sad“* (ocena 10). U toku trajanja osnovnih studija, obavio je dve kraće studentske prakse u bankarskom sektoru.

Akadske 2019/2020. godine upisuje **master akademske studije** drugog stepena na Ekonomskom fakultetu u Subotici, Univerziteta u Novom Sadu na studijskom programu *Računovodstvo i revizija*. Tokom master studija, bio je dobitnik stipendije *Fonda za mlade talente – Dositeja* (akadska 2019/2020. godina, stipendija obezbeđena za 460 najboljih studenata master studija u Republici Srbiji). Za vreme ovog nivoa studija, objavio je i drugi naučno-istraživački rad u studentskom časopisu *Politeuma*, u izdavaštvu Fakulteta političkih nauka, Univerziteta u Beogradu. Zvanje Master ekonomiste je stekao u septembru 2020. godine položivši sve ispite predviđene nastavnim planom i programom sa ukupnom prosečnom ocenom 10.00, te odbranivši master rad sa temom *Politika, karakteristike i trendovi oporezivanja dohotka fizičkih lica sa osvrtom na poreski klin i njegov uticaj na nezaposlenost – Srbija VS zemlje članice OECD-a* (ocena 10).

Akadske 2020/2021. godine upisuje **doktorske akademske studije** trećeg stepena na Ekonomskom fakultetu u Subotici, Univerziteta u Novom Sadu na studijskom programu *Poslovna ekonomija i menadžment*, modul *Poslovne finansije, računovodstvo i revizija*. Sve ispite predviđene planom i nastavnim programom, položio je do kraja akademske 2021/2022. godine, sa ukupnom prosečnom ocenom 10.00. Tokom doktorskih studija, napisao je i objavio 7 naučnih radova u časopisima raznih kategorizacija (M22, M24 i M51).

Profesionalnu karijeru započinje već 2019. godine, odmah po završetku osnovnih studija, i to u IT kompaniji *Schneider Electric DOO* u Novom Sadu, na poziciji *Finansijski kontrolor*. Tu je i trenutno zaposlen kao *Specijalista za finansijsko planiranje i analizu (FP&A)*. Uporedno sa završenim, prethodno pomenutim, master studijama, stiće prvu godinu radnog iskustva u privredi. U letnjim semestrima 2022. i 2023. godine, uporedno sa doktorskim studijama i redovnim poslom u kompaniji *Schneider Electric*, postaje i deo kolektiva Ekonomskog fakulteta u Novom Sadu kao eksterni predavač (*Demonstrator*) na predmetu *Kontroling*, gde je držao vežbe studentima osnovnih i master akademskih studija, sa idejom da se u prosvetu uključi što je više moguće prakse. Na ovoj poziciji je bio sve do juna 2023. godine, kada donosi odluku o punoj posvećenosti radu u privredi. Godine 2024, uvršten je na *WebMind*-ovu listu “30 ispod 30”, kao jedno od 30 najuspešnijih lica ispod 30 godina starosti u IT industriji i biznisu sa teritorije Republike Srbije.

Vođen mišlju da svaki dan može da nauči nešto novo, mimo formalnog obrazovanja kontinuirano radi na svom ličnom razvoju, te je završio brojne kurseve i stekao razne sertifikate: *ECDL (European Computer Driving License)*, *Pisanje biznis plana*, *Finansijsko modelovanje i predviđanje finansijskih izveštaja*, *Analiza finansijskih izveštaja*, *Analiza i vizuelizacija podataka*, *Veštačka inteligencija za praktičare*, *Asertivna komunikacija*, *Emotivna inteligencija*, *Upravljanje stresom*, *Rezilijentnost*, itd.