

Predviđanje nastavka poslovanja poduzeća metodom umjetnih neuronskih mreža

Dojčinović Drilo, Dejana

Doctoral thesis / Disertacija

2018

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

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:192:650131>

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

Download date / Datum preuzimanja: **2025-02-06**



SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Repository / Repozitorij:

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



SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Dejana Dojčinović Drilo

**PREDVIĐANJE NASTAVKA
POSLOVANJA PODUZEĆA METODOM
UMJETNIH NEURONSKIH MREŽA**

DOKTORSKI RAD

Rijeka, 2018.

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Dejana Dojčinović Drilo

**PREDVIĐANJE NASTAVKA
POSLOVANJA PODUZEĆA METODOM
UMJETNIH NEURONSKIH MREŽA**

DOKTORSKI RAD

Mentor: prof.dr.sc. Neda Vitezić, redoviti profesor u trajnom
zvanju

Rijeka, 2018.

UNIVERSITY OF RIJEKA
FACULTY OF ECONOMICS

Dejana Dojčinović Drilo

**FORECASTING COMPANY'S GOING
CONCERN USING ARTIFICIAL NEURAL
NETWORKS**

DOCTORAL THESIS

Rijeka, 2018

Mentor rada: prof.dr.sc. Neda Vitezić, redoviti profesor u trajnom zvanju

Doktorski rad obranjen je dana 22. studenoga 2018. godine na Ekonomskom fakultetu u Rijeci, Sveučilište u Rijeci, pred povjerenstvom u sastavu:

1. Prof. dr. sc. Mira Dimitrić, Ekonomski fakultet Rijeka, Sveučilište u Rijeci
2. Izvanredni prof. dr. sc. Robert Zenzerović, Fakultet ekonomije i turizma „Dr. Mijo Mirković“, Sveučilište u Puli
3. Prof. dr. sc. Adnan Rovčanin, Ekonomski fakultet u Sarajevu, Sveučilište u Sarajevu

Mojim roditeljima.

Predgovor

Ova doktorska disertacija predstavlja odgovor na brojna pitanja kojima se bavim još od studentskih dana: „Može li se poslovna kriza spriječiti, postoje li znakovi upozorenja na krizu i može li se predvidjeti nastavak poslovanja poduzeća?“ U svom magistarskom radu bavila sam se temom ranog upozorenja na poslovnu krizu, pa se tema predviđanja poslovne krize i nastavka poslovanja poduzeća, kao zahtjevnom nadogradnjom prvotne teme, sama po sebi nametnula.

Tijekom svog dugogodišnjeg radnog iskustva u međunarodnoj konzultantskoj kući, spoznala sam važnost pravovremenog prepoznavanja promjena smjera u poslovanju poduzeća i pravovremene reakcije managementa. Koliko jednostavno to teorijski zvuči, toliko je zahtjevno to zaista u praksi i provesti. Namjera mi je bila, u ovom radu, teorijski istražiti najvažnije opcije predviđanja poslovanja poduzeća, praktično istražiti njihovu primjenu, a zatim uz nadogradnju vlastitog znanja, pokušati dati novi dogovor na predviđanje nastavka poslovanja. Koliko sam u tome uspjela, pokazati će praksa, koja će, nadam se u primjeni mog modela prepoznati mogućnost točnije prognoze svog i tuđeg poslovanja. Modeli predviđanja, uz primjenu statističkih metoda umjetne inteligencije i strojnog učenja, nikada neće zamijeniti holistički pristup poslovanju kojeg u procjeni primjenjuju revizori i konzultanti (ili bi trebali primjenjivati), ali daju kvalitetnu podršku donošenju odluka i ocjeni poslovanja. Nadam se da će ovaj znanstveni rad, kao što je to bio i moj magistarski rad, biti mali doprinos obrazovanju i unaprjeđenju hrvatske gospodarske prakse.

Posljednji udarci po tipkovnici vezani za izradu ove doktorske disertacije posvećeni su osobama koje su obilježile pisanje ovog rada i želim im se ovim putem posebno zahvaliti.

Ovim putem se zahvaljujem svojoj mentorici prof.dr.sc. Nedi Vitezić, redovitoj profesorici u trajnom zvanju, na pomoći u odabiru teme, profesionalnoj podršci i mentorstvu tijekom pisanja rada te neizmjernom razumijevanju. Hvala Vam za sve razgovore o hipotezama, radu i literaturi koje smo vodile iza ponoći zbog naših pretrpanih rasporeda. Hvala Vam za konzultacije vikendima i praznicima, uvijek izvan

Vašeg radnog vremena, a uvijek kako je meni odgovaralo. Da niste bili toliko fleksibilni, puni razumijevanja i podrške, ovaj rad sigurno nikada ne bih završila.

Najsrdajnije se zahvaljujem i svojoj direktorici, gospođi Aniti Lukin, direktorici Sektora razvoja poslovanja i podrške u Erste&Steiermärkische Bank d.d. na podršci i razumijevanju tijekom pisanja rada. Zahvaljujem se i dr.sc. Sandru Skansi, docentu na Odsjeku za filozofiju, na Hrvatskim studijima Sveučilišta u Zagrebu, na suradnji i nesebičnoj pomoći tijekom pisanja rada.

Velika zahvala ide mojoj najboljoj prijateljici Kristini na iskrenoj podršci i prekrasnom prijateljstvu kojem je tek 20 godina, a kojem najbolje godine tek dolaze.

Hvala i mojim sinovima, Lukasu i Patriku, osnovnom izvoru moje životne energije.

Na kraju najveća zahvala od svih zahvala ide mojim roditeljima, najboljim roditeljima na svijetu, Aniti i Miliću. Hvala vam što ste moja životna stijena, sigurnosna mreža, najjači vjetar u leđa i zagrljaj oko vrata!

Sažetak

Nastavak poslovanja poduzeća je temeljna pretpostavka poslovanja poduzeća, a procjena nastavka poslovanja poduzeća od velike je važnosti za cjelokupnu poslovnu zajednicu i sve interesne skupine u lancu vrijednosti poslovanja poduzeća. Ključni faktor uspjeha u procjeni nastavka poslovanja poduzeća je odabir modela koji će na točan i objektivan način generirati ispravnu procjenu nastavka i omogućiti donošenje poslovnih odluka. Predviđanje nastavka poslovanja uglavnom se veže uz revizijske angažmane, no u vrijeme brzih promjena u svjetskom ekonomskom okruženju i korporativnim financijama, procjena nastavka poslovanja postala je jedna od glavnih tema svjetskih istraživača u svim ekonomskim područjima u posljednjih 35 godina.

Svrha ovog rada je istražiti učinkovitost modela predviđanja nastavka poslovanja poduzeća temeljenih na kvantitativnim financijskim pokazateljima u hrvatskom gospodarstvu i predložiti novi model, temeljen na kvantitativnim i kvalitativnim pokazateljima, sukladno karakteristikama poslovanja hrvatskih poduzeća u okruženju održive ekonomije, posebno nakon nastupanja poslovne krize 2008. godine. Osnovni ciljevi rada su objasniti učinkovitost tradicionalnih i suvremenih modela u cilju predviđanja nastavka poslovanja poduzeća, istražiti učinkovitost Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela u predviđanju nastavka poslovanja poduzeća, te predložiti novi model predviđanja nastavka poslovanja uključivanjem odabranih kvantitativnih (nefinancijskih) i kvalitativnih varijabli primjenom suvremene metode neuronskih mreža.

Empirijsko istraživanje i analiza učinkovitosti navedena tri statistička modela provela se na uzorku poduzeća iz hrvatskog gospodarstva, te su se istraživanjem i analizom potvrdile prve dvije pomoćne hipoteze rada kojima se dokazalo da tradicionalni modeli jesu uspješni u predviđanju poslovanja poduzeća u Republici Hrvatskoj, posebno uspješnih, ali da postoji razlika između učinkovitosti modela. Generalno gledano postoji nekoliko značajnih problema u primjeni tradicionalnih modela u poslovnoj praksi. Prvi signifikantan problem s tradicionalnim modelima predviđanja nastavka poslovanja s kojim se susreću korisnici je njihova općenita upotreba, odnosno problem generalne upotrebe u različitim specifičnim makroekonomskim okruženjima i

nacionalnim ekonomijama. Drugi problem je njihova učinkovitost u predviđanju budućih poremećaja ili nastavka poslovanja s obzirom na činjenicu da se većina temelji na tradicionalnim statističkim metodama (MDA, probit i logit) koje nisu adekvatne za procjenu kompleksnih i dinamičnih okruženja. Treći problem je činjenica da većina takvih modela koristi isključivo financijske pokazatelje poslovanja temeljene na povijesnim računovodstvenim podacima. Iz tog razloga takvi modeli nisu dovoljno osjetljivi i ne osiguravaju rane znakove upozorenja korisnicima modela.

Iz navedenih rezultata istraživanja javila se potreba definiranja novog modela koji bi uzeo u obzir sve nedostatke postojećih modela. Posljednjih nekoliko godina metoda umjetnih neuronskih mreža predlaže se, u literaturi i praksi, kao prikladna i bolja metoda od tradicionalnih statističkih metoda koja daje točnije rezultate bez potrebe poštivanja striktnih statističkih pretpostavki tradicionalnih metoda. U ovom istraživanju stoga je, za definiranje novog prediktivnog modela, upotrijebljena umjetna neuronska mreže te logistička regresija za definiciju najznačajnijih varijabli u samom modelu. Rezultat rada je definicija novog modela te algoritam, temeljem umjetne neuronske mreže „širenja unatrag“, za buduće procjene nastavka poslovanja poduzeća. Dodatnom analizom najznačajnije varijable za procjenu nastavka poslovanja poduzeća pokazale su se: ukupne obveze / kapital, ukupne obveze / (kapital + rezerve), dugoročne obveze / ukupna imovina, EBIT / trošak kamata, dugotrajna imovina / (kapital + dugoročne obveze).

Novi definirani model demonstrirao je uspješnost od 97,69% u predviđanju nastavka poslovanja poduzeća što je više od tradicionalnih modela istraženih u radu čime se potvrdila osnova hipoteza rada: „Suvremeni model predviđanja temeljen na kvantitativnim i kvalitativnim varijablama, odabranih pomoću statističke metode neuronskih mreža uvažavajući specifičnosti hrvatskog gospodarskog okruženja, omogućava učinkovitiju procjenu nastavka poslovanja u poduzećima u odnosu na postojeće modele i na taj način doprinosi stabilnosti i održivosti nacionalne ekonomije.“

Podaci korišteni u definiciji modela prikupljeni su u Republici Hrvatskoj koja reprezentativno predstavlja tranzicijske zemlje te je model primjenjiv u regionalnim tranzicijskim zemljama sa sličnim makroekonomskim i institucionalnim uvjetima.

Summary

The going concern concept is the basic prerequisite for company's business activities and its forecasting is essential for the entire business community as well as for the large number of stakeholders participating in company's value chain. The key success factor in going concern forecasting is the selection of the most appropriate model that can factually and accurately generate efficient going concern prediction, thus enabling the key decision makers to make the right decision. The going concern prediction is mostly connected to audit engagements, but in time of fast changes in global economic environment and corporate finance, going concern prediction has, in the last 35 years, become one of the global key economics research topics.

The purpose of this work was to examine the effectiveness of the going concern forecasting models based only on quantitative financial indicators in the Croatian economy and to propose the new model. The model should be based on both quantitative and qualitative indicators, considering major Croatian economy business characteristics in a sustainable economy environment, especially after financial crisis in 2008. The main goals of the thesis were to explain the effectiveness of traditional and contemporary going concern prediction models, examine the effectiveness of Altman Z'-score model, Zmijewski model and Ohlson model and to propose the new going concern prediction model based on selected financial, quantitative (non-financial) and qualitative variables developed with the support of artificial neural network method.

Empirical research and efficiency analysis performed on the selected three statistical models were conducted on the data sample from companies operating in Croatian economy. Conducted research and analysis confirmed the two supporting hypotheses of the work proving that traditional models are actually efficient in business performance prediction in Croatian economy, especially for the successful companies, but that there is a difference in the models' accuracy. In general, there are several main challenges in the traditional models' implementation in business practice. The first problem regarding traditional forecasting models users come across is their application in difference specific macroeconomic environments and national economies due to their general application set up. The second main issue is the models' accuracy rate

in business failure or going concern forecasting due to the fact that the models are based on traditional statistical methods (MDA, probit and logit) that are not always adequate for forecasting complex and dynamic situations. The third problem is the fact that majority of traditional models is based solely on financial business indicators resulting from historical accounting data. All things considered, these models do not ensure appropriate sensitivity and cannot guarantee early warning signals to models' users.

The need for the new model, that would take into account all disadvantages of the current models, came out as the result of the empirical research. In the last several years, artificial neural networks method is being suggested, both in theory and practice, as more appropriate and efficient method than traditional statistical methods, without respecting all restrictive statistical prerequisites of traditional methods. Therefore, artificial neural networks statistical method was used in this empirical research in order to define new forecasting model, as well as logistic regression to define the most important variables in the forecasting model. The main results of the thesis is the new model and algorithm, based on the backpropagation algorithm of the artificial neural networks, for the company's going concern forecasting. The most important variables for the forecasting are: total debt / equity, total debt / (equity + reserves), long-term liabilities / total assets, EBIT / interest, total assets / (equity + long-term liabilities).

The new defined model demonstrated the accuracy rate of 97.69% in companies' going concern prediction, which is higher than at traditional statistical methods analyzed in the thesis by which the main thesis hypothesis was confirmed: "Contemporary forecasting model, based on selected quantitative and qualitative variables by statistical method of neural networks and taking into account the specificity of the Croatian economic environment, can more efficiently assess companies' going concern in comparison to traditional models, thus contributing to the stability and sustainability of the national economy."

Data used in the forecasting model definition was collected in the Croatian economy and Croatia, as the country, successfully represents transitional countries. This makes the new model applicable in regional transitional countries with similar macroeconomic and institutional conditions.

Ključne riječi

Prediktivni modeli, nastavak poslovanja, Altman model, Ohlson model, Zmijewski model, financijske i nefinancijske varijable, kvantitativne i kvalitativne varijable, umjetne neuronske mreže

Key words

Predictive models, going concern, Altman model, Ohlson model, Zmijewski model, financial and non-financial variables, quantitative and qualitative variables, artificial neural networks

SADRŽAJ

Stranica

1. Uvod	1
1.1. Problem i predmet istraživanja	2
1.2. Znanstvene osnovne i pomoćne hipoteze	6
1.3. Svrha i cilj istraživanja	7
1.4. Ocjena dosadašnjih istraživanja	9
1.5. Izvori i metoda prikupljanja podataka	13
1.6. Sadržaj i struktura rada	17
2. Koncept nastavka poslovanja poduzeća	20
2.1. Razvoj koncepta i definicija nastavka poslovanja poduzeća	20
2.2. Razumijevanje i značaj utvrđivanja poslovnih poremećaja	23
2.3. Važnost procjene nastavka poslovanja i njezini korisnici.....	25
3. Modeli predviđanja nastavka poslovanja – analiza prethodnih istraživanja	32
3.1. Teorijski prikaz i ocjena tradicionalnih statističkih modela	33
3.2. Teorijski prikaz i ocjena ekspertnih sustava	46
3.3. Teorijski prikaz i ocjena teorijskih modela	48
3.4. Potreba za novim modelom predviđanja nastavka poslovanja	49
3.5. Dosadašnji rezultati istraživanja učinkovitosti modela primjenom statističke tehnike neuronskih mreža.....	51
4. Empirijsko istraživanje: Analiza učinkovitosti Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela	56
4.1. Odabir i karakteristike uzorka istraživanja	56
4.2. Razrada metode istraživanja	62
4.3. Rezultati empirijskog istraživanja.....	65
4.4. Usporedba rezultata učinkovitosti modela	82

5. Empirijsko istraživanje: Izrada suvremenog modela predviđanja nastavka poslovanja poduzeća	85
5.1. Teorijski prikaz metode umjetnih neuronskih mreža.....	86
5.1.1. Struktura umjetnih neuronskih mreža	87
5.1.2. Arhitektura umjetnih neuronskih mreža	92
5.1.3. Postupak učenja umjetnih neuronskih mreža	94
5.1.4. Backpropagation algoritam	96
5.1.5. Prednosti i nedostaci umjetnih neuronskih mreža	97
5.2. Analiza ulaznih varijabli za definiranje modela	99
5.2.1. Teorijske varijable iz prethodnih istraživanja	101
5.3. Odabir varijabli za definiranje modela.....	113
5.4. Programska izvedba i interpretacija rezultata umjetnih neuronskih mreža	118
5.5. Rezultati novog modela	127
5.6. Moguća ograničenja upotrebe novog modela.....	131
5.7. Mogućnosti primjene novog modela u post tranzicijskim zemljama	132
6. Usporedba učinkovitosti novog modela predviđanja nastavka poslovanja poduzeća u RH s tradicionalnim modelima	133
7. Zaključak.....	138
8. Smjernice za daljnja istraživanja	141

Literatura

Privitci

Popis ilustracija

Biografija

“Prediction is very difficult, especially if it's about the future.”

Niels Bohr, dobitnik Nobelove nagrade za fiziku (1922.)

1. UVOD

Koncept održive ekonomije, koji se u današnje vrijeme potencira, podrazumijeva pri upravljanju pored ostalog primjenu načela odgovornosti i transparentnog izvještavanja o poslovanju. Pravovremeno i točno izvještavanje, bazirano na analiziranju podataka, pretpostavka su donošenja kvalitetnih odluka koje osiguravaju kontinuitet u poslovanju bilo kojeg poslovnog subjekta. Stoga je voditi brigu o nastavku poslovanja poduzeća zadatak upravljačke strukture i od posebnog je značaja danas kada se traži odgovornost prema svim sudionicima u poslovnom procesu. Predviđanje nastavka poslovanja uglavnom se u praksi veže uz revizijske angažmane, no u današnje vrijeme brzih promjena u svjetskom ekonomskom okruženju pa otuda i u korporativnim financijama, kada se za iskazivanje uspješnosti i održivosti poduzeća koriste razni pokazatelji, procjena nastavka poslovanja poduzeća i stvaranje dodane vrijednosti ključni su, ne samo za vlasnike, upravu i zaposlenike, već i za veliki broj ostalih subjekata: financijske analitičare pri financijskim institucijama, analitičare u javnim službama, revizore, kontrolere i ostale zainteresirane subjekte.

Od pionirskog istraživanja Altmana 1968. godine, razvijen je znatni broj modela predviđanja nastavka poslovanja, koji se intenzivno primjenjuju u procjeni rizika poslovanja poduzeća od sredine 70-tih godina prošlog stoljeća. Originalni model Altmana podvrgnut je brojnim revizijama, a razvili su se i brojni drugi alternativni modeli primjenom različitih statističkih metoda i kombiniranjem raznih varijabli. Nakon izbivanja financijske krize u Aziji krajem 90-tih godina prošlog stoljeća, ponovo su zaživjela istraživanja o novim modelima, a posljednji val istraživanja nakon izbivanja svjetske krize 2008. godine pokazuje rastuću zabrinutost za nastavkom poslovanja poduzeća koja u slučaju negativnog razvoja svog poslovanja mogu prouzročiti domino efekt na međunarodnom financijskom nivou.

U tom kontekstu, prognostička svojstva razvijenih modela se stalno preispituju u namjeri da se pronađu i predlože učinkovitiji modeli. Stoga je u današnje vrijeme dinamičnih tržišta i rizičnosti poslovanja ova tema aktualna jer se kontinuiranim dodavanjem novih varijabli u modele, sukladno zahtjevima okruženja, pokušava povećati njihova učinkovitost predviđanja.

1.1. Problem i predmet istraživanja

U posljednjih 35 godina tema predviđanja nastavka poslovanja izrasla je u jednu od glavnih tema u korporativnim financijama. Veliki se broj akademskih istraživača bavio i bavi razvojem modela predviđanja nastavka poslovanja (Balcaen i Ooghe, 2006., daju pregled najznačajnijih svjetskih autora i modela u posljednjih 35 godina) temeljenim na različitim statističkim metodama i procjenama, preduvjetima i računalnoj kompleksnosti koji bi svim zainteresiranim skupinama mogli pomoći u procjeni nastavka poslovanja određenog poduzeća. To se posebno odnosi na teže poslovne poremećaje u poslovanju gdje stečaj poduzeća, kao najteži oblik, producira značajne gubitke vlasnicima i kreditorima poduzeća, te ima multiplikativne posljedice na cijelo društvo. Predviđanje poslovnih poremećaja predstavlja važan čimbenik uspjeha i održivosti nacionalne ekonomije, te nameće važnost i potrebu razvoja modela koji uključuje obilježja nacionalnog ili regionalnog gospodarskog okruženja. Osim znanstvenika koji se, globalno i lokalno, bave optimiranjem statističkih metoda definiranja modela predviđanja, zatim analizom i kombiniranjem raznih varijabli s ciljem pronalaska učinkovite formule predviđanja nastavka poslovanja, razvila se i posebna, vrlo unosna, djelatnost savjetovanja (odnosno konzaltinga) koja se prvenstveno time bavi. Aktualnost ove teme podupiru i zakonske potrebe, prvenstveno u okviru Zakona o financijskom poslovanju i predstečajnoj nagodbi gdje se traži procjena nastavka poslovanja u sklopu upravljanja rizicima poslovanja kao temeljnim obvezama Uprave poduzeća ili u sklopu pokretanja financijskog ili operativnog restrukturiranja.

Prvi problem istraživanja ovog doktorskog rada je kritička analiza učinkovitosti primjene modela predviđanja nastavka poslovanja i izračunavanje rizičnosti poslovanja poduzeća koji se temelje na financijskim pokazateljima. Za analizu su u disertaciji odabrani modeli po njihovoj učestalosti u literaturi, primjeni i stupnju točnosti prognoziranja, a to su: Altmanov model (Z'-score pokazatelj iz 1983. godine), Zmijewski model i Ohlson model. Analiza učinkovitosti se provela na hrvatskim poduzećima u makroekonomskim uvjetima u razdoblju od 6 godina (od 2010. do 2015. godine), nakon nastupanja financijske krize, a s ciljem otkrivanja i ocjene njihove učinkovitosti u pravovremenom prepoznavanju nastavka poslovanja i eventualnoj potrebi početka procesa restrukturiranja. Učinkovitost modela može se analizirati kroz tri dimenzije: sposobnost klasifikacije poduzeća u uspješna ili neuspješna, točnost

procjene nastupanja poslovnih poteškoća u odnosu na druge modele, te učinkovitost modela kada su troškovi pogrešne klasifikacije poduzeća u ona za koja se predviđa stečaj različiti od troškova pogrešne klasifikacije poduzeća u uspješna (Bauer, Agarwal, 2014.). U ovom radu analiza se vršila na prve dvije dimenzije: na odabranom uzorku poduzeća ispitala se učinkovitost modela u klasifikaciji poduzeća na uspješna i neuspješna, te točnost modela u identifikaciji nastupanja poslovnih poremećaja u poduzećima. Odabir ovih modela za analizu temelji se na činjenici da su modeli Altmana i Zmijewskog najcitiraniji kao statistički modeli predviđanja temeljeni na financijskim varijablama (Salimi, 2015., Lacher et al, 2015., Avenhuis, 2013., Alareeni, Branson, 2013., Vitezić, 2013., Prihatni, Zakaria, 2011., Sajter, 2009., Pindado et al, 2006., Balcaen, Ooghe, 2006., Boritz, Sun, 2004., Šarlija, 2002., Grice, Ingram, 2001. i drugi) u suvremenoj teoriji. Odabir Altmanovog revidiranog Z'-score pokazatelja iz 1983. za provođenje analize temelji se na njegovoj većoj učinkovitosti, odnosno točnosti u predviđanju poslovnih poremećaja u poduzećima u odnosu na prethodne dvije verzije Z-score pokazatelja, koju je utvrdio Altman (Altman, 1968., 1983.), ali i drugi istraživači (Hall, 2002., Oluwo, 2007.). Zmijewski model (Zmijewski, 1984.) je odabran zbog točnosti modela od 99% (na odabranim uzorku poduzeća) koju je prijavio Zmijewski i činjenice da je njegov model najčešće upotrebljavan model u računovodstvenim istraživanjima i među najcitiranijim u teoriji (Grice, Dugan, 2003.). Model Ohlsona (Ohlson, 1980.) je odabran zbog činjenice da je autor prvi definirao uzorak za definiranje modela s brojem poduzeća u bankrotu i poduzeća koja posluju prema omjeru u populaciji (105 poduzeća u bankrotu i 2.058 poduzeća koja nisu u bankrotu). Zajedničko obilježje ova tri modela je da svi koriste financijske pokazatelje koji mjere likvidnost, zaduženost i profitabilnost. Razlika među modelima se ogleda u različitim parametrima i statističkim tehnikama za predviđanje nastavka poslovanja (multivarijantna diskriminacijska analiza, probit i logit statističke metode).

Učinkovitost navedena tri modela proučava se već zadnjih dvadeset godina, a najveći problemi ovih modela su sljedeći:

- Statističke tehnike:
 - kritike multivarijantne diskriminacijske analize koju koristi Altman, te logit i probit koju koriste Ohlson i Zmijewski odnose se na njezinu statičnost

(Shumway, 2001.), pretpostavke o linearnosti i normalnosti raspodjele varijabli

- Parametri:

- parametri modela koji su isključivo temeljeni na računovodstvenim podacima koji se objavljuju jednom godišnje (ili kvartalno) i odražavaju prošlo stanje, te mogu biti predmetom manipulacije managementa (Chen, Du, 2009.)

- Definicija uzorka:

- primjenjivost modela u drugim makroekonomskim uvjetima zbog specifičnog uzorka na kojima su parametri modela definirani (na uzorcima iz specifičnih industrija u određenom vremenskom periodu) (Avenhuis, 2013., Grice, Ingram, 2001.),
- primjenjivost modela Altmanna i Zmijewskog zbog originalnog uzorka poduzeća, na kojem je model razvijen, koji se sastojao od neproporcionalno velikog udjela poduzeća u bankrotu u odnosu na stvarnu populaciju poduzeća (Boritz et al, 2007.),
- promjenjivost točnosti modela tijekom dužeg vremenskog perioda zbog izmijenjenih poslovnih uvjeta u kojima se model primjenjuje, te u slučaju kada se populacija poduzeća razlikuje od one u originalnoj metodologiji (Grice, Ingram, 2001., Boritz, Sun, 2004.).

Unatoč kritikama modela, kroz brojna istraživanja nije jednoglasno dokazano da su u svim ekonomskim uvjetima oni manje učinkoviti od modela baziranih na sve popularnijim umjetnim neuronskim mrežama ili teorijskim modelima, ili od modela koji uz računovodstvene podatke koriste i podatke tržišta (Wu et al, 2010., Boritz et al, 2007., Shumway, 2001., Trigueiros, Taffler, 1996.), već njihova učinkovitost ovisi o karakteristikama specifičnog tržišta, privrednoj strukturi i uvjetima poslovanja. Predmet interesa ove disertacije je problem pronalaska optimalnog modela za procjenu nastavka poslovanja u tranzicijskim zemljama, uzimajući u obzir neke činjenice karakteristične za tržište tranzicijskih zemalja, ali i specifičnosti poslovanja poduzeća u Hrvatskoj zbog zakona koji definiraju poslovanje (primjerice stečaj), gospodarsku

strukturu i makroekonomske uvjete. Stoga je **drugi problem istraživanja** doktorskog rada definiranje novog modela za procjenu nastavka poslovanja poduzeća koji će uvažiti većinu kritika analiziranih modela te će osim računovodstvenih kvantitativnih pokazatelja uključivati i ostale kvantitativne (nefinancijske) i kvalitativne pokazatelje, a biti će temeljen na suvremenoj statističkoj metodi umjetnih neuronskih mreža.

Iz problema istraživanja proizlazi i **prvi predmet istraživanja**, a to je ocjena uspješnosti tradicionalnih statističkih modela, Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela, u procjeni nastavka poslovanja poduzeća u tranzicijskim makroekonomskim uvjetima, na uzorku hrvatskih poduzeća. Uzorak se sastoji od uspješnih poduzeća koja kontinuirano posluju i neuspješnih poduzeća u hrvatskom gospodarstvu, koji su stupili u stečaj, pokrenuli predstečajnu nagodbu ili iskazuju negativne pokazatelje uspješnosti poslovanja: ostvareni gubitak, koeficijent zaduženosti veći od 1, te pokazatelj ubrzane likvidnosti manji od 1. Ova tri pokazatelja su promatrana jer se u ovom slučaju uspješnost promatra u širem kontekstu. Uspješnost se u ovom slučaju mjeri učincima u odnosu na ulaganja, a osnovne pretpostavke uspjeha su mala zaduženost i zadovoljavajuća likvidnost. Pokazatelji zaduženosti i likvidnosti nisu sami po sebi pokazatelji uspjeha, ali ih je potrebno analizirati da bi se mogla procijeniti uspješnost.

Uzorak se sastoji od srednjih i velikih poduzeća bez obzira da li se njihovim vrijednosnim papirima trguje na burzi. **Drugi predmet istraživanja** je predlaganje i testiranje učinkovitosti novog modela predviđanja nastavka poslovanja poduzeća baziranog na statističkoj metodi umjetnih neuronskih mreža. Radi se o pokušaju oblikovanja novog modela, primjenjivog u hrvatskoj praksi, ali i drugim sličnim ekonomijama, koji će se temeljiti na:

- znanstveno utemeljenim financijskim pokazateljima, odnosno najčešće korištenim parametrima u razvoju modela predviđanja drugih istraživača u posljednjih 35 godina,
- dodatnim kvantitativnim (nefinancijskim) i kvalitativnim pokazateljima (temeljem teorijske podloge i prakse),
- pokazateljima tržišta koji su učinkoviti u procjeni nastavka poslovanja poduzeća u hrvatskom gospodarskom okruženju,

- bankarskim pokazateljima korištenim u analizi kreditne sposobnosti klijenata,
- uzorku srednjih i velikih poduzeća neovisno o njihovom kotiranju na burzi (cilj je definirati model sa što većim uzorkom kako bi se realnije i učinkovitije procjenjivao nastavak poslovanja svih poduzeća, a ne samo 200-tinjak velikih na burzi) ili pripadnosti industrijskoj grani.

Dodatne kvantitativne i kvalitativne varijable ugrađene u novi model proizlaze iz općih karakteristika globalnog okruženja koje prihvaća zajednička načela temeljena na konceptu održivosti. Stoga će se ovaj model, koji će se testirati na hrvatskim poduzećima, moći primijeniti i na ostalim gospodarstvima, posebno post tranzicijskih zemalja Istočne i Centralne Europe, koja su prošla sličnu transformaciju ka privatizaciji i tržišno orijentiranoj ekonomiji.

1.2. Znanstvene osnovne i pomoćne hipoteze

Iz teorijske podloge i empirijskog istraživanja pokušati će se opravdati ili opovrgnuti postavljena temeljna i pomoćne hipoteze:

H0: „Suvremeni model predviđanja temeljen na kvantitativnim i kvalitativnim varijablama, odabranih pomoću statističke metode umjetnih neuronskih mreža uvažavajući specifičnosti hrvatskog gospodarskog okruženja, omogućava učinkovitiju procjenu nastavka poslovanja u poduzećima u odnosu na postojeće modele i na taj način doprinosi stabilnosti i održivosti nacionalne ekonomije.“

H1: „Altmanov Z'-score model, Zmijewski model i Ohlson model, temeljeni na kvantitativnim financijskim pokazateljima, učinkoviti su u predviđanju nastavka poslovanja poduzeća u dosadašnjim makroekonomskim uvjetima u Hrvatskoj koji su omogućavali da poduzeća unatoč svojim lošim rezultatima i dalje posluju.“

H2: „Postoji razlika u učinkovitosti predviđanja Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela u hrvatskom gospodarstvu.“

H3: „Odabirom kvantitativnih (financijskih i nefinancijskih) i kvalitativnih varijabli temeljem statističke metode umjetnih neuronskih mreža moguće je predložiti novi model s učinkovitijim svojstvima predviđanja nastavka poslovanja poduzeća u hrvatskom gospodarstvu u odnosu na modele temeljene samo na kvantitativnim financijskim pokazateljima.“

Da bi postavljena hipoteza i pomoćne hipoteze bile znanstveno dokazive, financijski izvještaji trebaju realno i objektivno prikazivati sve računovodstvene stavke koje uključuju. Zbog toga su u istraživanju korišteni revidirani financijski izvještaji.

1.3. Svrha i cilj istraživanja

Svrha rada je istražiti učinkovitost modela predviđanja nastavka poslovanja poduzeća temeljenih na kvantitativnim financijskim pokazateljima u hrvatskom gospodarstvu i predložiti novi model, temeljen na kvantitativnim i kvalitativnim pokazateljima, sukladno karakteristikama poslovanja hrvatskih poduzeća u okruženju održive ekonomije, posebno nakon nastupanja poslovne krize 2008. godine. Poseban je naglasak na hrvatskoj praksi zbog promjena institucionalnih uvjeta poslovanja hrvatskih poduzeća od 01.10.2012. godine nakon primjene Zakona o financijskom poslovanju i predstečajnoj nagodbi, te od 01.09.2015. godine stupanjem na snagu novog Stečajnog zakona. U sklopu novog Stečajnog zakona u potpunosti je reguliran postupak predstečajne nagodbe, a Zakon o financijskom poslovanju i predstečajnoj nagodbi, koji je i dalje na snazi, regulira financijsko poslovanje poduzetnika i rokove ispunjenja novčanih obveza. Identifikacija nastavka poslovanja u poduzećima od velikog je značaja za ocjenu boniteta i to od strane samog poduzeća, ali i financijskih institucija povezanih s poduzećem, poslovnih partnera i ostalih izravno vezanih dionika, te je od velikog značaja za sve proračunske korisnike, odnosno za cjelokupni realni i javni sektor.

Osnovni cilj rada je uporabom analitičkih i statističkih znanstvenih metoda dokazati ili opovrgnuti postavljenu osnovnu i pomoćne hipoteze. Cilj je predložiti novi suvremeni model primjenom metode umjetnih neuronskih mreža, s namjenom točnije procjene

nastavka poslovanja i sprečavanja poslovnih poremećaja koji dovode do nastupanja krize u poduzeću. Prije oblikovanja suvremenog modela, teorijski se istražila učinkovitost Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela te empirijski istražila njihova učinkovitost na primjeru hrvatskog gospodarstva.

Osnovni ciljevi rada glase:

- C1: Objasniti i sažeto predstaviti istraživanja učinkovitosti tradicionalnih i suvremenih modela u cilju predviđanja nastavka poslovanja poduzeća, uključujući kratko teorijsko predstavljanje najvažnijih modela.
- C2: Istražiti učinkovitost Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela u predviđanju nastavka poslovanja na poduzećima koja posluju u Republici Hrvatskoj nakon nastupanja poslovne krize 2008. godine.
- C3: Predložiti novi model predviđanja nastavka poslovanja uključivanjem odabranih kvantitativnih (nefinancijskih) i kvalitativnih varijabli primjenom suvremene metode umjetnih neuronskih mreža i uvažavajući specifičnosti hrvatskog gospodarskog okruženja.
- C4: Istražiti učinkovitost novog suvremenog modela u predviđanju nastavka poslovanja poduzeća u hrvatskom gospodarstvu i usporediti ga s učinkovitosti Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela na istom uzorku poduzeća.
- C5: Objasniti specifičnosti i ograničenja suvremenog modela u praktičnoj primjeni.

1.4. Ocjena dosadašnjih istraživanja

Počeci istraživanja i razvoja modela za nastavak poslovanja započinju svoj intenzivni razvoj početkom 20. stoljeća, nakon industrijske revolucije, kada su ubrzane poslovne aktivnosti rezultirale velikim brojem novih poduzeća i povećanjem njihove imovine i prihoda. Istovremeno je sve veći broj uključenih aktera zahtijevao informacije o

poslovnom riziku i financijskoj stabilnosti poduzeća. Do danas se veliki broj istraživača bavio analizom uspješnosti i razvojem modela predviđanja nastavka poslovanja kako bi identificirali poduzeća koja donose dobitak i/ili gubitke prvenstveno svojim vlasnicima i kreditorima. U predviđanju poslovnih uspjeha i neuspjeha, posebno onih financijskih, koristili su se i koriste se i danas razne statističke i suvremene sofisticirane metode iz područja umjetne inteligencije kao i teorijski modeli, a svima im je zajednički cilj ustanoviti simptome i uzroke neuspjeha poslovanja (Vitezić, 2013.).

Posljednji veliki izazov za modele predviđanja nastavka poslovanja poduzeća predstavlja velika financijska kriza 21. stoljeća koja je započela između 2007. i 2008. godine zbog propasti jedne od najvećih banaka u SAD-u: Lehman Brothers. Kriza je uvela zahtjevnije uvjete kontrole poslovanja jer se zbog razvijenog globalnog tržišta rizici poslovanja teže prepoznaju, ali je još teže ocijeniti intenzitet njihovog utjecaja na nastavak poslovanja poduzeća. Nakon uvođenja Basel II standarda, 2004., credit scoring modeli su postali obavezni u procjeni osiguranja dostatnog kapitala radi pokrivanja rizika u financijskim institucijama, što je rezultiralo još većom uporabom i razvojem modela za procjenu nastavka poslovanja poduzeća.

Posljedica velike financijske krize 21. stoljeća su brojna poduzeća u stečaju ili bankrotu, a prema istraživanjima u svijetu mnogi su faktori utjecali na takav negativni razvoj poslovanja, primjerice loše upravljanje i prijevare, neadekvatni kapital, loše zakonodavstvo (Samkin et al, 2012.), te nedostatak znanja o upravljanju financijama, loše upravljanje kapitalom, loše upravljanje dugom, neadekvatna priprema od iznenadnih nepovoljnih događaja, problematična operativna disciplina na financijskom tržištu (Chen, Du, 2009.).

Međunarodna literatura istražuje modele predviđanja stečaja i nastavka poslovanja poduzeća od prve polovice prošlog stoljeća, počevši od istraživanja jednovarijantnih modela tijekom 30-tih godina prošlog stoljeća (Smith, Winakor, 1930., Fitzpatrick, 1932.) do razvoja i usavršavanja neuronskih mreža u posljednjem desetljeću (Shumway, 2001., Chen, Du, 2009.). Znanstvenici su primjenjivali različite statističke metode na financijske pokazatelje kako bi definirali one najvažnije koji diferenciraju stabilna od nestabilnih poduzeća.

Istraživanja su započela autorima Smith i Winakor 1930. godine s prvom studijom i modelom predviđanja poslovanja upotrebom financijskih pokazatelja. Autori su odabrali 21 poduzeće i analizirali njihovo poslovanje u razdoblju od 10 godina prije nastupanja stečaja primjenom nekoliko financijskih pokazatelja i dokazali da su se isti pogoršali signifikantan broj godina prije nastupanja stečaja (Oluwo, 2007.). Sljedeće značajno istraživanje je proveo Fitzpatrick 1932. s ciljem definiranja financijskih pokazatelja koji razlikuju uspješna od neuspješnih poduzeća primjenom jednovarijantnog modela. Testirao je 13 financijskih pokazatelja na uzorku od 40 poduzeća (20 uspješnih i 20 neuspješnih) u razdoblju od 10 godina i dokazao da financijski pokazatelji ostvaruju različite iznose kod uspješnih i neuspješnih poduzeća, te također identificirao pet stupnjeva razvoja neuspjeha poduzeća: inkubacija, financijsko pogoršanje, financijska insolventnost, totalna insolventnost i potvrđena insolventnost (Fitzpatrick, 1932.).

Nakon Fitzpatricka i dalje se, sredinom prošlog stoljeća, predviđanju stečajeva i nastavka poslovanja poduzeća pristupalo jednostrukom analizom pojedinačnih financijskih pokazatelja i njihovom usporedbom s definiranim referentnim vrijednostima te izvođenjem zaključaka (Beaver, 1966.). Beaver je otkrio da određeni broj pokazatelja može diskriminirati poduzeća koja će bankrotirati i do pet godina prije nastupa samog bankrota. Daljnja istraživanja uključuju regresijsku analizu, posebno višestruku diskriminacijsku analizu, s ciljem pronalaska kombinacije financijskih pokazatelja koji objektivno diferenciraju stabilna od nestabilnih poslovnih subjekata.

Najpoznatiji od svih autora u tom znanstvenom području je Edward I. Altman koji je 1968. definirao sintetički pokazatelj nazvan Z-score (kasnije razrađivan kroz nekoliko varijanti), koji je i predmet istraživanja ovog rada, temeljem metodologije višestruke diskriminacijske analize (Altman, 1968., 1983., 2002., 2010.). Ostali autori kao Deakin (1972.), Ohlson (1980.), Edmister (1972.), Zavgren (1983.), Zmijewski (1984.), Theodossiou (1993.) koristili su slične statističke metode, ali na drugim uzorcima poduzeća, industrijskim granama ili državama. Uglavnom istraživači naglašavaju korištenje financijskih pokazatelja među kojima se ističu pokazatelji likvidnosti, solventnosti i profitabilnosti kao najvažniji pokazatelji modela predviđanja stečaja i nastavka poslovanja poduzeća (Vitezić, 2009., 2013.), dok su drugi pokazatelji rjeđe korišteni. Osim Altmana, među autorima se ističe i Zmijewski čiji model predviđanja

koriste istraživači (Grice, Dugan, 2003., Avenhuis, 2013., Kumar, Kumar, 2012.) za predviđanje nastavka poslovanja poduzeća ili ga uspoređuju s drugim modelima.

U posljednjih desetak godina koriste se ekspertni sustavi, a oni koriste umjetnu inteligenciju i suvremena softverska rješenja u predviđanju stečaja poduzeća. Primjer takvih sustava su data mining tehnike i umjetne neuronske mreže. Posljednji u razvoju su teorijski modeli koji se, za razliku od statističkih metoda i ekspertnih sustava, temelje na pronalasku uzroka (uglavnom kvalitativnih) neuspjeha poduzeća i na taj način predviđaju neuspjeh i nastavak poslovanja poduzeća (autorica prilagodila prema Vitezić, 2013.). Najpoznatiji teorijski modeli, temeljeni na matematičkim modelima, su teorija igara i teorija kreditnog rizika (Richter et al., 2007.). U radu su predstavljeni najvažniji modeli.

Učinkovitost postavljenog modela od njegovih začetaka izaziva pažnju niza znanstvenika, te se osim Altmana koji višestruko istražuje učinkovitost svog modela, u novije vrijeme ističu Salimi (2015.), Bauer, Agarwal (2014.), Branson, Alareeni, 2013., Li, Rahgozar (2012.), Wang, Cambell (2010.), Lugovskaya (2010.), Xu, Zhang (2009.), Balcaen, Ooghe (2006.), Grice, Ingram (2001.) i brojni drugi. Oni uspoređuju Altmanov model s drugim modelima i primijenjenim statističkim metodama, uspoređuju sva tri modela Z-score pokazatelja ili modificiraju Altmanov model za primjenu u pojedinim industrijskim granama, npr. bankarstvu (Rios, 2006.). Autori Agarwal i Taffler (2008.) uspoređuju učinkovitost modela predviđanja koji se temelje samo na računovodstvenim informacijama i modela koji se temelje na tržišnim pokazateljima na primjeru poduzeća iz Velike Britanije u razdoblju od 1985.-2001.godine. Navode prednosti i brojne nedostatke računovodstvenih modela, ali unatoč nedostacima njihova studija pokazuje veću učinkovitost Altmanovog modela (79% točnost) u odnosu na tržišne modele Hillegeista (68% točnost) ili Shumwaya (73% točnost).

U hrvatskoj znanstvenoj literaturi se do sada nekoliko autora bavilo pitanjem učinkovitosti i unaprjeđenja modela predviđanja. Škeljo (2000.) provodi istraživanje mogućnosti primjene Altmanovog modela u hrvatskom gospodarstvu i zaključuje da primjena Altmanovog modela u tranzicijskim zemljama nije prikladna, a Deverić (2002.) istražuje mogućnost primjene Altmanovog Z-score modela u hrvatskoj praksi prije nastupanja poslovne krize 2008. godine. Deverić ističe njegovu neučinkovitost u

predviđanju stečaja i nastavka poslovanja poduzeća u Hrvatskoj u odnosu na poduzeća u Sjedinjenim američkim državama. Šarlija (2002.) razvija kreditni scoring model za male poduzetnike na osnovu nekoliko statističkih tehnika, među kojima i neuronske mreže, na osnovu kvalitativnih parametara o poduzećima i vlasnicima. Zenzerović i Peruško 2006. godine daju pregled najvažnijih međunarodnih autora modela predviđanja i u svom zaključku navode potrebu izvođenja modela predviđanja stečaja poslovnih subjekata koji obavljaju djelatnost u tranzicijskim gospodarstvima uz uključivanje kvalitativnih pokazatelja.

Novak i Crnković (2007.) objavljuju rad u kojem se koriste diskriminacijskom analizom, logit modelom i metodom višedimenzionih skala za razvrstavanje trgovačkih društava prema urednosti izvršavanja obveza prema banci. Aljinović Barać i Belak (2007.) objavljuju BEX indeks procjenu poslovne izvrsnosti poduzeća na tržištu kapitala u Hrvatskoj kojeg je, uz određene korekcije, moguće koristiti i za ostala poduzeća, a temelji se na pokazateljima profitabilnosti, stvaranja vrijednosti, likvidnosti i financijske snage. Šarlija, Zekić-Sušac i Benšić (2008.) razvijaju model predviđanja primjenom neuronskih mreža iz financijskih pokazatelja bilance i računa dobiti i gubitka. Zenzerović (2009.) obrađuje temu predviđanja poslovnih financijskih problema u hrvatskom gospodarstvu kroz znanstveni članak i daje osvrt i na Altmanov model.

Vitezić u više znanstvenih članaka (1996., 2009., 2013.) istražuje prognostička svojstva modela među kojima i Altmanov, te daje komparaciju dosadašnjih metoda i korištenih varijabli predviđanja naglašavajući potrebu nadopunjavanja modela s kvalitativnim varijablama. Šarlija i Jeger (2011.) su razvile tri modela predviđanja primjenom logističke regresije na temelju računovodstvenih pokazatelja uzorka malih i srednjih poduzeća s ciljem identifikacije ključnih financijskih omjera prije i za vrijeme krize. Tomas Žiković (2013.) ispitala je vjerojatnost ulaska poduzeća u poslovnu krizu uzimajući u obzir promjene u financijskim pokazateljima i makroekonomskom okruženju uz pomoć logit i hazard analize.

Ostali praktičari i znanstvenici koji su kroz svoje stručne i znanstvene radove obrađivali temu modela predviđanja nisu kombinirali kvalitativne i kvantitativne pokazatelje (Paar, 2012., Streitenberger, Miloš Sprčić, 2011., Ivičić, Cerovac, 2009., Sajter, 2005.) što je

vidljivo i iz pregleda međunarodnih i domaćih autora modela predviđanja koje Sajter obrađuje 2009. godine.

U regiji, odnosno susjednoj Bosni i Hercegovini, autori Memić i Rovčanin (2012.) istražuju najznačajnije financijske indikatore za predviđanje vjerojatnosti nastanka statusa neispunjavanja obveza prema bankama (eng. credit default), pri čemu su dokazali da se ROA (povrat na imovinu) ističe kao najznačajniji indikator.

Unatoč činjenici da veliki broj studija, međunarodnih i domaćih, pokazuje zadovoljavajući stupanj učinkovitosti u predviđanju problema poslovanja do danas nije postignut konsenzus koje varijable (financijski pokazatelji) su najučinkovitije u predviđanju stečaja i nastavka poslovanja poduzeća, te koji je period optimalan za sigurno predviđanje stečaja. Također u hrvatskoj praksi se do danas nije razvio model koji osim financijskih pokazatelja uključuje i nefinancijske pokazatelje kako bi se model što više prilagodio održivoj ekonomiji i specifičnostima funkcioniranja hrvatskog gospodarstva i poduzeća.

Iz tog razloga će se u ovom radu istražiti niz kvantitativnih i kvalitativnih varijabli (iz teorije, prijašnjih istraživanja, bankarskog sektora i konzultantskog iskustva autorice) koje će omogućiti učinkovitije predviđanje nastavka poslovanja poduzeća primjenom suvremene metode neuronskih mreža. U radu će se pokušati postići i zadovoljavajući stupanj učinkovitosti predviđanja u razdoblju od jedne do tri godine.

1.5. Izvori i metode prikupljanja podataka

Sukladno hipotezama u radu je korišteno nekoliko znanstvenih metoda u analizi i obradi prikupljenih podataka, te u definiranju novog modela.

Pomoćna hipoteza H1:

1. **U prvoj fazi empirijskog istraživanja** definirao se uzorak na kojem se provela analiza učinkovitosti Altmanovog Z'-score, Zmijewski modela i Ohlson modela.

Učinkovitost se analizirala na uzorku od 1.796 poduzeća raspoređenih u dvije grupe srednjih i velikih poduzeća:

1. Prva skupina poduzeća koju čine:

- poduzeća u stečaju,
- poduzeća s pokrenutim postupkom predstečajne nagodbe
- poduzeća s negativnim rezultatima poslovanja (gubitak, visoka razina zaduženosti, nedovoljna likvidnost),

2. Druga skupina poduzeća koja uspješno posluju.

Prilikom definicije veličine poduzeća, fokus analize bio je na srednjim i velikim poduzećima prema visini prihoda bez obzira na strukturu vlasništva. Uzorak je tako definiran da je udio poduzeća u stečaju, predstečajnoj nagodbi ili s negativnim rezultatima poslovanja u ukupnom uzorku približno jednak udjelu takvih poduzeća u cijeloj populaciji. Analizom su obuhvaćeni podaci za poduzeća u razdoblju od 2010. do 2015. godine. Primjenjivost uzorka na cijelu populaciju srednjih i velikih poduzeća u Republici Hrvatskoj testirala se primjenom web aplikacije Sample Size Calculator (The Survey System).

2. U **drugoj fazi** prikupili su se financijski podaci za provedbu analize. Izvor podatka potrebnih za izračun financijskih pokazatelja bili su javni godišnji financijski izvještaji poduzeća iz godišnje objave Financijske agencije (GFI podaci FINA-e) i podaci dostupni sa Zagrebačke burze.
3. U **trećoj fazi** provela se metoda klasifikacije nakon izračuna Altmanovog Z'-score pokazatelja, Zmijewski pokazatelja i Ohlson pokazatelja za sve godine i poduzeća koristeći se SPSS programom. Analizirao se postotak točnosti predviđanja nastupanja poslovnog poremećaja te broj godina negativnih pokazatelja prije nastupanja stečaja poduzeća.

Pomoćna hipoteza H2:

- 1./2. **Prva i druga faza** empirijskog istraživanja podudaraju se s fazama potvrđivanja ili opovrgavanja pomoćne hipoteze H1. Za potvrđivanje ili opovrgavanje pomoćne hipoteze H2 korišteni su podaci dobiveni analizom podataka iz godišnjih financijskih izvještaja poduzeća.
3. **Treća faza** podrazumijeva metodu komparacije izračuna Altmanovog Z'-score pokazatelja, Zmijewski pokazatelja i Ohlson pokazatelja za razdoblje od 2010. do 2015. godine za sva poduzeća koristeći se SPSS programom, te izračun testova signifikantnosti za svaki model.

Pomoćna hipoteza H3:

1. **Prva faza** definiranja suvremenog modela podrazumijeva teorijsko formuliranje modela, odnosno definiranje financijskih i nefinancijskih varijabli te kvalitativnih varijabli za analizu. Za potvrđivanje ili opovrgavanje pomoćne hipoteze H3 korišteni su podaci dobiveni analizom podataka iz godišnjih financijskih izvještaja poduzeća i ostalih izvora.

Kao sekundarni izvori podataka korištene su knjige i članci domaćih i inozemnih autora, kao i stručne studije. Odabir nezavisnih varijabli koje su korištene kao ulazne varijable u modelu, temelje se na prethodnim istraživanjima drugih autora vezanim za predviđanje financijskih poremećaja i razvoj modela. Istraživanja autora Zenzerović, (2009.), Šarlija (2002., 2011.), Chen, Du, (2009.), Ivičić, Cerovac, (2009.), Lykke, Pedersen, Vinther (2004.) i drugi, sadrže varijable koje su autori smatrali najkorisnijim za predviđanje poslovnih poremećaja koje su korištene u formulaciji modela. Također su analizirane i varijable korištene u bankarskom sektoru za predviđanje pogoršanja kreditne sposobnosti klijenata banke te varijable koje bi mogle karakterizirati specifičnosti lokalnog tržišta. Nezavisne varijable, njih 80tak, su klasificirane u grupe: kvantitativni financijski pokazatelji (pokazatelji likvidnosti i solventnosti, zaduženosti, obrtaja imovine i profitabilnosti) i kvantitativni nefinancijski

pokazatelji, te kvalitativni pokazatelji. Sve varijable korištene u modelu su navedene i klasificirane u kasnijim poglavljima rada.

2. **Druga faza** podrazumijeva definiranje uzorka za analizu varijabli i prikupljanje podataka. Uzorak poduzeća obuhvatio je ista poduzeća kao i za pomoćnu hipotezu H1.
3. U **trećoj fazi** se provela statistička evaluacija teorijskog modela, odnosno odabira nezavisnih varijabli. Za osnovni dio definicije novog modela, odnosno statističku evaluaciju modela za procjenu nastavka poslovanja poduzeća je korištena metoda umjetnih neuronskih mreža uz podršku računalnog programa. Neuronske mreže spadaju u metode umjetne inteligencije koje su strukturirane prema ljudskom mozgu (Šarlija, 2002.). One su oblik nelinearne optimizacije i koriste različite pondere i funkcije s ciljem pretvaranja ulaznih podataka u korisne informacije (prema Zenzerović, Peruško, 2006.). Neuronske mreže su sastavljene od niza povezanih nelinearnih čvorišta raspoređenih po razinama koje paralelno komuniciraju (Chen, Du, 2009.). Na najnižoj razini svako čvorište predstavlja jednu ulaznu varijablu koja može obuhvaćati financijsko ili neko drugo obilježje poslovnog subjekta. Između najniže, srednje i najviše razine postoje određene veze. Srednja razina sastavljena je od neurona koji predstavljaju aktivacijske funkcije u okviru kojih se ulazne varijable transformiraju korištenjem zadane funkcije. Jakost veza između ulaznih i izlaznih varijabli, odnosno između različitih razina utvrđena je putem pondera i može se modificirati, te se na taj način neuronskim mrežama omogućava direktno učenje iz primjera bez nužnosti pružanja analitičkog rješenja problema. Upravo je to učenje neuronskih mreža osnovni proces kojim sustav dolazi do vrijednosti težina veza među neuronima. Treća, najviša razina predstavlja izlaznu varijablu koju čini ponderirani zbroj neurona i koja zapravo prikazuje procjenu nastavka poslovanja. Proces se ponavlja u mreži u onoliko iteracija koliko je potrebno za dostizanje izlaza koji je najbliže željenom rezultatu uz prihvatljivu razinu pogreške.

Rezultat dizajniranja neuronske mreže je **arhitektura mreže**. Mreže se mogu razlikovati prema vezama između neurona koje mogu biti između dva ili više

slojeva (interslojne veze) ili između neurona u jednom sloju (intraslojne veze) (prilagođeno prema Šarlija, 2002.). Jedna od najpoznatijih arhitektura neuronske mreže je mreža „širenja unatrag“ (engl. Backpropagation network (BPN)) i koristi se za rješavanje problema klasifikacije i predviđanja, te je korištena i kao arhitektura mreže u ovom radu. Prema metodologiji neuronskih mreža uzorak je bio podijeljen na uzorak za treniranje, testiranje i vrednovanje (60%, 20%, 20%). Za dizajniranje neuronskih mreža upotrijebljen je računalni program. Iz rezultata treniranja, validacije i analize značajnosti varijabli uključenih u model, definirale su se one varijable koje imaju najjači utjecaj na rezultat, odnosno na vrijednost izlazne varijable (poduzeće koje dobro posluje ili poduzeće koje loše posluje).

4. U **četvrtoj fazi** su se proveli testovi i testiranje učinkovitosti novog modela na početnom uzorku poduzeća primjenom nove formule s kvantitativnim i kvalitativnim pokazateljima na iste financijske podatke poduzeća koristeći se SPSS programom. Nakon testiranja učinkovitosti novog modela, korištena je komparativna metoda za uspoređivanje učinkovitosti tradicionalnih i novog suvremenog modela za nastavak poslovanja poduzeća.

U radu se također koristila induktivno-deduktivna metoda za dokazivanje i provjeravanje postavljenih hipoteza, metoda analize i sinteze, metoda dokazivanja, metoda klasifikacije, deskripcije i kompilacije odnosno preuzimanja tuđih spoznaja i zaključaka.

1.6. Sadržaj i struktura rada

Rad je podijeljen u osam glavnih dijelova čiji je sadržaj ukratko predstavljen u nastavku pod-poglavlja.

U prvom dijelu predstavljen je osnovni motiv pisanja doktorskog rada, te dva problema istraživanja iz kojih su proizašla i dva predmeta istraživanja. Nakon problema i predmeta istraživanja, predstavljena je osnovna znanstvena hipoteza rada te tri

pomoćne hipoteze. Temeljem hipoteza definirano je pet jasnih ciljeva rada te svrha rada. U radu je, u analizi i obradi prikupljenih podataka, te u definiranju novog modela, korišteno nekoliko znanstvenih metoda, koje su također predstavljene u ovom poglavlju. Prvo poglavlje završeno je pregledom i ocjenom dosadašnjih istraživanja međunarodnih i hrvatskih autora u području modela predviđanja stečaja i nastavka poslovanja poduzeća.

U drugom poglavlju teorijski je predstavljen pojam i koncept nastavka poslovanja poduzeća, njegov razvoj i važnost utvrđivanja poslovnih poremećaja. Važnost procjene nastavka poslovanja poduzeća i njezini korisnici objašnjeni su u aspektu dinamičnoga i nestabilnoga poslovnoga okruženja. Treće poglavlje obuhvaća kritički teorijski pregled tradicionalnih, ekspertnih i teorijskih modela te analizu prethodnih istraživanja s fokusom na dosadašnje rezultate prediktivnih modela razvijenih umjetnim neuronskim mrežama. Teorijski su obrađeni modeli Altmana, Ohlsona i Zmijewskog. Na kraju drugog poglavlja objašnjena je potreba za novim modelom predviđanja nastavka poslovanja poduzeća.

Nastavak rada obuhvaća dva empirijska istraživanja. Prvo empirijsko istraživanje, prezentirano u četvrtom poglavlju, predstavlja ocjenu primjene i učinkovitosti modela Altmana, Ohlsona i Zmijewskog u suvremenim hrvatskim ekonomskim uvjetima. U prvom dijelu poglavlja objašnjen je uzorak istraživanja, te su razrađene metode istraživanja kroz tri faze istraživanja. Poglavlje sadrži i prikaz rezultata istraživanja sva tri modela primjenom različitih statističkih postupaka, te usporedbu rezultata učinkovitosti modela.

Drugo empirijsko istraživanje, sadržano u petom poglavlju, rezultira novim razvijenim modelom za predviđanje nastavka poslovanja poduzeća uz pomoć statističke metode umjetnih neuronskih mreža. Teorijski je prikazana metoda umjetnih neuronskih mreža kroz objašnjenje strukture i arhitekture mreža te postupak učenja mreža kao njihove najvažnije karakteristike. Poglavlje sadrži i objašnjenje backpropagation algoritma koji je korišten u radu, te su prikazane prednosti i nedostaci umjetnih neuronskih mreža. Nakon teorijskog dijela, objašnjene su ulazne varijable (kvantitativne financijske i kvalitativne nefinancijske te kvalitativne) koje su korištene u razvoju modela te način

njihova odabira. Završni dio obuhvaća prikaz programske izvedbe modela za koju je korišten programski jezik Python 3 i interpretaciju njegovih rezultata.

Šesto poglavlje obuhvaća usporedbu učinkovitosti tradicionalnih modela za predviđanje nastavka poslovanja poduzeća i novo-razvijenog suvremenog modela. Glavna tri područja ocjene tradicionalnih i suvremenog modela su ocjena učinkovitosti, najznačajnije varijable koje koreliraju s vrijednostima pokazatelja modela i ocjena točnosti modela.

Sedmo poglavlje sažima osnovne zaključke doktorskog rada kroz potvrdu osnovne i pomoćnih hipoteza rada putem dvaju empirijskih istraživanja. Ukratko su prikazani rezultati oba modela i njihove ocjene učinkovitosti te su predstavljena očekivanja o daljnjoj uporabi novo-razvijenog suvremenog modela u financijskim institucijama.

U posljednjem osmom poglavlju prezentirane su smjernice i prijedlozi za daljnja istraživanja.

2. KONCEPT NASTAVKA POSLOVANJA PODUZEĆA

Nastavak poslovanja poduzeća (sinonimi: neograničenost vremena poslovanja, vremenska neograničenost poslovanja, engl. going concern) je temeljna pretpostavka poslovanja poduzeća. Koncept je nastao iz temeljnih računovodstvenih pretpostavki, a predstavlja vremenski neograničen, stabilan i predvidljiv nastavak poslovanja bez prekida poslovnih aktivnosti. Koncept nastavka poslovanja poduzeća uglavnom se u praksi veže uz računovođe i revizore te njihovu procjenu nastavka poslovanja svojih klijenata koje objavljuju u revizijama financijskih izvještaja za korisnike istih. No, u današnje vrijeme javlja se sve veći broj ostalih korisnika koncepta i procjene nastavka poslovanja poduzeća.

U nastavku će ukratko biti opisan razvoj koncepta nastavka poslovanja i njegova definicija, razumijevanje i razlozi zbog kojih je utvrđivanje poslovnih poremećaja izuzetno značajno, te važnost procjene nastavka poslovanja i njezini najznačajniji korisnici.

2.1. Razvoj koncepta i definicija nastavka poslovanja poduzeća

Nastavak poslovanja poduzeća prvi puta se obrađuje i spominje u literaturi 1962. godine kada je Komisija za vrijednosne papire i burze Sjedinjenih Američkih Država (engl. Securities and Exchange Commission ili SEC) objavila računovodstveni standard (engl. Accounting Series Release ili ASR) br. 90, te 1963. godine kada je Američki institut ovlaštenih revizora (engl. American Institute of Certified Public Accountants ili AICPA) objavio revizijski standard (engl. Statement on Auditing Procedures ili SAP) br. 33. U njima profesionalno usmjeravaju revizore te navode i objašnjavaju slučajeve u poduzećima u kojima nije moguće odrediti nastavak njihovog poslovanja. Nastavno na prve standarde, AICPA je 1974. godine objavio detaljniji Izvještaj o revizijskim standardima (Statements on Auditing Standards ili SAS) br. 2 gdje su prvi puta definirani specifični aspekti poslovanja na koje je potrebno obratiti pažnju prilikom procjene statusa nastavka poslovanja poduzeća (Bellovary et al., 2007.).

Nastavno na ovaj standard, Američki institut ovlaštenih revizora ili AICPA je objavio još dva standarda koji obrađuju temu nastavka poslovanja poduzeća, nakon brojnih bankrota poduzeća krajem 70-tih koja su netom prije bankrota revizori pozitivno ocijenili i velikog nezadovoljstva javnosti takvom revizijskom praksom:

1. 1981. godine SAS br. 34 pod nazivom „The Auditor's Considerations When a Question Arises About an Entity's Continued Existence“, te
2. 1988. godine SAS br. 59 pod nazivom „The Auditor's Consideration of an Entity's Ability to Continue as a Going Concern“.

Standard br. 34 propisuje da revizori ne bi trebali tražiti informacije koje upućuju na nastavak poslovanja, već moraju obratiti pozornost na informacije koje bi mogle upućivati na prestanak poslovanja te analizirati plan managementa za savladavanje problema u slučaju njihovog nastanka. Ovakav pasivni pristup koji je zahtijevao od revizora da, tek nakon što bi informacije ukazale na ugroženost nastavka poslovanja, detaljnije istraži poslovnu situaciju, nije bio dovoljno učinkovit.

Usljedile su nadopune revizijskog standarda u SAS-u br. 59, s ciljem aktivnog pristupa revizora u pronalasku okolnosti koje bi mogle dovesti do ugrožavanja pretpostavke nastavka poslovanja poduzeća i obaveze da se procjena nastavka poslovanja poduzeća provodi prilikom svakog revizijskog postupka, te da se u revizorskom mišljenju navodi ukoliko postoji sumnja u nastavak poslovanja poduzeća. U standardu se detaljno opisuju odgovornosti revizora, procedure, razmatranja i komunikacija s osobama odgovornim za upravljanje i dokumentaciju u poduzeću. Nakon ovog standarda nisu uslijedila značajna unaprjeđenja, te se stoga SAS br. 59 još uvijek smatra stručnim usmjerenjem za revizore prilikom procjene nastavka poslovanja, iako pojedini autori (Zavgren, 1983., Koh, Tan, 1999.) smatraju da su njegove smjernice subjektivne, općenite i dvosmislene, te da su revizori prepušteni sami sebi, svojoj subjektivnoj procjeni i iskustvu prilikom ocjene nastavka poslovanja poduzeća.

U današnjim međunarodnim revizijskim standardima i praksi podrazumijeva se da revizori primjenjuju analitičke procedure i statističke modele u identifikaciji nesigurnosti

nastavka poslovanja. Razvijen je značajan broj modela (uglavnom temeljenih na multivarijantnoj diskriminantnoj analizi ili MDA, logit i probit statističkim metodama) kao podrška revizorima u procjeni nastavka poslovanja poduzeća. Od 1988. do danas brojne su zemlje uključile smjernice koje proizlaze iz SAS-a br. 59 u svoje nacionalne standarde, a Međunarodni revizijski standardi propisuju pravila ocjene nastavka poslovanja u sklopu revizijskog angažmana u zasebnom standardu broj 570: Vremenska neograničenost poslovanja (Međunarodni revizijski standardi, 2009.).

Revizijski standard 570 bavi se odgovornošću revizora tijekom revizija financijskih izvješća s obzirom na pretpostavku vremenske neograničenosti poslovanja poduzeća i posljedicama za izvješće revizora. Odgovornost revizora je prikupiti dovoljno adekvatnih dokaza koji potvrđuju da je management poduzeća koristio računovodstvo u sastavljanju financijskih izvještaja na osnovi pretpostavke neograničenosti poslovanja, odnosno da će poduzeće nastaviti svoje poslovanje u doglednoj budućnosti. Druga odgovornost revizora je zaključiti, na temelju dokaza, da li će poduzeće nastaviti s vremenski neograničenim poslovanjem i o tome izvijestiti sve interesne skupine. Revizori koriste različite postupke procjene rizika te proučavaju niz događaja ili okolnosti koje bi mogle dovesti u sumnju going concern koncept. Polazi se od financijske analize: da li poduzeće ima negativne ključne financijske indikatore, da li je nelikvidno, kasni li u otplatama kredita bankama, da li kasni s plaćanjem dobavljačima i slično, preko analize poslovanja: da li poduzeće gubi glavne klijente ili tržišta, odlaze li ključni kadrovi iz poduzeća, da li konkurencija raste, do analize zakonodavstva koje može promijeniti okruženje i negativno utjecati na poduzeće ili eventualnih sudskih sporova koje poduzeće vodi. Takve procjene omogućavaju revizorima procjenu primjene računovodstva na temelju pretpostavke vremenske neograničenosti poslovanja.

Prilikom definicije nastavka poslovanja poduzeća, često se u literaturi može naići na preklapanje pojmova bankrota ili likvidacije poduzeća s pojmom nastavka poslovanja poduzeća. Ta su dva pojma povezana činjenicom da je status nastavka poslovanja poduzeća često upitan prije podnošenja zahtjeva za bankrotom ili likvidacijom poduzeća. Jedan od mogućih ishoda nastavka poslovanja je bankrot, kao najmanje željena opcija, ali nije i jedini ishod. U literaturi se također često preklapaju modeli

razvijeni za predviđanje bankrota poduzeća te modeli za procjenu nastavka poslovanja poduzeća, iako se oni ne odnose na potpuno isto područje.

Definicija nastavka poslovanja podrazumijeva da će poslovni subjekt nastaviti s poslovanjem u predvidivoj budućnosti te da će eksploatirati svoju imovinu i podmirivati financijske obveze normalnim tijekom poslovnih aktivnosti bez znatnog mijenjanja opsega poslovanja (autorica preradila prema Kuruppu, Laswad, Oyelere, 2003.). Definicija podrazumijeva da ne postoji opasnost od likvidacije poduzeća, namjerne ili posljedične, u predvidivoj budućnosti, najmanje 12 mjeseci od objave financijskih izvještaja (bilance, računa dobiti i gubitka, izvještaja o novčanim tijekovima) te da će poduzeće ostvarivati svoje ciljeve i planove u predvidivoj budućnosti. Koncept nastavka poslovanja pretpostavlja da poduzeće stvara vrijednost, ne samo za svoje vlasnike i zaposlenike, već i za cjelokupnu zajednicu. Poduzeće koje stvara vrijednost može se definirati kao ono u kojem management uspijeva integrirati interese i postupke svih koji su zainteresirani za poslovne procese tog poduzeća.

2.2. Razumijevanje i značaj utvrđivanja poslovnih poremećaja

Poslovni poremećaji mogu imati niz negativnih posljedica za veliki broj interesnih skupina. Stoga sve interesne skupine imaju veliku korist od upozorenja na signifikantne rizike prestanka poslovanja poduzeća s ciljem sprečavanja ili minimiziranja takvih negativnih posljedica. Domaća i strana tržišta kapitala snažno su se posljednjih godina razvila i omogućila brojnim investitorima financijska ulaganja. No, tržišta kapitala su volatilna i većina investitora postaje svjesna problema u poduzećima tek nakon što su financijski izvještaji poduzeća objavljeni. Radikalne promjene u korporativnim financijama i ekonomskom okruženju uzrokuju dinamične promjene financijskih pokazatelja koji odražavaju poslovanje poduzeća, te je njihovo pravilno čitanje i predviđanje poremećaja i nastavka poslovanja na temelju istih izuzetno bitno (autorica prema Chen, Du, 2009.).

Kada bi potencijalni investitori bili pravovremeno upozoreni, mogli bi odustati od transakcija s poduzećima koja imaju ugrožen nastavak poslovanja, a postojeći dioničari bi svoje gubitke mogli smanjiti smanjenjem investiranja u takva riskantna

poduzeća. Kreditne institucije bi mogle iskoristiti takva upozorenja za procjenu rizika povrata plasiranih sredstava i definiranja kamatnih stopa koje bi uključile potencijalni rizik.

Utvrđivanje poslovnih poremećaja i pravovremena upozorenja imaju veliki značaj u suvremenoj ekonomiji zbog više razloga:

- poslovni poremećaji imaju veliki utjecaj na odluke o kreditiranju poduzeća i ulaganju u iste, a samim time i profitabilnost investitora i financijskih institucija. Osnovni razlog zbog kojega financijske institucije analiziraju poslovanja klijenata je procjena poslovnih poremećaja i kreditnih rizika kojima se institucija izlaže u poslovanju, a osnovna je obveza financijskih institucija odrediti adekvatni iznos rezervacija i kapitala u odnosu na kreditne rizike. Upravo zbog negativnog utjecaja rezervacija na poslovni rezultat, financijske institucije nastoje izbjeći kreditiranje neurednih dužnika, pa zato one prije odobrenja kredita analiziraju poslovanje potencijalnih klijenata i procjenjuju vjerojatnost hoće li u tijeku trajanja kreditnoga odnosa doći do poremećaja u poslovanju klijenta i posljedično kašnjenja otplate kreditnih obveza,
- početkom ovog stoljeća, modeli predviđanja poslovanja poduzeća ponovo dobivaju na važnosti zbog izuzetnih zahtjeva Basel II standarda o adekvatnosti kapitala. Banke diljem svijeta i sve ostale financijske institucije su ili već razvile modele procjene kreditnog rizika odnosno modificirale postojeće interne modele ili trenutno razvijaju metode da bi se uskladile s najboljim praksama i procesima za procjenu nastavka poslovanja, odnosno u bankama za procjenu vjerojatnosti nastanka statusa neispunjavanja obveza (engl. PD Probability of default) i procjene gubitka zbog nastanka statusa neispunjavanja obveza za pojedinu izloženost (engl. LGD Loss given default),
- financijske institucije i ostala poduzeća mogu koristiti modele predviđanja nastavka poslovanja poduzeća kako bi se fokusirali na one industrije u kojima je takav postotak najbolji i prema njima usmjerile svoje akvizicijske aktivnosti,

- zbog globalizacije poslovanja, velike umreženosti poduzeća, te djelovanja poduzeća u većem broju industrija, poslovni poremećaji u jednom dijelu poslovne zajednice ne mogu ostati izolirani već se prelijevaju na druge regije, industrije i povezana poduzeća. Negativni učinak poslovnih poremećaja ili stečajevi pojedinih poduzeća imaju višestruke posljedice na širu poslovnu zajednicu i stanovništvo.

Glavni preduvjet predviđanja poslovnih poremećaja je točnost podataka prikazanih u financijskim izvještajima i drugim internim aktima poduzeća, te dostupnost tih podataka. Hrvatska je jedna od rijetkih zemalja u regiji koja ima urednu i sveobuhvatnu bazu podataka financijskih izvještaja koju, duži niz godina, prikuplja i objavljuje Financijska agencija, te je time i omogućen razvoj modela koji koriste te podatke.

2.3. Važnost procjene nastavka poslovanja i njezini korisnici

Nastavak poslovanja je netrivialni koncept koji je predmet velikih istraživačkih napora posljednjih nekoliko desetljeća, a procjenjivanje nastavka poslovanja poduzeća u kontekstu dinamičnoga i nestabilnoga poslovnoga okruženja osobito dobiva na značenju danas. Naime, važno je za svakoga dionika utvrditi je li poduzeće koje je predmet njegovoga interesa sposobno poslovati u vremenski neograničenome roku.

Veliki interes istraživača koji su se bavili i bave se konceptom nastavka poslovanja tj. vremenski neograničenim poslovanjem, ukazuje na njegovu važnost u praksi i teoriji. Autori istražuju različite aspekte koncepta nastavka poslovanja, obrađujući teme poput:

- da li revizori iskazuju nepovjerenje prema nastavku poslovanja poduzeća kada uočavaju indikatore koji bi na to mogli upućivati, te koji utjecaji imaju najveći značaj,

- koliko su revizorski standardi, u domeni neograničenog nastavka poslovanja, transparentni i jasni, te koliko osiguravaju nedvosmislenost u iskazivanju ocjene nastavka poslovanja poduzeća u revizorskim izvještajima,
- na koji način modeli predviđanja pomažu revizorima u donošenju mišljenja.

U nastavku su navedeni samo neki od brojnih istraživača koji obrađuju ovu temu. Švedski autori, Tagesson i Öhman (Tagesson, Öhman, 2015.) istražili su na primjeru revizorskih izvještaja 2.547 poduzeća, koja su proglasila stečaj 2010. godine, da li su revizori objavili modificirano mišljenje ili mišljenje s rezervom prema sposobnosti poduzeća da nastavi s vremenski neograničenim poslovanjem, godinu dana prije objave stečaja. Dokazali su da švedski revizori rijetko objavljuju modificirano mišljenje ili mišljenje s rezervom, ali da postoji pozitivna veza između revizora svjetskih revizorskih kuća odnosno visine naknade njihovih usluga s objavom modificiranih mišljenja ili mišljenja s rezervom. Stoga autori upućuju na potrebu detaljnih revizija, ali i pojednostavljivanja revizorskih standarda radi jednostavnije primjene. Kuruppu i autori, (Kuruppu, Laswad, Oyelere, 2012.) istražuju, temeljem istraživačkog upitnika, u kojoj mjeri modeli predviđanja stečaja pomažu revizorima u procjeni nastavka poslovanja, te zaključuju da revizori smatraju modele predviđanja korisnim jer smanjuju subjektivnost u procjeni, povećavaju analitičnost i pomažu prikupljanju objektivnih dokaza za objavu mišljenja.

Autori Beams i Yan (Beams, Yan, 2015.) proučavaju utjecaj financijske krize na konzervativnost revizora koja se očituje povećanim brojem modificiranih mišljenja ili mišljenja s rezervom prema sposobnosti poduzeća da nastavi s vremenski neograničenim poslovanjem. Studija uključuje američka poduzeća u razdoblju od 2005. do 2011. godine, te autori logističkom regresijom potvrđuju povećani broj modificiranih mišljenja pod utjecajem financijske krize, izbacujući ostale utjecaje na mišljenje. Autori potvrđuju i smanjenje broja modificiranih izvještaja smirivanjem krize što potvrđuje utjecaj makroekonomskog okruženja na mišljenje revizora.

Autorica Sormunen (Sormunen, 2014.) istražuje u kojoj mjeri bankari, u Danskoj, koriste revizorska mišljenja o procjeni nastavka poslovanja SME poduzeća prilikom

ocjene boniteta i odobravanja kredita klijentima. Autorica zaključuje da uporaba mišljenja ovisi o osobnom stavu bankara o revizorskim izvještajima i razini primjene informacija izvan domene financijskih izvještaja. Autori Vichitsarawong i Pornupatham (Vichitsarawong, Pornupatham, 2015.) istražuju povezanost mišljenja revizora o sposobnosti poduzeća da nastavi s vremenski neograničenim poslovanjem i održive profitabilnosti poduzeća na primjeru tajlandskih poduzeća u razdoblju od 2004. do 2008. godine. Autori zaključuju, uz pomoć logističke regresije, da poduzeća s modificiranim mišljenjima teže održavaju profitabilnost, te da stupanj održivosti profitabilnosti ovisi o vrsti modificiranog mišljenja. Takav zaključak upućuje na važnost revizorskih mišljenja i njihove primjene, te revizorima nameće visoke standarde objektivnosti u procjeni.

Autori Feldmann i Read (Feldmann, Read, 2013.) u svojoj studiji istražuju da li kreditni rating poduzeća utječe na revizorsko mišljenje o sposobnosti poduzeća da nastavi s vremenski neograničenim poslovanjem. Primjenom logističke regresije na poduzeća koja su prijavila stečaj u razdoblju od 2000. do 2009. godine autori su dokazali da kreditni rating agencije Standard & Poor's utječe na revizorsko mišljenje, ali i da kreditni rating poduzeća nakon modificiranog mišljenja ili mišljenja s rezervom ima tendenciju smanjivanja.

Za procjenu nastavka poslovanja izuzetno su važni interni podaci poduzeća koji se ne moraju javno objavljivati, ali management, računovođe i revizori poduzeća raspolažu takvim informacijama. Odgovornost managementa, računovođa i revizora (prilikom procjene poslovanja poduzeća) je da u svojim izvještajima koriste takve informacije radi procjene rizika poslovnih poremećaja i ugrožavanja pretpostavke nastavka poslovanja. Ukoliko takve informacije stavljaju sumnju na nastavak poslovanja, takvi zaključci moraju biti objavljeni kako bi se pravovremeno upozorile sve interesne skupine koje su korisnici takvih procjena.

Koncept nastavka poslovanja je prepoznat i priznat kao glavni koncept na kojem se temelji financijsko izvještavanje i osnova je za:

- periodično izvještavanje,
- obračunsko računovodstvo,

- procjenu vrijednosti poduzeća i imovine,
- računovodstveni koncept budućeg prihoda od imovine,
- podjelu imovine na kratkotrajnu i dugotrajnu te obveza na kratkoročne i dugoročne.

Podrazumijeva se da svako poduzeće ima namjeru nastavka poslovanja osim u slučaju informacija koje upućuju na suprotno. Primjer takve informacije je dospijeće obaveza koje poduzeće ne može podmiriti bez značajne prodaje svoje imovine ili restrukturiranja duga, negativni trend u realizaciji poslovnih prihoda ili sudski postupci protiv poduzeća. U slučaju identifikacije takvih informacija, računovođe su ih dužni objaviti.

U Hrvatskoj revizorskoj praksi se za nastavak poslovanja primjenjuje prije navedeni Međunarodni revizijski standard 570 „Vremenska neograničenost poslovanja“ kojeg je prevela i objavila Hrvatska revizorska komora 2009. godine. Njegova svrha je odrediti odgovornost neovisnog revizora u reviziji financijskih izvještaja spram klijentove primjene temeljne računovodstvene pretpostavke o vremenskoj neograničenosti poslovanja u sastavljanju financijskih izvještaja. Računovodstvena pretpostavka vremenske neograničenosti poslovanja (Going concern assumption) u računovodstvenom izvještavanju smatra da poslovni subjekt ne namjerava niti ima potrebu za likvidacijom, prekidanjem poslovanja ili traženjem zaštite od vjerovnika sukladno zakonima ili propisima (najmanje jednu godinu od datuma bilance). Sukladno tome, imovina i obveze se iskazuju uz pretpostavku da će poslovni subjekt realizirati svoju imovinu i podmiriti svoje obveze u normalnom tijeku poslovanja (prema Međunarodnom revizijskom standardu, 570, 2009.).

Revizori su sukladno s Međunarodnim revizijskim standardima, obvezni prilikom obavljanja revizije financijskih izvještaja ocijeniti je li procjena managementa o tome da se financijski izvještaji sastave na osnovi vremenske neograničenosti poslovanja prikladna i moraju razmotriti prisutnost okolnosti i događaja koji upućuju na postojanje značajnih neizvjesnosti povezanih s vremenskom neograničenošću poslovanja (Zenzerović, Peruško, 2009.).

Da bi u postupku revizijskog angažmana revizor ocijenio nastavak poslovanja poduzeća, dužan je:

1. Pribaviti dostatne i odgovarajuće revizijske dokaze u vezi s primjerenošću klijentove primjene pretpostavke vremenske neograničenosti poslovanja u sastavljanju financijskih izvještaja.
2. Donijeti zaključak o tome postoji li značajna neizvjesnost u vezi s događajima ili okolnostima koji mogu uzrokovati značajnu dvojbu u mogućnost subjekta da nastavi s vremenski neograničenim poslovanjem. U slučaju postojanja značajne neizvjesnosti revizor treba tražiti da se ona i njezin učinak objave u financijskim izvještajima neovisno od toga je li ono uvjetovano primijenjenim okvirom financijskog izvještavanja.
3. Utvrditi posljedice na izvještaje neovisnog revizora. Nepostojanje bilo kakvog pozivanja u izvještaju revizora na neizvjesnost nastavka vremenski neograničenog poslovanja poduzeća ne može se smatrati garancijom da će subjekt biti sposoban nastaviti s vremenski neograničenim poslovanjem (Krajačić, D., 2012.).

No, osim za potrebe računovođa pri sastavljanju izvještaja i revizora u sklopu revizijskih angažmana, u današnje vrijeme radikalnih promjena u korporativnim financijama i svjetskom ekonomskom okruženju, kada se poslovanje poduzeća i ključni financijski pokazatelji brzo mijenjaju, procjena nastavka poslovanja poduzeća i njegovih budućih rezultata ključna je za veliki broj drugih subjekata. To se prvenstveno odnosi na financijske institucije, dioničare, zaposlenike, financijske analitičare, analitičare javnih službi, te ostala poduzeća koja imaju potrebu procijeniti nastavak poslovanja svog ili drugog poduzeća.

Koncept nastavka poslovanja time nadilazi samo procjenu revizora o primjerenosti pretpostavke nastavka poslovanja za korisnike financijskih izvještaja. Ostali subjekti koji za potrebe procjene nastavka poslovanja nisu dužni primjenjivati Međunarodne revizijske standarde, u postupku procjene primjenjuju razne statističke modele, ovisno

o znanju i razvijenosti sustava u kojem poslovno ili profesionalno djeluju. Većina prediktivnih modela je usmjerena na predviđanje poslovnih poremećaja, a ne na procjenu sumnje nastavka poslovanja ili na samu procjenu nastavka poslovanja poduzeća.

No, značajni broj autora potvrdio je i preporučio upotrebu statističkih modela u procjeni vjerodostojnosti ocjene nastavka poslovanja poduzeća od strane revizora, ali i managementa te drugih zainteresiranih skupina. Najznačajniji postojeći statistički modeli korišteni u procjeni nastavka poslovanja poduzeća biti će detaljnije objašnjeni u nastavku rada. Bez obzira na model koji se koristi, istraživanja su potvrdila veću učinkovitost procjene nastavka poslovanja poduzeća od strane, čak i najjednostavnijih modela, u usporedbi s procjenom revizora o nastavku poslovanja poduzeća, što nameće zaključak o nužnosti primjene takvih modela (Boritz, Sun, 2004.).

Bez obzira na korišteni prediktivni model, procjena nastavka poslovanja poduzeća predstavlja osnovu za niz poslovnih aktivnosti, od kojih je potrebno istaknuti sljedeće:

- računovodstveno i financijsko izvještavanje,
- buduće aktivnosti managementa vezanih za realizaciju strateških i operativnih ciljeva poduzeća, posebno u pogledu definiranja reorganizacijskih aktivnosti ili restrukturiranja na temelju rezultata procjene,
- procjenu boniteta potencijalnih i sadašnjih klijenata od strane investitora i njihovo donošenje odluka o plasiranju financijskih sredstava i očekivanoj stopi povrata u odnosu na rizik ulaganja temeljenog na procjeni nastavka poslovanja poduzeća,
- ocjenu nastavka poslovanja poduzeća od strane revizora u okviru revizijskog angažmana u poduzeću,
- aktivnosti svih drugih zainteresiranih skupina ili dionika (dobavljača, kupaca, najmodavaca, poslovnih partnera i drugih) u poslovnom ciklusu poduzeća.

Zaključno, procjena nastavka poslovanja poduzeća je od velike važnosti za cjelokupnu poslovnu zajednicu i sve zainteresirane skupine u lancu vrijednosti poslovanja poduzeća. Ključni faktor uspjeha u procjeni nastavka poslovanja poduzeća je odabir modela koji će na točan i objektivan način generirati ispravnu procjenu nastavka poslovanja poduzeća i omogućiti pravovremeno donošenje poslovnih odluka.

3. MODELI PREDVIĐANJA NASTAVKA POSLOVANJA – ANALIZA PRETHODNIH ISTRAŽIVANJA

Istraživanja pojedinih autora pokazuju da statistički modeli predviđanja stečaja u većini slučajeva pokazuju veću učinkovitost u razlikovanju među poduzećima koja aktivno posluju i poduzećima koja će završiti u stečaju u odnosu na procjenu revizora (bez upotrebe modela) o nastavku poslovanja poduzeća (Kuruppu, Laswad, Oyelere, 2003.).

Također, ista istraživanja preispituju da li je procjena stečaja poduzeća najbolji pokazatelj za nastavak poslovanja zbog činjenice da stečaj nije sinonim za nedostatak pretpostavke o nastavku poslovanja poduzeća. U zemljama, kao primjerice SAD, gdje je stečajni zakon orijentiran prema dužnicima, procedura pokretanja stečaja podupire poduzeća u financijskim poteškoćama da nastave poslovanje s pretpostavkom nastavka poslovanja, te je stoga moguće da se ta ista poduzeća (s pokrenutim stečajem) reorganiziraju, restrukturiraju i izađu iz stečaja ili se spoje s drugim subjektom te nastave svoje poslovanje. Takva praksa je u suprotnosti s drugim zemljama kao primjerice Velikom Britanijom, Njemačkom ili Australijom gdje je likvidacija poduzeća najčešći rezultat problema insolventnosti poduzeća. Troškovi likvidacije poduzeća koje snose dioničari i ostale interesne skupine veći su od troškova pokretanja i provedbe stečaja. Poduzeća u pojedinim zemljama, koje su zakonodavno usmjerene prema vjerovnicima, mogu pokrenuti stečaj da bi izbjegla neprofitabilne ugovore.

Navedeni argumenti sugeriraju da modeli predviđanja stečaja nisu najbolji predstavnik procjene nastavka poslovanja poduzeća, već modeli koji predviđaju i ocjenjuju nastavak poslovanja poduzeća pri čemu je stečaj samo jedna od opcija nastavka poslovanja.

U nastavku će se ukratko prikazati tradicionalni i suvremeni modeli predviđanja nastavka poslovanja s fokusom na istraživanja i ocjenu njihove učinkovitosti u procjeni nastavka poslovanja.

3.1. Teorijski prikaz i ocjena tradicionalnih statističkih modela

Od svih tradicionalnih modela koji se temelje na računovodstvenim pokazateljima, najcitiraniji modeli su model Altmana (1968./1983.), Ohlsona (1980.) i Zmijewskog (1984.) (Salimi, 2015., Kumar, Kumar, 2012., Grice, Ingram, 2001.). To je i osnovni razlog odabira ova tri modela za detaljniju obradu i provedbu istraživanja.

Gotovo svi statistički modeli predviđanja koji su u današnje vrijeme u uporabi, varijacije su na sličnu temu. Oni uključuju kombinaciju niza kvantificiranih financijskih pokazatelja poslovanja poduzeća s manjim brojem dodatnih varijabli koje pokušavaju prikazati pojedine kvalitativne elemente kreditnog procesa ili poslovanja poduzeća. Zajedničko obilježje ova tri modela je upotreba računovodstvenih pokazatelja, koji mjere likvidnost, zaduženost i profitabilnost poslovanja poduzeća, u procjeni nastupanja stečaja poduzeća. Općenito govoreći, kada su likvidnost i profitabilnost niske, a zaduženost visoka, vjerojatnost nastupanja stečaja se povećava. Kretanje financijskih omjera kod neuspješnih poduzeća drugačije je nego kod uspješnih poduzeća. Razlika između ova tri modela su računovodstveni pokazatelji, njihov broj i statističke tehnike koje su korištene u definiranju modela za predviđanje stečaja poduzeća.

Značajan broj autora bavio se i kontinuirano se bavi istraživanjem (Lawrence et al, 2015., Branson, Alareemi, 2013., Wu et al, 2010., Agarwal, Taffler, 2008., Grice, Dugan, 2003., Kuruppu et al, 2003., Grice, Ingram, 2001., Boritz et al, 2007., Begley et al, 1996., Shumway, 2001. i drugi) modela Altmana, Ohlsona i Zmijewskog, analiziraju učinkovitost modela u suvremeno doba i u procjeni stečaja kroz duže vrijeme, te ispituju da li su modeli korisni i kod procjene drugih rezultata poslovanja poduzeća osim stečaja. Empirijski rezultati potvrđuju učinkovitost tih modela iako je njihova točnost smanjena u novijim, suvremenim uvjetima poslovanja poduzeća.

Na sljedećoj tablici prikazan je kratki sažetak i ocjene osnovnih karakteristika modela analiziranih u ovom poglavlju.

Tablica 1. Sažetak i ocjene osnovnih karakteristika modela Altman, Ohlson i Zmijewski

Autor	Metoda	Statistička tehnika	Nezavisne varijable	Komentari
Altman	-	-	+	Mali uzorak, rezultat MDA tehnike nema ograničenja uz striktne pretpostavke ograničenja distribucije, procjena 22 varijable i odabir 5 najznačajnijih
Ohlson	+	+	-/+	Veliki uzorak, logit funkcija mapira vrijednosti od 0 do 1, manje restriktivne pretpostavke nego MDA, 9 nezavisnih varijabli
Zmijewski	-/+	-/+	-	Mali uzorak, probit funkcija koja mapira vrijednosti od 0 do 1, manje restriktivne pretpostavke nego MDA, samo tri nezavisne varijable od čega dvije snažno koreliraju

Izvor: Autorica prema Avenhuis, 2013.

Pojedini autori (Grice, Dugan, 2003., Grice, Ingram, 2001.) redefinirali su, odnosno preradili modele Altmana, Ohlsona i Zmijewskog, u smislu prilagodbe smjera i vrijednosti koeficijenata varijabli, te su dokazali da se njihova učinkovitost može povećati. Varijable koje sadrže originalni modeli jesu stabilne u procjeni nastupa stečaja poduzeća, ali se njihovi koeficijenti moraju prilagoditi uvjetima poslovanja poduzeća za koje se isti primjenjuju. Iz saznanja i uspjeha ovih autora proizlaze i očekivanja za stabilnim modelom u hrvatskoj ekonomiji koji će ponuditi konzistentnost u vrijednostima i smjerovima varijabli te osigurati klasifikacijsku snagu modela kroz različita razdoblja i industrije.

U nastavku su ukratko obrađene osnovne metode i rezultati studija Altmana, Ohlsona i Zmijewskog. Prikazane su i najčešće kritike modela navedena tri autora i zaključci prethodnih studija koje su evaluirale navedene metodologije.

Altman (1968./1983.)

Pionirski rad Edwarda Altmana dokazao je mogućnost diskriminacije predznaka financijskih poremećaja u poduzećima uporabom i kombinacijom različitih financijskih omjera. E. Altman definirao je 1968. godine svoj prvi statistički scoring model za predviđanje financijskog neuspjeha. Za modeliranje i odabir specifičnih omjera upotrijebljena je višestruka diskriminacijska analiza (engl. Multivariate discriminant analysis, MDA) koju je 1936. godine razvio britanski statističar Ronald Fisher. E. Altman je bio prvi autor koji je za definiciju kombinacije pokazatelja u modelu i analizu poslovnih poremećaja primijenio MDA koja se do tada uglavnom koristila u biologiji i psihologiji (Lacher et al, 1995.). Nakon Altmanovog istraživanja, MDA se od 1968. godine koristi kao primarna statistička metoda pri identifikaciji poslovnih poremećaja u raznim industrijama.

MDA je tehnika koja omogućava istraživačima istovremeno ispitivanje i definiciju razlika između dvije ili više međusobno isključivih grupa u odnosu na nekoliko varijabli, odnosno ona klasificira opservaciju u jednu od nekoliko a priori grupa ovisno o individualnim karakteristikama opservacije. Ova tehnika kombinira omjerne i kategorijalne vrijednosti, a rezultira u mjeri, odnosno score-u, koja diskriminira između poduzeća koja su uspješna i ona koja su neuspješna. Glavno pitanje na koje MDA treba dati odgovor je definicija najvažnijih karakteristika koje predstavljaju multivarijantnu razliku pojedine grupe. Prvi korak je uspostavljanje jasnih karakteristika pojedinih grupa. Broj originalnih grupa može biti dva ili više. Nakon što su grupe uspostavljene, prikupljaju se podaci za objekte u grupama. MDA u svojoj najjednostavnijoj formi pokušava derivirati linearnu kombinaciju ovih karakteristika koje se najviše razlikuju među grupama. Ova tehnika ima prednost u tome što omogućava razmatranje cijelog profila karakteristika koje su zajedničke relevantnim poduzećima kao i razmatranje interakcija među tim obilježjima (Altman, 2002.). Primarno se koristi u procjeni ili predviđanju problema gdje se zavisna varijabla izražava kvantitativno, npr. stečaj ili ne-stečaj.

Istraživanje koje je proveo E. Altman provedeno je na uzorku koji se sastojao od 33 proizvodna poduzeća u stečaju (ili ona koja su pokrenula stečaj u razdoblju od 1946. do 1965. godine) i 33 proizvodna financijski uspješna poduzeća (ona koja su aktivno

poslovala jednu godinu nakon prikupljanja podataka o istima, u istom razdoblju od 1946. do 1965. godine). Uzorak koji se proteže u razdoblju od 20 godina nije najbolji izbor budući se prosječni pokazatelji mijenjaju tijekom vremena. Idealno bi bilo razmatrati listu pokazatelja u vremenskom razdoblju (t) s ciljem definiranja predikcija o drugim poduzećima u razdoblju koje slijedi (t+1). No, s obzirom na ograničenja podataka u tom razdoblju, to nije bilo moguće.

Altman je upario poduzeća prema veličini aktive i industrije u kojoj posluju. Upotrijebio je pristup cross validacije za provjeru funkcije, odnosno uzorak za modeliranje (procjenu funkcije) i uzorak za provjeru učinkovitosti procijenjene funkcije. Iz uzorka su bila isključena izuzetno mala (ispod 0,7 m \$ vrijednosti imovine) i izuzetno velika (više od 25,9 m \$ imovine) poduzeća, a promatrana su u razdoblju od 1946. do 1965. godine.

Rezultat istraživanja je definicija pet pokazatelja (od početnih 22) koji zajednički najbolje diskriminiraju poduzeća koja su vitalna i ona pred stečajem, te se njihovom kombinacijom dobiva mjera, odnosno Z score, score kreditnog rizika. Diskriminantna funkcija glasi:

$$\mathbf{Z\ score = 1.21X_1 + 1.42X_2 + 3.3X_3 + 0.6X_4 + 0.999X_5}$$

pri čemu je:

X_1 = radni kapital/ukupna imovina

Radni kapital predstavlja razliku između kratkoročne imovine i kratkoročnih obveza, te se može smatrati neto kratkoročnom imovinom. Ovaj omjer je dobar pokazatelj kratkoročne solventnosti. Poduzeće koje doživljava operativne gubitke imati će smanjenje kratkotrajne imovine u odnosu na ukupnu imovinu.

X_2 = zadržana dobit/ukupna imovina

Zadržana dobit je u većini slučajeva viša kod starijih, etabliranih poduzeća nego kod novih poduzeća, pod uvjetom da je sve ostalo jednako. Iz tog razloga bi ovaj pokazatelj mogao biti više naklonjen starijim poduzećima, budući i razne studije pokazuju da je potencijal za stečaj viši u prvim godinama poslovanja poduzeća jer mlada poduzeća nisu imala vremena kumulirati dobit.

X_3 = dobit prije oporezivanja (EBIT)/ukupna imovina

Ovaj pokazatelj je koristan za usporedbu poduzeća u različitim poreznim uvjetima i sa različitim stupnjevima financijskih poluga. S obzirom da je nastavak poslovanja poduzeća ovisan o sposobnosti poduzeća da svojom imovinom ostvaruje dobit, ovaj je pokazatelj vrlo koristan u predviđanju nastavka poslovanja poduzeća.

X_4 = tržišna vrijednost kapitala/knjigovodstvena vrijednost obveza

Ovaj pokazatelj uvodi u jednadžbu i poziciju poduzeća na tržištu te pokazuje koliko se vrijednosti imovine poduzeća može smanjiti prije nego obveze premaše iznos imovine, vodeći na taj način prema insolventnosti.

X_5 = ukupan prihod od prodaje/ukupna imovina

Ovaj pokazatelj mjeri stupanj iskoristivosti imovine poduzeća. Iako pokazatelj pojedinačno nema jaku diskriminirajuću statističku važnost, snažno doprinosi ukupnoj diskriminirajućoj sposobnosti jednadžbe u kombinaciji sa ostala četiri pokazatelja.

Uz vrijednosti diskriminantnih koeficijenata moguće je izračunati vrijednost ukupnog indeksa, tj. Z score-a. Altman je ustanovio da vrijednost Z scorea od 2,675 najbolje diskriminira poduzeća koja jesu u stečaju ili su financijski ugrožena, i ona poduzeća koja su generalno „zdrava“ i pozitivno posluju. Z score se temelji na minimalnom broju Pogrešaka tipa 1 i tipa 2 (Pogreška tipa 1 se definira kao broj poduzeća koja loše posluju, a netočno su klasificirana kao poduzeća koja pozitivno posluju u odnosu na ukupan broj poduzeća u uzorku, a Pogreška tipa 2 se definira kao broj poduzeća koja pozitivno posluju, a netočno su klasificirana kao poduzeća koja negativno posluju u odnosu na ukupan broj poduzeća u uzorku). Ukoliko poduzeće ima Z score iznad

2,675, poduzeće je klasificirano kao financijski stabilno, a ispod 2,675 kao poduzeće koje je pokrenulo stečajni postupak. Altman je potvrdio 95%-tnu uspješnost u pravilnoj klasifikaciji jednu godinu prije neuspjeha, te 82%-tnu uspješnosti u dvije godine prije neuspjeha u poslovanju poduzeća.

Altman je 1983. godine revidirao originalan model iz 1968. godine s ciljem definiranja pokazatelja za privatna poduzeća i to zamjenjujući tržišnu vrijednost knjigovodstvenom vrijednosti kapitala pri izračunavanju X_4 . Rezultat toga je Z' score model:

$$\mathbf{Z' \ score = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,420X_4 + 0,998X_5}$$

Donja granica iznosi Z' score = 1,23, poduzeća ispod te granice se smatraju neuspješnima, a gornja granica Z' score= 2,90 predstavlja granicu iznad koje se poduzeće smatra uspješnim.

Uspješnost klasifikacije revidiranog Z' score-a neuspješnih poduzeća bila je 91%, a korektna klasifikacija uspješnih 97%. Ovaj revidirani Z' score model biti će predmet empirijskog istraživanja ovog rada budući omogućava uključivanje i privatnih poduzeća u uzorak za analizu.

Altman, Hadelman i Narayanan kreirali su 1977. godine ZETA Model kao nadogradnju na Z score model. Njegova je svrha također diskriminacija između uspješnih i neuspješnih poduzeća. Upotrijebljena je višestruka diskriminacijska analiza, a analizirano je 27 varijabli dok se konačan model sastoji od sedam najznačajnijih varijabli: bruto dobit/ukupna imovina, stabilnost zarade, zarada prije poreza i kamata/ukupno plaćene kamate, profitabilnost mjerena omjerom zadržane zarade i ukupne imovine, kratkotrajna imovina/kratkoročne obveze, kapitalizacija kao udio vlastitog kapitala u ukupnom kapitalu i veličina poduzeća. ZETA model ima veću točnost u klasificiranju neuspješnih poduzeća u odnosu na Z score u razdoblju od 2 do 5 godina prije bankrota, dok je točnost za prvu godinu gotovo jednaka za oba modela. Pri klasificiranju uspješnih poduzeća veću točnost je pokazao Z score model u odnosu na ZETA model za razdoblje od dvije godine u slučaju kada je moguća direktna usporedba.

Osnovne kritike Altmanovog modela se odnose na sljedeće stavke:

- upotreba statističke metode MDA i sva ograničenja distribucije podataka koje ta metoda zahtijeva, npr. matrice varijanca i kovarijanca varijabla moraju biti iste za obje skupine,
- originalni parametri su definirani na temelju malog i jednako raspodijeljenog uzorka što ne osigurava njegovu reprezentativnost cijele populacije. Uzorak je sadržavao poduzeća znatno manje vrijednosti imovine od današnjih prosječnih vrijednosti (to je djelomično ispravljeno uzorkom u ZETA modelu gdje niti jedno poduzeće nema vrijednost imovine manju od 20 m \$). Uzorak je sadržavao poduzeća samo iz nekoliko industrija (primjerice nije iz industrije trgovine koja je izuzetno osjetljiva i nestabilna),
- autori Grice i Dugan (2003.) smatraju da je uzorak na kojem se provjeravala učinkovitost modela pristran jer se sastoji od poduzeća u istim industrijama kao i osnovni uzorak,
- autori Wu, Gaunt, Gray (2010.), Grice i Ingram (2001.) smatraju da je stupanj učinkovitosti Altmana u novijem razdoblju i novim makroekonomskim uvjetima znatno niži u odnosu na ostale modele u literaturi (Ohlson, Zmijewski, Shumway). Wu i ostali autori su proveli testiranje na uzorku poduzeća u SAD-u koja kotiraju na burzi u razdoblju od 1980. do 2006. godine, a autori Grice i Ingram (2001.) na velikom uzorku (proizvodnih i neproizvodnih poduzeća) s proporcionalnim udjelom poduzeća u stečaju kao i u cijeloj populaciji.

Ohlson (1980.)

James A. Ohlson razvio je 1980. godine model na temelju logit statističke metode te se pokušao udaljiti od tehnika koje su do tada bile uobičajene pri analizi nastupanja stečaja. Logit metodu je 1944. godine uveo Joseph Berkson, a Ohlson je njome zamijenio MDA koju je koristio Altman kako bi izbjegao statističko-metodološke probleme te tehnike. Ohlson je kritizirao MDA i Altmanov Z score u više segmenata:

- dvije osnovne pretpostavke moraju biti primijenjene za upotrebu diskriminantne funkcije. Prva je normalna distribucija nezavisnih varijabli, a druga je jednaka varijanca i kovarianca nezavisnih varijabli za poduzeća u stečaju i poduzeća koja nisu u stečaju (Ohlson, 1980.),
- Z score je jednostavni model rangiranja koji ograničava mogućnost interpretacije,
- poduzeća u stečaju i ona koja to nisu, uparena su prema veličini i vrsti industrije, a to je proizvoljno. Ohlson je primijenio znatno veći uzorak za definiranje modela kako bi izračunao pouzdane koeficijente za devet varijabli.

Ohlson je tvrdio da se upotrebom logit analize anuliraju svi nedostaci MDA metode te da je njegov model jednostavan i da se može koristiti u različitim uvjetima (Ohlson, 1980.) Logit funkcija je prikladna za predviđanje stečaja poduzeća budući zavisna varijabla može imati samo dvije kategorije (stečaj ili ne-stečaj). Logit funkcija sparuje vrijednost s vjerojatnošću koja se kreće u rasponu od 0 do 1, a u Ohlsonovom modelu granica je iznosila 0,38 budući je pri toj granici bila najmanja razina Pogreške tipa 1 i Pogreške tipa 2.

Ohlson je proveo istraživanje za razdoblje od 1970. do 1976. godine na uzorku od 2.163 poduzeća (105 poduzeća nad kojima je bio pokrenut stečajni postupak i 2.058 financijski zdrava poduzeća), a obilježja njegovog uzorka su bila sljedeća:

- promatralo se razdoblje od 1970. do 1976. godine,
- poduzeće je moralo imati izdane vrijednosne papire na burzi ili OTC tržištu,
- poduzeće je trebalo biti klasificirano kao industrijsko i proizvodno.

Istraživanjem su prikupljeni podaci financijskih izvještaja poduzeća za razdoblje od tri godine prije pokretanja stečajnog postupka nad poduzećima.

Glavnim odrednicama predviđanja stečaja Ohlson smatra: veličinu, financijsku strukturu mjerenu pokazateljem zaduženosti, pokazatelje uspješnosti poslovanja koji uključuju odnos neto dobiti i ukupne imovine i/ili odnos novčanog toka od poslovnih aktivnosti i ukupnih šest dummy varijabla (koje se koriste u slučajevima kada se u funkcijama žele istaknuti prisutnost ili odsutnost određenih obilježja), obveza te naposljetku pokazatelje likvidnosti (udio radnog kapitala u ukupnoj imovini ili isti pokazatelj kombiniran s odnosom kratkoročnih obveza i kratkotrajne imovine) (Zenzerović, Peruško, 2006.). Otkrio je negativnu korelaciju između vjerojatnosti bankrota i veličine, profitabilnosti i likvidnosti poduzeća, te pozitivnu korelaciju između vjerojatnosti bankrota i zaduženosti poduzeća.

Finalna logit funkcija s varijablama i pripadajućim procijenjenim koeficijentima je bila sljedeća:

$$\text{Ohlson} = -1,3 - 0,4X_1 + 6,0X_2 - 1,4X_3 + 0,8X_4 - 2,4X_5 - 1,8X_6 + 0,3X_7 - 1,7X_8 - 0,5X_9$$

$$\text{Vjerojatnost nastupanja stečaja} = P(B) = \frac{1}{(1 + \exp\{-\beta^I X\})}$$

Ova formula je logistička regresija koja je korištena u istraživanju, pri čemu je P vjerojatnost nastupanja stečaja, a X predstavlja odabrane varijable. Logit funkcija mapira vrijednost $\beta^I X$ prema vjerojatnosti u rasponu od 0 do 1. Rezultat $P(B) > 0,5$ upućuje na poduzeće u riziku, a $P(B) < 0,5$ na sigurno poduzeće od bankrota.

Objašnjenja svih varijabli prikazana su u nastavku:

X_1 = veličina mjerena logaritmom odnosa ukupne imovine i BDP deflatora (engl. GDP price level index)

Prilagođena veličina pri čemu Ohlson mjeri veličinu imovine korigiranu za inflaciju uz pomoć BDP deflatora. Manja poduzeća imaju veći rizik od nastupanja negativnog razvoja poslovanja.

$$\text{BDP deflator} = (\text{Nominalni BDP} / \text{Realni BDP}) * 100$$

Nominalni bruto domaći proizvod je pokazatelj koji se izražava u tekućim cijenama, pri čemu se pri obračunu BDP-a količina množi s cijenama koje su aktualne u godini izračuna BDP-a. Realni bruto domaći proizvod je pokazatelj koji se izražava u stalnim cijenama, pri čemu se u obračunu BDP-a količina množi s cijenama određene bazne godine.

$$X_2 = \text{ukupne obveze} / \text{ukupna imovina (stanje na dan)}$$

Ovaj pokazatelj je dizajniran da prikaže zaduženost poduzeća. Što je poduzeće zaduženije to je manje otporno na iznenadne oscilacije u poslovanju.

$$X_3 = \text{radni kapital} / \text{ukupna imovina (stanje na dan)}$$

Ova varijabla mjeri radni kapital poduzeća. U situacijama kada poduzeće raspolaže značajnom imovinom i posluje profitabilno, mora imati zadovoljavajuću likvidnost kako bi servisirala kratkoročne obveze i nadolazeće operativne troškove.

$$X_4 = \text{kratkoročne obveze} / \text{kratkotrajna imovina}$$

Ovaj pokazatelj također mjeri likvidnost poduzeća.

$$X_5 = \text{dummy varijabla } 0 \text{ ili } 1 \text{ (} 1 = \text{ ukoliko su ukupne obveze veće od ukupne imovine, } 0 = \text{ obrnuto)}$$

Ova varijabla je u najvećem broju slučajeva dummy jer je njezina vrijednost, a time i utjecaj na formulu 0. Ukupne obveze su veće od ukupne imovine vrlo rijetko u praksi, ali Ohlson je smatrao da se takva ekstremna situacija treba zabilježiti u modelu.

$$X_6 = \text{neto dobit} / \text{ukupna imovina (stanje na dan)}$$

Varijabla koja mjeri profitabilnost poduzeća.

X_7 = novčani tok od poslovnih aktivnosti / ukupne obveze

Novčani tok od poslovnih aktivnosti se izračunava kao zbroj dobiti prije oporezivanja i vrijednosnih usklađenja. Ovom varijablom se mjeri sposobnost poduzeća da financira svoj dug koristeći samo operativnu dobit. To je konzervativni pristup budući ne koristi druge izvore gotovine. Ako je vrijednost ovog omjera manja od 1, poduzeće ima problem s financiranjem.

X_8 = dummy varijabla 0 ili 1 (1 = ukoliko je neto dobit negativna kroz posljednje dvije godine, 0 = obrnuto)

Ova varijabla je u najvećem broju slučajeva dummy pa je njezina vrijednost, a time i utjecaj na formulu 0

$X_9 = (NI_t - NI_{t-1}) / (|NI_t| + |NI_{t-1}|)$, pri čemu je NI_t neto dobit u posljednjem razdoblju promatranja

Ova varijabla je dizajnirana kako bi uzela u obzir potencijalne progresivne gubitke u posljednje dvije godine.

Logit analiza je rezultirala definiranjem tri modela za predviđanje stečaja koji se temelje na četiri pokazatelja likvidnosti, dva pokazatelja profitabilnosti i dva pokazatelja zaduženosti. Model 1 koji predviđa stečaj unutar prve godine, Model 2 unutar druge godine (ukoliko stečajni postupak nije pokrenut u prvoj godini), te Model 3 koji predviđa stečaj unutar razdoblja od tri godine. Sva tri modela su imala zadovoljavajuću učinkovitost od 85% do 96% točno klasificiranih poduzeća.

Ohlson je priznao da je nedostatak njegovog modela u činjenici da model ne uzima u obzir tržišnu vrijednost poduzeća niti transakcije vrijednosnim papirima poduzeća. Također je preporučio daljnja istraživanja koja bi povećala točnost i učinkovitost njegovog modela, budući su rezultati ipak bili slabiji od Altmanovog Z'-score modela, dodavanjem dodatnih varijabli. Jedan od nedostataka modela je i usporedba kumulativnih veličina kao što si prihodi i dobit s varijablama koje se iskazuju stanjima na dan. Izračun varijabli temeljem prosječnih vrijednosti dalo bi točnije rezultate, no to

nije uvijek moguće zbog dostupnosti podataka. Druge značajnije kritike Ohlsonovog modela nisu iznijeli niti ostali istraživači.

Zmijewski (1984.)

Zmijewski je 1984. godine definirao model za predviđanje stečaja, na temelju uzorka poduzeća koji je uključivao 40 poduzeća u stečaju (onih koja su podnijela zahtjev za pokretanjem stečaja) i 800 financijski zdravih poduzeća. U studiji koju je Zmijewski objavio analizirana su dva metodološka aspekta definiranja uzorka koja mogu imati utjecaj na smanjenje objektivnosti i točnosti modela: ciljano odabrani uzorak i odabrani uzorak s potpunim podacima. Prvi aspekt se odnosi na pretjerani broj poduzeća u stečaju u ukupnom uzorku poduzeća, odnosno kada se odabiru parovi poduzeća u stečaju i financijski zdrava poduzeća (jedan na jedan), pri čemu je potencijal stečaja precijenjen u modelu. Drugi problem pri odabiru uzorka je modeliranje na temelju uzorka s potpunim podacima pri čemu se rezultati modela izuzetno razlikuju od onog uzorka u kojem istraživač ne raspolaže sa svim potrebnim podacima.

Zmijewski je pokušao izbjeći problem utjecaja ciljano odabranog uzorka u modelu koji dovodi do pristranosti koeficijenata u modelu i predviđanja koja precjenjuju udio poduzeća u stečaju koja su točno klasificirana. Iz tog razloga je proveo modeliranje na cjelokupnoj populaciji poduzeća. Zmijewski je zaključio da oba problema odnosno pristranosti uzorka ne utječu značajno na statističke zaključke modela i ukupnu klasifikacijsku točnost modela.

Zmijewski je u model uključio sva poduzeća koja su kotirala na New York Stock Exchange u razdoblju do 1972. do 1978., a nisu spadala u industriju uslužnih djelatnosti, financijskih usluga ili javne administracije. Koristio je probit statističku metodu, a finalna funkcija sadrži tri varijable. Zmijewski model je zadržao isti stupanj točnosti kao i Altman i Ohlson iako uključuje tek tri varijable, a stupanj točnosti modela iznosio je 99% na odabranom uzorku. Finalna probit funkcija s varijablama i pripadajućim procijenjenim koeficijentima je bila sljedeća:

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

pri čemu je:

X_1 = neto dobit / ukupna imovina (stanje na dan)

X_2 = ukupne obveze / ukupna imovina (stanje na dan)

X_3 = kratkotrajna imovina / kratkoročne obveze

Kao i kod logit funkcije, probit funkcija mapira vrijednosti zavisne varijable u rasponu od 0 do 1.

$$P = \Phi(\beta^T X)$$

Pri čemu je P vjerojatnost nastupanja stečaja, X predstavlja odabrane varijable, a $\Phi(\beta^T X)$ kumulativnu funkciju standardizirane normalne raspodjele. Probit funkcija mapira vrijednost $\beta^T X$ prema vjerojatnosti u rasponu od 0 do 1. Ukoliko je vrijednost funkcije P jednaka ili veća od 0,5 vjerojatnost stečaja je vrlo velika.

Zmijewski je klasificirao vrijednosti drugačije od Ohlsona na način da su poduzeća koja su imala vrijednost zavisne varijable jednaku ili veću od 0,5 klasificirana kao poduzeća u stečaju, a ona s vrijednosti manjom od 0,5 kao financijski zdrava poduzeća.

Osnovne kritike Zmijewski modela odnose se na sljedeće stavke:

1. pokazatelj koji uključuje neto dobit u sebi sadrži financijske rashode vezane za troškove kamata i tečajnih razlika. Neto dobit sadrži prihode i rashode koji nisu vezani za poslovne operacije poduzeća i u sebi sadrže utjecaj strukture kapitala i financiranja poslovanja, a ne čistu profitabilnost poslovnih aktivnosti. Pojedini autori (Avenhuis, 2013., Grice, Dugan, 2003.) smatraju da su pokazatelji koji uključuju EBIT (zarada prije poreza i kamata) bolji pokazatelji profitabilnosti poslovanja poduzeća od onih koji uključuju neto dobiti kao mjeru profitabilnosti,

2. Shumway (Shumway, 2001.) smatra da model nema signifikantnu produktivnu sposobnost budući se temelji samo na jednoj varijabli jer su X_1 i X_2 izuzetno korelirane,
3. Grice i Dugan (2003.) navode da je nedostatak modela činjenica da varijable u modelu nisu izabrane na osnovi teorijskog obrazloženja, već učinkovitosti varijabli u istraživanjima i modelima drugih autora, što je također nedostatak modela Altmana i Ohlsona,
4. jedan od nedostataka modela je njegov razvoj samo na proizvodnim poduzećima što bi moglo biti ograničavajuće u primjeni modela na poduzećima koja posluju u drugim industrijama.

Sva tri modela su često korištena u praksi te su prema dostupnoj literaturi predmet od velikog interesa brojnih istraživača. Sva tri modela su jednostavna i razumljiva za primjenu u većem broju industrija te temeljena na javno dostupnim podacima što olakšava njihovu primjenu. No, s obzirom na činjenicu da su sva tri modela razvijena na relativno malom uzorku poduzeća i s malim brojem računovodstvenih varijabli iz javno dostupnih podataka, postavlja se pitanje njihove učinkovitosti u današnje vrijeme kada kvantitativni podaci prethodne godine predstavljaju zastarjele podatke, a kvalitativni podaci često imaju jaču prediktivnu moć od kvantitativnih.

3.2. Teorijski prikaz i ocjena ekspertnih sustava

U posljednjih desetak godina koriste se ekspertni sustavi, a oni koriste umjetnu inteligenciju i suvremena softverska rješenja u predviđanju stečaja poduzeća. Primjer takvih sustava su data mining tehnika, stabla odlučivanja, umjetne neuronske mreže i metoda genetskih algoritama. Umjetne neuronske mreže će biti detaljno teorijski i empirijski objašnjene u 5. poglavlju ovog rada, stoga se u nastavku poglavlja ukratko opisuje data mining tehnika.

Data mining tehnika, koja se još zove i tehnika otkrivanja znanja u bazama podataka, je proces otkrivanja smislenih uzoraka u velikim bazama podataka. Data mining je istraživački i kompliciran proces koji uključuje mnogobrojne iteracije, a odvija se u sljedećim osnovnim koracima (prilagođeno prema Chen, Du, 2009.):

1. korak: Identifikacija i razumijevanje domene primjene data mining tehnike. Prikupljanje potrebnog znanja i razumijevanje cilja tehnike sa aspekta krajnjeg korisnika.
2. korak: Odabir prikladnog seta podataka ili fokus na podskup varijabli ili podataka koje su relevantne za analizu iz velikih baza podataka.
3. korak: Provedba pred-obrađe podataka što uključuje čišćenje podataka i odbacivanje nepotrebnih podataka s ciljem definiranja učinkovitog broja varijabli koje će biti primijenjene u procesu.
4. korak: Provedba data mininga kao osnovnog procesa i primjene metode traganja za smislenim obrascima ponašanja podataka u reprezentativnim formama kao što su primjerice klasifikacijska stabla, tehnike clusteringa i slično.
5. korak: Izvlačenje znanja temeljeno na prethodnim koracima i vizualizacija izvučenih uzoraka / obrazaca podataka.
6. korak: Aplikacija definiranog znanja na tekuću aplikaciju od interesa.
7. korak: Identifikacija najinteresantnijih uzoraka na tekućoj aplikaciji od interesa.

Data mining tehnike ostvaruju učinkovitost od 86% do 99% u predviđanju nastupanja stečaja poduzeća što ih svrstava u izuzetno učinkovite modele (Santos, Pereira, Quintela, 2006.).

3.3. Teorijski prikaz i ocjena teorijskih modela

Posljednji u razvoju su teorijski modeli koji su, za razliku od statističkih metoda i ekspertnih sustava, usmjereni na kvalitativne razloge neuspjeha poslovanja i temelje se na pronalasku tih uzroka (uglavnom kvalitativnih) te na taj način predviđaju neuspjeh i nastavak poslovanja poduzeća (autorica prilagodila prema Vitezić, 2013.). Najpoznatiji teorijski modeli, temeljeni na matematičkim modelima, su hazard modeli, teorija igara i teorija kreditnog rizika koja je prvenstveno vezana uz financijske institucije. U nastavku će se kratko obraditi hazard modeli budući su ti modeli najčešće korišteni u procjeni nastavka poslovanja poduzeća.

Hazard modeli u svojoj procjeni koriste i računovodstvene pokazatelje i tržišne odnosno makroekonomske pokazatelje u procjeni rizika nastupanja stečaja poduzeća, te koriste varijable ovisne o vremenu za procjenu nastupanja stečaja poduzeća u svakom definiranom trenutku. Vjerojatnost nastupanja stečaja poduzeća u trenutku $t+1$ ovisi o preživljavanju poduzeća do trenutka t , a zavisna varijabla je vrijeme koje poduzeće provede u grupi zdravih poduzeća te daje informacije o najvjerojatnijem vremenu propasti. U hazard modelima rizik od nastupanja stečaja se kod poduzeća mijenja tijekom vremena, a njegovo je financijsko zdravlje funkcija posljednjih financijskih podataka i starosti poduzeća. Hazard modeli su multi-period tehnike budući tretiraju varijable istog poduzeća u različitim razdobljima kao međuzavisne varijable.

Istraživači su aktivno počeli primjenjivati hazard modele u 80-tim godinama prošlog stoljeća, ali je tek Shumway 2001. godine popularizirao primjenu hazard modela dokazivanjem da je multiperiodni logit model jednak hazard modelu u diskretnom vremenu (kraćem razdoblju promatranja) s hazard funkcijom, što je pojednostavilo oblikovanje modela za predviđanje poslovnih poteškoća (prilagođeno prema Tomas Žiković, 2013.).

Prema ekonometrijskoj ocjeni, postoje tri osnovna razloga superiornosti hazard modela za predviđanje stečaja poduzeća u odnosu na statističke tj. statičke modele (prilagođeno prema Shumway, 1999.):

1. Statistički model ne uspijevaju kontrolirati trajanje rizika nastupanja stečaja poduzeća. Kada je period u kojem se analizira odabrani uzorak poduzeća dugačak, vrlo je važno kontrolirati činjenicu da pojedina poduzeća mogu pokrenuti stečaj nakon dugog niza godina u stanju rizika od nastupanja stečaja, a druga nakon samo jedne godine prisustva rizika. Statički tj. statistički modeli ne provode prilagodbu varijabli za taj period, a hazard modeli ju provode automatski.
2. Hazard modeli uključuju godišnje kovarijance (mjeru povezanosti odnosno koeficijent korelacije dviju varijabli) koje se mijenjaju tijekom vremena odnosno eksplanatorne varijable (npr. varijable Altmana ili Zmijewskog) koje se mijenjaju tijekom vremena. Ukoliko se poslovanje poduzeća pogoršava prije nastupanja stečaja, onda je važno prikazati promjenu financijskog zdravlja poduzeća pomoću financijskih pokazatelja. Također u model se uključuju makroekonomske ili tržišne varijable koje su iste za sva poduzeća u određenom trenutku (npr. veličina tržišta poduzeća), te važnu ulogu nezavisne varijable ima i starost poduzeća.
3. Hazard modeli mogu obraditi veliki broj podataka, znatno veći nego statički modeli, i dati učinkovita predviđanja na temelju uzorka podataka. Modeli se mogu promatrati kao binarni logit modeli koji promatraju svaku godinu svakog poduzeća kao zasebnu opservaciju.

Postoji značajan broj autora, primjerice Shumway (2001.), Bauer, Agarwal, (2014.), koji su empirijski dokazali superiornost hazard modela u odnosu na statističke modele u točnosti procjene nastupanja stečaja poduzeća. Rezultati modela su jednostavni za interpretaciju pri čemu pozitivni koeficijent upućuje na povećani rizik poslovnih poteškoća u poslovanju poduzeća.

3.4. Potreba za novim modelom predviđanja nastavka poslovanja

Kao što je prikazano u prethodnim poglavljima, još od sredine prošlog stoljeća istraživači i teoretičari razvijaju modele predviđanja nastavka poslovanja poduzeća što

je rezultiralo velikim brojem modela raznih stupnjeva učinkovitosti, kompleksnosti i promjenjivosti na tržištu. Posljednja financijska kriza podcrtala je važnost transparentnosti, objektivnosti, homogenosti, provjerljivosti i specifičnosti prediktivnih modela, posebno onih koji se koriste u bankarskom sustavu. Modeli se razlikuju od onih prvih jednovarijantnih koji koriste samo jedan pokazatelj u procjeni, što se u praksi nije pokazalo učinkovitim, do multivarijantnih modela koji kombiniraju veći broj financijskih pokazatelja. No, postoji nekoliko značajnih problema u primjeni postojećih modela.

Prvi signifikantan problem s modelima predviđanja nastavka poslovanja s kojim se susreću korisnici modela je njihova općenita upotreba, odnosno problem generalne upotrebe u različitim makroekonomskim okruženjima i nacionalnim ekonomijama. Razlog tome je činjenica da je svaki pojedini model razvijen na specifičnom uzorku koji uključuje poduzeća u specifičnim industrijama u specifičnom vremenskom razdoblju. Izazov svakom modelu je njegova učinkovitost u industrijama i vremenskim razdobljima izvan originalnog uzorka. Ovaj rad upućuje na taj problem, kao i brojni drugi autori, primjerice Avenhuis (2013.), Alareeni, Branson (2013.), Begley et al (1996.), ali i sam Altman (2014., 2016.). Ne postoji jednostavno rješenje navedenog problema u obliku definiranja jednostavnog modela s malim brojem varijabli primjenjivih na veliki broj makroekonomskih okruženja ili s druge strane razvoj kompleksnog modela koji bi uključivao sve specifičnosti velikog broja makroekonomskih okruženja i stupnjeva razvoja nacionalnih ekonomija, već je najučinkovitiji pristup rješenju ovog problema, razvoj modela prilagođenih pojedinim okruženjima, tržištima, regulatornim specifičnostima i stupnju razvoja ekonomija.

Drugi problem s kojim se susreću korisnici modela razvijenih prema specifičnostima pojedinih tržišta, je njihova učinkovitost u predviđanju budućih poremećaja ili nastavka poslovanja s obzirom na činjenicu da se većina temelji na tradicionalnim statističkim metodama (MDA, probit i logit). Rezultati modela temeljenih na tradicionalnim statističkim metodama podrazumijevaju striktno pretpostavke linearnosti, normalne distribucije, te nezavisnosti prediktivnih varijabli (Lacher et al, 1995.), a one nisu kompatibilne s kompleksnošću, ograničenjima i međusobnom povezanosti financijskih pokazatelja. Iz tog razloga MDA, logit i probit metode nisu dovoljno učinkovite u analizi financijskih pokazatelja.

U posljednjih nekoliko godina metoda neuronskih mreža se predlaže kao prikladna i bolja metoda od tradicionalnih statističkih metoda koja daje točnije rezultate bez potrebe poštivanja striktnih statističkih pretpostavki tradicionalnih metoda, te se stoga smatra metodom sa signifikantnim potencijalom u procjeni nastavka poslovanja poduzeća. Neuronske mreže ostvaruju znatno bolje rezultate, odnosno niže vrijednosti, u Pogreškama tipa 1 koje pogrešno klasificiraju poduzeća s negativnom poslovnom perspektivom u zdrava poduzeća.

Treći problem postojećih modela je činjenica da većina modela koristi isključivo financijske pokazatelje poslovanja koji su temeljeni na povijesnim računovodstvenim podacima te javno dostupnim informacijama koje u trenutku svoje objave već mogu biti zastarjele. Iz tog razloga takvi modeli nisu dovoljno osjetljivi i ne osiguravaju rane znakove upozorenja korisnicima modela dovoljno rano kao modeli koji bi bili temeljeni i na internim (koji se ne objavljuju javno) podacima poduzeća.

Iz navedenih razloga i potrebe za što točnijom prognozom nastavka poslovanja poduzeća za veliki broj korisnika, javlja se potreba definiranja novog modela za procjenu nastavka poslovanja poduzeća koji uzima u obzir sve nedostatke postojećih modela. Osnovni cilj je dobiti pokazatelj za procjenu nastavka poslovanja poduzeća, a ne za procjenu stečaja poduzeća. Nemogućnost podmirivanja obaveza ne znači uvijek nužno nastupanje stečaja poduzeća. Proučavanje samo poduzeća u stečaju, odnosno uključivanje isključivo poduzeća u stečaju u uzorak neuspješnih poduzeća, može dovesti do pristranosti modela zbog činjenice da financijski poremećaji, financijska nefleksibilnost i troškovi financijskih poremećaja nastupaju nekoliko godina prije pokretanja stečaja poduzeća. Čak i Altman 1983. naglašava važnost financijskih poremećaja bez obzira na finalni ishod istog.

3.5. Dosadašnji rezultati istraživanja učinkovitosti modela primjenom statističke tehnike neuronskih mreža

Literatura za predviđanje bankrota ili nastavka poslovanja poduzeća je dobro poznata i nadograđuje se uglavnom na Altmanov model, iako je prvi model razvio Beaver 1966.

godine. Doprinosi u posljednjem desetljeću se ponajprije odnose na razvoj modela posebno dizajniran po pojedinim karakteristikama poduzeća, npr. veličina, industrija ili starost, te utjecaj ne-financijskih varijabli. Dodatno, posljednjih se godina zamjenjuju najpopularnije statističke tehnike (MDA i logistička regresija) raznim ne-parametarskim metodama umjetne inteligencije kao što su umjetne neuronske mreže s ciljem povećanja učinkovitosti modela.

Većina istraživanja bavi se problematikom učinkovitosti umjetnih neuronskih mreža koje koriste uzorke s ciljem povećanja učinkovitosti prediktivnih modela. Značajan broj istraživača primjenjuje umjetne neuronske mreže u financijama, te se osim predviđanja stečaja i financijskih poteškoća poduzeća, koriste za predviđanje tečajeva valuta i cijena dionica. Neki od najznačajnijih istraživanja se navode u nastavku.

Autori Ciampi i Gordini su 2013. godine, koristeći bazu podataka od 7.000 talijanskih malih poduzeća (Small Enterprises), demonstrirali superiornost i veću točnost umjetnih neuronskih mreža u odnosu na klasičnu logističku regresiju i linearnu diskriminantnu analizu. Njihovi rezultati također sugeriraju da podjela uzorka poduzeća u smislu industrije u kojoj posluju, njihove veličine i zemljopisnog područja, povećava točnost prediktivnih modela.

Koristeći se podacima iz slovenskog bankarskog sustava, **Jagrić, Kraćun i Jagrić** su 2011. godine proveli istraživanje superiornosti neuronske mreže učeće vektorske kvantizacije (eng. learning vector quantization LVQ) i klasičnog logit modela prilikom definiranja modela kreditnog rizika u retail bankarstvu (poslovanje s građanstvom). Bazu podataka činilo je 1.904 pojedinačnih klijenata (svaki klijent, jedan kredit) banaka kojima je odobren kredit u razdoblju od 2006.-2007. godine. Istraživanja su potvrdila početnu hipotezu autora da umjetne neuronske mreže bolje ocrtavaju nelinearne veze između varijabli (npr. godište, spol, bračno stanje, obrazovanje, radno mjesto, zaposlenje, regija, raspoloživi dohodak, iznos kredita, način povrata kredita, otplatne rate, kamatna stopa i ostale) te ostvaruju najbolje rezultate u točnosti klasifikacije dobrih klijenata u odnosu na točnost logit modela.

Autori W. Chen i Y. Du proveli su 2009. godine istraživanje usporedbe učinkovitosti predviđanja poslovnih poremećaja pomoću dvije statističke metode: metode

neuronskih mreža i data mining metode. Analizirali su učinkovitost prognoziranja poslovnih poremećaja na primjeru 68 poduzeća čijim se vrijednosnim papirima trguje na Tajvanskoj burzi u periodu od 7 godina i 10 mjeseci pomoću odabranih varijabli. Rezultati istraživanja pokazuju da statistička metoda neuronskih mreža ostvaruje višu razinu točnosti predviđanja stečaja poduzeća u odnosu na data mining metodu, te da točnost predviđanja stečaja poduzeća postaje točnija vremenskim približavanjem trenutku stečaja. Također prosječna vrijednost Pogreške tipa 2 (koja je investitorima najkorisnija buduću pokazuje pogrešku modela da neuspješna poduzeća klasificira kao uspješna) je niža kod modela razvijenog uz primjenu neuronskih mreža nego kod modela razvijenog uz primjenu data mining metode.

Od ostalih autora ističu se **Neves i Vieira** koji su 2006. godine bazirali svoje istraživanje na oko 1.000 industrijskih poduzeća u Francuskoj tijekom razdoblja 1998.-2000. i dokazali veću učinkovitost umjetnih neuronskih mreža nad linearnom diskriminantnom analizom. Autori su razvili novi hibridni model (algoritam HLVQ-C, Hidden Layer Learning Vector Quantization) koji uključuje mrežu učeće vektorske kvantizacije i mreže inter-slojnih veza te može obraditi veliki broj financijskih indikatora, tj. nezavisnih varijabli. Autori su također dokazali veću učinkovitost modela u slučaju uravnoteženog uzorka s podjednakim brojem poduzeća u stečaju u odnosu na financijski zdrava poduzeća.

Autori H.C. Koh i S.S. Tan istražili su 1999. godine upotrebu neuronskih mreža u kontekstu definiranja modela procjene nastavka poslovanja poduzeća na temelju financijskih pokazatelja. Korištena je neuronska mreža s tri sloja, feedforward, back propagation model, te input layer-om od 6 neurona za šest financijskih pokazatelja. Uzorak poduzeća, koji se sastoji od 165 poduzeća s negativnom ocjenom nastavka poslovanja i 165 poduzeća s pozitivnom ocjenom nastavka poslovanja, preuzet je iz prethodne studije jednog od autora, H.C.Koh, iz 1991. kako bi se usporedila učinkovitost probit metode, na kojoj je provedena prethodna studija, i neuronske mreže korištene u ovoj studiji. U modelu je korišteno 300 poduzeća za treniranje mreže, te 30 za provjeru neuronske mreže. Rezultati provedene studije pokazuju 100% učinkovitost mreže u procjeni poduzeća u oba uzorka i autori su time dokazali superiornost neuronske mreže u odnosu na probit metodu kojoj je učinkovitost točnosti procjene

iznosila 99% (84% za klasificiranje poduzeća u problematična, te 100% za klasificiranje poduzeća u uspješna) na odabranom uzorku.

Autori Zhand et al su 1999. godine usporedili točnost umjetnih neuronskih mreža i logističke regresije u predviđanju nastupanja stečaja u poduzećima. Inputi za oba modela bili su formirani od šest varijabli koje su uključivale 5 indikatora koje je koristio Altman i indikator odnosa kratkotrajne imovine i kratkoročnih obveza. Uzorak se sastojao od 220 parova američkih proizvodnih poduzeća u stečaju i poduzeća koja posluju u razdoblju od 1980. – 1991. godine. Pod-setovi su se poklapali prema industriji i veličini poduzeća. Autori su dokazali veću učinkovitost predviđanja i klasifikacije poduzeća umjetnih neuronskih mreža u odnosu na logističku regresiju.

Autori Lacher, R.C. et al su 1995. godine proveli istraživanje na istom setu financijskih pokazatelja koje je koristio E. Altman za svoj prvi Zscore pokazatelj iz 1968., ali primjenjujući neuronske mreže, četiri algoritma Cascor, te su usporedili učinkovitost arhitekture neuronskih mreža s Altmanovim rezultatima. Istraživanje su proveli na 94 poduzeća s upitnim nastavkom poslovanja (going concern napomena u revizorskom izvještaju) i 188 poduzeća sa pozitivnim poslovanjem u periodu od 1970.-1989. godine. Polovica uzorka korištena je za učenje, a polovica za testiranje mreže, pri čemu su prikupljeni podaci od godine u kojoj je objavljen going concern status i tri prethodne godine. Rezultati istraživanja pokazuju da je Cascor algoritam učinkovitija metoda u predviđanju financijskih poteškoća s obzirom da je algoritam ostvario bolje rezultate u Pogreškama tipa 1 i tipa 2 te dugoročnijem predviđanju poteškoća poslovanja poduzeća.

Altman, Marco i Varetto su proveli istraživanje i usporedili rezultate identificiranja poduzeća s financijskim poteškoćama dobivene pomoću diskriminacijske analize i neuronskih mreža, na uzorku talijanskih banaka u periodu između 1985. i 1991. godine. Testiranje statističkog kredit scoring modela dobivenog pomoću diskriminacijske analize je pokazao stupanj točnosti od 86% u periodu od 3 godine prije otkrivanja stvarnog stanja do 97% u periodu od 1 godine do otkrivanja stvarnog stanja. Kod definiranja modela putem neuronske mreže koristila se troslojna mreža, a na kraju trenirajućeg perioda mreža je bila u mogućnosti prepoznati 98% zdravih i 97%

loših poduzeća. Usporedba tih rezultata pokazuje da je sposobnost mreže za točnom klasifikacijom poduzeća veća nego sposobnost diskriminacijske analize.

No, osim istraživanja ovih rezultata, pojedini autori su prijavili drugačije iskustvo i rezultate tijekom istraživanja učinkovitosti umjetnih neuronskih mreža u odnosu na tradicionalne statističke tehnike. **Autori Boritz i Kennedy** su 1995. godine usporedili nekoliko umjetnih neuronskih mreža s linearnom diskriminantnom analizom, logističkom regresijom i probit modelom. Njihovo istraživanje nije dokazalo superiornost neuronskih mreža u odnosu na druge metode. Altman u pojedinim radovima (npr. 1994.) kritizira neuronske mreže i njihovu preveliku generalizaciju. Također, autori Laitinen i Kankaanpaa, u svom istraživanju 1999. godine, nisu pronašli signifikantne razlike u točnosti između neuronskih mreža i pet alternativnih tehnika za predviđanje poslovnih poteškoća. Istraživanje je provedeno na Finskim poduzećima od jedne do tri godine prije nastupanja poteškoća. Umjetne neuronske mreže su bile jednako učinkovite kao linearna diskriminantna analiza u istraživanju prije 30-ak godina.

4. EMPIRIJSKO ISTRAŽIVANJE: ANALIZA UČINKOVITOSTI ALTMANOVOG Z'-SCORE MODELA, OHLSON MODELA I ZMIJEWSKI MODELA

Modeli Altmana, Ohlsona i Zmijewskog razvijeni su i primijenjeni u SAD-u i pojedinim Europskim razvijenim zemljama u specifičnom vremenskom periodu s ekonomskim obilježjima koja se razlikuju od današnjih. Iz tog je razloga opravdana sumnja učinkovitosti i primjenjivosti tih modela u tranzicijskim zemljama u današnje vrijeme, u izazovnim ekonomskim i političkim uvjetima. U ovom poglavlju se testira i istražuje općenita primjenjivost sva tri statistička modela u hrvatskom okruženju, koje se može smatrati reprezentativnim za tranzicijske zemlje u regiji. Ovim će se istraživanjem potvrditi ili opovrgnuti prva i druga pomoćna hipoteza. Istraživanje se temelji na uzorku od 1.796 poduzeća (uspješna i neuspješna) na kojima se testiralo mogu li odabrani modeli predvidjeti nastavak poslovanja poduzeća kao što su mogli u matičnim gospodarskim okruženjima. Istraživanje je pokazalo da su modeli Altmana i Zmijewskog učinkoviti u predviđanju neuspješnih poduzeća, dok je model Ohlsona osigurao slabije pokazatelje za diferencijaciju između uspješnih i neuspješnih poduzeća.

4.1. Odabir i karakteristike uzorka istraživanja

Empirijsko istraživanje i analiza učinkovitosti navedena tri modela provela se na uzorku poduzeća iz hrvatskog gospodarstva. Učinkovitost se analizirala na uzorku od **1.796** poduzeća raspoređenih u dvije grupe srednjih i velikih poduzeća:

1. prva skupina poduzeća koju čine:
 - poduzeća u stečajju,
 - poduzeća s pokrenutim postupkom predstečajne nagodbe
 - poduzeća s iskazanim negativnim pokazateljima uspješnosti poslovanja
2. druga skupina poduzeća koja uspješno posluju

Prilikom definicije veličine poduzeća, fokus analize je na srednjim i velikim poduzećima prema visini prihoda (ukupnim godišnjim poslovnim prihodom većim od 7,5 milijuna HRK), bez obzira na strukturu vlasništva, s pokušajem usklađivanja veličine prihoda poduzeća koja su raspoređena u uzorak. Uzorak nije obuhvatio samo poduzeća koja kotiraju na burzi jer procjenu nastavka poslovanja trebaju sva poduzeća, a ne samo ona s izdanim vrijednosnim papirima. Mala poduzeća nisu uključena u analizu zbog potencijalnog nedostatka objektivnih informacija o financijskim rezultatima, njihovog velikog broja i pojedinačno relativno malog utjecaja na funkcioniranje nacionalnog gospodarstva.

Analizom su obuhvaćeni podaci za sva uspješna i neuspješna poduzeća za razdoblje od posljednjih 6 godina tj. od 2010. do 2015. godine. U radu se prati pristup Ohlsona i Zmijewskog koji, za razliku od Altmana, koriste nejednak broj (neupareni uzorak) poduzeća koja su uspješna i neuspješna. Uzorak je tako definiran da je udio poduzeća u stečaju, predstečajnoj nagodbi ili s negativnim rezultatima poslovanja u ukupnom uzorku približno jednak udjelu takvih poduzeća u cijeloj populaciji (svim poduzećima u Republici Hrvatskoj koja imaju prihode veće od 7,5 milijuna HRK, njih oko 7.500 prema GFI podacima Financijske agencije). U skupinu poduzeća u stečaju ili predstečajnoj nagodbi uvrstiti će se poduzeća koja su ušla u predstečajnu nagodbu nakon donošenja Zakona o financijskom poslovanju i predstečajnoj nagodbi. Prema pregledu zbirnih podataka iz sustava predstečajnih nagodbi za razdoblje od 1.10.2012. do 30.10.2015. godine koje je objavila Financijska Agencija 30.10.2015. na svojim web stranicama, ukupno je u proces predstečajne nagodbe ušlo 8.960 predmeta kao što je prikazano u tablici br. 2, za koje se može pretpostaviti da su jednaki broju pravnih subjekata u procesu predstečajne nagodbe (uzima se pretpostavka da jedan pravni subjekt nije ušao više od jednog puta u proces predstečajne nagodbe u razdoblju od tri godine budući je prosječno trajanje predstečajne nagodbe 267 dana (prema Koščak, Bešević Vlajo, Pribičević, 2014.)

Prema prosječnom broju zaposlenika, uzima se pretpostavka da su 7.840 predmeta otvorila mala poduzeća s prosječnim brojem od 3 zaposlenika koji ne ulaze u uzorak ovog istraživanja, a ostalih 1.120 predmeta poduzeća s prosječnim brojem od 42 zaposlenika i prijavljenim obvezama većim od 10 milijuna HRK. Za potrebe procjene udjela poduzeća u predstečajnoj nagodbi u ukupnom broju aktivnih srednjih i velikih

poduzeća uzima se broj od 1.120 predmeta odnosno poduzeća, što iznosi 14,9% od ukupnog broja aktivnih srednjih i velikih poduzeća na tržištu.

Tablica 2. Zbirni pregled predmeta prema iznosu prijavljenih obveza

Predmeti prema iznosu prijavljenih obveza	Iznos prijavljenih obveza	Broj zaposlenih prema prijavi dužnika	Prosječni broj zaposlenika	Broj predmeta
Prijavljene obveze manje od 10 m HRK	8,4 mlrd HRK	19.758	3	7.840
Prijavljene obveze veće od 10 m HRK	73,6 mlrd HRK	47.068	42	1.120
Ukupno	82,0 mlrd HRK	66.826	7	8.960

Izvor: Prema FINA – informacijski sustav predstečajnih nagodbi

Drugi kriterij odabira poduzeća u prvoj skupini uzorka su poduzeća s iskazanim negativnim pokazateljima uspješnosti poslovanja:

- ostvareni gubitak (glavni kriterij) ili
- ostvarena dobit, ali
 - koeficijent zaduženosti > 1 (ukupne obveze / ukupna imovina)
 - i
 - koeficijent ubrzane likvidnosti < 1 ((kratkotrajna imovina – zalihe) / ukupne kratkoročne obveze)

Koeficijent zaduženosti pokazuje do koje mjere poduzeće koristi zaduživanje kao oblik financiranja, odnosno koji je postotak imovine nabavljen zaduživanjem. Što je veći odnos duga i imovine, veći je financijski rizik. U pravilu bi vrijednost koeficijenta zaduženosti trebala biti 50% ili manja. Koeficijent ubrzane likvidnosti govori o tome ima li poduzeće dovoljno kratkoročnih sredstva da podmiri dospjele kratkoročne obveze, a bez prodaje zaliha. Poželjna vrijednost ovog koeficijenta je ona koja ne odstupa značajno od industrijskog prosjeka, a ukoliko prosjek nije poznat, tada je

poželjna vrijednost koeficijenta jednaka omjeru 1:1. Preporučena minimalna vrijednost ovog koeficijenta iznosi 0,9.

Drugu skupinu poduzeća čine poduzeća okarakterizirana kao uspješna što se temelji na ostvarenoj dobiti, koeficijentu zaduženosti < 1 ili pokazatelju ubrzane likvidnosti > 1. Ovi pokazatelji ne jamče da financijski izvještaji ovih poduzeća nisu bili falsificirani ili da negativno poslovanje poduzeća neće biti kasnije otkriveno, već samo garantiraju da u trenutku odabira poduzeća, prema financijskim izvještajima iz 2010. godine, ne postoji dokaz o poslovnim poremećajima u tim poduzećima.

Prema izračunu navedenih koeficijenata, na uzorku poduzeća iz 2010. i 2013. godine, rezultati upućuju na udjele poduzeća s poslovnim poremećajima u ukupnoj masi poduzeća od 35% u što su uključena i poduzeća koja su već ušla u proces predstečajne nagodbe, što je prikazano na sljedećoj tablici.

Tablica 3. Udio poduzeća s negativnim poslovanjem u udjelu srednjih i velikih poduzeća, na primjeru 2010. i 2013. godine

God.	Broj aktivnih poduzeća s prihodom > 7,5 m HRK	Broj poduzeća s ostvarenim gubitkom	Broj poduzeća s ostvarenom dobiti, KZ > 1 i KUL < 1	Ukupno poduzeća s poslovnim poremećajem	Udio poduzeća s poslovnim poremećajem	Udio poduzeća u predsteč. nagodbi	Poduzeća s poslovnim poremećajem i u predsteč. nagodbi
2010.	7.593	1.411	187	1.598	21%	15%	36%
2013.	7.253	1.241	237	1.478	20%	15%	35%

Izvor: Prema GFI podacima

Ukoliko bi se uzeo udio poduzeća koja su ostvarila dobit, a imaju ili loš koeficijent zaduženosti ili loš koeficijent ubrzane likvidnosti, udio poduzeća s poslovnim poremećajima bi iznosio preko 75%. Taj je broj odbačen, kao potencijalni udio poduzeća s poslovnim poremećajem u uzorku, zbog prevelikog udjela takvih poduzeća

u uzorku i rizika da će krajnji model biti pristran i više primjenjiv za poduzeća koja već ostvaruju evidentno loše rezultate. Time bi se umanjila vrijednost modela čija bi osnovna funkcija trebala biti da predviđanje nastavka poslovanja poduzeća koja u trenutku izračuna dobro posluju.

Zaključno, prema navedenom izračunu, udio poduzeća u istraživanju iz prve skupine s poslovnim poremećajem i udio poduzeća iz druge skupine s pozitivnim poslovanjem iznositi će 38%:62% u uzorku istraživanja. Zbog dostupnosti podataka nije bilo moguće uskladiti uzorak na 35%:65%, ali ipak uzorak vrlo realno odražava udjele u gospodarstvu. Sva poduzeća u uzorku su klijenti banke u kojoj je zaposlena autorica rada kako bi se u istraživanje mogli uključiti i dodatni podaci (prvenstveno nefinancijski) kojim se raspolaže u bazi podataka financijske institucije. Svi korišteni podaci su anonimizirani, bez matičnih podataka (nakon prvotne selekcije), te nigdje neće biti prikazan popis uključenih poduzeća u istraživanje s njihovim nazivom ili matičnim brojem. Raspodjela poduzeća uključenih u uzorak prema udjelu u industrijama prikazana je u nastavku.

Tablica 4. Distribucija uzorka poduzeća prema grupama industrija

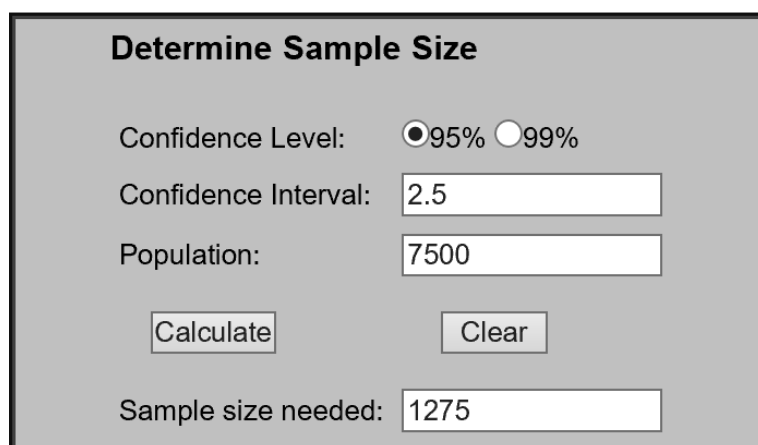
Grupirane industrije u uzorku	Dobra	Loša	Ukupno
Trgovina, prijevoz i skladištenje	457	229	686
Poljoprivreda, rudarstvo i vađenje i prerađivačka industrija	336	200	536
Građevinska industrija i poslovanje nekretninama	103	80	183
Informacije i komunikacije, financijske djelatnosti i djelatnosti osiguranja, administrativne djelatnosti	76	54	130
Stručne, znanstvene, tehničke djelatnosti, obrazovanje, umjetnost, zabava, rekreacija i djelatnosti zdravstvene zaštite	66	46	112
Djelatnost pružanja smještaja i restorana te ostale uslužne djelatnosti	38	51	89
Opskrba električnom energijom i vodom	30	30	60
Ukupno	1106	690	1796

Broj poduzeća koja su uključena u uzorak definirao se na temelju visoke razine pouzdanosti od 99% i uskog intervala pouzdanosti od 2%. Interval pouzdanosti je objektivna procjena (ne)preciznosti i veličine uzorka istraživanja. Na interval pouzdanosti možemo gledati kao na mjerilo kvalitete uzorka istraživanja. Ovisno o razini pouzdanosti mijenja se i raspon tj. granice intervala pouzdanosti. Tradicionalno se koristi razina ili stupanj pouzdanosti od 95% koji je u vezi sa općeprihvaćenom razinom statističke značajnosti $P < 0,05$. (Šimundić, 2008.) Zbog činjenice da samo istraživanja provedena na velikom uzorku daju vrlo uski interval pouzdanosti koji ukazuje na veliku preciznost procjene, u uzorak će biti uvršteno 1.796 poduzeća (prema podacima iz financijskih izvještaja 2010. godine):

- 690 poduzeća s poslovnim poremećajima, te
- 1106 poduzeća koja posluju uspješno

Primjenjivost uzorka na cijelu populaciju srednjih i velikih poduzeća u Republici Hrvatskoj testirala se primjenom web aplikacije Sample Size Calculator (The Survey System) prikazanoj na slici.

Slika 1. Izračun primjenjivosti uzorka prema Sample Size Calculator (www.surveysystem.com)



Determine Sample Size

Confidence Level: 95% 99%

Confidence Interval:

Population:

Sample size needed:

Sample Size Calculator predstavlja javni servis za istraživače i kalkulira potvrdu reprezentativnosti uzorka i primjenjivost rezultata uzorka na cijelu populaciju.

Temeljem stupnja pouzdanosti od 95% i intervala pouzdanosti od 2.5, potrebno je 1.275 poduzeća uključiti u uzorak kako bi reprezentativno predstavljao cjelokupnu populaciju čime je potvrđen broj od 1.796 jedinica u uzorku.

4.2. Razrada metode istraživanja

Osnovna metodologija ovog dijela istraživanja podrazumijeva izračun sva tri pokazatelja za cjelokupni uzorak poduzeća tijekom 6 reprezentativnih godina, procjena nastavka poslovanja prema definiranim vrijednostima u originalnim modelima, te ocjena učinkovitosti modela. Definirane su i provedene tri faze istraživanja:

1. Prva faza istraživanja podrazumijeva definiranje uzorka istraživanja što je objašnjeno u prethodnom poglavlju.
2. Druga faza podrazumijeva prikupljanje financijskih podataka za provedbu analize. Izvor podatka potrebnih za izračun financijskih pokazatelja su javni financijski izvještaji od 2010. do 2015. godine iz godišnjih objava Financijske agencije i podaci dostupni sa Zagrebačke burze.
3. Treća faza istraživanja podrazumijeva izračun pokazatelja za 1.796 poduzeća kroz 6 godina za tri modela, ukupno 10.776 pokazatelja za svaki model. Nakon izračuna Altmanovog Z'-score pokazatelja, Zmijewski pokazatelja i Ohlson pokazatelja, provela se metoda klasifikacije koristeći se SPSS programom. Analizirao se postotak točnosti predviđanja nastupanja poslovnog poremećaja te broj godina negativnih pokazatelja prije nastupanja stečaja poduzeća. Također se testirala i učinkovitost prognoziranja uspješnog nastavka poslovanja poduzeća za subjekte iz te skupine.

U trećoj fazi istraživanja, u izračunu pokazatelja korišteni su sljedeći modeli:

1. Altman Z' score = $0,717X_1 + 0,847X_2 + 3,107X_3 + 0,420X_4 + 0,998X_5$

Z' score < 1,23 → neuspješna poduzeća, Z' score > 2,90 uspješna poduzeća, Z' score = 1,23 do 2,90 poduzeća u sivoj zoni

Pri čemu je: X_1 = radni kapital/ukupna imovina, X_2 = zadržana dobit/ukupna imovina, X_3 = dobit prije oporezivanja (EBIT)/ukupna imovina, X_4 = tržišna vrijednost kapitala/knjigovodstvena vrijednost obveza, X_5 = ukupan prihod od prodaje/ukupna imovina

2. Ohlson O score = $-1,3 - 0,4X_1 + 6,0X_2 - 1,4X_3 + 0,8X_4 - 2,4X_5 - 1,8X_6 + 0,3X_7 - 1,7X_8 - 0,5X_9$

O score > 0,5 → poduzeće u riziku, O score < 0,5 → sigurno poduzeće

Pri čemu je: X_1 = veličina mjerena logaritmom odnosa ukupne imovine i BDP deflatora, X_2 = ukupne obveze / ukupna imovina, X_3 = radni kapital / ukupna imovina, X_4 = kratkoročne obveze / kratkotrajna imovina, X_5 = dummy varijabla 0 ili 1 (1 = ukoliko su ukupne obveze veće od ukupne imovine, 0 = obrnuto), X_6 = neto dobit / ukupna imovina, X_7 = novčani tok od poslovnih aktivnosti / ukupne obveze, X_8 = dummy varijabla 0 ili 1 (1 = ukoliko je neto dobit negativna kroz posljednje dvije godine, 0 = obrnuto), X_9 = $(NIt - NIt-1) / (|NIt| + NIt-1)$, pri čemu je: NIt neto dobit

3. Zmijewski score = $-4,3 - 4,5X_1 + 5,7X_2 + 0,004X_3$

Z Score > 0,5 → poduzeće u riziku, Z score < 0,5 → sigurno poduzeće.

Pri čemu je: X_1 = neto dobit / ukupna imovina, X_2 = ukupne obveze / ukupna imovina, X_3 = kratkotrajna imovina / kratkoročne obveze

U trećoj fazi istraživanja uvedena su dva analogna termina za procjenu točnosti predviđanja poslovanja, tip 1 i tip 2 ocjena točnosti, te Pogreške tipa 1 i 2:

1. Ocjena točnosti tipa 1 se definira kao broj poduzeća koja loše posluju, točno prognozirana kao poduzeća koja loše posluju, u odnosu na ukupan broj poduzeća u uzorku
2. Ocjena točnosti tipa 2 se definira kao broj poduzeća koja pozitivno posluju, točno prognozirana kao poduzeća s pozitivnim poslovanjem, u odnosu na ukupan broj poduzeća u uzorku
3. Pogreška tipa 1 se definira kao broj poduzeća koja loše posluju, a netočno su klasificirana kao poduzeća koja pozitivno posluju u odnosu na ukupan broj poduzeća u uzorku
4. Pogreška tipa 2 se definira kao broj poduzeća koja pozitivno posluju, a netočno su klasificirana kao poduzeća koja negativno posluju u odnosu na ukupan broj poduzeća u uzorku

Dodatno je uključena ukupna ocjena točnosti i pogreške predviđanja sva tri modela na cjelokupnom uzorku, te na pod-skupovima poduzeća prema industrijama u kojima posluju:

1. Ukupni indikator točnosti definiran kao broj poduzeća točno klasificiran (kao uspješna ili neuspješna) prema modelima u odnosu na ukupan broj poduzeća u uzorku
2. Ukupni indikator pogreške definiran kao broj poduzeća netočno klasificiran (kao uspješna ili neuspješna) prema modelima u odnosu na ukupan broj poduzeća u uzorku

Također je korišten test Mann-Whitney za testiranje sposobnosti predviđanja score-ova sva tri modela koji ocjenjuje diskriminirajuću moć score-ova između uspješnih i

neuspješnih poduzeća putem prikazivanja značajnih razlika u medijanima score-ova između dva uzorka (uspješna i neuspješna poduzeća). Korišteni su testovi opisne statistike i matrica korelacija.

4.3. Rezultati empirijskog istraživanja

Ovo poglavlje sadrži prikaz rezultata empirijskog istraživanja učinkovitosti predviđanja poslovanja poduzeća sva tri modela primjenom različitih statističkih postupaka u skladu s problemom i predmetom istraživanja i odnosi se na sva poduzeća u uzorku, kao i na poduzeća klasificirana u pojedine skupine industrija. Prikaz izračuna svih varijabli po svakom pokazatelju prikazan je po pojedinom poduzeću u Priritku 1. Analize koje uključuju deskriptivnu statistiku i korelaciju matrica provedene su u programu IBM SPSS 21.

Provedena analiza može se podijeliti na sljedeće dijelove:

- značajan broj statističkih testova (deskriptivna ili opisna statistika) s ciljem ispitivanja karakteristika uzorka te dobivanja podataka o razlikama uspješnosti sva tri pokazatelja u procjeni uspješnosti poduzeća u pojedinim razdobljima, te razlikama o pojedinim varijablama unutar tih pokazatelja,
- analiza varijance (prosječno kvadratno odstupanje od prosjeka) radi ispitivanja razlika u izraženosti promatranih karakteristika,
- analiza korelacije među promatranim varijablama s ciljem dobivanja početnog uvida u međusobni odnos varijabli postavljenih u istraživanju, ali i provjeravanja još jednog vida valjanosti skala (konvergentne valjanosti),
- analiza Pogreške tipa 1 i Pogreške tipa 2 te ukupni indikator točnosti i pogreške.

Statistički testovi (opisna statistika)

Rezultati statističkih testova opisne statistike kojima su se uspoređivala oba uzorka poduzeća (dobra i loša) po sve tri metode izračuna (Altman, Ohlson i Zmijewski) u razdoblju od 2010. – 2015. godine upućuju na značajne statističke razlike između dobrih i loših poduzeća u svim razdobljima i po svim metodologijama, što je potvrđeno pokazateljima standardne pogreške (F,p). Ohlsonov pokazatelj uspješnosti nije bilo moguće izračunati za 2010. g. s obzirom da podaci za prethodno razdoblje, 2009. godinu, nisu bili dostupni.

Tablica u nastavku sadrži osnovne pokazatelje opisne statistike te, osim pokazatelja standardne pogreške F i p, uključuje broj poduzeća u uzorku, medijan kao pokazatelj srednje vrijednosti koji dijeli numeričku seriju na dva jednaka dijela, te standardnu devijaciju kao prosječno odstupanje pojedinačnih vrijednosti od srednje vrijednosti. Što je standardna devijacija manja, manje je odstupanje od prosječne vrijednosti te je prosjek pouzdaniji i reprezentativniji. Empirijskim F-omjerom se ispituje nulta hipoteza da su aritmetičke sredine osnovnih skupova međusobno jednake, odnosno, da u cjelini nema statistički značajne razlike. Cilj je ispitati odnos varijacija između uzoraka s varijacijama unutar uzoraka. Ako je taj odnos, tzv. empirijski F-omjer, statistički značajan zaključujemo kako promatrani uzorci ne pripadaju istoj populaciji, odnosno aritmetičke sredine se značajno razlikuju. Što je empirijski F-omjer veći, to znači da su kod kategorija koje uspoređujemo (npr. dobra i loša poduzeća u 2010. godini) prisutne veće statistički značajne razlike, te da pokazatelji dobro diferenciraju jednu od druge skupine poduzeća. Recipročno u odnosu na empirijski F-omjer, p vrijednost će se smanjivati.

Na temelju rezultata statističkih testova i analize zaključuje se da se dobra i loša poduzeća u prosjeku statistički značajno razlikuju u vrijednostima svih pokazatelja i svim razdobljima na razini signifikantnosti od 1%.

Tablica 5. Usporedba pokazatelja uspješnosti dobrih i loših poduzeća prema Altmanu, Ohlsonu i Zmijewskom u razdoblju između 2010. – 2015. godine.

Pokazatelj		Broj poduzeća	Medijan	St. devijacija	F-omjer	p-vrijednost
Altman2010	Dobra	1106	2,95	1,77	239,39	p<0,01
	Loša	690	1,56	1,98		
	Ukupno	1796				
Zmijewski2010	Dobra	1106	-1,47	1,76	283,02	p<0,01
	Loša	690	0,45	3,08		
	Ukupno	1796				
Altman2011	Dobra	1106	2,99	1,86	239,04	p<0,01
	Loša	690	1,54	2,02		
	Ukupno	1796				
Ohlson2011	Dobra	1106	0,59	0,28	43,13	p<0,01
	Loša	690	0,68	0,31		
	Ukupno	1796				
Zmijewski2011	Dobra	1106	-1,40	1,71	301,53	p<0,01
	Loša	690	0,62	3,21		
	Ukupno	1796				
Altman2012	Dobra	1106	2,85	1,77	217,98	p<0,01
	Loša	690	1,50	2,08		
	Ukupno	1796				
Ohlson2012	Dobra	1105	0,56	0,31	72,19	p<0,01
	Loša	690	0,69	0,32		
	Ukupno	1795				
Zmijewski2012	Dobra	1106	-1,33	1,63	264,52	p<0,01
	Loša	690	1,05	4,40		
	Ukupno	1796				
Altman2013	Dobra	1106	3,00	1,81	287,73	p<0,01
	Loša	690	1,40	2,16		
	Ukupno	1796				
Ohlson2013	Dobra	1106	0,52	0,31	133,69	p<0,01
	Loša	690	0,69	0,33		
	Ukupno	1796				
Zmijewski2013	Dobra	1106	-1,59	1,57	329,19	p<0,01
	Loša	690	1,40	5,11		
	Ukupno	1796				
Altman2014	Dobra	1106	3,16	1,89	292,31	p<0,01
	Loša	690	1,42	2,38		
	Ukupno	1796				
Ohlson2014	Dobra	1106	0,48	0,30	214,93	p<0,01
	Loša	690	0,69	0,32		
	Ukupno	1796				
Zmijewski2014	Dobra	1106	-1,81	1,51	291,06	p<0,01

	Loša	690	1,74	6,66		
	Ukupno	1796				
Altman2015	Dobra	1106	3,23	1,96	312,55	p<0,01
	Loša	690	1,30	2,64		
	Ukupno	1796				
Ohlson2015	Dobra	1106	0,46	0,30	270,40	p<0,01
	Loša	690	0,71	0,34		
	Ukupno	1796				
Zmijewski2015	Dobra	1106	-1,86	1,53	143,56	p<0,01
	Loša	690	2,94	13,19		
	Ukupno	1796				

Interpretacija medijana, odnosno srednje vrijednosti, pokazuje da se medijani kod svih pokazatelja približavaju svojoj referentnoj vrijednosti u razdoblju od 2010. do 2015. godine. Od 2010. prema 2015., tj. sa skraćivanjem vremenskog perioda u odnosu na finalni rezultat poslovanja poduzeća, standardna devijacija pokazatelja se smanjuje čime se potvrđuje bolja reprezentativnost prosječne vrijednosti uzroka po godinama.

Interpretacije pokazatelja:

1. Medijan Altman Z'-score-a dobrih poduzeća u 2010. godini iznosi 2,95 dok je prosječno odstupanje od tog prosjeka 1,77. Za loša poduzeća srednja vrijednost Altman Z'-score-a iznosi 1,56 (što spada u sivu zonu poslovanja) uz prosječno odstupanje od prosječne vrijednosti od 1,98. U 2011. medijan Z'-score-a raste na 2,99, a loših pada na 1,54, no još uvijek u sivoj zoni poslovanja, a ne u zoni lošeg poslovanja. U 2012. medijan dobrih poduzeća pada na 2,85, kao i loših na 1,50. Zbog izuzetno loše ekonomske situacije u 2012. kada je ostvaren vrhunac financijske krize, svi pokazatelji (ne samo Altmanov) imaju najnižu vrijednost u uzorku dobrih poduzeća. U razdoblju od 2013. do 2015., medijan dobrih poduzeća raste što pokazuje jačanje njegove prediktivne učinkovitosti, dok medijan loših poduzeća pada. Medijan loših poduzeća se tijekom svih pet godina nalazi u zoni sivog poslovanja što upućuje na povećanu mogućnost Pogreške tipa 2 Z'-score pokazatelja.

Rezultati analize ukazuju na učinkovitost Z'-score-a u prognozi poslovanja dobrih poduzeća, posebno u razdoblju od dvije godine prije nastupanja poslovnog događaja, dok je slabija za prognozu loših poduzeća.

2. Medijan Ohlson pokazatelja u 2011. iznosi 0,59, dok je prosječno odstupanje od tog prosjeka 0,28. Za loša poduzeća medijan pokazatelja iznosi 0,68 uz standardnu devijaciju od 0,31. Iako je medijan uzorka dobrih poduzeća niži od medijana uzorka loših, ipak se nalazi u zoni lošeg poslovanja što upućuje na potencijalnu Pogrešku tipa 1. U 2012. godini, medijan vrijednosti pokazatelja dobrih poduzeća se još uvijek nalazi u zoni lošeg poslovanja. Od 2013. godine medijan dobrih poduzeća kontinuirano pada do vrijednosti od 0,46 u zoni dobrog poslovanja prema definiciji Ohlsona. Medijan uzorka loših poduzeća raste do vrijednosti od 0,72 u 2015. godini što se nalazi u zoni lošeg poslovanja prema definiciji Ohlsona. Sve godine uzorak prati niska standardna devijacija što upućuje na reprezentativnost uzorka.

Učinkovitost prognoze Ohlson pokazatelja može se smatrati prihvatljivom u razdoblju od jedne godine prije nastupanja poslovnog događaja, iako postoji opasnost od Pogreške tipa 1.

3. Vrijednosti medijana Zmijewski pokazatelja iznose -1,47 u 2010. godini za dobra poduzeća uz standardnu devijaciju od 1,76, a za loša 0,45 uz standardnu devijaciju od 3,08. Vrijednost medijana u 2010. godini odstupa od definicije Zmijewskog za loša poduzeća uz visoku standardnu devijaciju, stoga se pokazatelj ne može smatrati učinkovitim pet godina prije nastupanja poslovnog događaja. Srednja vrijednost Zmijewskog u 2011. godini iznosi -1,40 za dobra poduzeća, a 0,62 za loša poduzeća te ulazi u definiciju dobrog i lošeg poslovanja, iako je standardna devijacija visoka posebno u uzorku loših poduzeća. U svim narednim godinama, vrijednosti medijani pokazatelja potvrđuju definiciju Zmijewskog, iako je standardna devijacija u uzorku loših poduzeća konstantno visoka.

Zmijewski pokazatelj je učinkovit u prognozi poslovanja poduzeća i četiri godine prije nastupanja poslovnog događaja uz ograničenje zbog visoke standardne devijacije uzorka.

Iz opisanog se može zaključiti da se testovima opisne statistike može ustanoviti reprezentativnost uzoraka i učinkovitost pokazatelja u diferencijaciji dobrih i loših poduzeća, ali u različitim razdobljima predviđanja. Prosječne vrijednosti za pokazatelje su sljedeće:

Dobra poduzeća

- Altman Z'-score: 3,03 (uspješna poduzeća prema Altmanu)
- Ohlson score: 0,52 (poduzeće u riziku prema Ohlsonu)
- Zmijewski score: -1,58 (nema rizika od stečaja prema Zmijewskom)

Loša poduzeća

- Altman Z'-score: 1,45 (siva zona prema Altmanu)
- Ohlson score: 0,69 (poduzeće u riziku prema Ohlsonu)
- Zmijewski score: 1,37 (velika vjerojatnost stečaja prema Zmijewskom)

Prosječne vrijednosti pokazatelja su u skladu s originalnim rasponima pokazatelja osim u slučaju Ohlson pokazatelja kod dobrih poduzeća.

Radi detaljne analize pokazatelja uspješnosti poduzeća provedeni su testovi o razlikama aritmetičkih sredina dobrih i loših poduzeća po pojedinim grupama industrija. Usporedba pokazatelja i njihova interpretacija po svim grupama industrija navedena je u Pravitku 1.

Analiza korelacije

Kako bi se utvrdila karakteristika odnosa varijabli u modelu, postavljena je korelacijska matrica za utvrđivanje smjera i jačine kretanja pokazatelja uspješnosti. Korelacija je statistička povezanost dviju ili više varijabli. Korelacijskom analizom mjeri se stupanj jakosti statističkih veza, a normirani pokazatelji korelacije su koeficijenti korelacije. Ako se između dviju varijabli pretpostavlja postojanje linearne statističke veze, tada se jakost i smjer veze mjeri koeficijentom linearne korelacije r ($-1 \leq r \leq 1$).

Promatrane varijable su pozitivno korelirane ako je porast jedne praćen porastom druge i obratno, a negativno korelirane ako se varijable ne mijenjaju u istom smjeru. Korelacija (pozitivna, negativna) je to jača što je r bliži 1. Među promatranim varijablama postoji negativna, odnosno pozitivna funkcionalna (egzaktna, deterministička) veza ako je $r=-1$ ili $r=1$, a ako je $r=0$ promatrane su varijable međusobno nekorelirane. U nastavku je prikazana korelacijska matrica za Altmanov Z'-score pokazatelj, Ohlsonov i Zmijewski pokazatelje koja sadrži koeficijente linearne korelacije između parova varijabli.

Tablica 6. Korelacijska matrica komponenata pokazatelja uspješnosti Altman Z'-score-a i Altman Z'-score-a kroz promatrano razdoblje između dobrih i loših poduzeća.

Kriterij		Z (2010)	Z (2011)	Z (2012)	Z (2013)	Z (2014)	Z (2015)
Dobra poduzeća	X1	0,403**	0,397**	0,364**	0,374**	0,394**	0,381**
	X2	0,300**	0,321**	0,282**	0,271**	0,264**	0,280**
	X3	0,324**	0,368**	0,354**	0,353**	0,383**	0,335**
	X4	0,496**	0,556**	0,561**	0,626**	0,580**	0,577**
	X5	0,432**	0,484**	0,514**	0,455**	0,443**	0,381**
Loša poduzeća	X1	0,225**	0,253**	0,310**	0,382**	0,370**	0,459**
	X2	0,247**	0,329**	0,289**	0,300**	0,260**	0,219**
	X3	0,110**	0,200**	0,251**	0,291**	0,314**	0,335**
	X4	0,424**	0,531**	0,542**	0,521**	0,552**	0,349**
	X5	0,571**	0,533**	0,466**	0,434**	0,432**	0,397**

** $p < 0,01$; * $p < 0,05$

Analizirani pokazatelji:

1. X1 – radni kapital/ukupna imovina

Kod poduzeća s dobrim Altman pokazateljima, varijabla X1 (radni kapital/ukupna imovina) najjače je korelirala s ukupnim Z'-scoreom u prvom razdoblju. Koeficijent korelacije između X1 i Z'-scorea u prvom razdoblju slab je po čvrstoći, a pozitivan po smjeru ($r=0,40$; $p<0,01$). U trećem razdoblju (2012.) koeficijent korelacije između X1 i Z'-scorea bio je najslabije izražen ($r=0,36$; $p<0,01$). Kod poduzeća s lošim Altman pokazateljima, varijabla X1 najjače je korelirala s ukupnim Z'-scoreom u zadnjem razdoblju. Koeficijent korelacije umjeren je po čvrstoći, a pozitivan po smjeru. U prvom razdoblju koeficijent korelacije između X1 i Z'-scorea bio je najslabije izražen ($r=0,23$; $p<0,01$).

2. X2 – zadržana dobit/ukupna imovina

Pokazatelj X2 s Altmanovim pokazateljem uspješnosti kroz promatrana razdoblja korelira u domeni od 0,26 (2014.) do 0,32 (2011.) kod dobrih poduzeća. Najviši koeficijent korelacije zabilježen je 2011., te je po smjeru pozitivan, a po čvrstoći slab te se može zaključiti da s porastom omjera zadržane dobiti i ukupne imovine, raste i sam Altman Z'-score ($r=0,32$). X2 pokazatelj s Altmanovim pokazateljem uspješnosti kod loših korelira u domeni od 0,22 (2015.) do 0,33 (2011.), po smjeru pozitivan, a po čvrstoći slab te se može zaključiti da s porastom omjera zadržane dobiti i ukupne imovine, raste i sam Altman Z'-score ($r=0,32$, $p<0,01$).

3. X3 – EBIT/ukupna imovina

Kod povezanosti omjera EBIT i ukupne imovine i ukupnog Altman Z'-scorea uočavaju se koeficijenti korelacije između 0,32 i 0,38 kod dobrih poduzeća. Najniži koeficijent korelacije između promatranih varijabli zabilježen je 2010. godine. Taj je koeficijent korelacije po smjeru pozitivan, a po čvrstoći slab ($r=0,32$; $p<0,01$). Koeficijent korelacije između prethodno navedenih varijabli najčvršći je bio 2015., te se može zaključiti da se s povećanjem odnosa EBIT i ukupne imovine u zadnjoj godini najtočnije može predvidjeti kretanje ukupnog

Altman Z'-scorea. Pri lošim poduzećima, uočavaju se koeficijenti korelacije između 0,11 i 0,34.

4. X4 – knjigovodstvena vrijednost kapitala/knjigovodstvena vrijednost obveza
Koeficijent korelacije između odnosa knjigovodstvene vrijednosti kapitala i knjigovodstvene vrijednosti obveza i Altmanovog Z'-scorea najjače su od svih varijabli prema koeficijentima povezanosti. Koeficijenti korelacija u odnosu između ovih varijabli kreću se u domeni od 0,5 do 0,63 te se povećanjem odnosa knjigovodstvene vrijednosti kapitala i knjigovodstvene vrijednosti obveza u najvišem omjeru može predvidjeti kretanje Altmanova Z'-scorea. Koeficijent korelacije između X4 i Altmanovog Z'-scorea najjači su od svih varijabli prema koeficijentima povezanosti i kod loših poduzeća.

5. X5 – ukupan prihod od prodaje/ukupna imovina
Varijabla X5 statistički značajno korelira s Altmanovim Z'-scoreom kod dobrih poduzeća. Najniže zabilježen koeficijent korelacije zabilježen je u zadnjem razdoblju, te je po smjeru pozitivan, a po čvrstoći slab, dok je najviše zabilježena vrijednost bila 2013. godine. Može se zaključiti da će povećanje koeficijenta odnosa ukupnih prihoda od prodaje i ukupne imovine uzrokovati najviši rast Altmanovog Z'-scorea. Kod loših poduzeća ova varijabla također statistički značajno korelira s Altmanovim Z'-scoreom u svim promatranim razdobljima.

Zaključno, varijable „knjigovodstvena vrijednost kapitala / knjigovodstvena vrijednost obveza“ te „ukupan prihod od prodaje / ukupna imovina“ statistički najznačajnije koreliraju s Altmanovim Z'-scoreom kod dobrih i loših poduzeća. Korelacija je pozitivna što znači da će povećanje ili smanjenje varijabli najviše utjecati na rast ili pad Altmanovog Z'-score-a.

Tablica 7. Korelacijska matrica komponenata Ohlsonovih pokazatelja uspješnosti i Ohlsonovog pokazatelja uspješnosti kroz promatrano razdoblje između dobrih i loših poduzeća

Kriterij		O (2011)	O (2012)	O (2013)	O (2014)	O (2015)
Dobra poduzeća	X1	-0,069*	-0,114**	-0,097**	-0,086**	-0,094**
	X2	0,800**	0,857**	0,859**	0,835**	0,796**
	X3	-0,588**	-0,592**	-0,632**	-0,652**	-0,614**
	X4	0,528**	0,548**	0,588**	0,587**	0,548**
	X5	0,137**	0,138**	0,135**	0,131**	0,108**
	X6	-0,145**	-0,123**	-0,180**	-0,238**	-0,261**
	X7	-0,292**	-0,319**	-0,320**	-0,315**	-0,300**
	X8	-0,064*	-0,073*	-0,05	-0,03	-0,03
	X9	0,118**	0,104**	0,090**	0,04	-0,04
Loša poduzeća	X1	-0,253**	-0,217**	-0,211**	-0,227**	-0,205**
	X2	0,446**	0,469**	0,483**	0,479**	0,472**
	X3	-0,361**	-0,401**	-0,404**	-0,380**	-0,394**
	X4	0,160**	0,181**	0,192**	0,183**	0,186**
	X5	0,435**	0,454**	0,487**	0,499**	0,475**
	X6	-0,131**	-0,145**	-0,125**	-0,154**	-0,174**
	X7	-0,208**	-0,237**	-0,281**	-0,292**	-0,297**
	X8	-0,07	-0,097*	-0,06	-0,02	-0,04
	X9	0,082*	0,133**	0,152**	0,164**	0,116**

** $p < 0,01$; * $p < 0,05$

Analizirani pokazatelji:

1. X1 – Logaritam ukupne imovine na BDP

Kod dobrih poduzeća, varijabla X1 najjače je korelirala s ukupnim Ohlsonovim pokazateljem u drugom razdoblju. Koeficijent korelacije između X1 i Ohlsonovog pokazatelja u drugom razdoblju slab je po čvrstoći, a negativan po smjeru ($r = -0,11$; $p < 0,01$). U prvom razdoblju (2011.) koeficijent korelacije između X1 i Ohlsonovog pokazatelja bio je najslabije izražen ($r = -0,07$; $p < 0,05$). Preostali koeficijenti korelacije između X1 i Ohlsonovog pokazatelja kretali su se u vrijednosti oko -0,09 te su svi statistički značajni na razini signifikantnosti od 1% ili 5%.

Kod loših poduzeća, varijabla X1 najjače je korelirala s ukupnim Ohlson pokazateljem 2011. godine. Koeficijent korelacije između X1 i Ohlson pokazatelja u prvom razdoblju slab je po čvrstoći, a negativan po smjeru ($r=-0,25$; $p<0,01$).

2. X2 – Ukupne obveze/ukupna imovina

U uzorku dobrih poduzeća, varijabla X2 najjače je korelirala s ukupnim Ohlson pokazateljem u trećem razdoblju. Koeficijent korelacije između X2 i Ohlson pokazatelja u trećem razdoblju jak je po čvrstoći, a pozitivan po smjeru ($r=0,86$; $p<0,01$). Kod loših poduzeća, varijabla X2 najjače je korelirala s ukupnim Ohlson pokazateljem 2013. godine ($r=0,48$, $p<0,01$), iako se svih godina korelacija kretala oko 0,4.

3. X3 – Radni kapital/ukupna imovina

U uzorku dobrih poduzeća, varijabla X3 najjače je korelirala s ukupnim Ohlson pokazateljem 2014. godine, u vrijednosti od $r=-0,65$, koeficijent negativan po smjeru. U prvom razdoblju (2011.) koeficijent korelacije između X3 i Ohlson pokazatelja bio je najslabije izražen ($r=-0,59$; $p<0,01$). Preostali koeficijenti korelacija između X3 i Ohlsona kretali su se u vrijednostima oko -0,6 te su svi statistički značajni na razini signifikantnosti od 1%. Kod loših poduzeća, varijabla X3 najjače je korelirala s ukupnim Ohlson pokazateljem 2013. godine ($r=-0,4$, $p<0,01$).

4. X4 – Kratkoročne obveze/kratkotrajna imovina

U uzorku dobrih poduzeća, varijabla X4 najjače je korelirala s ukupnim Ohlson pokazateljem u trećem razdoblju ($r=0,59$; $p<0,01$). Kod loših poduzeća, varijabla X4 najjače je korelirala s ukupnim Ohlson pokazateljem 2013. godine ($r=0,19$, $p<0,01$), iako je svih godina korelacija bila slaba i kretala se oko 0,1.

5. X5 – Dummy; ukoliko su ukupne obveze veće od ukupne imovine=1, i obrnuto=0

Dummy varijabla je, u uzorku dobrih poduzeća, statistički značajno korelirala sa Ohlsonovim pokazateljem, ali je koeficijent korelacije slab i kreće se od 0,10 u 2015. do 0,13 u prethodnim godinama. Kod loših poduzeća varijabla X5 je korelirala sa Ohlsonovim pokazateljem jače nego kod dobrih poduzeća s pozitivnim smjerom.

6. X6 – Neto dobit/ukupna imovina

U uzorku dobrih poduzeća, varijabla X6 najjače je korelirala s ukupnim Ohlson pokazateljem u posljednjem razdoblju. Koeficijent korelacije između X6 i Ohlson pokazatelja u posljednjem razdoblju slab je po čvrstoći, a negativan po smjeru ($r=-0,26$; $p<0,01$). Kod loših poduzeća, varijabla X6 najjače je korelirala s ukupnim Ohlson pokazateljem 2015. iako je svih godina korelacija bila slaba.

7. X7 – NT od poslovnih aktivnosti/ukupne obveze

U uzorku dobrih poduzeća, varijabla X7 najjače je korelirala s ukupnim Ohlson pokazateljem 2013, a kod loših 2015. godine. Koeficijent korelacije između X7 i Ohlson pokazatelja u trećem razdoblju slab je po čvrstoći, a negativan po smjeru

8. X8 – Dummy; Neto dobit negativna kroz posljednje dvije godine=1 i obrnuto=0

Dummy varijabla je, u uzorku dobrih poduzeća, statistički značajno korelirala sa Ohlsonovim pokazateljem samo u prve dvije godine, a kod loših samo 2012. Koeficijent korelacije je slab. a u ostalim godinama koeficijent korelacije nije statistički značajan.

9. X9 – $(NIt - NIt-1)/(|NIt| + NIt-1)$

U uzorku dobrih poduzeća, varijabla X9 statistički je značajno korelirala s Ohlsonovim pokazateljem u prve tri godine u slabim vrijednostima od oko 0,1. Kod loših poduzeća, varijabla X9 najjače je korelirala s ukupnim Ohlson pokazateljem 2014. ($r=0,16$, $p<0,01$), iako je svih godina korelacija bila slaba.

Zaključno, varijable „ukupne obveze / ukupna imovina“ i „kratkoročne obveze / kratkotrajna imovina“ statistički najznačajnije pozitivno koreliraju s Ohlsonovim score-om kod dobrih poduzeća. Povećanje ili smanjenje varijabli najviše će utjecati na rast (povećanje rizika) ili pad (smanjenje rizika) Ohlsonovog score-a. Varijabla „radni kapital / ukupna imovina“ statistički značajno korelira sa Ohlsonovim score-om i kod dobrih i kod loših poduzeća, ali s negativnim predznakom, što znači da smanjenje tog pokazatelja utječe na rast Ohlsonovog score-a pokazatelja tj. povećanje rizika od stečaja.

Tablica 8. Korelacijska matrica komponenata Zmijewski pokazatelja uspješnosti i Zmijewski pokazatelja uspješnosti kroz promatrano razdoblje između dobrih i loših poduzeća

Kriterij		ZM (2010)	ZM (2011)	ZM (2012)	ZM (2013)	ZM (2014)	ZM (2015)
Dobra poduzeća	X1	-0,374**	-0,395**	-0,372**	-0,447**	-0,480**	-0,466**
	X2	0,803**	0,863**	0,884**	0,873**	0,840**	0,777**
	X3	-0,461**	-0,484**	-0,460**	-0,479**	-0,485**	-0,453**
Loša poduzeća	X1	-0,200**	-0,362**	-0,420**	-0,440**	-0,627**	-0,710**
	X2	0,644**	0,746**	0,792**	0,759**	0,768**	0,743**
	X3	0,01	0	0,01	-0,01	0,01	0

** $p < 0,01$; * $p < 0,05$

Analizirani pokazatelji:

1. X1 – Neto dobit/ukupna imovina

Kod dobrih poduzeća, varijabla X1 najjače je korelirala s ukupnim Zmijewski pokazateljem u četvrtom razdoblju pri čemu je koeficijent korelacije slab po čvrstoći, a negativan po smjeru ($r = -0,48$; $p < 0,01$). Kod loših poduzeća, varijabla X1 najjače je korelirala s ukupnim Zmijewski pokazateljem u posljednjem razdoblju, a koeficijent korelacije je jak po čvrstoći, a negativan po smjeru.

2. X2 – Ukupne obveze/ukupna imovina

Kod dobrih i loših poduzeća, varijabla X2 najjače je korelirala s ukupnim Zmijewski pokazateljem 2012. godine pri čemu je koeficijent korelacije jak po čvrstoći, a pozitivan po smjeru.

3. X3 – Kratkotrajna imovina/kratkoročne obveze

Kod dobrih poduzeća, varijabla X3 najjače je korelirala s ukupnim Zmijewski pokazateljem u četvrtom razdoblju pri čemu je koeficijent korelacije slab po čvrstoći, a negativan po smjeru ($r=-0,48$; $p<0,01$). Kod loših poduzeća, varijabla X3 nije statistički značajno korelirala s ukupnim Zmijewski pokazateljem.

Zaključno, varijabla „ukupne obveze / ukupna imovina“ najznačajnije statistički korelira sa Zmijewski score-om kod dobrih i loših poduzeća. Korelacija je pozitivna što znači da će povećanje ili smanjenje odnosa obveza i imovine najviše utjecati na rast (rast rizika od stečaja) ili pad (smanjenje rizika od stečaja) Zmijewski score-a. Varijabla „kratkotrajna imovina / kratkoročne obveze“ također statistički značajno korelira kod dobrih poduzeća, ali je smjer negativan, što znači da će pogoršanje varijable utjecati na povećanje Zmijewski score-a tj. porast rizika od stečaja.

Analiza pogreške tipa 1 i 2

U sljedećoj tablici prikazani su rezultati dobivenim primjenom Altmanovog modela na cijelom uzorku od 1.796 poduzeća, a tablica se sastoji od dva dijela. U prvom dijelu tablice prikazana je podjela poduzeća, prema izračunatom Z'-score-u, na: neuspješna, sumnjiva (siva zona) i uspješna, u svim godinama za koje su bili raspoloživi financijski izvještaji u usporedbi sa stvarnim stanjem poduzeća (uspješna i neuspješna) te izračunatim ocjenama točnosti tipa 1 i 2. U desnom dijelu tablice prikazani su pokazatelji Pogreška tipa 1 i Pogreška tipa 2 modela:

1. Pogreška Tipa 1 se definira kao broj poduzeća koja loše posluju, a netočno su klasificirana kao poduzeća koja pozitivno posluju u odnosu na ukupan broj poduzeća u uzorku
2. Pogreška Tipa 2 se definira kao broj poduzeća koja pozitivno posluju, a netočno su klasificirana kao poduzeća koja negativno posluju u odnosu na ukupan broj poduzeća u uzorku

Pogreške tipa 1 i tipa 2 izračunate su za svih 1.796 poduzeća. Podaci su razmatrani za sve godine poslovanja poduzeća uključene u uzorak, pri čemu T1 predstavlja prvu godinu promatranja, odnosno 2010. godinu, a T6 posljednju godinu, odnosno 2015. godinu.

Kao što je prikazano u tablici 9. ocjena točnosti tipa 1 Altmanovog modela iznosi 57% za prvu, 54% za drugu, 53% za treću, četvrtu i petu i 52% za šestu godinu prije promatranja poslovanja poduzeća. Ocjena točnosti tipa 2 je iznosila samo 46% za prvu, 44% za drugu, 41% za treću, 37% za četvrtu, 40% za petu i 41% za šestu godinu. Dodatno, ukupna ocjena učinkovitosti je iznosila 85%, 86%, 83%, 79%, 81% i 79% od prve do šeste godine. Pogreška tipa 1 Altmanovog modela iznosila je 17% za prvu godinu te 16% od druge do šeste godine prije promatranja poslovanja, a Pogreška tipa 2 je iznosila 4%, 3%, 6%, 8%, 8%, te 9% od prve do šeste godine.

Ostvareni rezultati su donekle u skladu s originalnim Altmanovim rezultatima, s jednom iznimkom. Pogreške tipa 1 su nešto više nego u originalnoj studiji, a te pogreške mogu, u najvećem broju slučajeva, rezultirati stvarnim gubicima za investitore, financijske institucije i druge zainteresirane skupine. Pogreške tipa 2 najčešće rezultiraju propuštenim prilikama: investitori mogu izgubiti priliku za dobrom investicijom, financijske institucije priliku za odobravanjem kvalitetnih kredita klijentima s dobrim ratingom, a prodavači priliku da prodaju proizvode. Istraživači su procijenili da Pogreške tipa 1 su od 2 do 20 puta značajnije od Pogrešaka tipa 2 iz razloga što su troškovi Pogreške tipa 1 puno viši od Pogreške tipa 2 (Branson, Alareeni, 2013.).

Tablica 9. Izračun Pogreške tipa 1 i 2 Altmanovog Z'-score pokazatelja na uzorku hrvatskih poduzeća

Godina	Stvarno stanje poduzeća	Klasifikacija prema Altman z'modelu (1983.)						Pogreške Tipa 1 i 2			
		z < 1,23		1,23 < z > 2,90		z > 2,90		Pogreška Tipa 1		Pogreška tipa 2	
		Neuspješno		Siva zona		Uspješno					
T1	Neuspješna poduzeća	360	52%	217	31%	113	16%	113	16%	97	9%
	Uspješna poduzeća	97	9%	557	50%	452	41%				
	Ukupno točno klasificiranih	79%									
T2	Neuspješna poduzeća	366	53%	211	31%	113	16%	113	16%	83	8%
	Uspješna poduzeća	83	8%	579	52%	444	40%				
	Ukupno točno klasificiranih	81%									
T3	Neuspješna poduzeća	367	53%	212	31%	111	16%	111	16%	91	8%
	Uspješna poduzeća	91	8%	605	55%	410	37%				
	Ukupno točno klasificiranih	79%									
T4	Neuspješna poduzeća	367	53%	214	31%	109	16%	109	16%	62	6%
	Uspješna poduzeća	62	6%	596	54%	448	41%				
	Ukupno točno klasificiranih	83%									
T5	Neuspješna poduzeća	376	54%	204	30%	110	16%	110	16%	33	3%
	Uspješna poduzeća	33	3%	588	53%	485	44%				
	Ukupno točno klasificiranih	86%									
T6	Neuspješna poduzeća	391	57%	182	26%	117	17%	117	17%	45	4%
	Uspješna poduzeća	45	4%	553	50%	508	46%				
	Ukupno točno klasificiranih	85%									

U sljedećoj tablici 10. prikazani su rezultati dobiveni primjenom Ohlsonovog modela na cijelom uzorku. Tablica ima istu strukturu kao i prethodna, osim što promatranja počinju od 2011. godine. Prema rezultatima ocjena točnosti tipa 1 Ohlsonovog modela iznosi 73% za prvu, 72% za drugu i treću, 73% za četvrtu i 71% za petu godinu prije promatranja poslovanja poduzeća. Ocjena točnosti tipa 2 je iznosila samo 57% za prvu, 55% za drugu, 47% za treću, 42% za četvrtu i 44% za petu godinu.

Dodatno, ukupna ocjena učinkovitosti je iznosila 63%, 62%, 57%, 54%, 55% od prve do pete godine. Pogreška tipa 1 Ohlsonovog modela znatno je viša od Altmanovog modela i iznosila je 27% za prvu godinu te 28% za drugu i treću godinu, 27% za četvrtu i 29% za petu godinu prije promatranja poslovanja, a Pogreška tipa 2 je iznosila 43%, 45%, 53%, 58% te 56% od prve do pete godine.

Tablica 10. Izračun Pogreške tipa 1 i 2 Ohlsonovog O-score pokazatelja na uzorku hrvatskih poduzeća

Godina	Stvarno stanje poduzeća	Klasifikacija prema Ohlson modelu				Pogreške Tipa 1 i 2			
		O > 0,5		O < 0,5		Pogreška Tipa 1		Pogreška tipa 2	
		Neuspješno	Uspješno						
T2	Neuspješna poduzeća	490	71%	200	29%	200	29%	615	56%
	Uspješna poduzeća	615	56%	491	44%				
	Ukupno točno klasificiranih	55%							
T3	Neuspješna poduzeća	503	73%	187	27%	187	27%	642	58%
	Uspješna poduzeća	642	58%	464	42%				
	Ukupno točno klasificiranih	54%							
T4	Neuspješna poduzeća	498	72%	192	28%	192	28%	588	53%
	Uspješna poduzeća	588	53%	518	47%				
	Ukupno točno klasificiranih	57%							
T5	Neuspješna poduzeća	494	72%	196	28%	196	28%	493	45%
	Uspješna poduzeća	493	45%	613	55%				
	Ukupno točno klasificiranih	62%							
T6	Neuspješna poduzeća	507	73%	183	27%	183	27%	477	43%
	Uspješna poduzeća	477	43%	629	57%				
	Ukupno točno klasificiranih	63%							

Visoke Pogreške tipa 1 i tipa 2 ukazuju na manju točnost u odnosu na Altmanov model i oprez pri korištenju modela u ocjeni poslovanja poduzeća.

U sljedećoj tablici prikazani su rezultati dobiveni primjenom Zmijewski modela na cijelom uzorku s istom strukturom kao i u prethodne dvije tablice.

Prema rezultatima ocjena točnosti tipa 1 Zmijewski modela iznosi 61% za prvu, 54% za drugu, 53% za treću, 51% za četvrtu, 47% za petu godinu i 44% za šestu godinu prije promatranja poslovanja poduzeća. Ocjena točnosti tipa 2 iznosila je visokih 95% za prvu, 94% za drugu, 92% za treću, 86% za četvrtu, 88% za petu i 89% za šestu godinu. Dodatno, ukupna ocjena učinkovitosti je iznosila 82%, 79%, 77%, 73%, 72% i 71% od prve do šeste godine. Pogreška tipa 1 Zmijewski modela iznosila je 39% za prvu godinu te 46% za drugu, 47% za treću godinu, 49% za četvrtu, 53% za petu i 56% za šestu godinu prije promatranja poslovanja, a Pogreška tipa 2 je iznosila 5%, 6%, 8%, 14%, 12% te 11% od prve do šeste godine.

Tablica 11. Izračun Pogreške tipa 1 i 2 Zmijewski pokazatelja na uzorku hrvatskih poduzeća

Godina	Stvarno stanje poduzeća	Klasifikacija prema Zmijewski modelu				Pogreške Tipa 1 i 2			
		$z > 0,5$		$z < 0,5$		Pogreška Tipa 1		Pogreška tipa 2	
		Neuspješno	Uspješno						
T1	Neuspješna poduzeća	302	44%	388	56%	388	56%	124	11%
	Uspješna poduzeća	124	11%	982	89%				
	Ukupno točno klasificiranih	71%							
T2	Neuspješna poduzeća	326	47%	364	53%	364	53%	137	12%
	Uspješna poduzeća	137	12%	969	88%				
	Ukupno točno klasificiranih	72%							
T3	Neuspješna poduzeća	353	51%	337	49%	337	49%	151	14%
	Uspješna poduzeća	151	14%	955	86%				
	Ukupno točno klasificiranih	73%							
T4	Neuspješna poduzeća	368	53%	322	47%	322	47%	94	8%
	Uspješna poduzeća	94	8%	1012	92%				
	Ukupno točno klasificiranih	77%							
T5	Neuspješna poduzeća	376	54%	314	46%	314	46%	61	6%
	Uspješna poduzeća	61	6%	1045	94%				
	Ukupno točno klasificiranih	79%							
T6	Neuspješna poduzeća	419	61%	271	39%	271	39%	53	5%
	Uspješna poduzeća	53	5%	1053	95%				
	Ukupno točno klasificiranih	82%							

Pogreške tipa 1 i 2 više su kod Zmijewskog nego kod Altmana, ali niže nego kod Ohlsona što ukazuje na bolju točnost modela od Ohlsonovog modela, a nižu točnosti u odnosu na Altmanov model.

4.4. Usporedba rezultata učinkovitosti modela

U radu je postavljena hipoteza H1 koja glasi: „Altmanov Z'-score model, Zmijewski model i Ohlson model, temeljeni na kvantitativnim financijskim pokazateljima, su učinkoviti u predviđanju nastavka poslovanja poduzeća u dosadašnjim makroekonomskim uvjetima u Hrvatskoj koji su omogućavali da poduzeća unatoč svojim lošim rezultatima i dalje posluju“.

Ovim prvim empirijskim istraživanjem u radu potvrdila se prva pomoćna hipoteza temeljem sljedećih dokaza:

- rezultati statističkih testova opisne statistike kojima su se uspoređivala oba uzorka poduzeća po sve tri metode izračuna (Altman, Ohlson i Zmijewski) u razdoblju od 2010. – 2015. godine upućuju na značajne statističke razlike između dobrih i loših poduzeća u svim razdobljima i po svim metodologijama, što je potvrđeno pokazateljima standardne pogreške,
- dobra i loša poduzeća u prosjeku se statistički značajno razlikuju u vrijednostima svih pokazatelja i svim razdobljima na razini signifikantnosti od 1%,
- skraćivanjem vremenskog perioda u odnosu na finalni rezultat poslovanja poduzeća, standardna devijacija pokazatelja se smanjuje čime se potvrđuje bolja reprezentativnost prosječne vrijednosti uzorka po godinama i učinkovitost modela,
- Pogreške tipa 1 i tipa 2 sva tri modela su prihvatljive, a ukupne ocjene učinkovitosti visoke (Altman i Zmijewski oko 80%, Ohlson iznad 60%).

Također, ovim dijelom empirijskog istraživanja htjela se opovrgnuti ili potvrditi i druga pomoćna hipoteza H2 koja glasi: „*Postoji razlika u učinkovitosti svojstava predviđanja Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela u hrvatskom gospodarstvu*“.

Druga pomoćna hipoteza potvrđena je temeljem sljedećih dokaza:

- istraživanje je pokazalo da su Altman Z'-score vrijednosti imale najtočnije rezultate i ocjene ukupne učinkovitosti, zatim Zmijewski vrijednosti, dok je Ohlsonov model rezultirao najlošijim prognozama iako još uvijek prihvatljivim s obzirom na vrijednosti Pogrešaka tipa 1 i tipa 2,

- analiza je potvrdila učinkovitost Z'-score pokazatelja u prognozi poslovanja dobrih poduzeća, posebno u razdoblju od dvije godine prije nastupanja poslovnog događaja, dok je slabija za prognozu loših poduzeća,
- sve godine istraživanja Ohlsonovog pokazatelja, uzorak poduzeća prati niska standardna devijacija što upućuje na reprezentativnost uzorka, ali učinkovitost prognoze Ohlson pokazatelja može se smatrati prihvatljivom u razdoblju od jedne godine prije nastupanja poslovnog događaja,
- Zmijewski pokazatelj učinkovit je u prognozi poslovanja poduzeća i četiri godine prije nastupanja poslovnog događaja uz ograničenje zbog visoke standardne devijacije uzorka.

Osim razlika u učinkovitosti modela, vrijednosti pokazatelja se razlikuju i prema industrijama u kojima se računaju. Najbolje procjene, modeli su ostvarili u industrijskim granama: trgovina, prijevoz, skladištenje, građevina, gdje su u svim razdobljima i svim metodologijama izračuna pokazatelja uspješnosti bile ostvarene značajne razlike između dobrih i loših poduzeća.

Rezultati matrica korelacije, odnosno varijable s najvišim stupnjem korelacije sa samim pokazateljem korišteni su u odabiru najreprezentativnijih varijabli u kreiranju novog modela temeljem statističke metode umjetnih neuronskih mreža.

5. EMPIRIJSKO ISTRAŽIVANJE: IZRADA SUVREMENOG MODELA PREDVIĐANJA NASTAVKA POSLOVANJA PODUZEĆA

Jedno od osnovnih pitanja koje se postavlja glasi: da li financijska situacija i buduće poslovanje poduzeća pokazuju uzročno posljedični uzorak koji može biti identificiran i definiran, te, ako ima, može li isti biti diskriminacijski faktor među različitim kategorijama poduzeća? Prije razvoja kvantitativnih mjerenja poslovanja poduzeća, postojale su agencije za pružanje podataka kvalitativnog tipa o procjeni kreditne sposobnosti pojedinih trgovaca, npr. Dun & Bradstreet Inc. Agencija koja je bila osnovana 1849. godine za pružanje neovisnih kreditnih istraživanja i procjena (Altman, 2002.). No, iako su početkom prošlog stoljeća, agencije za ocjenu poslovanja poduzeća uglavnom koristile samo opisne pokazatelje, u današnje vrijeme je prihvaćena činjenica da financijski pokazatelji imaju prediktivni potencijal u procjeni financijskog poslovanja i nastavka poslovanja poduzeća.

Predviđanjima i procjenama nastavka poslovanja dominirale su linearne metode brojnim desetljećima. Linearna metoda se jednostavno razvija i implementira, te jednako lako interpretira i razumije. No, kao što je nekoliko puta u radu navedeno, linearne metode posjeduju ozbiljna ograničenja u obradi nelinearnih odnosa među podacima i njihova primjena na komplicirane nelinearne odnose nije uvijek zadovoljavajuća.

Umjetne neuronske mreže su matematički model i računalni sistem inspiriran strukturom, organizacijom, metodom obrade i sposobnošću učenja ljudskog mozga (Prema Osman, 2015.). Umjetne neuronske mreže su simulacija biološkog mozga s ciljem da nauče prepoznavati uzorke ponašanja i odnose u podacima. Jednom kada je neuronska mreža istrenirana na uzorku podataka, ona može izvršiti predviđanja pronalaženjem sličnih uzorka ponašanja u budućim podacima.

U ovom poglavlju definira se razvoj modela, u skladu s ciljevima rada, koji osigurava procjenu nastavka poslovanja poduzeća.

Ovaj pristup je okarakteriziran trima svojstvima koji model razlikuje od trenutno aktualnih u literaturi, posebno domaćoj:

1. zavisna binarna varijabla ovisi o nastavku poslovanja poduzeća
2. odabir opisnih varijabli se temelji na tri izvora: financijskoj teoriji, iskustvima istraživača i prethodnim istraživanjima, te bankarskoj praksi
3. model se temelji na suvremenoj statističkoj metodi umjetnih neuronskih mreža za razliku od većine modela koji se temelje samo na regresiji.

5.1. Teorijski prikaz metode umjetnih neuronskih mreža

Mogućnost ljudskog mozga za provođenjem kompleksnih zadataka, kao što su prepoznavanje uzorka, motivirala je veliki broj istraživača i potaknula istraživanja o računalnim mogućnostima intenzivno povezanih mreža relativno jednostavnih elementa. Kao rezultat takvih istraživanja razvijene su umjetne neuronske mreže (engl. Artificial neural networks ili ANNs) kao set algoritama inspirirane arhitekturom ljudskog mozga i mogućnostima paralelnog procesiranja podataka. Umjetne neuronske mreže se ubrajaju u metode umjetne inteligencije i predstavljaju matematičko-statistički model koji se temelji na biološkim neuronskim mrežama. Iako su umjetne neuronske mreže inicijalno razvijene kako bi se bolje razumjele funkcije mozga kod sisavaca, u zadnjih godina se istraživači u raznim znanstvenim disciplinama (osim u ekonomiji, također i u biologiji, medicini, psihologiji, ekologiji) bave potencijalnom matematičkom mogućnosti algoritama umjetnih neuronskih mreža pri rješavanju velikog raspona problema (Olden et al, 2004.). One se često koriste za rješavanje problema identifikacije, asocijacije, klasifikacije i predviđanja (Šarlija, 2002.).

Umjetne neuronske mreže se smatraju petim računalnim programskim jezikom, a njihovim idejnim začetnikom može se smatrati britanski matematičar Alan Turing koji je 1950. godine demonstrirao da računala i mašine mogu oponašati ljudsko zaključivanje oponašajući uzorke funkcija ljudskog mozga. Njegov je rad postavio osnove razvoja teorije umjetnih neuronskih mreža (Thevnin, 2003.). Umjetne neuronske mreže su u osnovi višestruke regresijske mašine koje imaju mogućnost


učenja iz primjera i ne zahtijevaju nikakvo prethodno znanje o problemu istraživanja. Klasifikacija podataka se može smatrati regresijskim problemom, odnosno može se razmatrati kao traženje funkcije koja mapira ulazne podatke u odgovarajuće klase i pri tome nastoji minimizirati udio krive klasifikacije. ANN imaju sposobnost unutarnje nelinearne regresije što ih čini izuzetno sposobnim za rješavanje teških klasifikacijskih problema (Neves, Vieira, 2006.). One predstavljaju način obrade seta ulaznih informacija i njihovih povezanih izlaznih rezultata (ili odgovora) na način da se približavaju uzorku koji na zadovoljavajući način reflektira sve ulazno-izlazne veze (Lacher et al, 1995.). Nastojeći simulirati mrežu neurona u mozgu, neuronska mreža oblikuje skupinu povezanih (umjetnih) neurona i informacijske procese među njima. Umjetne neuronske mreže su učinkovite u modeliranju kompleksnih, nelinearnih procesa gdje konvencionalne metode nisu upotrebljive ili imaju nedostatne rezultate, te postoje izrazito kompleksne veze između ulaznih i izlaznih podataka.

5.1.1. Struktura umjetnih neuronskih mreža

Da bi se razumjela struktura umjetnih neuronskih mreža, potrebno je poznavati građu biološkog neurona (živčane stanice). Ljudski mozak sastavljen je od oko 10^{11} neurona kojih ima više od 100 vrsta i koji su shodno svojoj funkciji raspoređeni prema točno definiranom rasporedu. Svaki je neuron u prosjeku povezan sa 104 drugih neurona. Četiri su osnovna dijela neurona: tijelo stanice, skup dendrita, aksona (dugačke cjevčice koje prenose električke poruke) i niza završnih članaka. Slika 2 prikazuje građu biološkog neurona.

Na sinapsama, spojnom sredstvu dvaju neurona kojim su pokriveni dendriti, primaju se informacije od drugih neurona u vidu post-sinaptičkog potencijala koji utječe na potencijal stanice povećavajući ili smanjujući ga. U tijelu stanice sumiraju se post-sinaptički potencijali susjednih neurona, u ovisnosti o vremenu dolaska ulaznih informacija. Ako ukupni napon pređe određeni prag, neuron "pali" i generira tzv. akcijski potencijal.

Slika 2. Građa biološkog neurona



Kada se informacija akcijskim potencijalom prenese do završnih članaka, onda oni, ovisno o veličini potencijala, proizvode i otpuštaju kemikalije, tzv. neurotransmitere. To zatim inicira niz opisanih događaja u daljnjim neuronima (autorica prilagodila prema Dalbello Bašić et al, 2008.).

Model umjetnih neuronskih mreža koristi sličnu analogiju. Signali su opisani numeričkim iznosom i na ulazu u neuron množe se težinskim faktorom (eng. weight) koji opisuje jakost sinapse, a signali pomnoženi težinskim faktorima zatim se sumiraju analogno sumiranju potencijala u tijelu stanice. Ukoliko je dobiveni iznos iznad definiranog praga (eng. treshold ili bias), neuron daje izlazni signal. Umjetni neuron umjesto funkcije praga može imati i neku drugu funkciju, tzv. prijenosnu funkciju (aktivacijsku funkciju).

Neuronska mreža se sastoji od međusobno povezanih procesnih jedinica tj. neurona raspoređenih u dva ili više slojeva (inter-slojne ili intra-slojne veze). Postoji više vrsta neurona, od jednostavnih do složenih. Prvi, najjednostavniji, umjetni neuroni zovu se **perceptroni**, no danas se koriste drugi umjetni neuroni od kojih je najpopularniji **sigmoidalni neuron**. Oni su spojeni u mrežu tako da izlaz svakog neurona čini ulaz u jedan ili više drugih neurona. Svaki neuron zaprima ulazne signale kojima se dodjeljuju


pripadajući ponderi tj. težinski faktor (eng. weight, w), a njihov zbroj predstavlja interno stanje neurona. Ulazni signali općenito su realni brojevi u intervalu $[-1, 1]$, $[0, 1]$.

Perceptroni funkcioniraju na način da neuron prima nekoliko binarnih inputa 0 ili 1, koji se mogu označiti kao x_1, x_2, x_3 , itd., i proizvodi binarni output na način da svaki input ima svoju težinu (eng. weight), koje se mogu označiti kao w_1, w_2, w_3 , itd., tj. stvarni broj koji predstavlja važnost određenog inputa na output. Output neurona (koji može biti 0 ili 1) je određen prema kriteriju da li je zbroj umnožaka inputa i težina veći od definirane vrijednosti praga (eng. treshold ili bias). Definirana vrijednost praga, bias, je stvarni broj (kao i težine) koji predstavlja parametar neurona. Matematički model perceptrona glasi:

$$\text{Output neurona} \begin{cases} 0 \text{ ako je } \sum_j w_j x_j \leq \text{definirane vrijednosti praga} \\ 1 \text{ ako je } \sum_j w_j x_j > \text{definirane vrijednosti praga} \end{cases}$$

Shematski prikaz neurona, perceptorna, je prikazan na slici 3.

Slika 3. Shematski prikaz perceptrona




Perceptron ne reprezentira u potpunosti model ljudskog donošenja odluka, ali pokazuje da davanjem različitih težina pojedinim inputima, perceptron može donijeti određeni zaključak, a kompleksna mreža perceptrona, prikazana na slici 4., može donijeti čak i zahtjevne zaključke.

U mreži na slici 4., prvi stupac perceptorna, odnosno prvi sloj (eng. layer), donosi tri vrlo jednostavne odluke dodjeljujući različite težine pojedinim inputima. Perceptroni u drugom sloju donose odluke dodjeljujući različitu težinu odlukama iz prvog sloja. Na taj način perceptorni iz drugog sloja mogu donositi sofisticiranije odluke nego iz prvog

sloja. Najsofisticiranije odluke se mogu donositi u trećem sloju, te na ovaj način multi-layer mreže mogu biti uključene u sofisticirane metode donošenja odluka.

Slika 4. Mreža perceptrona



Ukoliko se simplificira matematički model perceptrona i „definirana vrijednost“ se prebaci na lijevu stranu jednadžbe, te se definirana vrijednost praga označi sa „b“ (eng. bias), matematički model perceptrona izgleda kako slijedi:

$$\text{Output neurona} \begin{cases} 0 \text{ ako je } w \times x + b \leq 0 \\ 1 \text{ ako je } w \times x + b > 0 \end{cases}$$

Vrijednost b, prag ili bias, se može promatrati kao mjera koja je potrebna da output perceptrona bude 1, odnosno objašnjeno na primjeru biološkog neurona, da se neuron "pali" i generira tzv. akcijski potencijal. Prag je mjera koliko jednostavno perceptron može doseći iznos outputa 1. Perceptroni su metoda vaganja dokaza u donošenju odluka. Perceptroni se mogu koristiti za izračunavanje jednostavnih logičkih funkcija, a mreža perceptrona za izračunavanje bilo kojih logičkih funkcija.

Postavlja se pitanje kako naučiti mrežu perceptrona da riješi određeni problem, odnosno kako definirati mrežu da nauči težinu (eng. weight) i prag inputa na način da output mreže ispravno klasificira odnosno riješi određeni problem (primjerice ispravno klasificira skupinu pixela kao inputa u određeno slovo ili brojku). Mreža može ispravno riješiti problem, ako se svaki put prilikom promjene težine ili praga i output mreže promijeni za određenu deltu.

Ponavljajući taj postupak, dok se ne postignu odgovarajuće težine i bias da mreža može ispravno riješiti problem, mreža uči. Sam postupak učenja neuronske mreže biti će objašnjen u sljedećim poglavljima. No, ukoliko se radi o mreži perceptrona, mala promjena težine inputa ili biasa može dovesti do toga da se output značajno promijeni, odnosno da rezultira iznosom 0 ili 1. Takva reakcija outputa značajno otežava postepeno prilagođavanje mreže željenom ponašanju. Taj se problem riješio uvođenjem nove vrste umjetnog neurona po nazivom sigmoidalni neuron (eng. sigmoid neuron).

Sigmoidalni neuroni slični su perceptronima, ali modificirani na način da mala promjena težine inputa ili biasa, rezultira malom promjenom outputa. To je ključna karakteristika koja mreži takvih neurona omogućava učenje. Sigmoidalni neuroni izgledaju identično kao i perceptroni s inputima x_1, x_2, x_3 prikazano na slici 3. No, inputi, za razliku od perceptrona, mogu poprimiti bilo koju vrijednost između 0 i 1 (npr. 0,543). Inputi kod sigmoidalnog neurona također imaju težine w_1, w_2 , itd. (eng. weight) kao i kod perceptrona, te bias. No, output neurona nije 0 ili 1, već funkcija koja se naziva sigmoidalna funkcija i glasi:

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$


Funkcija s inputima x_1, x_2, x_3 , težinama w_1, w_2, w_3 i pragom ili biasom b , glasi:

$$\frac{1}{1 + \exp(-\sum wx - b)}$$

Iako na prvi pogled funkcije perceptrona i sigmoidalnog neurona ne izgledaju slično, u biti su prilično slične. Ukoliko je $z = w \times x - b$ veliki pozitivni broj, tada je $e^{-z} \sim 0$, a $\sigma(z) \sim 1$, odnosno output sigmoidalne funkcije je približno jednak 1 kao što je bio i kod perceptrona. Vrijedi i kada je $z = w \times x - b$ veliki negativni broj, sigmoidalni neuron se ponaša kao perceptron i iznosi približno 0. Jedino u slučaju kada je $w \times x - b$ umjerene veličine, postoji velika razlika između sigmoidalnog neurona i perceptrona.

Algebarski oblik sigmoidalne funkcije, prikazan na slici 5., dokazuje također kako sigmoidalni neuron predstavlja ublaženi oblik perceptrona. Glatkoća σ znači da male promjene u težini i biasu inputa rezultiraju malim promjenama u outputu. Output sigmoidalnog neurona nije samo 0 ili 1 kao kod perceptrona, već može biti bilo koji broj između 0 i 1.

Slika 5.: Sigmoidalna funkcija



Sigmoidalna funkcija ponekad se naziva i logističkom funkcijom, te se upotrebljava u mreži „širenja unatrag“ (eng. backpropagation). Sigmoidalna funkcija je prijenosna funkcija koja se primjenjuje na interno stanje rezultirajući izlaznim signalom. Izlaz neurona prema drugim neuronima s kojima je povezan se računa prema prijenosnoj funkciji. Osim sigmoidalne funkcije, prijenosna funkcija može biti bilo koja diskriminirajuća funkcija, od kojih se još često koriste funkcija skoka te linearna funkcija.


5.1.2. Arhitektura umjetnih neuronskih mreža

Neuronska mreža se sastoji od tri vrste slojeva: ulazni, skriveni i izlazni sloj. Ulazni sloj prima ulazne podatke, odnosno ulazne ili input neurone, i šalje ih u jedan ili više skrivenih slojeva u kojem se obrađuju informacije neurona i šalju u izlazne ili u output neurone u izlaznom sloju. Srednji sloj se zove skriveni sloj iz razloga što neuroni u tom sloju nisu niti input niti output mreže. Mreža može imati jedan ili više skrivenih slojeva,

a mreža s više skrivenih slojeva se zove duboka neuronska mreža (eng. deep neural network). Struktura mreže s jednim skrivenim slojem je prikazana na slici 6. Dizajn input i output slojeva u najvećem broju je jednostavan, ali je proces dizajniranja skrivenih slojeva zahtijevan.

Informacije putuju nazad kroz mrežu, a vrijednosti težina veza (snaga između dva neurona) između neurona se prilagođavaju izlaznom rezultatu. Proces se ponavlja u onoliko iteracija koliko je potrebno za dostizanje željenog izlaza. Neuron poprima onoliko ulaza koliko ima ulaznih veza, te proizvodi jedan izlaz prema prijenosnoj funkciji.

Slika 6. Pojednostavljeni prikaz arhitekture umjetne neuronske mreže



Rezultat dizajniranja neuronske mreže je arhitektura mreže, odnosno način na koji su neuroni međusobno organizirani i povezani u mreži određuju njezinu arhitekturu. Postoje četiri osnovne arhitekture:

1. Aciklička (engl. feedforward neural network) mreža → neuronska mreža u kojoj output jednog sloja input drugog sloja, bez povratnih veza između neurona pa

signali koji krenu od ulaznih neurona nakon određenog broja prijelaza dolaze do izlaza mreže.

2. Mreža s povratnom vezom (engl. recurrent neural network) → sadrže u svojoj strukturi barem jednu povratnu vezu, odnosno output jednog neurona može biti input tog neurona u različitom razdoblju, ali ne istovremeno.
3. Lateralno povezana mreža (rešetkasta)
4. Hibridna mreža

Mreže s povratnom vezom su manje značajne od acikličkih mreža zbog slabije snage njezinih algoritama, iako su sličnije načinu funkcioniranja ljudskog mozga od acikličkih. U nastavku rada će se obrađivati acikličke mreže zbog svoje široke primjene.

Nakon dizajniranja arhitekture mreže, potrebno je mrežu naučiti provoditi određene zadatke.

5.1.3. Postupak učenja umjetnih neuronskih mreža

Svaki neuron prilagođava svoje ulazno-izlazno ponašanje prema okruženju te se na taj način neuronske mreže mogu istrenirati za provođenje različitih zadataka (Lacher et al, 1995.). Upravo je najvažnija karakteristika umjetnih neuronskih mreža njihova sposobnost učenja. Učenje neuronskih mreža je proces kojim se dolazi do vrijednosti težina veza između neurona.

U slučaju kada se koriste složenije prijenosne funkcije, poput sigmoidalne, uobičajeno se definira arhitektura mreže, i prije postupka obrade podataka obavi postupak učenja ili treniranja. Za razliku od konvencionalnih tehnika obrade podataka gdje je postupak obrade potrebno analitički razložiti na određeni broj algoritamskih koraka, kod ovog tipa neuronskih mreža takav algoritam ne postoji. Znanje o obradi podataka, tj. znanje o izlazu kao funkciji ulaza, pohranjeno je implicitno u težinama veza između neurona. Te se težine postupno prilagođavaju kroz postupak učenja neuronske mreže sve do trenutka kada je izlaz iz mreže, provjeren na skupu podataka za testiranje, zadovoljavajući. Pod postupkom učenja kod neuronskih mreža podrazumijevamo

iterativan postupak predočavanja ulaznih primjera (uzoraka, iskustva) i eventualno očekivana izlaza.

Učenje neuronskih mreža može biti nadgledano ili slobodno (engl. supervised vs. unsupervised). Nadgledano učenje odvija se u situaciji kada je svakom inputu, u uzorku za učenje, dodijeljen pripadajući output tj. u postupku učenja *á priori* je poznat izlaz iz mreže, a slobodno učenje kada ne postoji *a priori* točan odgovor u uzorku za učenje. Važnosti inputa u nadgledanom učenju dodjeljuju se s obzirom na definirani output (prema A. Geitgay, 2017.).

Kako bi se neuronska mreža trenirala ispravno potrebna je znatna količina kvalitetnih primjera koji su reprezentativni i bez pogrešnih podataka, odnosno set podataka za treniranje. U slučaju problematike stečajeva, istraživači trebaju biti oprezni pri donošenju zaključaka prema treniranim mrežama na samo 100 ili 200 primjera. Klasificiranje višedimenzionalnih podataka je zahtijevan zadatak. Ukoliko je primjerice jedna procesna jedinica okarakterizirana s 10 varijabli, svaka jedinica se multiplicira sa 10, što rezultira sa 1010 mogućih konfiguracija, a to zahtijeva opsežno treniranje da bi se pokrilo tako veliko područje pretrage. No, ipak većina varijabli je korelirana i regresijska funkcija omogućuje da se razumna procjena može doseći s manje podataka. Skup primjera za učenje često se dijeli na tri odvojena skupa: skup za učenje, skup za testiranje i skup za provjeru (validaciju).

Osnovni cilj učenja ili treniranja mreže predstavlja pronalazak formule za prilagođavanje težina među neuronima, odnosno naći težine i biase mreže s kojima se minimizira suma kvadrata grešaka, odnosno razlike između izračunatog i stvarnog izlaza neurona za dane ulazne podatke. Taj se cilj može postići uz pomoć funkcije padajućeg gradijenta koja nalazi lokalni minimum funkcije tako što izvršava više koraka proporcionalnih negativnoj vrijednosti gradijenta odgovarajuće funkcije.

Funkcija padajućeg gradijenta, koja ima širu matematičku primjenu, računalno se sastavlja kroz algoritam backpropagation. Jedan od najčešćih računalnih programa koji se koristi za pisanje algoritma primjenom padajućeg gradijenta je Python, koji će se koristiti i u ovom radu.

5.1.4. BACKPROPAGATION algoritam

Najčešće korištene arhitekture umjetnih neuronskih mreža su višeslojne mreže s vezama unaprijed jer su vrlo dobre za probleme klasifikacije, a popularna i učinkovita metoda učenja takvih višeslojnih mreža je algoritam „backpropagation“, najpopularniji algoritam zbog svoje jednostavnosti.

Backpropagation algoritam je originalno osmišljen 1970. godine, ali njegova važnost nije bila prepoznata sve do 1986. godine i članka autora Rumelhart, Hinton, Williams koji opisuju nekoliko neuronskih mreža u kojima backpropagation funkcionira puno brže nego prijašnji pokušaji učenja, pri čemu je omogućio da umjetne neuronske mreže riješe probleme koji su do tada bili nerješivi. U današnje vrijeme backpropagation algoritam predstavlja osnovu učenja u neuronskim mrežama. Backpropagation nije samo brzi algoritam za učenje već objašnjava kako promjena težine (ili biasa) među neuronima mijenja sveukupno ponašanje mreže. (prema M. Nielsen, 2017.)

Backpropagation mreža se sastoji od ulaznog sloja, izlaznog i najmanje jednog skrivenog sloja, s vezom unaprijed. Ulazni sloj učitava podatke iz ulaznog vektora i šalje ih u prvi skriveni sloj. Jedinice u skrivenom sloju primaju vagani ulaz i prenose ga u sljedeći skriveni sloj ili izlazni sloj koristeći prijenosnu sigmoidalnu funkciju. Za svaku jedinicu obrade u izlaznom sloju treba se izračunati skaliranu lokalnu grešku koja se računa za svaki sloj i težine se podešavaju. Algoritam nakon inicijalnog postavljanja težina u glavnoj petlji ponavlja predstavljanje svih primjera mreži sve dok nije ispunjen uvjet zaustavljanja. Kao uvjet može poslužiti maksimalni dozvoljeni iznos pogreške dobivene obradom primjera iz skupa za učenje ili skupa za testiranje, a zatim se postupak može zaustaviti nakon fiksnog broja iteracija. Na osnovi odstupanja stvarnog izlaza od ciljnog, računa se pogreška i ugađaju svi težinski faktori u cilju njezine minimizacije.

Budući primjeri za učenje određuju ciljne vrijednosti samo izlaznog sloja neurona, poznata je jedino pogreška izlaznog sloja. Backpropagation algoritam računa pogrešku bilo kojeg skrivenog neurona tako da zbraja pogreške svih onih neurona na koje utječe izlaz ovog neurona, uz dodatno množenje težinskim faktorom. Faktor ukazuje na to u

kojoj je mjeri skriveni neuron pridonio nastanku pogreške na izlazu jedinice. Računajući pogrešku svakog neurona, algoritam propagira pogrešku od izlaznog sloja ka ulaznome, dakle unazad kroz mrežu. Odatle i naziv backpropagation algoritam.

Konkretni primjeri pokazuju zanimljivo svojstvo ovog algoritma koji je u stanju pronaći karakteristična obilježja ulaznih primjera koja nisu eksplicitno zadana, ali koja su bitna za pravilno učenje ciljne funkcije. Budući da algoritam ni na koji način nije ograničen pri postavljanju iznosa težina za skriveni sloj, težine će postaviti tako da minimiziraju izlaznu pogrešku.

5.1.5. Prednosti i nedostaci umjetnih neuronskih mreža

Umjetne neuronske mreže se najčešće primjenjuju u financijama i ulaganjima, u području ekonomskih znanosti. Najčešći problemi koji se rješavaju ovom metodom su predviđanje stečaja poduzeća, procjene kreditnih rizika te predviđanja kretanja dionica. Osim visoke učinkovitosti i točnosti predviđanja, kao najvažnije prednosti umjetnih neuronskih mreža koju su dokazali brojni autori prezentirani u prethodnim poglavljima rada, jedna od ostalih prednosti ove metode je i njihova jednostavna upotreba, uz preduvjet razumijevanja teorijske osnove mreža, primjenom pristupačnih i svima dostupnih softverskih rješenja za osobna računala. Neuronske mreže su stekle svoju popularnost zahvaljujući činjenici da nije nužno zadovoljiti pretpostavke o distribucijama podataka upotrjebljenih u modelu. Tradicionalne statističke metode zahtijevaju puno vremena, znanja i iskustva u cilju pronalaženja nelinearnih veza između podataka i otkrivanja interakcija između prediktivnih varijabli. Neuronske mreže imaju mogućnost analizirati podatke sa smetnjama, rješavati probleme koji nemaju jednostrano rješenje, te učiti na prošlim podacima (Šarlija, 2002.). Upravo ta njihova mogućnost da predstavljaju nelinearne veze čini ih prikladnim za modeliranje često nelinearnih odnosa između vjerojatnosti nastupa stečaja poduzeća i varijabli tj. financijskih indikatora.

Za istraživača i financijskog analitičara, jedan od glavnih prednosti ove metode je također u činjenici da nije potrebno specificirati funkcionalni odnos među varijablama,

Budući su mreže konektivno učeće mašine, znanje je direktno ugrađeno u set odnosa (pondera) među procesnim čvorovima tj. neuronima.

Uz sve prednosti koje umjetne neuronske mreže omogućavaju u istraživačkom radu, pojedini kritičari ANN-a spominju nekoliko potencijalnih nedostataka ove metode (prilagođeno prema Lee et al., 2002.):

1. dugotrajni proces učenja mreže tijekom definiranja optimalne mrežne topologije
2. poteškoće u identificiranju relativne važnosti potencijalnih input varijabli:

Metodologija umjetnih neuronskih mreža ne omogućava testiranje hipoteza niti testove signifikantnosti na temelju t, F ili drugih distribucija vjerojatnosti (Trigueiros, Taffler, 1996.). Neuronske mreže nisu u mogućnosti rezultirati definiranjem važnosti pojedinih varijabli (input varijabli) u mreži, te ju čak, iz tog razloga, neki autori nazivaju pristupom „crne kutije“ u modeliranju podataka. Umjesto jedinstvene linearne, nelinearne ili logističke jednadžbe umjetna neuronska mreža stvara nekoliko prijelaznih među-modela. Niti jedan drugi statistički model ne stvara odnos između zavisne i nezavisnih varijabli pomoću među-funkcija (neurona), te potom optimiziranjem sveukupnog modela. Iz tog razloga klasični testovi signifikantnosti niti ne mogu biti upotrijebljeni.

3. moguće poteškoće u interpretaciji rezultata:

Stoga se u zadnje vrijeme interes istraživanja neuronskih mreža mijenja s njihovih prediktivnih raspona prema razvoju učinkovitih metoda za kvantificiranje doprinosa tj. važnosti prediktivnih varijabli. Autori Olden, Joy, Death (2004.) uz pomoć Monte Carlo simulacija proveli su usporedbu devet različitih metodologija za procjenu doprinosa varijabli u neuronskim mrežama, na primjeru 50 situacija s pet prediktivnih varijabli. Od svih metoda (Connection weights, Garsonov algoritam, Partial Derivatives, metoda uznemirenja inputa, analiza osjetljivosti i ostale), autori dokazuju najveću učinkovitost metode Connection weights inicijalno opisane od strane autora Olden i Jackson (2002.).

5.2. Analiza ulaznih varijabli za definiranje modela

Do sada se veliki broj autora bavio istraživanjem metoda odabira i samim odabirom najpreciznijih varijabli za izračun i uključanje u model predviđanja nastavka poslovanja poduzeća. Najveći problem u odabiru varijabli je veliki broj pokazatelja koji se mogu koristiti. U posljednjih 50 godina objavljeno je preko 200 izvornih znanstvenih radova s temom predviđanja stečaja poduzeća koristeći više od 500 pokazatelja kao varijabli u finalnim verzijama modela (Du Jardin, 2010.). Upravo iz tog razloga varijable se većinom, u novijim modelima, biraju između onih korištenih u prethodnim studijama u istom ili sličnom području, odnosno među onima koje su već dokazale svoju učinkovitost u predviđanju stečaja poduzeća u drugim modelima. U najvećem broju slučajeva uključuju se i varijable koje su identificirane još od strane pionira metoda predviđanja stečaja poduzeća kao što su Altman, Beaver, Ohlson, Zmijewski i drugi, u razdoblju od 1930. do 1970. godine.

Du Jardin, jedan od autora koji se bavio istraživanjem metoda odabira varijabli, je 2010. godine dokazao da postoji povezanost između diskriminantne sposobnosti varijable, mjereno t testom ili F testom, i njezinog odabira kao ulazne varijable za definiranje modela kod velikog broja istraživača. On je proveo analizu metoda odabira prvog skupa varijabli za modele temeljene na umjetnim neuronskim mrežama i rezultati njegovog istraživanja su prikazani u tablici 12. Prilikom definiranja kriterija za odabir varijabli treba uzeti u obzir veći broj kriterija, budući je dokazano da točnost modela čije su ulazne varijable odabrane po točno definiranim kriterijima izrazito ovisi o stupnju korelacije među varijablama, stupnju linearne razdvojenosti podataka i razini šuma (Du Jardin, 2010.). Ovi rezultati jasno upućuju na nedostatke pristupa odabira varijabli samo jednim kriterijem, čak i u slučaju da je kriterij snažno prilagođen vrsti statističke tehnike kojom se model modelira. Zaključak istraživanja je nužnost raznolikosti kriterija odabira ulaznih varijabli kod istraživača, kao i prednosti ukoliko se prilikom odabira varijabli koristi veći broj kriterija zbog povećanja točnosti i bolje primjene finalnog modela za predviđanje poslovnih poteškoća poduzeća.

Tablica 12. Sažetak odabira metoda selekcije varijabli za izradu modela temeljenih na umjetnim neuronskim mrežama

Autori	Kriteriji odabira ulaznih varijabli za definiranje modela	Neuronska mreža korištena u kreiranju modela
Agarwal	Varijable iz istraživanja Altmana, Wilsona, Sharda i još nekoliko studija	Multi-Layer Perceptron - Back-Propagation
Alfaro et al.	Varijable iz prethodnih istraživanja	Multi-Layer Perceptron - Back-Propagation
Altman et al.	Metode i kriteriji odabira nisu objašnjeni	Multi-Layer Perceptron - Back-Propagation
Back et al.	Genetički algoritam primijenjen na set varijabli iz prethodnih istraživanja	Multi-Layer Perceptron - Back-Propagation
Boritz and Kennedy	Varijable iz istraživanja Altmana i Ohlsona	Multi-Layer Perceptron - Back-Propagation
Boyacioglu et al.	t test i faktorska analiza na set varijabli iz prethodnih istraživanja	Multi-Layer Perceptron - Back-Propagation
Brabazon and Keenan	Genetički algoritam primijenjen na set varijabli iz prethodnih istraživanja Altmana, Ohlsona, Baecka i ostalih istraživača	Multi-Layer Perceptron - Genetički algoritam
Dorsey et al.	Varijable iz prethodnih istraživanja	Multi-Layer Perceptron - Genetički algoritam
Kim and McLeod	Procjena eksperta nakon provedene faktorske analize na varijablama iz prethodnih istraživanja	Multi-Layer Perceptron - Genetički algoritam
Leshno and Spector	Procjena eksperta nakon testa korelacije na varijablama iz prethodnih istraživanja Altmana	Multi-Layer Perceptron - Back-Propagation
Min and Lee	Stepwise metoda s kriterijem optimiranim za logističku regresiju, t test, faktorska analiza	Multi-Layer Perceptron - Back-Propagation
Piramuthu et al.	Drvo klasifikacije	Multi-Layer Perceptron - Back-Propagation
Salchenberger et al.	Višestruka regresija primijenjena na varijablama iz prethodnih istraživanja	Multi-Layer Perceptron - Back-Propagation
Tam and Kiang	Odabir varijabli koji spadaju u kategoriju: imovina, prihodi, likvidnost	Multi-Layer Perceptron - Back-Propagation-Generic Self-Organizing Fuzzy NN
Wallrafen et al.	Genetički algoritam primijenjen na varijable iz kategorija: likvidnost, profitabilnost, imovina, zaduženost	Multi-Layer Perceptron - Genetički algoritam
Wilson and Sharda	Varijable iz istraživanja Altmana	Multi-Layer Perceptron - Back-Propagation
Yang et al	Varijable iz prethodnih istraživanja	Multi-Layer Perceptron - Back-Propagation

Izvor: Autorica prilagodila prema Du Jardin, 2010.

Modeli neuronskih mreža se često temelje na tradicionalnom odabiru varijabli temeljenim na faktorskim analizama, ali poneke neuronske mreže daju bolje rezultate ukoliko se odabir varijabli kao ulaznih vektora temelji na drugim metodama, primjerice genetičkim algoritmima. S obzirom da je metoda odabira varijabli tematika koja je zahtjevna sama po sebi, u ovom radu će se odabir varijabli temeljiti na više tradicionalnih kriterija: učestalost upotrebe i rezultati varijabli u prethodnim teorijskim istraživanjima povezanim s problemom predviđanja nastavka poslovanja poduzeća, te univarijantni testovi značajnosti.

No, za razliku od većine drugih autora i modela, kao ulazne varijable koristiti će se i financijski i nefinancijski pokazatelji iz praktične primjene u bankarskom sektoru. Tim se pokazateljima, koji se prvenstveno koriste u odjelima Upravljanja kreditnim rizicima u bankama, ocjenjuje rizičnost sadašnjeg i budućeg poslovanja korisnika proizvoda ili usluga banke ili se procjenjuje rizičnost potencijalnog klijenta za odobrenje kreditnog plasmana. Osim pokazatelja iz bankarske prakse, koristiti će se makroekonomski pokazatelji čije su vrijednosti iste za sva poduzeća na tržištu, ali različito utječu na poslovanje svakog od njih.

U nastavku poglavlja navedene su varijable iz tri definirana izvora: teorijske varijable iz prethodnih istraživanja, varijable iz prakse financijskih institucija te makroekonomske varijable.

5.2.1. Teorijske varijable iz prethodnih istraživanja

Kao i kod drugih istraživača, odabir teorijskih varijabli se temelji na njihovoj upotrebi i stupnju značajnosti u prijašnjim objavljenim studijama i istraživanjima. U procesu odabira varijabli signifikantnih za prognozu poslovnih poremećaja u ovom radu su korišteni rezultati prethodnih istraživanja odabranih domaćih i stranih autora.

Tablica 13. Popis dijela istraživačkih radova i pokazatelja korištenih u odabiru ulaznih varijabli u modeliranju prediktivnog modela

Autori	Godina istraživanja	Naziv članka	Odabrane varijable iz radova
Altman, E., R. Haldeman, and P. Narayanan	1977.	Zeta Analysis	EBIT / Ukupna imovina
			Prihodi od prodaje / Ukupne obveze
			Prihodi od prodaje / Ukupna imovina
			EBIT / Prihodi od prodaje
			Dugotrajna imovina
			Stopa pokrića kamata (ICR)
			Dobit prije oporezivanja / Ukupne obveze
			Cash flow / Ukupne obveze
			Radni kapital / Ukupne obveze
			Koeficijent tekuće likvidnosti
			Radni kapital / Ukupna imovina
			Zadržana dobit / Ukupna imovina
			Vlastiti kapital / Ukupne obveze
			Smanjenje EBIT-e
			Smanjenje marže
Mary Jane Lenard Pervais Alam Gregory R. Madey	1995.	The Application of Neural Networks and a Qualitative Response Model to the Auditor's Going Concern Uncertainty Decision	Prihodi od prodaje / Dugotrajna imovina
			Cash flow iz operacija / Ukupne obveze
			Kratkotrajna imovina / Kratkoročne obveze
			(Ukupna imovina - Ukupne obveze) / Ukupne obveze
			Dugoročne obveze / Ukupna imovina
Taffler, Tisshaw	1996.	Neural networks and empirical research in accounting	Neto dobit prije poreza / Prihodi od prodaje
			Neto dobit / Ukupna imovina
			Gubitak prethodne godine
			Dobit prije oporezivanja / Kratkoročne obveze
			Kratkotrajna imovina / Ukupne obveze
2. H.C. Koh, S.S: Tan	1999.	A neural network approach to the prediction fo going concern status	Kratkoročne obveze / Ukupna imovina
			(Kratkotrajna imovina - Kratkoročne obveze) / (Operativni troškovi - Deprecijacija)
			Kratkotrajna imovina / Kratkoročne obveze
			Tržišna vrijednost kapitala / Ukupna imovina
			Ukupne obveze / Ukupna imovina
Lykke, M., Pedersen, K.J.	2004.	A failure rate model for Danish Corporate Sector	Neto prihod / Ukupna imovina
			Zadržana dobit / Ukupna imovina
			Trošak kamata /EBIT
			Kratkotrajna imovina / Ukupna imovina
			Kapital / Ukupna imovina
Altman, Sabato	2005.	Modeling credit risk for SMEs: Evidence from the US market	Starost poduzeća
			Oblik vlasništva (dummy 1 = doo, 0 = dd)
			Kratkoročne obveze / Operativni rezultat
			Novac / Ukupna imovina
			EBITDA / Ukupna imovina
Julio Pindado	2006.	Estimating the Probability of Financial Distress	EBITDA / Trošak kamata
			Kratkoročne obveze / Vlastiti kapital
			Zadržana dobit / Ukupna imovina
			EBIT / Ukupna imovina
			Financijski troškovi / Ukupna imovina
L. Ivičić S. Cerovac	2009.	Procjena kreditnog rizika poduzeća u Hrvatskoj	Neto dobit / Ukupna imovina
			Ukupna prodaja / Ukupne obveze
			Novac / Ukupna imovina
			Kapital i rezerve / Ukupna imovina
			Kapital i rezerve / Ukupne obveze
X. Chen, Y. Du	2009.	Using neural networks and data mining techniques for the financial distress forecasting model	Novac / Kratkoročne obveze
			(Neto dobit + Amortizacija / Ukupne obveze) / 365
			365 / Potraživanja od kupaca
			EBIT / Ukupne obveze
			Ukupne obveze / Ukupni kapital
			Ukupni kapital / Ukupna imovina
			ROA
			Zarada po dionici
			ROE
			Koeficijent tekuće likvidnosti
Test ubrzane likvidnosti (acid ratio)			
M. Streitenberger, D. Miloš Sprčić	2011.	Prediktivna sposobnost financijskih pokazatelja u predviđanju kašnjenja u otplati kredita	Kratkotrajna imovina / Ukupna imovina
			Cash flow / Ukupne obveze
			Cash flow / Kratkoročne obveze
			Zalihe / Ukupna imovina
			Zalihe / Pprihodi od prodaje
			Obrtni kapital / Ukupna imovina
			Kapital i rezerve / Ukupne obveze
			(Kratkotrajna imovina - Zalihe) / Kratkoročne obveze
			Kratkotrajna imovina / Kratkoročne obveze
			Ukupne obveze / Poslovni prihodi
			ROI
			Poslovni prihodi / Poslovni rashodi

Autori	Godina istraživanja	Naziv članka	Odabrane varijable iz radova
Pereira, Basto, Farreira da Silva	2014.	Comparative Analysis between Statistical and Artificial Intelligence Models in Business Failure Prediction	Ukupna imovina / Ukupne obveze
			(Kratkotrajna imovina - Zalihe) / Kratkoročne obveze
			(Kratkotrajna imovina - Kratkoročne obveze) / Ukupne obveze
			Kratkotrajna imovina / Ukupna imovina
			Dugotrajna imovina / Kratkotrajna imovina
			Usklađivanje vrijednosti / Operativni prihod
			Kapital / Ukupna imovina
			Kapital / Ukupne obveze
			Cash flow / Kratkoročne obveze
			Cash-flow / Ukupne obveze
			Trošak kamata / Operativni prihod
			Trošak kamata / Operativna dobit
			Zalihe / Ukupna imovina
			Zalihe / Prihodi od prodaje
			Radni kapital / Ukupna imovina
			Trošak plaća/ Dugotrajna imovina
			Trošak plaća / Operativni prihod
			Dugotrajna imovina / Ukupna imovina
			Ukupne obveze / Kapital
			Operativni prihod / Operativni troškovi
			Operativni prihod / Dugotrajna imovina
			(Neto dobit prije poreza+ Deprecijacija + Provisions) / Trošak kamata
			Izvanredni prihod / Neto dobit
			Neto dobit / Ukupna imovina
			Neto dobit / Operativni prihod
			Operativna dobit / Trošak kamata
			Operativna dobit / Prihodi od prodaje
			Prihodi od prodaje / Novac
			Prihodi od prodaje / Zalihe
			(Neto dobit prije poreza + Trošak kamata) / Prihodi od prodaje
Neto dobit prije poreza / (Neto dobit prije poreza + Trošak kamata)			

Pokazatelji koji su, iz teorijskog istraživanja i pregleda postojećih najučinkovitijih pokazatelja u postojećim modelima, uključeni u prvi skup varijabli mogu se razvrstati prema osnovnim kategorijama pokazatelja i potvrditi da su svi aspekti poslovanja pokriveni ovim osnovnim skupom varijabli. Svi navedeni pokazatelji su odabrani jer su međusobno uvjetovani i utječu na uspjeh poslovnog procesa.

Upravljanje likvidnošću je za svako poduzeće izuzetno značajno jer je likvidnost, kao sposobnost podmirivanja kratkoročnih operativnih i financijskih obveza na vrijeme, pretpostavka uspješnost poslovanja poduzeća. Likvidnost je također sposobnost poduzeća da slobodno raspolaže svojom imovinom, a na to management poduzeća utječe svojim odlukama i osiguranjem pravilnog odnosa između kratkotrajne imovine i njezinih izvora. Solventnost poduzeća je njegova sposobnost da podmiruje svoje dugoročne obveze u rokovima njihovih dospijea, što je pretpostavka uspješnog poslovanja poduzeća. U trenutku kada je poduzeće insolventno, odnosno kada management poduzeća ne raspolaže novcem kojim može podmiriti svoje dugove, dovodi se u pitanje nastavak poslovanja. Likvidnost i solventnost su međusobno povezane.

Na sposobnost podmirivanja obveza utječu prihodi koje poduzeće ostvaruje uz pomoć svoje imovine. Uloga imovine u poslovnom procesu je da poduzeće preoblikovanjem određenih resursa (imovine, sirovine) stvara gotove proizvode čijom prodajom ostvaruje prihode. Brže pretvaranje imovine, odnosno obrtaj imovine, utječe na brže stvaranje prihoda, ukoliko postoji potražnja, a to na veću profitabilnost poduzeća uz određene troškove poslovanja. Usporavanje obrtaja imovine utječe i na pad rentabilnosti poslovanja. Iz tog razloga se analiziraju pokazatelji obrtaja imovine, ekonomičnosti i profitabilnosti.

Pretpostavka za uspjeh je i pravilna struktura financiranja poslovanja koja osigurava da poduzeće nije prezaduženo, odnosno da je imovina poduzeća dostatna za pokrivanje postojećih obveza. Različiti stupnjevi zaduženosti poduzeća imaju višestruke implikacije. Posljedice povećanja stupnja zaduženosti utječu na povećanje financijskog rizika, smanjenje kreditnog boniteta i povećanje troškova financiranja (Učkar, 2007.). Svojim svakodnevnim odlukama o financiranju poslovanja, management poduzeća utječe na uspješnost poslovanja, te je to razlog odabira varijabli zaduženosti kao input varijabli u modelu.

U nastavku su navedene odabrane varijable:

1. **Pokazatelji likvidnosti i solventnosti** kojima se mjeri sposobnost poduzeća da podmiruje svoje dospjele obveze:
 - $\text{Kratkotrajna imovina} / \text{Kratkoročne obveze}$
 - $(\text{Novac} + \text{Potraživanja}) / \text{Kratkoročne obveze}$
 - $\text{Novac} / \text{Kratkoročne obveze}$
 - $(\text{Kratkotrajna imovina} - \text{Zalihe}) / \text{Kratkoročne obveze}$
 - $\text{Dugotrajna imovina} / (\text{Kapital} + \text{Dugoročne obveze})$
 - $\text{Kratkotrajna imovina} / \text{Ukupne obveze}$

2. **Pokazatelji ekonomičnosti**, kojima se utvrđuje stupanj prihoda poduzeća po jedinici rashoda:
 - $\text{Poslovni prihodi} / \text{Poslovni rashodi}$
 - EBIT

3. **Pokazatelji obrtaja imovine** ili pokazatelji aktivnosti imovine, kojima se utvrđuje koliko efikasno se koriste resursi poduzeća u poslovnom procesu:
- $\text{Prihodi od prodaje} / \text{Ukupna imovina}$
 - $\text{Prihodi od prodaje} / \text{Kratkotrajna imovina}$
 - $\text{Prihodi od prodaje} / \text{Novac}$
 - $\text{Prihodi od prodaje} / \text{Zalihe}$
 - $\text{Koeficijent obrtaja potraživanja} (\text{Prihodi od prodaje} / \text{Potraživanja})$
 - $365 / \text{Koeficijent obrtaja potraživanja}$
4. **Pokazatelji profitabilnosti**, kojima se utvrđuje povrat kojima se utvrđuje povrat angažirane imovine i uloženog kapitala:
- $\text{Neto dobit prije poreza} / \text{Prihodi od prodaje}$
 - $\text{Neto dobit} / \text{Ukupna imovina}$
 - $\text{Neto dobit} / \text{Vlastiti kapital}$
 - $\text{Zadržana dobit} / \text{Ukupna imovina}$
 - $\text{Neto dobit} / \text{Poslovni prihod}$
 - $\text{Operativna dobit} / \text{Ukupna imovina}$
 - $\text{Operativna dobit} / \text{Trošak kamata}$
 - $\text{Operativna dobit} / \text{Operativni prihod}$
 - $\text{Operativna dobit} / \text{Prihodi od prodaje}$
 - $(\text{Neto dobit prije poreza} + \text{Trošak kamata}) / \text{Prihodi od prodaje}$
5. **Pokazatelji zaduženosti** pokazuju na koji način se poduzeće financira i kako koristi tuđa sredstva za financiranje:
- $\text{Dugoročne obveze} / \text{Ukupna imovina}$
 - $\text{Kapital i rezerve} / \text{Ukupna imovina}$
 - $\text{Kapital i rezerve} / \text{Ukupne obveze}$
 - $\text{Ukupne obveze} / \text{Kapital i rezerve}$

Sve varijable računate su s iznosima stavki iz financijskih izvještaja sa stanjima na dan, a ne prosječnim vrijednostima stanja.

Varijable korištene u radu financijskih institucija

U bankarskoj praksi se za određivanje boniteta poduzeća (sadašnjeg ili potencijalnog klijenta), prvenstveno koriste podaci iz financijskih izvještaja te bihevioralni podaci iz odnosa s klijentom (transakcije po poslovnom računu, učestalost korištenja bilančnih i vanbilančnih proizvoda, urednost podmirivanja obaveza i slično). Neki od najučestalijih financijskih pokazatelja koji se koriste su navedeni u tablici br. 14.

Tablica 14. Najučestaliji financijski pokazatelji pri procjeni boniteta klijenta

Pokazatelj	Izračun
EBIT prinos	$(\text{EBIT} / \text{Poslovni prihodi}) \times 100$
Faktor pokrića kamatnih troškova	$\text{EBITDA} / \text{Kamatni trošak}$
Profitna marža	$(\text{Dobit iz redovnog poslovanja} / \text{Poslovni prihodi}) \times 100$
Sklonost investiranju	$((\text{Porast stalne imovine} / (\text{Amortizacija} + \text{Otpis imovine})) \times 100$
Indikator kapitala	$(\text{Kapital} / \text{Aktiva}) \times 100$
Koeficijent financijske stabilnosti	$((\text{Kapital} + \text{Dugoročne obveze} + \text{Dugoročna rezerviranja}) / \text{Dugotrajna imovina}) \times 100$
Stopa rentabilnosti kapitala	$(\text{Dobit iz redovnog poslovanja} / \text{Kapital}) \times 100$
Koeficijent ubrzane likvidnosti	$(\text{Novac} + \text{Potraživanja}) / \text{Kratkoročne obveze}$
Koeficijent opće likvidnosti	$\text{Kratkotrajna imovina} / \text{Kratkoročne obveze}$
Neto radni kapital	$\text{Kratkotrajna imovina} - \text{Kratkoročne obveze}$
Debt coverage ratio	$(\text{Ukupne obveze prema financijskim institucijama} - \text{Novac}) / \text{EBITDA}$
Financijska poluga	$((\text{Ukupne obveze} - \text{Novac}) / (\text{Kapital} + \text{Rezerve})) \times 100$

Osim financijskih pokazatelja, koriste se i kvalitativne informacije, tj. ostale činjenice koje određuju položaj poduzeća. Kvalitativne informacije ne pomažu samo u preciznijem određivanju boniteta poduzeća, nego služe i kao pokazatelj njegovih potreba te ukazuju na određene snage i slabosti pojedinog poduzeća. Kvalitativne

informacije se uobičajeno unose u vrijednostima: neutralan, negativan, pozitivan, nema informacija, ovisno o definiranim kriterijima za svaku od vrijednosti. Pojedine ocjene mogu biti subjektivnog karaktera djelatnika banke, dok su za druge propisane referentne brojčane vrijednosti koje se dobivaju iz pojedinih izvješća ili dokumenata.

Najznačajnije kvalitativne informacije korištene u bankama prikazane su u tablici 15.

Tablica 15. Najznačajnije kvalitativne informacije („soft facts“) o klijentima korištene u bankama

Kvalitativne informacije	Kategorijske vrijednosti
Konkurentnost na tržištu	<p>Bolja → poduzeće je tržišni lider/monopolist, proizvod/usluga koji nudi je jedinstven, ima jaku prednost u vidu veličine tržišta ili cijena</p> <p>Lošija → poduzeće nudi proizvod/usluge koje su lošije od konkurencije te nema konkurentsku prednost</p> <p>Prosječna → poduzeće ima stabilnu poziciju na tržištu te nudi proizvod/usluge koje su usporedivi s najvećim konkurentima</p> <p>Nije relevantno → nema informacija o tržištu</p>
Razvoj tržišnog udjela	<p>Smanjenje → smanjenje prihoda pripadajuće industrije</p> <p>Povećanje → rast prihoda pripadajuće industrije</p>
Veličina tržišta	<p>Globalno → poduzeće ostvaruje prihode od prodaje na svjetskoj razini – multinacionalne kompanije koje imaju urede i podružnice u drugim zemljama</p> <p>Internacionalno → više od 25% prihoda poduzeće ostvaruje van RH</p> <p>Nacionalno → više od 75% prihoda poduzeće ostvaruje unutar RH</p> <p>Regionalno ili lokalno → većina prihoda ostvaruje se u županiji (regionalno) ili naselju, gradu i okolici</p>
Ovisnost o kupcima	<p>Niska → poduzeće ima diversificirane kupce koji ne mogu lako naći novog dobavljača</p> <p>Zadovoljavajuća → poduzeće ima značajan broj kupaca s potpisanim ugovorima</p> <p>Visoka → poduzeće ima mali broj velikih kupaca</p>

	Kritična → poduzeće ima jednog ili dva glavna kupca bez potpisanih ugovora, kupci lako mogu zamijeniti dobavljača
Ovisnost o dobavljačima	Niska → poduzeće ima velik broj dobavljača, nije ovisan o njihovim specifičnostima Zadovoljavajuća → poduzeće ima dovoljan broj različitih dobavljača Visoka → poduzeće ima nekoliko dobavljača, ali je vezan uz njih zbog pojedinih specifičnosti Kritična → poduzeće ima jednog dobavljača monopolistu
Tržišna pozicija	Nije relevantna → poduzeće ima slabu tržišnu poziciju Regionalno važna → poduzeće ima jaku tržišnu poziciju unutar tržišta na kojem posluje i nalazi se među deset vodećih poduzeća Nacionalno važna → poduzeće ima jaku tržišnu poziciju unutar tržišta na kojem posluje i nalazi se među deset vodećih poduzeća Internacionalno važna → poduzeće ima jaku tržišnu poziciju unutar tržišta na kojem posluje i nalazi se među deset vodećih poduzeća
Tržišna diversifikacija	Visoko diverzificirano → poduzeće ne generira > 30% prihoda od jednog proizvoda/usluge ili na jednom (geografskom) tržištu Diverzificirano → poduzeće generira između 30% i 50% prihoda od jednog proizvoda/usluge ili na jednom (geografskom) tržištu Slabo diverzificirano → poduzeće generira između 50% i 70% prihoda od jednog proizvoda/usluge ili na jednom (geografskom) tržištu Nije diverzificirano → poduzeće generira > 70% prihoda od jednog proizvoda/usluge ili na jednom (geografskom) tržištu
Kvaliteta planiranja	Ne postoji planiranje → klijent nije dostavio realan budžet Optimistično planiranje → budžet je u razdoblju od dvije do pet godina bio >15% iznad stvarno realiziranog rezultata Realno planiranje → budžet se u razdoblju od dvije do pet godina razlikovao +/-15% od stvarno realiziranog rezultata

Spremnost za preuzimanje rizika	<p>Oprezno prihvaćanje rizika → rizik se radije izbjegava nego prihvaća, dodatan rizik se prihvaća samo u iznimnim slučajevima</p> <p>Kalkulirano prihvaćanje rizika → upravljanje rizikom se bazira na očekivanoj vrijednosti rizika</p> <p>Spremnost na prihvaćanje rizika → management je spreman na prihvaćanje rizika obzirom da ih vidi kao izazove</p>
Rizik managementa	<p>Visok → nepostojanje pouzdanih planova poslovanja, upravljački kadar pretežito SSS kvalificiran i iskustvo u djelatnosti manje od dvije godine, kontinuirane izmjene upravljačkog kadra</p> <p>Prosječan → iako upravljački kadar ima pretežno iskustvo u djelatnosti između dvije i pet godina, pokazuje slabosti i ispodprosječne performanse</p> <p>Nizak → većina upravljačkog kadra ima iskustvo u djelatnosti više od pet godina, postojanje pouzdanih planova poslovanja, stabilan upravljački kadar</p> <p>Vrlo nizak → dugoročno stabilan, kompetentan upravljački kadar, uspješno poslovanje tvrtke pod upravljačkim kadrom u zadnjih tri do pet godina</p>
Mogućnost zaduživanja	<p>Neograničena mogućnost → nema ograničenja u zaduživanju</p> <p>Ograničena mogućnost → postoji ograničena mogućnost</p> <p>Vrlo ograničena mogućnost → postoji minimalna mogućnost financiranja</p> <p>Ne postoji mogućnost → nema mogućnosti zbog prezaduženosti</p>
Kvaliteta financijskih izvještaja	<p>Loša → krivo prikazani podaci, potrebna dodatna objašnjenja</p> <p>Zadovoljavajuća → potrebna dodatna objašnjenja</p> <p>Dobra → uredno prikazani podaci bez dodatnih objašnjenja</p>
Mogućnost dokapitalizacije	<p>Postoji mogućnost → poduzeće se može dokapitalizirati</p> <p>Ograničena mogućnost → postoji ograničena mogućnost dokapitalizacije</p> <p>Ne postoji mogućnost → nema mogućnosti dokapitalizacije</p>
Revizorsko mišljenje	<p>Ograničeno / s rezervom → revizorsko izvješće s ograničenim mišljenjem revizora i mišljenjem revizora s rezervom</p>

	<p>Neograničeno → revizorsko izvješće s neograničenim mišljenjem revizora</p> <p>Odbijeno → revizorsko izvješće sa sumnjom revizora u neograničeni nastavak poslovanja</p>
Valutni rizik	<p>Ne postoji → plasmani poduzeća su valutno usklađeni, nema kredita u stranoj valuti ili su hedgirani</p> <p>Nizak → izloženost poduzeća u financijskim institucijama u stranoj valuti iznosi < 25% ukupne izloženosti i/ili su hedgirani</p> <p>Srednji → izloženost poduzeća u financijskim institucijama u stranoj valuti iznosi < 50% ukupne izloženosti i/ili su hedgirani</p> <p>Visok → izloženost poduzeća u financijskim institucijama u stranoj valuti iznosi > 50% ukupne izloženosti i/ili su hedgirani</p>
Tržišni i robni rizik	<p>Ne postoji → poduzeće ili nije izloženo tržišnom i robnom riziku ili su hedgirani</p> <p>Nizak → poduzeće je izloženo robnom riziku sa stabilnim robnim cijenama</p> <p>Srednji → profit poduzeća ovisi o fluktuacijama tržišnih cijena robe, kamatnih stopa ili deviznog tečaja</p> <p>Visok → značajna izloženost tržišnom i robnom riziku</p>
Vanbilančni rizik	<p>Nizak → ne postoji vanbilančna izloženost</p> <p>Ispod prosjeka → vanbilančna izloženost nije značajna</p> <p>Iznad prosjeka → vanbilančna izloženost bi pod određenim okolnostima mogla utjecati na solventnost poduzeća</p> <p>Visok → vanbilančna izloženost koja utječe na solventnost poduzeća</p>
Status klijenta kao dužnika u drugim bankama	<p>Negativan → utužen, neuredan, trenutno blokiran i/ili blokada računa u proteklih šest mjeseci > 15 dana</p> <p>Nema informacija → bez izloženosti, samo promet po računu</p> <p>Pozitivan → uredan u podmirenju obveza</p>
Dosadašnja suradnja s bankom	<p>Loša → neuredan klijent s kašnjenjima iznad 30 dana</p> <p>Zadovoljavajuća → ured klijent u podmirenju obveza, platni promet manji od udjela banke u financiranju klijenta</p> <p>Dobra → uredan klijent s izloženosti uz platni promet iznad ili jednak udjelu banke u financiranju klijenta</p> <p>Nema informacija</p>

Odnos s bankom	<p>Novi klijent → otvoren transakcijski račun u banci u posljednja tri mjeseca</p> <p>Glavna banka klijentu → klijent ima više od 50% svih svojih financijskih obveza kod banke</p> <p>Druga banka klijentu → klijent ima manje od 50% svih svojih financijskih obveza kod banke</p> <p>Ostalo</p>
Vlasnički rizik	<p>Nizak → dva vlasnika ili više ako se radi o članovima uže obitelji</p> <p>Prosječan → tri ili više vlasnika ili jedan vlasnik ako daje privatnu imovinu za kolateral</p> <p>Visok → jedan vlasnik bez privatne imovine kao kolateral</p> <p>Nema informacija</p>
Rizik ključnih osoba	<p>Nizak → tri ili više ključnih osoba</p> <p>Prosječan → dvije ključne osobe</p> <p>Visok → jedna ključna osoba, ali zamjenjiva s odgovarajućim nasljednikom</p> <p>Vrlo visok → jedna ključna osoba teško zamjenjiva zbog posebnih vještina (npr. intelektualnog vlasništva)</p>
Tehnička opremljenost	<p>Nema potrebe za investicijama → poduzeće prati razvojne trendove u tehnologiji, nedavno izdvojeni izdaci za tekuće održavanje</p> <p>Niska → ograničeni izdaci potrebni za održavanje poslovanja klijenta</p> <p>Srednja → značajni izdaci potrebni za održavanje poslovanja klijenta</p> <p>Visoka → zastarjela ili otpisana tehnologija, nedovoljni izdaci za tekuće održavanje, visoka potreba za investicijama</p> <p>Kritično visoka → visoka potreba za značajnim investicijama u tehnologiji</p>
Status klijenta u drugim bankama	<p>Negativan → utužen, neuredan, trenutno blokiran i/ili blokada računa u proteklih šest mjeseci > 15 dana</p> <p>Neutralan → bez izloženosti, samo promet po računu</p> <p>Pozitivan → uredan u podmirenju obveza</p> <p>Nema informacija</p>
Porezni dug	<p>Ne postoji → ne postoji porezni dug</p>

	Restrukturiran → postoji dug prema Poreznoj upravi koji je reprogramiran Postoji → postoji dug prema Poreznoj upravi koji nije reprogramiran
Neusklađenost s propisima Negativni utjecaj na okoliš Neg. kritična informacija Neg. interna informacija Neg. značajna informacija Reputacijski rizik	Da → postoji Ne → ne postoji

Svi navedeni pokazatelji su korišteni i u radu kao input vektori u modelu.

Makroekonomske varijable

Statistički modeli su u svojoj prirodi statički modeli i stoga se mogu primijeniti u bilo kojem trenutku bez obzira na trenutno ili očekivano ostvarenje nacionalne ekonomije ili utjecaja ekonomije na ključne parametre rizika: vjerojatnost nastanka statusa neispunjavanja obveza (eng. probability of default, PD) ili gubitak zbog nastanka statusa neispunjavanja obveza za izloženost (eng. loss given default, LGD). Agregirani PD-evi variraju tijekom vremena, stoga će poduzeće s određenim setom varijabli često loše poslovati tijekom recesije i obrnuto, dobro poslovati tijekom ekspanzije.

Znatni broj autora upućuje na utjecaj makroekonomskih faktora na iniciranje i izazivanje poslovnih poteškoća u poduzećima, ali se rijetko kada makroekonomske varijable pojavljuju u prediktivnim modelima. Autori općenito napominju da je utjecaj makroekonomskih varijabli već uključen kroz financijske indikatore poslovanja poduzeća. Pojedini autori su ipak dokazali jasnu povezanost pojedinih makroekonomskih varijabli (primjerice BDP, kamatne stope, stopa inflacije) s poslovnim poteškoćama poduzeća kroz dokazivanje njihovih prediktivnih sposobnosti. Sami (2014.) regresijom dokazuje utjecaj stope inflacije (indeks potrošačkih cijena, indeks cijena na veliko deflator domaćeg proizvoda), M^m monetarnog agregata, broja novoosnovanih poduzeća na broj poduzeća u stečaju iako varijable signifikantno

koreliraju. Altman (1983., 1999.), te Bunn i Redwood (2003.) sugeriraju da makroekonomski uvjeti (posebno BDP) mogu utjecati na fenomen stečaja poduzeća, kao i da se broj poduzeća u stečaju povećava u razdoblju recesije i smanjuje u razdoblju ekspanzije nacionalnog gospodarstva.

Općenito, može se zaključiti da su najznačajniji faktor utjecaja na poslovne poteškoće poduzeća, s makroekonomskog aspekta, generalni ekonomski uvjeti u kojima poduzeće posluje, te da na makroekonomskom nivou postoji povezanost između stečaja poduzeća i ekonomske recesije koja se demonstrira kroz pojedine varijable. Ipak, utjecaj makroekonomskih varijabli na poslovanje poduzeća se mora iščitavati s oprezom budući one ne utječu jednako na sva poduzeća i potrebna je kreativnost u uključivanju makroekonomskih varijabli u model. Jedna od ideja je dodavanje agregiranog pokazatelja stečajeva poduzeća za svaku godinu kako bi se reflektirao niski ili visoki rizik okruženja i kako bi se mogla proučiti eksplanatorna vrijednost te varijable u prediktivnom modelu. Makroekonomske varijable nisu presudne za nastupanje poslovnih poteškoća poduzeća, već se trebaju promatrati kao katalizatori jer je problematično poslovanje poduzeća rezultat i vanjskih utjecaja i internih aktivnosti.

Za analizu utjecaja makroekonomskih varijabli u poduzeća, u ovom radu su uključene BDP, stopa inflacije (indeks potrošačkih cijena) i prosječna cijena kratkoročnih kredita zbog potvrde utjecaja tih varijabli na poslovanje poduzeća u pojedinim europskim ekonomijama, te raspoloživosti samih podataka. Primjerice, Moravec je dokazao utjecaj BDP-a, inflacije, kamatnih stopa i zaduženosti poduzeća na broj poduzeća u stečaju u Češkoj, a autori Gaffeo i Santoro dugoročni i kratkotrajni utjecaj BDP-a i kamatnih stopa na poslovanje poduzeća u Italiji.

5.3. Odabir varijabli za definiranje modela

Važna stavka rada je odabir opisnih varijabli. Odabir opisnih varijabli ne bi se trebao temeljiti na sekvencijalnom procesu eliminacije varijabli prema kriteriju maksimalnog kapaciteta predviđanja budući takav pristup može dovesti do previše prilagođenog

modela s neodgovarajućim koeficijentima i predznacima (Scott, 1981.). Također, stabilan i pouzdan model ne bi trebao sadržavati veliki broj varijabli jer ga malen broj varijabli, s teorijskim obrazloženjem i snažnom povezanošću s financijskim poremećajima, čini pouzdanim u pogledu magnituda, koeficijenata i usmjerenja varijabli (Pindado et al, 2006.).

S ciljem da se smanji višedimenzioniranost skupa varijabli, neki od istraživača provode faktorsku analizu nad varijablama. Faktorska analiza, kao skup matematičko-statističkih postupaka, ispituje međuzavisnosti unutar velikog broja varijabli, te ih se nastoji objasniti pomoću manjeg broja zajedničkih faktora i na taj način reducirati podatke te klasificirati varijable. Testira se razlika između varijabli i dokazuje da je razlika među njima dovoljno signifikantna. Ukoliko varijabla nema dovoljno značajnu različitost, varijabla se smatra nedovoljno informativnom i neće se uključiti u daljnje modeliranje. Faktorska analiza, odnosno pred-selekcija varijabli, se uobičajeno koristi kod tradicionalnih statističkih modela kada istraživač ne može sa sigurnošću pretpostaviti kolika je količina specifične varijance i želi ju isključiti.

Značajnost umjetnih neuronskih mreža leži u njihovoj sposobnosti da definiraju veze između varijabli temeljem velikog uzorka. Iz tog je razloga idealno ostaviti umjetnoj neuronskoj mreži sve varijable koje su inicijalno odabrane bez obzira na sam način odabira varijabli (Perez, 2004.). Varijable koje mreža tada odabere mogu identificirati i objasniti poteškoće u poslovanju poduzeća na drugačiji način od varijabli koje su teorijski pred-selektirane. Nakon što su varijable definirane potrebno je pred-obraditi računovodstvene i financijske podatke (normalizirati podatke) kako bi podaci postali razumljivi za mrežu, no varijable se prema novijim istraživanjima ne pred-selektiraju.

U ovom radu će se varijable također ostaviti u svom originalnom broju. Kao rezultat provedene analize literature, teorijskih saznanja i prakse u financijskim institucijama, odabrani su pokazatelji za prognostički model, te su prikazani u sljedećim tablicama 16. i 17.

Tablica 16. Odabrane financijske varijable za input vektore u definiciji modela

Financijski pokazatelji		
Br.	Skupina pokazatelja	Pokazatelji za ANN
1	Likvidnost	Kratkotrajna imovina / Kratkoročne obveze
2	Likvidnost	Novac / Kratkoročne obveze
3	Likvidnost	(Novac + Potraživanja) / Kratkoročne obveze
4	Likvidnost	Dugotrajna imovina / (Kapital + Dugoročne obveze)
5	Likvidnost	Neto dobit / Ukupne obveze
6	Likvidnost	(Kratkotrajna imovina - Kratkoročne obveze) / Ukupne obveze
7	Likvidnost	Radni kapital / Ukupna imovina
8	Solventnost	Novac / Kratkotrajna imovina
9	Dugoročna stabilnost	Ukupna imovina / Ukupne obveze
10	Dugoročna stabilnost	(Ukupna imovina - Ukupne obveze) / Ukupne obveze
11	Ekonomičnost	Poslovni prihodi / Poslovni rashodi
12	Ekonomičnost	EBIT / Troškovi kamata
13	Obrtaj imovine	Prihodi od prodaje / Ukupna imovina
14	Obrtaj imovine	Prihodi od prodaje / Dugotrajna imovina
15	Obrtaj imovine	Prihodi od prodaje / Kratkotrajna imovina
16	Obrtaj imovine	Prihodi od prodaje / Novac
17	Obrtaj imovine	Prihodi od prodaje / Zalihe
18	Obrtaj imovine	Prihodi od prodaje / Potraživanja
19	Obrtaj imovine	Prihod od prodaje / Ukupne obveze
20	Obrtaj imovine	365 / Koeficijent obrtaja potraživanja
21	Profitabilnost	Neto dobit prije poreza / Prihodi od prodaje
22	Profitabilnost	Neto dobit / Poslovni prihodi
23	Profitabilnost	Neto dobit / Ukupna imovina
24	Profitabilnost	Neto dobit / Vlastiti kapital
25	Profitabilnost	EBIT / Ukupna imovina
26	Profitabilnost	Zadržana dobit / Ukupna imovina
27	Profitabilnost	EBIT / Trošak kamata
28	Profitabilnost	EBIT / Poslovni prihodi
29	Profitabilnost	EBIT / Prihodi od prodaje

30	Profitabilnost	(Neto dobit prije poreza + Trošak kamata) / Prihodi od prodaje
31	Profitabilnost	Radni kapital / Prihodi od prodaje
32	Zaduženost	Dugoročne obveze / Ukupna imovina
33	Zaduženost	Kapital / Ukupna imovina
34	Zaduženost	Kapital / Ukupne obveze
35	Zaduženost	Kapital / Dugotrajna imovina
36	Zaduženost	Ukupne obveze / Poslovni prihodi
37	Zaduženost	Ukupne obveze / Ukupna imovina
38	Zaduženost	Ukupne obveze / Kapital i rezerve
39	Zaduženost	Kratkoročne obveze / Kratkoročna imovina
40	Zaduženost	Kratkoročne obveze / Ukupna imovina
41	Zaduženost	Kratkoročne obveze / EBITDA
42	Zaduženost	Ukupne obveze / (Zadržana dobit + Amortizacija)
43	Zaduženost	Trošak kamata / EBIT
44	Zaduženost	Trošak kamata / Operativni prihod
45	Zaduženost	Trošak kamata / Ukupne obveze prema financijskim institucijama
46	Zaduženost	Financijski troškovi / Ukupna imovina
47	Zaduženost	Obveze prema dobavljačima / Ukupna imovina
48	Zaduženost	(Kratkoročne obveze X 360) / Ukupna imovina
49	Vertikalna struktura bilance	Dugotrajna imovina / Kratkotrajna imovina
50	Udio zaliha	Zalihe/ Kratkotrajna imovina

Sve odabrane financijske varijable su međusobno povezane i uvjetovane, te utječu na uspješnost poslovanja i sposobnost poduzeća za nastavkom poslovanja. Likvidnost je preduvjet solventnosti, optimalno financiranje i zaduženost su preduvjeti dugoročne stabilnosti, a ekonomičnost i obrtaj imovine utječu na profitabilnost poslovanja i ostvarivanje zadovoljavajućih rezultata vlasnicima poduzeća.

Nefinancijske varijable i makroekonomske varijable odabrane su prema dostupnosti unesenih podataka za svaku varijablu i pojedinačno za svakog klijenta, te su najčešće korištene u bankarskoj praksi kao što je u prethodnom poglavlju objašnjeno.

Tablica 17. Odabrane nefinancijske varijable za input vektore u definiciji modela

Nefinancijski kvalitativni pokazatelji	
Br.	Pokazatelji za ANN
1	Negativna informacija o klijentu kao lošem dužniku (HROK)
2	Status dužnika u drugim bankama
3	Revizorsko mišljenje
4	Konkurentnost na tržištu
5	Kvaliteta planiranja
6	Dosadašnja suradnja s bankom
7	Mogućnost zaduživanja
8	Ovisnost o kupcima
9	Ovisnost o dobavljačima
10	Diversifikacija na tržištu
11	Mogućnost dokapitalizacije
12	Financijski odnos s bankom
13	Valutni rizik
14	Rizik ključnih osoba
15	Rizik managementa
16	Tržišni i robni rizici
17	Razvoj tržišta
18	Tržišna pozicija
19	Razvoj tržišnog udjela
20	Vanbilančni rizik
21	Tehnička opremljenost
22	Porezni dug
23	Vlasnički rizik
24	Kvaliteta financijskih izvještaja
25	Spremnost za prihvaćanje i rješavanje rizika
26	Veličina tržišta
27	Neusklađenost s propisima
28	Negativna interna informacija
29	Negativni utjecaj na okoliš
30	Negativne kritične informacije

31	Reputacijski rizik
32	Stopa rasta Bruto domaćeg proizvoda
33	Stopa inflacije (indeks potrošačkih cijena)
34	Prosječna cijena kratkoročnih kredita

Navedene financijske i nefinancijske varijable će se koristiti kao input vektori u modelu umjetnih neuronskih mreža, a umjetna neuronska mreža će svojim algoritmom zamijeniti faktorsku analizu.

5.4. Programska izvedba i interpretacija rezultata umjetnih neuronskih mreža

Za programsku izvedbu modela korišten je programski jezik Python 3. Python je dinamički programski jezik koji je nastao devedesetih godina prošlog stoljeća te je dobio naziv po serijalu Monty Python jer ga je kreator Python-a, Guido van Rossum, smatrao izuzetno dinamičnim i zabavnim. Python je programski jezik opće namjene i otvorenog koda koji je vrlo čitljiv i lagan za upotrebu. Izuzetno je popularan budući koristi jednostavnu sintaksu i minimalni broj funkcija potrebnih za efektivno pisanje koda, a često se upotrebljava u obradi velikih količina podataka. Python ne predstavlja revolucionarni programski jezik, ali integrira najbolje ideje i principe rada drugih programskih jezika. Python 3 je unaprijeđena verzija prethodnih izdanja Python-a koja je ispravila pojedine nedostatke prethodnih izdanja jezika.

Jedno od njegovih osnovnih obilježja je da koristi uvlačenje za razlikovanje programskih blokova, odnosno ne koristi zagrade ili ključne riječi kao većina programskih jezika. Povećanje uvlačenja znači da dolazi novi blok, a smanjenje označava kraj trenutnog bloka. Dinamičnost jezika je jedna od njegovih bitnih karakteristika, te za razliku od drugih programskih jezika nije potrebno deklarirati tip varijable prije izvršavanja. Na taj način se tip varijable prije izvršavanja može lako promijeniti. Postoje dvije osnovne gradivne jedinice Python-a: ugrađene funkcije i stringovi. Ugrađene funkcije su funkcije koje ne treba definirati nego su dostupne s Python-om (u biblioteci) prilikom instalacije. To su sve standardne funkcije, poput aritmetičkih, logičkih, printanje, otvaranje fileova i slično.

Slika 7. Snimka (eng. Screenshot) glavne skripte koda u programskom jeziku Python

```

In [1]: import pandas as pd
import numpy as np

In [2]: podatci = pd.read_csv("main.csv")
podatci.head()

Out[2]:


|   | A | B | C    | D    | E    | F    | G    | H    | I    | J    | ... | VO | VP | VQ | VR | VS | VT | VU | VV | VW | VX |
|---|---|---|------|------|------|------|------|------|------|------|-----|----|----|----|----|----|----|----|----|----|----|
| 0 | 1 | 0 | 0.6  | -0.3 | -0.1 | -0.6 | -0.4 | -0.5 | -0.2 | -0.2 | ... | 0  | 0  | 0  | 0  | 1  | 0  | 0  | 0  | 0  | 1  |
| 1 | 2 | 0 | -1.4 | 3.3  | 0.3  | 2.0  | 5.9  | -0.1 | -0.9 | -0.1 | ... | 1  | 0  | 0  | 0  | 0  | 0  | 1  | 0  | 0  | 1  |
| 2 | 3 | 0 | 0.6  | -0.5 | -0.3 | -0.4 | -0.5 | 0.5  | 0.9  | 0.2  | ... | 0  | 0  | 0  | 0  | 0  | 0  | 1  | 0  | 0  | 1  |
| 3 | 4 | 0 | -0.9 | -0.4 | 0.4  | -0.5 | -0.3 | -0.5 | 1.5  | 0.0  | ... | 0  | 1  | 0  | 0  | 1  | 0  | 0  | 0  | 0  | 1  |
| 4 | 5 | 0 | 0.5  | -0.2 | -0.3 | -0.0 | -0.4 | 0.0  | -0.1 | -0.3 | ... | 0  | 0  | 0  | 1  | 0  | 0  | 0  | 0  | 0  | 1  |



5 rows x 596 columns

In [7]: import sklearn
print(sklearn.__version__)#

0.18.1

In [5]: TARGET_VARIJABLA = "B"
HIDDEN_LAYER = (1500,)
TRAIN_TEST_SPLIT=0.3
MOST = 5 #how many of the most important features to return?

OUT_FILE = "newfile01.csv"
OPTIMIZER = "adam" #alternative "sgd"

#####
### A je ID

trgts = ["B"]#all possible targets (this list includes the target used and anything else you want out of the dataframe)
ostali_trg = [x for x in trgts if x!=TARGET_VARIJABLA]

# train-test split
mask = np.random.rand(len(podatci)) < TRAIN_TEST_SPLIT
tr_podatci = podatci[mask]
te_podatci = podatci[~mask]

# label-data split
tr_data = tr_podatci.drop(trgts,axis=1)
tr_labels = tr_podatci[[TARGET_VARIJABLA]]
te_data = te_podatci.drop(trgts,axis=1)
te_labels = te_podatci[[TARGET_VARIJABLA]]

from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score
from sklearn.metrics import precision_score
from sklearn.metrics import recall_score

## Logistic regression
LR = LogisticRegression()
LR.fit(tr_data,np.ravel(tr_labels))
pr1 = LR.predict(te_data)

A_lr = accuracy_score(np.ravel(te_labels), pr1)
P_lr = precision_score(np.ravel(te_labels), pr1)
R_lr = recall_score(np.ravel(te_labels), pr1)

print("\nAccuracy LogReg: "+ str(A_lr) + "\nPrecision LogReg: " + str(P_lr) + "\nRecall LogReg: "+ str(R_lr))

vaznosti = np.ravel(np.transpose(LR.coef_)).tolist() #kao (1,589) array
imena = tr_data.columns.tolist()
IMP = list(zip(imena,vaznosti))
IMP2= sorted(IMP, key=lambda x: x[1], reverse=True)
print(IMP2[:MOST])

```



```

from sklearn.neural_network import MLPClassifier

ANN = MLPClassifier(solver=OPTIMIZER, hidden_layer_sizes=HIDDEN_LAYER, random_state=1, activation = "logistic")
ANN.fit(tr_data,np.ravel(tr_labels))
pr2 = ANN.predict(te_data)

A_ann = accuracy_score(np.ravel(te_labels), pr2)
P_ann = precision_score(np.ravel(te_labels), pr2)
R_ann = recall_score(np.ravel(te_labels), pr2)

print("\nAccuracy ANN: "+ str(A_ann) + "\nPrecision ANN: " + str(P_ann) + "\nRecall ANN: "+ str(R_ann))

resulting_col_name_1 = "LogReg_Predictions_for_col_"+TARGET_VARIJABLA
resulting_col_name_2 = "ANN_Predictions_for_col_"+TARGET_VARIJABLA
resultingDF = te_data
resultingDF[resulting_col_name_1] = pr1
resultingDF[resulting_col_name_2] = pr2

resultingDF.to_csv(OUT_FILE, encoding="utf8", index=False, sep=";")

import pickle
with open('logreg1.pkl', 'wb') as logreg:
    pickle.dump(LR, logreg)
with open('ann1.pkl', 'wb') as ann1:
    pickle.dump(ANN, ann1)

# to load them:
with open('ann1.pkl', 'rb') as ann_saved:
    ANN_2 = pickle.load(ann_saved)

resultingDF

```

```

Accuracy LogReg: 0.971337579618
Precision LogReg: 0.969199178645
Recall LogReg: 0.957403651116
[('GL', 0.3722081165334594), ('II', 0.35690860440930183), ('IT', 0.26943264741465234), ('IY', 0.22118937117606768), ('GX', 0.21044190682612776)]

Accuracy ANN: 0.976910828025
Precision ANN: 0.96963562753
Recall ANN: 0.971602434077

```

Out[12]:

	A	C	D	E	F	G	H	I	J	K	...	VQ	VR	VS	VT	VU	VV	VW	VX	LogReg_Predictions_for_col_B	ANN_Predictions_for
1	2	-1.4	3.3	0.3	2.0	5.9	-0.1	-0.9	-0.1	0.0	...	0	0	0	0	1	0	0	1	0	0
4	5	0.5	-0.2	-0.3	-0.0	-0.4	0.0	-0.1	-0.3	-0.2	...	0	1	0	0	0	0	0	1	0	0
7	8	-0.2	-0.6	-0.5	-0.5	-0.5	-0.6	1.9	0.2	0.1	...	0	0	0	0	1	0	0	1	0	0
8	9	0.2	-0.5	-0.2	-0.4	-0.3	-0.1	-0.2	0.1	-0.1	...	0	0	1	0	0	0	1	0	0	0
9	10	1.1	-0.9	-0.6	-0.6	-0.4	-0.7	-0.8	0.9	0.4	...	0	0	1	0	0	0	1	0	0	0
10	11	0.2	-0.3	-0.3	-0.5	-0.4	-0.6	0.4	-0.2	-0.2	...	0	0	0	0	1	0	0	1	0	0
11	12	0.7	-0.7	-0.3	-0.6	-0.4	-0.3	-0.2	0.4	0.0	...	0	1	0	0	0	0	0	1	0	0
13	14	-0.7	1.4	1.9	0.3	0.6	0.1	-0.9	-0.4	-0.2	...	0	0	0	0	1	0	0	1	0	0

Moguće je slagati kompleksne funkcije od unaprijed definiranih funkcija. Stringovi (oznaka: str) su niz znakova koje ne želimo da Python interpretira kao naredbu, nego da ih tretira kao tekst. Stringovi su zatvoreni u polu-navodnike ili navodnike. Drugi osnovni tip podataka su cijeli brojevi (int), i oni se zapisuju kao -2,-1,0,1,2, itd. Treći su decimalni brojevi (float) i oni se uvijek moraju pisati s točkom. Stringovi i cijeli brojevi su podaci, ali su različitog tipa. (S. Skansi, 2016.)

Prethodno na slici 7., prikazan je kod skripte u programskom jeziku Python kojim je definiran kod za prognozu nastavka poslovanja poduzeća temeljem umjetnih neuronskih mreža, te kod za definiranje najvažnijih varijabli i njihovog smjera prilikom definiranja nastavka poslovanja poduzeća.

Kod se sastoji od pet osnovnih blokova. Pojedini blokovi skripte (isječci s ekrana) s njihovim redosljedom i objašnjenjima koda prikazani su na slici 8.

Slika 8. Snimka (eng Screenshot) pojedinih blokova koda s objašnjenjima

<pre style="font-family: monospace; font-size: 0.9em;">In [1]: import pandas as pd import numpy as np In [2]: podatci = pd.read_csv("main.csv") podatci.head()</pre> <div style="margin-top: 10px;"> <p style="color: #c00000; font-weight: bold;">Out[2]:</p> <table border="1" style="border-collapse: collapse; text-align: center; font-size: 0.8em;"> <thead> <tr> <th></th> <th>A</th> <th>B</th> <th>C</th> <th>D</th> <th>E</th> <th>F</th> <th>G</th> <th>H</th> <th>I</th> <th>J</th> <th>...</th> <th>VO</th> <th>VP</th> <th>VQ</th> <th>VR</th> <th>VS</th> <th>VT</th> <th>VU</th> <th>VV</th> <th>VW</th> <th>VX</th> </tr> </thead> <tbody> <tr> <td>0</td> <td>1</td> <td>0</td> <td>0.6</td> <td>-0.3</td> <td>-0.1</td> <td>-0.6</td> <td>-0.4</td> <td>-0.5</td> <td>-0.2</td> <td>-0.2</td> <td>...</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <td>1</td> <td>2</td> <td>0</td> <td>-1.4</td> <td>3.3</td> <td>0.3</td> <td>2.0</td> <td>5.9</td> <td>-0.1</td> <td>-0.9</td> <td>-0.1</td> <td>...</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <td>2</td> <td>3</td> <td>0</td> <td>0.6</td> <td>-0.5</td> <td>-0.3</td> <td>-0.4</td> <td>-0.5</td> <td>0.5</td> <td>0.9</td> <td>0.2</td> <td>...</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <td>3</td> <td>4</td> <td>0</td> <td>-0.9</td> <td>-0.4</td> <td>0.4</td> <td>-0.5</td> <td>-0.3</td> <td>-0.5</td> <td>1.5</td> <td>0.0</td> <td>...</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> </tr> <tr> <td>4</td> <td>5</td> <td>0</td> <td>0.5</td> <td>-0.2</td> <td>-0.3</td> <td>-0.0</td> <td>-0.4</td> <td>0.0</td> <td>-0.1</td> <td>-0.3</td> <td>...</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>0</td> <td>1</td> </tr> </tbody> </table> <p style="font-size: 0.8em; margin-top: 5px;">5 rows x 596 columns</p> </div>		A	B	C	D	E	F	G	H	I	J	...	VO	VP	VQ	VR	VS	VT	VU	VV	VW	VX	0	1	0	0.6	-0.3	-0.1	-0.6	-0.4	-0.5	-0.2	-0.2	...	0	0	0	0	1	0	0	0	0	1	1	2	0	-1.4	3.3	0.3	2.0	5.9	-0.1	-0.9	-0.1	...	1	0	0	0	0	0	1	0	0	1	2	3	0	0.6	-0.5	-0.3	-0.4	-0.5	0.5	0.9	0.2	...	0	0	0	0	0	0	1	0	0	1	3	4	0	-0.9	-0.4	0.4	-0.5	-0.3	-0.5	1.5	0.0	...	0	1	0	0	1	0	0	0	0	1	4	5	0	0.5	-0.2	-0.3	-0.0	-0.4	0.0	-0.1	-0.3	...	0	0	0	1	0	0	0	0	0	1	<p>In(1) → Učitavanje modula Pandas, odnosno modula Python-a koji osigurava brze i fleksibilne podatkovne strukture dizajnirane za intuitivni rad s definiranim „labeled“ podacima, odnosno modul koji radi s tablicama. Naredba Python-u da ga naziva „pd“ kroz kod. Učitavanje modula Numpy, odnosno modula Python-a koji osigurava rad s matricama i ekstenzijama. Naredba Python-u da ga naziva „np“ kroz kod.</p>
	A	B	C	D	E	F	G	H	I	J	...	VO	VP	VQ	VR	VS	VT	VU	VV	VW	VX																																																																																																																
0	1	0	0.6	-0.3	-0.1	-0.6	-0.4	-0.5	-0.2	-0.2	...	0	0	0	0	1	0	0	0	0	1																																																																																																																
1	2	0	-1.4	3.3	0.3	2.0	5.9	-0.1	-0.9	-0.1	...	1	0	0	0	0	0	1	0	0	1																																																																																																																
2	3	0	0.6	-0.5	-0.3	-0.4	-0.5	0.5	0.9	0.2	...	0	0	0	0	0	0	1	0	0	1																																																																																																																
3	4	0	-0.9	-0.4	0.4	-0.5	-0.3	-0.5	1.5	0.0	...	0	1	0	0	1	0	0	0	0	1																																																																																																																
4	5	0	0.5	-0.2	-0.3	-0.0	-0.4	0.0	-0.1	-0.3	...	0	0	0	1	0	0	0	0	0	1																																																																																																																
	<p>In(2) → Unos podataka u csv. datoteci, prikaz samo prvih 5 redova radi provjere točnosti unesene tablice</p>																																																																																																																																				

```
In [1]: import pandas as pd
import numpy as np
```

```
In [2]: podatci = pd.read_csv("main.csv")
podatci.head()
```

```
Out[2]:
```

	A	B	C	D	E	F	G	H	I	J	...	VO	VP	VQ	VR	VS	VT	VU	VV	VW	VX
0	1	0	0.6	-0.3	-0.1	-0.6	-0.4	-0.5	-0.2	-0.2	...	0	0	0	0	1	0	0	0	0	1
1	2	0	-1.4	3.3	0.3	2.0	5.9	-0.1	-0.9	-0.1	...	1	0	0	0	0	0	1	0	0	1
2	3	0	0.6	-0.5	-0.3	-0.4	-0.5	0.5	0.9	0.2	...	0	0	0	0	0	0	1	0	0	1
3	4	0	-0.9	-0.4	0.4	-0.5	-0.3	-0.5	1.5	0.0	...	0	1	0	0	1	0	0	0	0	1
4	5	0	0.5	-0.2	-0.3	-0.0	-0.4	0.0	-0.1	-0.3	...	0	0	0	1	0	0	0	0	0	1

5 rows x 596 columns

```
Out[2]:
```

	A	B	C	D	E	F	G	H	I	J	...	VO	VP	VQ	VR	VS	VT	VU	VV	VW	VX
0	1	0	0.6	-0.3	-0.1	-0.6	-0.4	-0.5	-0.2	-0.2	...	0	0	0	0	1	0	0	0	0	1
1	2	0	-1.4	3.3	0.3	2.0	5.9	-0.1	-0.9	-0.1	...	1	0	0	0	0	0	1	0	0	1
2	3	0	0.6	-0.5	-0.3	-0.4	-0.5	0.5	0.9	0.2	...	0	0	0	0	0	0	1	0	0	1
3	4	0	-0.9	-0.4	0.4	-0.5	-0.3	-0.5	1.5	0.0	...	0	1	0	0	1	0	0	0	0	1
4	5	0	0.5	-0.2	-0.3	-0.0	-0.4	0.0	-0.1	-0.3	...	0	0	0	1	0	0	0	0	0	1

5 rows x 596 columns

```
In [7]: import sklearn
print(sklearn.__version__)#
0.18.1
```

In(7) → Unos funkcije za strojno učenje i prikaz trenutno instalirane verzije (0.18)

```
In [7]: import sklearn
print(sklearn.__version__)#
0.18.1
```

```
In [8]: TARGET_VARIJABLA = "B"
HIDDEN_LAYER = (1500,)
TRAIN_TEST_SPLIT=0.3
MOST = 5 #how many of the most important features to return?

OUT_FILE = "newfile01.csv"
OPTIMIZER = "adam" #alternative "sgd"

#####
### A je ID

trgts = ["B"]#all possible targets (this list includes the target used and anything else yo
ostali_trg = [x for x in trgts if x!=TARGET_VARIJABLA]

# train-test split
mask = np.random.rand(len(podatci)) < TRAIN_TEST_SPLIT
tr_podatci = podatci[mask]
te_podatci = podatci[~mask]

# label-data split
tr_data = tr_podatci.drop(trgts,axis=1)
tr_labels = tr_podatci[[TARGET_VARIJABLA]]
te_data = te_podatci.drop(trgts,axis=1)
te_labels = te_podatci[[TARGET_VARIJABLA]]
```

In(8) → Blok u kojem se definira *Target varijabla* tj. ciljana varijabla B (B stupac u tablici sadrži podatak da li je poduzeće uspješno ili neuspješno prema definiranim parametrima). *Hidden layer* definira broj neurona u skrivenom sloju mreže od 1500. Složenije mreže započinju s 250 neurona u skrivenom sloju (veći broj neurona osigurava bolju točnost), a 1500 bi

```
In [7]: import sklearn
print(sklearn.__version__)
0.18.1

In [8]: TARGET_VARIJABLA = "B"
HIDDEN_LAYER = (1500,)
TRAIN_TEST_SPLIT=0.3
MOST = 5 #how many of the most important features to return?
OUT_FILE = "newfile01.csv"
OPTIMIZER = "adam" #alternative "sgd"

#####
### A je ID

trgts = ["B"]#all possible targets (this list includes the target used and anything else you
ostali_trg = [x for x in trgts if x!=TARGET_VARIJABLA]

# train-test split
mask = np.random.rand(len(podatci)) < TRAIN_TEST_SPLIT
tr_podatci = podatci[mask]
te_podatci = podatci[~mask]

# label-data split
tr_data = tr_podatci.drop(trgts,axis=1)
tr_labels = tr_podatci[[TARGET_VARIJABLA]]
te_data = te_podatci.drop(trgts,axis=1)
te_labels = te_podatci[[TARGET_VARIJABLA]]
```

trebao osigurati dovoljnu razinu točnosti mreže.

Train test split definira postotak neurona za treniranje, dok se ostatak koristi za testiranje. Red *Most* definira broj obilježja koja se žele vratiti kroz logističku regresiju, koji u ovom slučaju iznosi 5 *Out file* određuje mjesto za spremanje utrenirane neuronske mreže.

Optimizer izdaje naredbu za uporabu algoritma za optimizaciju loss funkcije, odnosno pogreške. Neuronska mreža provlači podatke i izračuna pogrešku od primjerice 0.5, zatim uzima optimizer (Adam) koji mijenja weights na način da se pogreška minimizira (eng. backpropagate the error).

In(8) → Blok definira stupac B kao target varijablu treniranja

```

OUT_FILE = "newfile01.csv"
OPTIMIZER = "adam" #alternative "sgd"

#####
### A je ID

trgts = ["B"] #all possible targets (this list includes the target used and anything else you
ostali_trg = [x for x in trgts if x!=TARGET_VARIJABLA]

# train-test split
mask = np.random.rand(len(podatci)) < TRAIN_TEST_SPLIT
tr_podatci = podatci[mask]
te_podatci = podatci[~mask]

# label-data split
tr_data = tr_podatci.drop(trgts,axis=1)
tr_labels = tr_podatci[[TARGET_VARIJABLA]]
te_data = te_podatci.drop(trgts,axis=1)
te_labels = te_podatci[[TARGET_VARIJABLA]]

```

neuronske mreže.
Postoji samo jedna target varijabla, ne postoje ostale targetne varijable.

```

OUT_FILE = "newfile01.csv"
OPTIMIZER = "adam" #alternative "sgd"

#####
### A je ID

trgts = ["B"] #all possible targets (this list includes the target used and anything else you
ostali_trg = [x for x in trgts if x!=TARGET_VARIJABLA]

# train-test split
mask = np.random.rand(len(podatci)) < TRAIN_TEST_SPLIT
tr_podatci = podatci[mask]
te_podatci = podatci[~mask]

# label-data split
tr_data = tr_podatci.drop(trgts,axis=1)
tr_labels = tr_podatci[[TARGET_VARIJABLA]]
te_data = te_podatci.drop(trgts,axis=1)
te_labels = te_podatci[[TARGET_VARIJABLA]]

```

In(8) → *Train-test split* razdvaja sve podatke na dva dijela po slučajnom uzorku (eng. random split), te uzima 30% podataka za treniranje i 70% za testiranje mreže, kako je definirano u prethodnom bloku. *Label-test split* izdvaja stupac B (ciljanu varijablu) iz train i test uzorka.

```

# label-data split
tr_data = tr_podatci.drop(trgts,axis=1)
tr_labels = tr_podatci[[TARGET_VARIJABLA]]
te_data = te_podatci.drop(trgts,axis=1)
te_labels = te_podatci[[TARGET_VARIJABLA]]

from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score
from sklearn.metrics import precision_score
from sklearn.metrics import recall_score

## Logistic Regression
LR = LogisticRegression()
LR.fit(tr_data,np.ravel(tr_labels))
pr1 = LR.predict(te_data)

A_lr = accuracy_score(np.ravel(te_labels), pr1)
P_lr = precision_score(np.ravel(te_labels), pr1)
R_lr = recall_score(np.ravel(te_labels), pr1)

print("\nAccuracy LogReg: " + str(A_lr) + "\nPrecision LogReg: " + str(P_lr) + "\nRecall LogReg: " + str(R_lr))

```

In(8) → Blok unosi funkcije odnosno model logističke regresije u algoritam. Unose se parametri logističke regresije i funkcije za provjeru učinkovitosti modela.

In(8) → Blok provodi treniranje podataka odnosno treniranje

```

# label-data split
tr_data = tr_podatici.drop(trgts,axis=1)
tr_labels = tr_podatici[[TARGET_VARIJABLA]]
te_data = te_podatici.drop(trgts,axis=1)
te_labels = te_podatici[[TARGET_VARIJABLA]]

from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score
from sklearn.metrics import precision_score
from sklearn.metrics import recall_score

## Logistic regression
LR = LogisticRegression()
LR.fit(tr_data,np.ravel(tr_labels))
pr1 = LR.predict(te_data)

A_lr = accuracy_score(np.ravel(te_labels), pr1)
P_lr = precision_score(np.ravel(te_labels), pr1)
R_lr = recall_score(np.ravel(te_labels), pr1)

print("\nAccuracy LogReg: " + str(A_lr) + "\nPrecision LogReg: " + str(P_lr) + "\nRecall LogReg: " + str(R_lr))

```

```

# label-data split
tr_data = tr_podatici.drop(trgts,axis=1)
tr_labels = tr_podatici[[TARGET_VARIJABLA]]
te_data = te_podatici.drop(trgts,axis=1)
te_labels = te_podatici[[TARGET_VARIJABLA]]

from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score
from sklearn.metrics import precision_score
from sklearn.metrics import recall_score

## Logistic regression
LR = LogisticRegression()
LR.fit(tr_data,np.ravel(tr_labels))
pr1 = LR.predict(te_data)

A_lr = accuracy_score(np.ravel(te_labels), pr1)
P_lr = precision_score(np.ravel(te_labels), pr1)
R_lr = recall_score(np.ravel(te_labels), pr1)

print("\nAccuracy LogReg: " + str(A_lr) + "\nPrecision LogReg: " + str(P_lr) + "\nRecall LogReg: " + str(R_lr))

```

modela na uzorku za treniranje (*LR.fit*), a zatim testiranje modela i podataka na test uzorku (*pr1*). U nastavku kod provodi testiranje točnosti testiranih podataka, odnosno *accuracy score* koji pokazuje postotak ispravno klasificiranih poduzeća u testnom uzorku. *Precision score* koji se računa kao omjer točno klasificiranih poduzeća koja dobro posluju (*true positive tp*) i zbroja poduzeća koja su točno i netočno klasificirana (*false positive fp*) kao poduzeća koja dobro posluju. Omjer pokazuje sposobnost modela da ne označi pozitivnim, poduzeća koja loše posluju:

$$\frac{tp}{(tp + fp)}$$

te *recall score* koji se računa kao omjer poduzeća koja dobro posluju u odnosu na zbroj takvih poduzeća i poduzeća pogrešno klasificiranih kao

```

from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score
from sklearn.metrics import precision_score
from sklearn.metrics import recall_score

## Logistic regression
LR = LogisticRegression()
LR.fit(tr_data,np.ravel(tr_labels))
pr1 = LR.predict(te_data)

A_lr = accuracy_score(np.ravel(te_labels), pr1)
P_lr = precision_score(np.ravel(te_labels), pr1)
R_lr = recall_score(np.ravel(te_labels), pr1)

print("\nAccuracy LogReg: " + str(A_lr) + "\nPrecision LogReg: " + str(P_lr) + "\nRecall LogReg: " + str(R_lr))

```

negativna (*false negative fn*), omjer pokazuje sposobnost modela da pronade pozitivne primjere:

$$\frac{tp}{(tp + fn)}$$

Posljednji red označava ispis podataka.

```

## Logistic regression
LR = LogisticRegression()
LR.fit(tr_data,np.ravel(tr_labels))
pr1 = LR.predict(te_data)

A_lr = accuracy_score(np.ravel(te_labels), pr1)
P_lr = precision_score(np.ravel(te_labels), pr1)
R_lr = recall_score(np.ravel(te_labels), pr1)

print("\nAccuracy LogReg: " + str(A_lr) + "\nPrecision LogReg: " + str(P_lr) + "\nRecall LogReg: " + str(R_lr))

vznosti = np.ravel(np.transpose(LR.coef_)).tolist() #kao (1,589) array
imena = tr_data.columns.tolist()
IMP = list(zip(imena,vznosti))
IMP2= sorted(IMP, key=lambda x: x[1], reverse=True)
print(IMP2[:MOST])

```

In(8) → Dio koda koji izvlači važnosti pojedinih varijabli i sortira ih prema važnosti, te ispisuje pet najvažnijih varijabli (obilježja) na temelju ove metodologije.

```

vznosti = np.ravel(np.transpose(LR.coef_)).tolist() #kao (1,589) array
imena = tr_data.columns.tolist()
IMP = list(zip(imena,vznosti))
IMP2= sorted(IMP, key=lambda x: x[1], reverse=True)
print(IMP2[:MOST])

from sklearn.neural_network import MLPClassifier

ANN = MLPClassifier(solver=OPTIMIZER, hidden_layer_sizes=HIDDEN_LAYER, random_state=1, activation = "logistic")
ANN.fit(tr_data,np.ravel(tr_labels))
pr2 = ANN.predict(te_data)

A_ann = accuracy_score(np.ravel(te_labels), pr2)
P_ann = precision_score(np.ravel(te_labels), pr2)
R_ann = recall_score(np.ravel(te_labels), pr2)

print("\nAccuracy ANN: " + str(A_ann) + "\nPrecision ANN: " + str(P_ann) + "\nRecall ANN: " + str(R_ann))

```

In(8) → Dio koda kojim se unosi funkcija umjetne neuronske mreže i njezini parametri. Parametri su isti onima logističke regresije osim sortiranja najvažnijih varijabli (to nije moguće na ovaj način dobiti iz umjetne

	<p>neuronske mreže). Posljednji red označava ispis podataka.</p>
<pre> A_ann = accuracy_score(np.ravel(te_labels), pr2) P_ann = precision_score(np.ravel(te_labels), pr2) R_ann = recall_score(np.ravel(te_labels), pr2) print("\nAccuracy ANN: " + str(A_ann) + "\nPrecision ANN: " + str(P_ann) + "\nRecall ANN: " + str(R_ann)) resulting_col_name_1 = "LogReg_Predictions_for_col_"+TARGET_VARIJABLA resulting_col_name_2 = "ANN_Predictions_for_col_"+TARGET_VARIJABLA resultingDF = te_data resultingDF[resulting_col_name_1] = pr1 resultingDF[resulting_col_name_2] = pr2 resultingDF.to_csv(OUT_FILE, encoding="utf8", index=False, sep=";") import pickle with open('logreg1.pkl', 'wb') as logreg: pickle.dump(LR, logreg) with open('ann1.pkl', 'wb') as ann1: pickle.dump(ANN, ann1) # to load them: with open('ann1.pkl', 'rb') as ann_saved: ANN_2 = pickle.load(ann_saved) resultingDF </pre>	<p>In(8) → Posljednji blok unosi rezultate predikcije u stupce unutar osnovnog seta podataka (<i>dataframe</i>) uz podatke o poduzeću, za logističku regresiju i umjetnu neuronsku mrežu. Sve se zapisuje u novi file. Svi se rezultati logističke regresije i umjetne neuronske mreže zapisuju u Python formatu za spremanje <i>Pickle</i>.</p>

5.5. Rezultati novog modela

Metodom umjetnih neuronskih mreža izvršena je podjela cijelog uzorka podataka koji obuhvaća 1.796 poduzeća na dio za treniranje, testiranje i validaciju, prema omjeru 60%:20%:20%. Budući je u uzorcima bilo potrebno osigurati nepristran broj uspješnih i neuspješnih poduzeća, Python je svojom ugrađenom funkcijom nasumice odabrao poduzeća. Broj ulaznih varijabli iznosio je 82, a definirane su dvije izlazne varijable: 0 varijabla koja označava loša poduzeća (definirana prema ranije objašnjenim kriterijima), te 1 varijabla koja označava poduzeća koja dobro posluju.

Umjetna neuronska mreža je ostvarila sljedeće rezultate uspješnosti, prikazano na slici 9.:

- **Accuracy ANN** → Postotak ispravno klasificiranih poduzeća (dobra kao dobra te loša kao loša) iznosi 97,69%
- **Precision ANN** → Uspješnost modela da ne označi pozitivnim poduzećima, poduzeća koja loše posluju iznosi 96,96 %
- **Recall ANN** → Uspješnost modela u ispravnom klasificiranju poduzeća koja dobro posluju iznosi 97,16 %

U radu je primijenjena i statistička metoda logističke regresije s osnovnim ciljem analize značajnosti varijabli uključenih u model s obzirom na njihov utjecaj na ishod poslovanja poduzeća. Neuronska mreža ne može na jednostavan način odrediti smislene važnosti varijabli. Logistička regresija (ili logit model) je vrsta regresije u kojoj je zavisna varijabla dihotomna i može poprimiti dvije vrijednosti (0 ili 1), te označavaju pojavu nekog događaja ili atributa. Logistička regresija se i koristi s ciljem prikazivanja kako vjerojatnost nastupanja određenog atributa (uspješnost poduzeća) ovisi, odnosno pod utjecajem je jedne ili više ulaznih varijabli.

U slučaju ovog rada, dihotomna varijabla ima vrijednost poduzeća koje loše posluje (0) ili poduzeća koje dobro posluje (1), te se ne pretpostavlja linearna zavisnost između zavisne i nezavisnih varijabli. U postavkama modela definirano je da se odabere pet najznačajnijih varijabli.

Dobiven je regresijski model koji može predvidjeti vrijednost zavisne varijable te regresijske koeficijente koji pokazuju relativni utjecaj svake nezavisne varijable.

Logistička regresija je ostvarila sljedeće rezultate uspješnosti, prikazano na slici 9.:

- **Accuracy LogReg** → Postotak ispravno klasificiranih poduzeća (dobra kao dobra te loša kao loša) iznosi 97,13%

- **Precision LogReg** → Uspješnost modela da ne označi pozitivnim poduzećima, poduzeća koja loše posluju iznosi 96,91 %
- **Recall LogReg** → Uspješnost modela u ispravnom klasificiranju poduzeća koja dobro posluju iznosi 95,74 %

Rezultati uspješnosti i preciznosti oba modela su izuzetno visoki, no umjetna neuronska mreža točnije klasificira poduzeća koja dobro posluju i ona koja loše posluju. Očekivano visoki rezultati su rezultat dobro utrenirane umjetne neuronske mreže na velikom broju kvalitetnih i točnih podataka te značajnom broju ulaznih varijabli.

Slika 9. Ispis rezultata modela logističke regresije i umjetne neuronske mreže

```
import pickle
with open('logreg1.pkl', 'wb') as logreg:
    pickle.dump(LR, logreg)
with open('ann1.pkl', 'wb') as ann1:
    pickle.dump(ANN, ann1)

# to load them:
with open('ann1.pkl', 'rb') as ann_saved:
    ANN_2 = pickle.load(ann_saved)

resultingDF

Accuracy LogReg: 0.971337579618
Precision LogReg: 0.969199178645
Recall LogReg: 0.957403651116
[('GL', 0.3722081165334594), ('II', 0.35690860440930183), ('IT', 0.26943264741465234), ('IY', 0.22118937117606768), ('GX', 0.21044190682612776)]

Accuracy ANN: 0.976910828025
Precision ANN: 0.96963562753
Recall ANN: 0.971602434077
```

Out[12]:

	A	C	D	E	F	G	H	I	J	K	...	VQ	VR	VS	VT	VU	VV	VW	VX	LogReg_Predictions_for_col_B	ANN_Predictions_for
1	2	-1.4	3.3	0.3	2.0	5.9	-0.1	-0.9	-0.1	0.0	...	0	0	0	0	1	0	0	1	0	0
4	5	0.5	-0.2	-0.3	-0.0	-0.4	0.0	-0.1	-0.3	-0.2	...	0	1	0	0	0	0	0	1	0	0
7	8	-0.2	-0.6	-0.5	-0.5	-0.5	-0.6	1.9	0.2	0.1	...	0	0	0	0	1	0	0	1	0	0
8	9	0.2	-0.5	-0.2	-0.4	-0.3	-0.1	-0.2	0.1	-0.1	...	0	0	1	0	0	0	1	0	0	0
9	10	1.1	-0.9	-0.6	-0.6	-0.4	-0.7	-0.8	0.9	0.4	...	0	0	1	0	0	0	0	1	0	0
10	11	0.2	-0.3	-0.3	-0.5	-0.4	-0.6	0.4	-0.2	-0.2	...	0	0	0	0	1	0	0	1	0	0

Logistička regresija također je definirala sljedećih pet varijabli kao najznačajnijih varijabli za predviđanje nastavka poslovanja poduzeća s pripadajućim koeficijentima:

1. Stupac GL= **Ukupne obveze / Kapital**, koeficijent = 0,37
2. Stupac II= **Ukupne obveze / (Kapital + Rezerve)**, koeficijent = 0,36
3. Stupac IT= **Dugoročne obveze / Ukupna imovina**, koeficijent = 0,27
4. Stupac IY= **EBIT / Trošak kamata**, koeficijent = 0,22

5. Stupac GX= **Dugotrajna imovina / (Kapital + Dugoročne obveze)**,
koeficijent = 0,21

Ukoliko se model proširi za dvije dodatne najznačajnije varijable, model izdvaja sljedeće dvije varijable:

6. Stupac IB= **Radni kapital / Prihodi od prodaje**, koeficijent = 0,20
7. Stupac IB= **Kvaliteta financijskih izvještaja** (loša, dovoljna zadovoljavajuća, dobra), koeficijent = 0,19

Python u rezultatima modela prikazuje sve linije, odnosno poduzeća, i daje prognozu nastavka poslovanja prema metodi umjetne neuronske mreže i logističke regresije što je prikazano na slici 10.

Slika 10. Prikaz dijela rezultata testiranja podataka na modelu logističke regresije i umjetne neuronske mreže (iz Python-a)

Out [8]:

	A	C	D	E	F	G	H	I	J	K	...	VQ	VR	VS	VT	VU	VV	VW	VX	LogReg_Predictions_for_col_B	ANN_Predictions_for
1	2	-1.4	3.3	0.3	2.0	5.9	-0.1	-0.9	-0.1	0.0	...	0	0	0	0	1	0	0	1	0	0
2	3	0.6	-0.5	-0.3	-0.4	-0.5	0.5	0.9	0.2	-0.1	...	0	0	0	0	1	0	0	1	0	0
3	4	-0.9	-0.4	0.4	-0.5	-0.3	-0.5	1.5	0.0	-0.0	...	0	0	1	0	0	0	0	1	0	0
5	6	-0.3	0.1	0.4	0.5	-0.2	0.0	-0.2	-0.3	-0.2	...	0	1	0	0	0	0	0	1	0	0
6	7	-0.4	0.6	-0.5	0.1	0.1	-0.5	-0.9	-0.4	-0.2	...	0	1	0	0	0	0	0	1	0	0
7	8	-0.2	-0.6	-0.5	-0.5	-0.5	-0.6	1.9	0.2	0.1	...	0	0	0	0	1	0	0	1	0	0
8	9	0.2	-0.5	-0.2	-0.4	-0.3	-0.1	-0.2	0.1	-0.1	...	0	0	1	0	0	0	1	0	0	0
9	10	1.1	-0.9	-0.6	-0.6	-0.4	-0.7	-0.8	0.9	0.4	...	0	0	1	0	0	0	1	0	0	0
10	11	0.2	-0.3	-0.3	-0.5	-0.4	-0.6	0.4	-0.2	-0.2	...	0	0	0	0	1	0	0	1	0	0
12	13	-0.0	-0.4	-0.5	-0.2	-0.1	-0.0	-0.9	0.1	-0.1	...	0	1	0	0	0	0	0	1	0	0
13	14	-0.7	1.4	1.9	0.3	0.6	0.1	-0.9	-0.4	-0.2	...	0	0	0	0	1	0	0	1	0	0
14	15	1.5	-0.5	-0.4	-0.4	-0.5	-0.3	-0.9	0.2	-0.2	...	0	0	0	0	1	0	0	1	0	0
16	17	-1.4	7.8	0.4	5.0	5.6	0.8	-0.9	-0.3	-0.2	...	0	0	0	0	1	0	0	1	0	0
18	19	1.0	-0.3	0.8	-0.2	-0.4	0.3	-0.6	-0.3	-0.2	...	1	0	0	0	0	0	0	1	0	0
19	20	-0.1	-0.5	-0.4	-0.6	-0.1	-0.2	-0.9	0.1	-0.1	...	0	0	0	0	1	0	0	1	0	0
20	21	0.6	-0.5	-0.5	-0.5	-0.5	-0.3	0.5	-0.0	-0.2	...	0	1	0	0	0	0	0	1	0	0
21	22	0.5	-0.0	0.8	0.2	-0.3	0.3	-0.9	-0.4	-0.3	...	0	1	0	0	0	0	0	1	0	0
22	23	-0.7	-0.3	1.6	-0.4	-0.4	-0.3	1.3	-0.1	-0.1	...	1	0	0	0	0	0	0	1	0	0

23	24	-0.3	-0.2	0.3	-0.2	-0.3	-0.1	0.4	-0.2	-0.2	...	0	0	0	0	1	0	0	1	0	0
24	25	0.6	-0.4	-0.3	-0.6	-0.5	-0.5	0.3	-0.0	-0.2	...	0	0	1	0	0	0	0	1	0	0
27	28	1.6	-0.5	0.1	-0.6	-0.5	0.3	-0.9	-0.1	-0.2	...	0	0	1	0	0	0	0	1	0	0
28	29	-0.5	0.9	0.6	-0.0	0.2	0.3	-0.9	-0.4	-0.3	...	0	0	1	0	0	0	0	1	0	0
30	31	1.4	-0.4	-0.0	-0.2	-0.5	0.3	-0.7	-0.4	-0.2	...	0	0	0	0	1	0	0	1	0	0
32	33	-0.6	0.7	-0.0	-0.0	0.4	-0.2	-0.9	-0.1	-0.2	...	0	0	1	0	0	0	0	1	0	0
33	34	-0.5	-0.3	1.2	-0.1	-0.3	0.3	0.6	0.0	-0.1	...	0	0	1	0	0	0	0	1	0	0
35	36	1.5	-0.7	-0.5	-0.6	-0.5	-0.2	-0.7	1.5	-0.1	...	0	0	1	0	0	0	0	1	0	0
36	37	-0.1	0.3	-0.5	0.2	-0.1	0.2	-0.9	-0.4	-0.2	...	0	0	1	0	0	0	0	1	0	0
37	38	-0.7	-0.2	-0.2	0.1	-0.4	0.4	1.7	-0.1	-0.1	...	0	0	1	0	0	0	0	1	0	0
38	39	-0.7	-0.0	-0.3	0.2	-0.1	-0.3	0.3	-0.1	-0.2	...	0	0	1	0	0	0	0	1	0	0
40	41	-0.8	-0.3	-0.4	-0.4	0.2	-0.6	-0.4	0.0	0.1	...	0	0	1	0	0	0	0	1	0	0
...
1757	1758	-0.2	-0.3	0.2	-0.1	-0.2	-0.0	-0.2	-0.1	-0.1	...	0	0	1	0	0	0	0	1	1	1
1758	1759	0.0	-0.2	0.1	-0.1	-0.3	-0.1	-0.1	-0.1	-0.2	...	0	0	1	0	0	0	0	1	1	1
1761	1762	-0.3	-0.2	0.1	-0.2	-0.2	-0.1	0.1	-0.1	-0.2	...	0	0	0	1	0	0	0	1	1	1
1762	1763	-0.9	-0.0	-1.2	0.0	1.6	20.6	-0.8	-0.1	-0.0	...	0	0	0	1	0	0	0	1	1	1
1763	1764	1.0	-0.3	0.1	-0.0	-0.4	-0.1	-0.8	-0.9	-0.2	...	0	0	1	0	0	0	0	1	1	1
1764	1765	0.4	-0.2	-0.1	-0.2	-0.3	-0.1	-0.7	-0.1	-0.2	...	0	0	0	1	0	0	0	1	1	1
1765	1766	-0.5	0.0	0.2	-0.2	-0.3	-0.1	0.6	-0.1	-0.2	...	0	0	0	1	0	0	0	1	1	1
1767	1768	1.3	-1.0	-1.0	-0.2	-0.4	-0.1	-0.8	-0.4	-0.1	...	0	0	0	1	0	0	1	0	1	1
1768	1769	-0.5	-0.1	0.2	-0.0	0.3	-0.1	-0.8	-0.1	-0.1	...	0	0	0	1	0	0	0	1	1	1
1769	1770	0.6	-0.3	0.1	-0.0	-0.3	-0.1	-0.8	-0.0	-0.2	...	0	0	0	1	0	0	0	1	1	1

Vrijednost rezultata modela se ogleda u definiranom algoritmu, u programskom jeziku Python, i utreniranoj umjetnoj neuronskoj mreži u koju se može unijeti novi set podataka za pojedino poduzeće ili skupinu poduzeća, a model će kao rezultat izbaciti predikciju nastavka poslovanja poduzeća. Model će za predikciju koristiti utrenirano ponašanje neuronske mreže temeljem uzorka unesenog u ovom radu na setu podataka za posljednjih pet godina.

5.6. Moguća ograničenja upotrebe modela

Algoritam funkcionira na način da je potrebno unijeti sveobuhvatni i kvalitetni set podataka u kod, odnosno u utreniranu neuronsku mrežu. Temeljem naučenog ponašanja i utjecaja varijabli na ishod poslovanja, neuronska mreža može izračunati očekivani nastavak ili problem nastavka u poslovanju poduzeća.

Ograničenja u upotrebi modela odnose se na kvalitetu i obuhvatnost podataka koji se unose u model kao ulazne varijable za pojedino poduzeće. Ukoliko podaci kao indikatori nisu ispravni ili su indikatori ispravno izračunati, ali temeljeni na nekvalitetnim

podacima iz financijskih ili drugih izvještaja, neuronska mreža neće dati ispravni output kojeg će donosioci odluka sa sigurnošću moći koristiti u poslovnim aktivnostima. To se ograničenje ne odnosi na algoritam mreže, već na ulazne varijable i predstavlja osnovno ograničenje upotrebe modela.

5.7. Mogućnosti primjene novog modela u post tranzicijskim zemljama

Podaci korišteni u definiciji modela prikupljeni su u Republici Hrvatskoj koja reprezentativno predstavlja tranzicijske zemlje te se može pretpostaviti da poduzeća u svim regionalnim tranzicijskim zemljama posluju u sličnim makroekonomskim, institucionalnim i tržišnim uvjetima.

Iz tog se razloga model može primijeniti u bilo kojoj tranzicijskoj zemlji u regiji (npr. Sloveniji, Srbiji, Bosni i Hercegovini, Makedoniji) pod pretpostavkom dostupnosti svih podataka koji su korišteni kao input za model, odnosno za algoritam. Ukoliko su podaci dostupni i točni, model se može primijeniti kao pomoć pri procjeni nastavka poslovanja poduzeća za bilo koju interesnu skupinu vezanu za poduzeće: financijske institucije, potencijalni partneri, dobavljači i ostali.

Očekivana uporaba modela najizvjesnija je u financijskim institucijama u tranzicijskim zemljama zbog potrebe za jednostavnim i brzim modelima skoringa poduzeća koji su dovoljno učinkoviti da bi ubrzali kreditni proces, ali financijskim institucijama osigurali optimalno upravljanje rizicima. Preporučuje se primjena modela na malim i srednjim poduzećima zbog jednostavnijih i transparentnijih pravila poslovnog ponašanja, te time i točnijim podacima iz financijskih izvještaja na kojim je model parcijalno temeljen.

6. USPOREDBA UČINKOVITOSTI NOVOG MODELA PREDVIĐANJA NASTAVKA POSLOVANJA PODUZEĆA U RH S TRADICIONALNIM MODELIMA

U ovom poglavlju prikazati će se osnovni rezultati prvog i drugog empirijskog istraživanja provedenog u radu, te će se usporediti učinkovitost tradicionalnih modela predviđanja nastavka poslovanja i novog suvremenog modela. Temeljem rezultata empirijskih istraživanja potvrditi će se ili opovrgnuti postavljene hipoteze.

U prvom dijelu rada provedeno je empirijsko istraživanje učinkovitosti predviđanja poslovanja poduzeća na temelju tri modela: Altman, Ohlson i Zmijewski primjenom različitih statističkih postupaka u skladu s problemom i predmetom istraživanja. Istraživanje je obuhvatilo sva poduzeća u uzorku, kao i poduzeća klasificirana u pojedine skupine industrija. Uz istraživanje učinkovitosti predviđanja, definirane su i najznačajnije varijable u modelima, te ocjene točnosti predviđanja.

Osnovni rezultati prvog empirijskog istraživanja, koji obuhvaćaju tri glavna područja ocjene tradicionalnih modela, su sljedeći:

1. Ocjena učinkovitosti

- a. Rezultati analize ukazuju na učinkovitost Altmanovog Z'-score-a u prognozi poslovanja dobrih poduzeća, posebno u razdoblju od dvije godine prije nastupanja poslovnog događaja, dok je slabija za prognozu loših poduzeća.
- b. Učinkovitost prognoze Ohlson pokazatelja može se smatrati prihvatljivom u razdoblju od jedne godine prije nastupanja poslovnog događaja, iako postoji rizik od Pogreške tipa 1.
- c. Zmijewski pokazatelj je učinkovit u prognozi poslovanja poduzeća i četiri godine prije nastupanja poslovnog događaja uz ograničenje zbog visoke standardne devijacije uzorka.

2. Najznačajnije varijable koje koreliraju s vrijednostima pokazatelja modela

Prema utjecaju na vrijednost Altman, Ohlson ili Zmijewski pokazatelja, najznačajnije varijable su sljedeće:

- Knjigovodstvena vrijednost kapitala / Knjigovodstvena vrijednost obveza
 - Ukupan prihod od prodaje / Ukupna imovina
 - Ukupne obveze / Ukupna imovina
 - Kratkoročne obveze / Kratkotrajna imovina
 - Radni kapital / Ukupna imovina
- a. Varijable „knjigovodstvena vrijednost kapitala / knjigovodstvena vrijednost obveza“ te „ukupan prihod od prodaje / ukupna imovina“ statistički najznačajnije koreliraju s Altmanovim Z'-score-om kod dobrih i loših poduzeća. Korelacija je pozitivna što znači da će povećanje ili smanjenje varijabli najviše utjecati na rast ili pad Altmanovog Z'-score-a.
- b. Varijable „ukupne obveze / ukupna imovina“ i „kratkoročne obveze / kratkotrajna imovina“ statistički najznačajnije pozitivno koreliraju s Ohlsonovim score-om kod dobrih poduzeća. Povećanje ili smanjenje varijabli najviše će utjecati na rast ili pad Ohlsonovog score-a. Varijabla „radni kapital / ukupna imovina“ statistički značajno korelira s Ohlsonovim score-om kod dobrih i loših poduzeća, ali s negativnim predznakom, što znači da smanjenje tog pokazatelja utječe na rast Ohlsonovog pokazatelja tj. povećanje rizika od stečaja.
- c. Varijabla „ukupne obveze / ukupna imovina“ najznačajnije statistički korelira sa Zmijewski score-om kod dobrih i loših poduzeća. Korelacija je pozitivna što znači da će povećanje ili smanjenje najviše utjecati na rast ili pad Zmijewski score-a. Varijabla „kratkotrajna imovina / kratkoročne obveze“ također statistički značajno korelira kod dobrih poduzeća, ali je smjer negativan, što znači da će pogoršanje varijable utjecati na povećanje Zmijewski score-a tj. porast rizika od stečaja.

3. Ocjena točnosti

- a. Ukupna ocjena točnosti Altmanovog modela iznosi 85%, 86%, 83%, 79%, 81% i 79% od prve do šeste godine promatranja. Pogreška tipa 1 Altmanovog modela iznosi 17% za prvu godinu te 16% od druge do šeste godine prije promatranja poslovanja, a Pogreška tipa 2 iznosi 4%, 3%, 6%, 8%, 8%, te 9% od prve do šeste godine.
- b. Ukupna ocjena točnosti Ohlsonovog modela iznosi 63%, 62%, 57%, 54%, 55% od prve do pete godine. Pogreška tipa 1 Ohlsonovog modela znatno je viša od Altmanovog modela i iznosi 27% za prvu godinu te 28% za drugu i treću godinu, 27% za četvrtu i 29% za petu godinu prije promatranja poslovanja, a Pogreška tipa 2 iznosi 43%, 45%, 53%, 58% te 56% od prve do pete godine.
- c. Ukupna ocjena točnosti Zmijewski modela iznosi 82%, 79%, 77%, 73%, 72% i 71% od prve do šeste godine. Pogreška tipa 1 Zmijewski modela iznosi 39% za prvu godinu te 46% za drugu, 47% za treću, 49% za četvrtu, 53% za petu i 56% za šestu godinu prije promatranja poslovanja, a Pogreška tipa 2 iznosi 5%, 6%, 8%, 14%, 12% te 11% od prve do šeste godine.

Osnovni rezultati drugog empirijskog istraživanja, obuhvaćajući također tri glavna područja ocjene, su sljedeći:

1. Ocjena učinkovitosti

- a. Umjetna neuronska mreža je ostvarila sljedeće rezultate uspješnosti: uspješnost modela da ne označi pozitivnim poduzećima, poduzeća koja loše posluju iznosi 96,96 %, a uspješnost modela u ispravnom klasificiranju poduzeća koja dobro posluju iznosi 97,16 %.

- b. Logistička regresija je ostvarila sljedeće rezultate uspješnosti: uspješnost modela da ne označi pozitivnim poduzećima, poduzeća koja loše posluju iznosi 96,91 %, a uspješnost modela u ispravnom klasificiranju poduzeća koja dobro posluju iznosi 95,74 %.

2. Najznačajnije varijable koje koreliraju s vrijednostima pokazatelja modela

Prema utjecaju na nastavak poslovanja poduzeća, najznačajnijim varijablama pokazale su sljedeće:

- Ukupne obveze / Kapital
- Ukupne obveze / (Kapital + Rezerve)
- Dugoročne obveze / Ukupna imovina
- EBIT / Trošak kamata
- Dugotrajna imovina / (Kapital + Dugoročne obveze)
- Radni kapital / Prihodi od prodaje
- Kvaliteta financijskih izvještaja

3. Ocjena točnosti

- a. Ukupna ocjena točnosti modela definiranog temeljem umjetne neuronske mreže, odnosno postotak ispravno klasificiranih poduzeća (dobra kao dobra te loša kao loša) iznosi 97,69%.
- b. Ukupna ocjena točnosti modela definiranog temeljem logističke regresije, odnosno postotak ispravno klasificiranih poduzeća (dobra kao dobra te loša kao loša) iznosi 97,13%.

Ovim rezultatima empirijskog istraživanja i usporedbom točnosti i učinkovitosti tradicionalnih modela i novodefiniranog suvremenog modela potvrđena je superiornost novog modela, ali i učinkovitost tradicionalnih modela.

Time je potvrđena temeljna hipoteza rada koja je glasila: „Suvremeni model predviđanja temeljen na kvantitativnim i kvalitativnim varijablama, odabranih pomoću statističke metode neuronskih mreža uvažavajući specifičnosti hrvatskog gospodarskog okruženja, omogućava učinkovitiju procjenu nastavka poslovanja u poduzećima u odnosu na postojeće modele i na taj način doprinosi stabilnosti i održivosti nacionalne ekonomije.“

Prve dvije pomoćne hipoteze (H1 i H2) potvrđene su rezultatima prvog empirijskog istraživanja, što je objašnjeno u prethodnim poglavljima rada.

Rezultatima drugog empirijskog istraživanja i njihovom usporedbom s rezultatima prvog empirijskog istraživanja, potvrđena je i treća pomoćna hipoteza (H3) koja je glasila: „Odabirom kvantitativnih (financijskih i nefinancijskih) i kvalitativnih varijabli temeljem statističke metode neuronskih mreža moguće je predložiti novi model s učinkovitijim svojstvima predviđanja nastavka poslovanja poduzeća u hrvatskom gospodarstvu u odnosu na modele temeljene samo na kvantitativnim financijskim pokazateljima.“

7. ZAKLJUČAK

Nastavak poslovanja poduzeća je temeljna pretpostavka poslovanja poduzeća te podrazumijeva pri upravljanju primjenu načela odgovornosti i transparentnog izvještavanja o poslovanju što je pretpostavka donošenja kvalitetnih odluka. Predviđanje nastavka poslovanja uglavnom se u praksi veže uz revizijske angažmane te je u posljednjih 35 godina upravo ta tema izrasla u jednu od glavnih tema u korporativnim financijama. Procjena nastavka poslovanja poduzeća je od velike važnosti za cjelokupnu poslovnu zajednicu i sve interesne skupine u lancu vrijednosti poslovanja poduzeća. Veliki se broj akademskih istraživača bavio i bavi razvojem modela predviđanja nastavka poslovanja temeljenim na različitim statističkim metodama koji bi svim zainteresiranim skupinama mogli pomoći u procjeni nastavka poslovanja određenog poduzeća.

Jedni od najpopularnijih modela za predviđanje nastavka poslovanja poduzeća su modeli Altmana, Zmijewskog i Ohlsona, koji su analizirani u radu. Postoje određeni nedostaci modela koji utječu na njihovu učinkovitost, a odnose se na statičnost statističkih tehnika koje koriste, računovodstveno temeljene parametre te neprikladne uzorke na kojima su modeli razvijeni što smanjuje njihovu općenitu upotrebu. No, unatoč kritikama modela, kroz brojna istraživanja nije jednoglasno dokazano da su u svim ekonomskim uvjetima oni manje učinkoviti od modela baziranih na umjetnim neuronskim mrežama ili teorijskim modelima, ili od modela koji uz računovodstvene podatke koriste i podatke tržišta, već njihova učinkovitost ovisi o karakteristikama specifičnog tržišta, privrednoj strukturi i uvjetima poslovanja poduzeća.

Iako nema jednoglasne odluke da li bolju učinkovitosti ostvaruju tradicionalni ili suvremeni modeli, ipak se u posljednjih nekoliko godina metoda neuronskih mreža predlaže kao prikladna i bolja metoda od tradicionalnih statističkih metoda koja daje točnije rezultate bez potrebe poštivanja striktnih statističkih pretpostavki tradicionalnih metoda, te se stoga smatra metodom sa značajnim potencijalom u procjeni nastavka poslovanja poduzeća. Značajan broj istraživača uspješno primjenjuje umjetne neuronske mreže u financijama, te se osim predviđanja stečaja i financijskih poteškoća poduzeća, koriste za predviđanje tečajeva valuta i cijena dionica.

Empirijskim istraživanjem u radu se potvrdila hipoteza da su Altmanov Z'-score model, Zmijewski model i Ohlson model, temeljeni na kvantitativnim financijskim pokazateljima, učinkoviti u predviđanju nastavka poslovanja poduzeća u dosadašnjim makroekonomskim uvjetima u Hrvatskoj koji su omogućavali da poduzeća unatoč svojim lošim rezultatima i dalje posluju. Također se potvrdilo da postoji razlika u učinkovitosti svojstava predviđanja Altmanovog Z'-score modela, Zmijewski modela i Ohlson modela u hrvatskom gospodarstvu, te da su Altman Z'-score vrijednosti imale najtočnije rezultate i ocjene ukupne učinkovitosti, zatim Zmijewski vrijednosti te Ohlson.

Jedno od osnovnih pitanja koje se postavlja glasi: da li financijska situacija i buduće poslovanje poduzeća pokazuju uzročno posljedični uzorak koji može biti identificiran i definiran, te, ako ima, može li isti biti diskriminacijski faktor među različitim kategorijama poduzeća? Drugim empirijskim istraživanjem u radu, dokazalo se da postoji uzorak i da se može definirati model koji će prepoznati diskriminacijski faktor.

Temeljna hipoteza, potvrđena u radu, bila je da suvremeni model predviđanja temeljen na kvantitativnim i kvalitativnim varijablama, odabranih pomoću statističke metode neuronskih mreža uvažavajući specifičnosti hrvatskog gospodarskog okruženja, omogućava učinkovitiju procjenu nastavka poslovanja u poduzećima u odnosu na postojeće modele i na taj način doprinosi stabilnosti i održivosti nacionalne ekonomije. Rezultati istraživanja potvrdili su postavljenu hipotezu.

Novi model predviđanja nastavka poslovanja definiran je temeljem umjetnih neuronskih mreža, a za programsku izvedbu modela korišten je dinamički programski jezik otvorenog koda Python 3. Važna stavka definicije modela bio je odabir opisnih varijabli. Za razliku od većine drugih autora i modela, kao ulazne varijable koristile su se financijski i nefinancijski pokazatelji iz praktične primjene u bankarskom sektoru, te makroekonomski pokazatelji čije su vrijednosti iste za sva poduzeća na tržištu, ali različito utječu na poslovanje svakog od njih. Značajnost umjetnih neuronskim mreža leži u njihovoj sposobnosti da definiraju veze između varijabli temeljeno na velikom

uzorku. Iz tog su razloga ostavljene umjetnoj neuronskoj mreži sve varijable koje su inicijalno odabrane bez obzira na sam način odabira varijabli.

Model definiran temeljem umjetne neuronske mreže ostvario je sljedeće rezultate uspješnosti: postotak ispravno klasificiranih poduzeća od 97,7%, uspješnost modela da ne označi pozitivnim poduzećima, poduzeća koja loše posluju od 97,0%, te uspješnost modela u ispravnom klasificiranju poduzeća koja dobro posluju od 97,2%.

Model je također rezultirao varijablama s najznačajnijim utjecajem na nastavak poslovanja poduzeća:

1. Ukupne obveze / Kapital
2. Ukupne obveze / (Kapital + Rezerve)
3. Dugoročne obveze / Ukupna imovina
4. EBIT / Trošak kamata
5. Dugotrajna imovina / (Kapital + Dugoročne obveze)
6. Radni kapital / Prihodi od prodaje
7. Kvaliteta financijskih izvještaja

Očekivana uporaba novog modela najizvjesnija je u financijskim institucijama u tranzicijskim zemljama zbog potrebe za jednostavnim i brzim modelima skoringa poduzeća koji su dovoljno učinkoviti da bi ubrzali kreditni proces, a financijskim institucijama osigurali optimalno upravljanje rizicima. Preporučuje se primjena modela na malim i srednjim poduzećima zbog jednostavnijih i transparentnijih pravila poslovnog ponašanja, te time i točnijim podacima iz financijskih izvještaja na kojima je model parcijalno temeljen.

U budućim istraživanjima mogu se, u definiranju prediktivnog modela, primijeniti druge tehnike umjetne inteligencije, primjerice druge metode neuronskih mreža, data mining, genetički algoritmi ili ostale metode. Također, može se primijeniti duži vremenski period ili se mogu uključiti i mala, tj. mikro poduzeća u istraživanje.

8. SMJERNICE ZA DALJNJA ISTRAŽIVANJA

Budući je rezultat ovog doktorskog rada model za predviđanje nastavka poslovanja poduzeća koji se može primijeniti u praksi te unaprijediti upravljanje rizicima u poslovanju poduzeća ili financijskih institucija, otvara se prostor drugim istraživačima za daljnja istraživanja i nadogradnju modela.

U budućim istraživanjima mogu se, u definiranju prediktivnog modela, primijeniti druge tehnike umjetne inteligencije, primjerice druge metode neuronskih mreža, data mining, genetički algoritmi ili ostale metode. Također, može se primijeniti duži vremenski period ili se mogu uključiti i mala, tj. mikro poduzeća (ispod 7 milijuna HRK godišnjeg prihoda) u istraživanje.

Jedna od smjernica za daljnja istraživanja može biti i razvoj modela za definiranje post-stečajnog ishoda ili rezultata. Takva istraživanja do sada nisu bila zastupljena u Republici Hrvatskoj zbog malog broja poduzeća koja su izašla iz restrukturiranja pa se nije mogao formirati statistički validan uzorak kao temelj istraživanja. No posljednje četiri godine, porastao je broj poduzeća u predstečajnim nagodbama i procesu restrukturiranja te bi se uzorak mogao formirati. Umjetne neuronske mreže također mogu biti primijenjene u drugim područjima financijske analize, kao što je primjerice analiza učinkovitosti poslovanja te se daljnje istraživanje primjene mreža može nastaviti i u tom smjeru.

Druga smjernica daljnjeg istraživanja može obuhvatiti razvoj metodologije odabira ulaznih varijabli prilagođene neuronskim mrežama i lokalnim specifičnostima tržišta te utjecaju pojedinih grupa varijabli na poslovanje poduzeća. U ovom radu su ukratko prikazane mogućnosti različitih metoda selekcije varijabli, a one se mogu dalje razrađivati kako bi se dobio optimalni input za razvoj modela. Također, jedan od ključnih faktora uspješnosti prediktivnog modela je i količina kvalitetnih podataka na temelju kojeg se postavlja model. Razvoj opsežnije baze podataka kroz duži vremenski rok od 5 godina bi osigurao definiranje još učinkovitijeg i točnijeg prediktivnog modela.

POPIS LITERATURE

Knjige i članci

1. Agarwal, V., Taffler, R.: Comparing the performance of market-based and accounting-based bankruptcy forecasting models, *Journal of Banking & Finance*, Vol. 32, No. 8, 2008., p. 1541-1551
2. Alareeni, B., Branson, J.: Predicting Listed Companies' Failure in Jordan Using Altman Models: A Case Study, *International Journal of Business and Management*, Vol. 8, No. 1, 2013., p. 113-126
3. Altman, E.I.: Financial Ratios, Discriminant Analysis and the Forecasting of Corporate Bankruptcy, *The Journal of Finance*, 23 (4), 1968., p. 89-609
4. Altman, E.I.: *Corporate financial distress and bankruptcy*, 2nd ed, John Wiley&Sons, New York, 1993.
5. Altman, E.I.: *Predicting financial distress of companies, revisiting the Z'-score and ZETA model*, Stern school of finance, New York University, 2000.
6. Altman, E.I.: *Corporate distress prediction models in a turbulent economic and Basel II environment*, Stern school of finance, New York University, 2002.
7. Altman, E.I.: The Altman Z-score after 50 Years: Use and Misuse, *Enterprising investor blog*, Interview proveo Larry Cao, <https://blogs.cfainstitute.org/investor/2016/02/09/the-altman-Z'-score-after-50-years-use-and-misuse/> (16.11.2016.)
8. Altman, E.I., Iwanicz-Drozdowska, M., Laitinen, E.K., Suvas, A.: *Distressed Firm and Bankruptcy prediction in an international context: a review and empirical analysis of Altman's Z'-score Model*, NYU Stern, 2016.
9. Altman, E.I., Eisenbeis, R., Sinkey, J: *Applications of classification procedures in business, banking and finance*, JAI Press, Greenwich, CT, 1981.
10. Altman, E.I., Marco, G., Varetto, F.: "Corporate Distress Diagnosis: Comparisons Using Linear Discriminant Analysis and Neural Networks (the Italian Experience)," *Journal of Banking and Finance*, Vol. 18, No. 3, 1994., p. 505-529
11. Altman E.I., Halderman, R., Narayana, P.: Zeta Analysis. *Journal of Banking and Finance*, Vol. 1, 1977., p. 29-54

12. Altman, E., Narayanan, P.: International survey of business failure classification models, *Financial markets, institutions and instruments*, Vol. 6, No. 2, 1997., p. 1-57
13. Altman, E.I., Rijken, H.: *The Z-Metrics methodology for estimating company credit ratings and default risk probabilities*, Stern school of finance, New York University, 2010.
14. Altman, E.I., Sabato, G.: Modeling credit risk for SMEs: Evidence from the US market, *Abacus*, Vol. 43, No. 3, 2007., p. 332–357
15. Aljinović Barać, Ž., Belak, V.: Business excellence (BEX) indeks – za procjenu poslovne izvrsnosti tvrtki na tržištu kapitala u Republici Hrvatskoj, *Računovodstvo, revizija i financije*, Vol. 10, 2007., p. 15-25
16. Anjum, S.: Business bankruptcy forecasting models: A significant study of the Altman's Z'-score model, *Asian journal of management research*, Vol. 3, No. 1, 2012.,p. 212-219
17. Avenhuis, J.O.: *Testing the generalizability of the bankruptcy forecasting models of Altman, Ohlson and Zmijewski for Dutch listed and large non-listed firms*, Study, The School of Management and Governance, University of Twente, The Netherlands, 2013.
18. Balcaen, S., Ooghe, H.: 35 years of studies on business failure: an overview of the classical statistical methodologies and their related problems, *The British Accounting review*, Vol. 38, No. 1, 2006., p. 63-93
19. Bauer, J., Agarwal, V.: Are hazard models superior to traditional bankruptcy forecasting approaches? A comprehensive test, *Journal of Banking and finance*, Vol. 40, 2014., p. 432-442
20. Beams, J., Yan, Y. :The effect of financial crisis on auditor conservatism: US evidence, *Accounting Research Journal*, Vol. 28, No. 2, 2015., p. 160-171
21. Beaver, W.H.: Financial Ratios as predictors of failure. *Journal of Accounting Research*, Vol. 4, 1966., p. 71-111
22. Begley, J., Ming, J. & Watts: Bankruptcy classification errors in the 1980s: An empirical analysis of Altman's and Ohlson's models, *Review of Accounting Studies*, Vol. 1, 1996., p. 267-284
23. Bellovary, J., Giacomin, D., Akers, M.: A review of going concern prediction studies:1976 to present, *Journal of Business & Economics Research*, No. 5, 2007., p.9-28

24. Boritz, J.E., Sun, J.: Predicting going concern risks in Canada, University of Waterloo, School of Accountancy, 2004.
25. Boritz, J.E., Kennedy, D.B., Sun, J.Y.: Predicting business failures in Canada, University of Waterloo, School of Accountancy, 2007., <http://papers.ssrn.com> (20.10.2014.)
26. Branson, J., Alareeni, B.: Predicting Listed Companies' Failure in Jordan Using Altman Models: A Case Study, *International Journal of Business and Management*, Vol. 8, No. 1, 2013., p. 113-126
27. Ciampi, F., Gordini, N.: Small Enterprise default prediction modeling through artificial neural networks: an empirical analysis of Italian small enterprises, *Journal of Small Business Management*, Vol. 51, 2013., p. 23-45
28. Chen, W., Du, Y.: Using neural networks and data mining techniques for the financial distress forecasting model, *Expert system with applications*, Vol. 36, 2009., p. 4075-4086
29. Dalbelo Bašić, B.: Umjetne neuronske mreže, Materijali sa predavanja, Zavod za elektroniku, mikroelektroniku i inteligentne sustave, Fakultet elektrotehnike i računarstva, 2008.
30. Deakin, E.B.: A Discriminant Analysis of Predictors of Business Failure, *Journal of Accounting Research*, Spring, 1972., p. 167-179
31. Deverić, O.: Istraživanje solventnosti hrvatskih poduzeća pokazateljima Altmana i Kraliceka, Magistarski rad, Ekonomski fakultet Zagreb, Zagreb, 2002.
32. Du Jardin, P.: Predicting bankruptcy using neural networks and other classification methods: The influence of variable selection techniques on model accuracy, *EDHEC Business School, Neurocomputing*, Vol. 73, No. 10-12, 2010., p. 2047–2060
33. Edmister, R.: An empirical test of financial ratio analysis for small business failure forecasting, *Journal of Financial and Quantitative Analysis*, March 1972., p. 1477-1493
34. Feldmann, D., Read, W.J.: Going-concern audit opinions for bankrupt companies – impact of credit rating, *Managerial Auditing Journal*, Vol. 28, No. 4, 2013., p. 345-363
35. Fitzpatrick, P.J.: A comparison of ratios of successful industrial enterprises with those of failed companies, *Certified Public Accountant*, 1932., p. 598-605

36. Gaffeo, E., Santoro, E.: Business failures, macroeconomic risk and the effect of recessions on long run growth: a panel cointegration approach, *Journal of Economics and Business*, Vol. 61, 2009., p. 435-452
37. Grice, J.S., Ingram, R.W.: Tests of the generalizability of Altman's bankruptcy forecasting model, *Journal of Business Research*, Vol. 54, 2001., p. 53-61
38. Grice, J.S., Dugan, M.T.: Re-estimations of the Zmijewski and Ohlson bankruptcy prediction models, *Advances in Accounting*, Vol. 20, 2003., p. 77-93
39. Hall, S.G.: The macroeconomic and microeconomic factors influencing financial distress: A comparison of Altman's 1983 and 1993 bankruptcy forecasting models, Dissertation, School of Business and Entrepreneurship, Nova Southeastern University, Florida, United States, 2002.
40. Harrison, M.E.: A study of Altman's revised four-variable (1983) Z'-score bankruptcy predicting model for asset sizes and manufacturing and service companies, Dissertation, H. Wayne Huizenga School of Business and Entrepreneurship, Nova Southeastern University, Florida, United States, 2005.
41. Hillegeist et al: Assessing the probability of bankruptcy, *Review of Accounting Studies*, Vol. 9, 2002., p. 5-34
42. Ivičić, L., Cerovac, S.: Procjena kreditnog rizika poduzeća u Hrvatskoj, *Financijska teorija i praksa*, Vol. 33, 2009., p. 385-413
43. Jagric V., Kracun D., Jagric T.: Does Non-linearity Matter in Retail Credit Risk Modeling?, *Journal of Economics and Finance*, 61(4), 2011., p. 384–402
44. Koh, H.C., Tan, S.S.: A neural network approach to the prediction of going concern status, *Accounting and Business Research*, Vol. 29, No. 3, 1999., p. 211-216
45. Koščak, S., Bešević Vlajo, M., Pribičević, V.: Predstečajne nagodbe - za mnoge tek odgoda stečaja, časopis Banka, www.banka.hr, objavljeno 13.07.2014.
46. Krajačić, D.: Neograničenosti vremena poslovanja, Hrvatska revizorska komora, Stručno savjetovanje ovlaštenih revizora, Prezentacija sa predavanja, 2012.
47. Kumar, R.G., Kumar, K.: A comparison of bankruptcy models, *International journal of marketing, financial services and management research*, Vol. 1, No. 4, 2012., p. 76-86

48. Kuruppu, N., Laswad, F., Oyelere, P.: The efficacy of liquidation and bankruptcy forecasting models for assessing going concern, *Managerial Auditing Journal*, Vol. 18, No. 6/7, 2003., p. 577-590
49. Kuruppu, K., Laswad, F., Oyelere, P.: Assessing going concern: The practical value of corporate failure models and auditors' perceptions, *Pacific Accounting Review*, Vol. 24, 2012.
50. Lacher, R.C., Coats, P.K., Fant, L.F.: A neural network for classifying the financial health of a firm, *European Journal of Operational research*, Vol. 85, 1995., p. 53-56
51. Laitinen, T., Kankaanpaa, M.: Comparative analysis of failure prediction methods: the Finnish case, *European Accounting Review*, Vol. 8, 1999., p. 67-92
52. Li, J., Rahgozar, R.: Application of the Z -Score model with consideration of total assets volatility in predicting corporate financial failures from 2000-2010, *Journal of Accounting and Finance*, Vol. 12, 2012., p. 11-19
53. Lawrence, J.R., Pongsatit, S., Lawrence, H.: The use of Ohlson o-score for bankruptcy prediction in Thailand, *The Journal of applied business research*, Vol. 31, No. 6, December 2015, p. 2069-2078
54. Lugovskaya, L: Predicting default of Russian SMEs on the basis of financial and non-financial variables, *Journal of Financial Services Marketing*, Vol. 14, March 2010., p. 301-313
55. Lykke, M., Pedersen, K. J., Vinther, H. M.: A failure-rate model for the Danish corporate sector, *Danmarks Nationalbank Working Papers*, No.16, 2004.
56. Međunarodni revizijski standardni, 750 Vremenska neograničenost poslovanja, *Hrvatska revizorka komora*, p. 536-553, 2009.
57. Memić, D., Rovčanin, A.: On the main financial predictors of credit default: evidence from Federation of Bosnia and Herzegovina, *Our Economy*, Vol. 1-2, 2012., p. 3-15
58. Moravec, T.: The bankruptcy in Czech Republic – influence of macroeconomic variables, *Acta academica karviniensia*, School of business administration in Karvina, Vol, 3, 2013., p.136-145
59. Neves, J.C., Vieira, A.: Improving Bankruptcy Prediction with Hidden Layer Learning Vector Quantization, *European Accounting Review*, Vol. 15, No. 2,2006., p. 253-271

60. Novak, B., Crnković, I.: Klasifikacija dužnika banke prema razini poslovnih problema na osnovi podataka iz osnovnih financijskih izvješća, *Ekonomski pregled*, Br. 58/1-2, Zagreb, 2007., p. 41-71
61. Ohlson, J.: Financial ratios and the probabilistic forecasting of bankruptcy, *Journal of Accounting Research*, Vol. 18, Spring, 1980., p. 109-131
62. Olden, J.D., Joy, M.K., Death, R.G.: An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data, *Ecological Modelling*, Vol. 178, No. 3-4, 2004., p. 389-397
63. Oluwo, M: Strategic use of financial ratio to prevent bankruptcy: a study of opportunity for business enterprises, *Dissertation*, Capella University, Minneapolis, 2007.
64. Paar, T.: Oblikovanje modela za predviđanje bankrota poduzeća u RH, *Diplomski rad*, Sveučilište u Splitu, Split, 2012.
65. Perez, M.: Artificial neural networks and bankruptcy forecasting: a state of the art, *Neural Computing and Application*, Vol. 15, No. 2, 2006., p. 154-163
66. Pindado, J., Rodrigues, L., Torre, C.: Estimating the Probability of Financial Distress: International Evidence, *SSRN Electronic Journal*, No January, 2006.
67. Prihatni, R., Zakaria, A.: The financial performance analysis using Altman Z-score and its effect to stock price banking sector in Indonesian stock exchange, *2nd International conference on business and economic research proceeding*, 2011., p. 798-805
68. Richter, F.: Introduction in Credit Risk Assessment Revisited: Methodological Issues and Practical Implications, *Working paper*, ECCBSDO, 2007.
69. Rios, T: The adaptation of Altman's corporate bankruptcy forecasting model to banks and thrifts and development of a banking model: a comparative analysis, *Dissertation*, H. Wayne Huizenga School of Business and Entrepreneurship, Nova Southeastern University, 2006.
70. Salimi, Y.A.: Validity of Altmans Z'-score model in predicting bankruptcy in recent years, *Academy of Accounting and Financial Studies Journal*, Vol. 19, No. 2, 2015., p. 233-238
71. Sami, B.J.: Macroeconomic variables in financial distress: A non-parametric method, *Working paper 2014-313*, IPAG Business school, Pariz, 2014.

72. Samkin, G., Low, M., Adams, T.: The Use of Z'-scores to predict finance company collapses, Research note, University of Waikato, New Zealand journal of applied business research, Vol. 10, No. 2, 2012., p. 69-82
73. Sajter, D.: Rano predviđanje poslovnih poteškoća banaka, Magistarski rad, Sveučilište J.J.Stossmayera, Ekonomski fakultet u Osijeku, Osijek, 2005.
74. Sajter, D.: Pregled određenih metoda i istraživanja poslovnih poteškoća uz predviđanje stečaja, Ekonomska misao i praksa, Časopis Sveučilišta u Dubrovniku, 2009., p. 429-452
75. Scott, J.: The probability of bankruptcy: A comparison of empirical predictions and theoretical models., Journal of Banking and Finance, September, 1981. p. 317-344
76. Shumway, T.: Forecasting bankruptcy more accurately: a simple hazard model, Journal of Business, January 2001., p. 101-124
77. Sormunen, N.: Bank officers' perceptions and uses of qualified audit reports, Accounting & Management, Vol. 1, No. 3, 2014., p. 215-237
78. Streitenberger, M., Miloš Sprčić, D.: Prediktivna sposobnost financijskih pokazatelja u predviđanju kašnjenja u otplati kredita, Ekonomski pregled, Vol. 62, Broj 7-8, 2011., p. 383-403
79. Šarlija, N.: Modeli kreditnog rizika u ocjenjivanju kreditne sposobnosti malih poduzetnika, Doktorska disertacija, Sveučilište u Zagrebu, Ekonomski fakultet u Zagrebu, Zagreb, 2002.
80. Šarlija, N., Jeger, M.: Comparing financial distress forecasting models before and after recession, Croatian operational research review, Split, 2011., p. 133-142
81. Šarlija, N., Zekić-Sušac, M., Benšić, M.: Insolvency forecasting by neural networks, Proceedings of the 12th international conference on operational research, Pula, 2008., p. 175-188
82. Šimundić, A.: Interval pouzdanosti, Biochemica Medica, Vol. 18, No. 2, 6./2008.
83. Škeljo, K.: Istraživanje mogućnosti primjene Altmanovog modela u hrvatskom gospodarstvu, Magistarski rad, Ekonomski fakultet Zagreb, Zagreb, 2000.
84. Tagesson, T., Öhman, P. :To be or not to be – auditors' ability to signal going concern problems, Journal of Accounting & Organizational Change, Vol. 11, No. 2, 2015.

85. Theodossiou, P.: Predicting shifts in the mean of a multivariate time series process: an application in predicting business failures, *Journal of American Statistical Association*, Vol. 88, No. 422, June 1993., p. 441-449
86. Thevnin, C.: A Comparative Examination of Bankruptcy Prediction: Altman MDA Study versus Luther ANN Study: A Test Of Predictive Strength Between The Two Techniques, *Doktorska disertacija*, Nova Southeastern University, 2003.
87. Tomas Žiković, I.: Dinamički pristup predviđanja poslovnih poteškoća korištenjem financijskih informacija na razini poduzeća i iz ekonomskog okruženja, *Ekonomski fakultet u Splitu, Split*, 2013., doktorska disertacija
88. Trigueiros, D., Taffler, R.: Neural networks and empirical research in accounting, *Accounting and Business Research*, Vol. 26, No. 4, 1996., p. 347-355
89. Učkar, D.: Mogućnosti optimizacije financijske strukture poduzeća u Republici Hrvatskoj, *Ekonomski istraživanja*, Vol. 20, No. 2, 2007., p. 24-34
90. Vichitsarawong, T., Pornupatham, S.: Do audit opinions reflect earnings persistence?, *Managerial Auditing Journal*, Vol. 30, No. 3, 2015., p. 244-276
91. Vitezić, N.: Dijagnosticiranje financijske krize i mogućnosti prognoziranja, *XXIX Simpozij Računovodstvo, poslovne financije i revizija*, Hrvatska zajednica računovodstvenih i financijskih djelatnika, Pula, lipanj, 1994.
92. Vitezić, N., Tearney, M.: Dijagnosticiranje financijske krize pomoću cash-flow modela, *Zbornik radova Ekonomskog fakulteta Rijeka*, br.14/II, 1996., p. 49-68
93. Vitezić, N., Knez-Riedl, J.: The assessment of the creditworthiness of an enterprise in the knowledge economy, *International Conference: An Enterprise Odyssey: Economics and Business in the New Millennium 2002*, University of Zagreb, Graduate School of Economics and Business, Zagreb, June 27-28, 2002., p. 1606-1616
94. Vitezić, N., Knez-Riedl, J.: The use of financial and non-financial measures in decision-making process of enterprises performance in transition economy, *Sixth International Conference on "Enterprise in Transition"*, University of Split, Faculty of Economics Split, May, 26-28, 2005., p. 247-259
95. Vitezić, N.: Predviđanja stečaja i pokazatelji ranog upozorenja / Financijsko restrukturiranje profitnog i neprofitnog sektora u Hrvatskoj / *Zbornik radova*,

- Tadijančević, Stjepan; Cota, Bogomil (ur.), Zagreb, Hrvatska zajednica računovođa i financijskih djelatnika, 2006., p. 195-203
96. Vitezić, N.: Učinkovitost modela prognoziranja poslovnih poremećaja// Zbornik referatov XIV. posvetovanja društva računovodij, finančnikov in revizorjev Maribor, Društvo računovodij, finančnikov in revizorjev Maribor, 2009., p. 38-53
97. Vitezić, N.: Učinkovitost prognostičkih modela u ocjeni nastavka poslovanja, RRIF, Br. 3, 2013., p. 83-86
98. Zavgren, C.: The forecasting of corporate failure: the state of the art, Journal of Accounting Literature, Vol. 2, 1983., p. 1-37
99. Zenzerović, R.: Business's financial problems forecasting - Croatian experience, Josip Juraj Dobrića, Ekonomski fakultet u Puli, Pula, 2009., doktorska disertacija
100. Zenzerović, R., Peruško, T.: Ocjenjivanje pretpostavke vremenske neograničenosti poslovanja u tranzicijskom okruženju – empirijski nalazi u Republici Hrvatskoj, Ekonomski pregled, Vol. 60, No. 7-8, 2009., p. 348-368
101. Zenzerović, R., Peruško, T.: Kratki osvrt na modele za predviđanje stečaja, Pregledni rad, Ekonomska istraživanja, Vol. 19, No. 2, 2006., p. 132-151
102. Zhand, P.G., Hu, M.Y., Indro, D.C., Patuwo, B.D.: Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis, European Journal of Operational Research, Vol. 116, 1999., p. 16-32
103. Zmijewski, M.E.: Methodological issues related to the estimation of financial distress forecasting models, Journal of Accounting research, Supplement to Vol. 22, 1984., p. 59-86
104. Wang, Y., Campbell, M.: Business failure prediction for publicly listed companies in China, Journal of Business & Management; 2010, Vol. 16, No. 1, p. 75-88
105. Wu, Y., Gaunt, C., Gray, S.: A comparison of alternative bankruptcy forecasting models, Journal of contemporary Accounting & Economics, 6, 2010., p. 1-14
106. Xu, M., Zhang, C.: Bankruptcy prediction: the case of Japanese listed companies, Review of Accounting studies, Vol. 14, No. 4, 2009., p. 534-558
107. Zakon o financijskom poslovanju i predstečajnoj nagodbi, Narodne novine, br. 108/2012.

Ostalo

1. <https://medium.com/@ageitgey/machine-learning-is-fun-80ea3ec3c471>
(10.05.2017.)
2. <http://neuralnetworksanddeeplearning.com/> (17.03.2017.)

Privitak 1

Opisna statistika Altmana, Ohlsona i Zmijewskog po pojedinim grupama industrija

U Privitku 1 analizirani su pokazatelji opisne statistike po pojedinim grana industrije. Pojedine industrije grupirane su u cjeline zbog sličnosti samih industrija i ponašanja poduzeća unutar tih grupa.

Poljoprivreda, rudarstvo i vađenje i prerađivačka industrija

U sklopu prve promatrane industrije obuhvaćeno je 536 poduzeća, od kojih su 336 okarakterizirana kao dobra, a 200 kao loša. Rezultati analize nalaze se u sljedećoj tablici 18.

Tablica 18. Usporedba pokazatelja uspješnosti dobrih i loših poduzeća industrije: poljoprivreda, rudarstvo i vađenje i prerađivačka industrija

Pokazatelj	Kriterij	Broj poduzeća	Medijan	St. devijacija	F-omjer	p-vrijednost
Altman2010	Dobra	336	2,69	1,60	94,737	p<0,01
	Loša	200	1,28	1,64		
	Ukupno	536	2,16	1,75		
Zmijewski2010	Dobra	336	-1,42	1,81	48,558	p<0,01
	Loša	200	0,11	3,27		
	Ukupno	536	-0,85	2,57		
Altman2011	Dobra	336	2,65	1,60	108,730	p<0,01
	Loša	200	1,19	1,51		
	Ukupno	536	2,11	1,72		
Ohlson2011	Dobra	336	0,57	0,28	1,464	p>0,05
	Loša	200	0,61	0,33		
	Ukupno	536	0,59	0,30		
Zmijewski2011	Dobra	336	-1,38	1,55	57,068	p<0,01
	Loša	200	0,29	3,52		
	Ukupno	536	-0,76	2,60		
Altman2012	Dobra	336	2,58	1,59	66,195	p<0,01
	Loša	200	1,32	1,96		
	Ukupno	536	2,11	1,84		

Ohlson2012	Dobra	335	0,54	0,31	10,317	p<0,01
	Loša	200	0,63	0,33		
	Ukupno	535	0,58	0,32		
Zmijewski2012	Dobra	336	-1,35	1,53	42,911	p<0,01
	Loša	200	0,61	5,11		
	Ukupno	536	-0,61	3,48		
Altman2013	Dobra	336	2,70	1,51	113,861	p<0,01
	Loša	200	1,10	1,92		
	Ukupno	536	2,10	1,84		
Ohlson2013	Dobra	336	0,50	0,30	18,454	p<0,01
	Loša	200	0,62	0,33		
	Ukupno	536	0,54	0,32		
Zmijewski2013	Dobra	336	-1,59	1,51	60,724	p<0,01
	Loša	200	0,91	5,57		
	Ukupno	536	-0,66	3,80		
Altman2014	Dobra	336	2,89	1,60	152,013	p<0,01
	Loša	200	1,05	1,78		
	Ukupno	536	2,20	1,89		
Ohlson2014	Dobra	336	0,44	0,29	55,820	p<0,01
	Loša	200	0,64	0,33		
	Ukupno	536	0,51	0,32		
Zmijewski2014	Dobra	336	-1,90	1,44	57,308	p<0,01
	Loša	200	1,39	7,75		
	Ukupno	536	-0,67	5,12		
Altman2015	Dobra	336	2,99	1,86	119,343	p<0,01
	Loša	200	1,03	2,25		
	Ukupno	536	2,26	2,23		
Ohlson2015	Dobra	336	0,42	0,29	74,933	p<0,01
	Loša	200	0,66	0,34		
	Ukupno	536	0,51	0,33		
Zmijewski2015	Dobra	336	-1,99	1,41	55,290	p<0,01
	Loša	200	2,27	10,34		
	Ukupno	536	-0,40	6,73		

Altmanov Z' score u prosjeku se 2010. statistički značajno razlikuje između dobrih i loših poduzeća ($F1=94,74$; $p<0,01$). Zmijewski score je također statistički značajan pri usporedbi prosječnih vrijednosti ($F3=48,56$; $p<0,01$). U 2011. godini statistički značajne razlike prisutne su kod metodologije Altman i Zmijewski ($F1=108,73$; $p<0,01$, $F3=57,07$; $p<0,01$), dok statistički značajne razlike u prosječnim vrijednostima pokazatelja nisu pronađene kod metodologije Ohlson. U razdoblju od 2012. – 2015. godine pokazatelji uspješnosti poduzeća u prosjeku se statistički značajno razlikuju u

sve tri metodologije kada se uspoređuju dobra i loša poduzeća, na razini signifikantnosti od 1%.

Opskrba električnom energijom i vodom

Rezultati analize pokazatelja uspješnosti unutar industrije opskrbe energijom i vodom ne ukazuju na značajne razlike u pojedinim razdobljima i prema pojedinim metodologijama izračuna pokazatelja uspješnosti ($p > 0,05$). U sklopu industrije opskrbe energijom i vodom analizirano je 60 poduzeća od kojih su 30 poduzeća iz uzorka dobrih, a 30 poduzeća iz uzorka loših. Kompletan pregled rezultata analize unutar prethodno navedene industrije nalazi se u tablici 19.

Tablica 19. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća industrije opskrbe električnom energijom i vodom

Pokazatelj	Kriterij	Broj poduzeća	Medijan	St. devijacija	F-omjer	p-vrijednost
Altman2010	Dobra	30	1,79	0,89	0,085	$p > 0,05$
	Loša	30	1,91	1,98		
	Ukupno	60	1,85	1,53		
Zmijewski2010	Dobra	30	-1,91	1,79	0,685	$p > 0,05$
	Loša	30	-1,41	2,77		
	Ukupno	60	-1,66	2,33		
Altman2011	Dobra	30	1,98	1,07	0,322	$p > 0,05$
	Loša	30	2,27	2,60		
	Ukupno	60	2,12	1,98		
Ohlson2011	Dobra	30	0,49	0,30	0,012	$p > 0,05$
	Loša	30	0,48	0,38		
	Ukupno	60	0,48	0,34		
Zmijewski2011	Dobra	30	-1,89	1,74	0,325	$p > 0,05$
	Loša	30	-1,56	2,61		
	Ukupno	60	-1,72	2,21		
Altman2012	Dobra	30	2,02	1,16	0,046	$p > 0,05$
	Loša	30	1,93	1,87		
	Ukupno	60	1,98	1,54		
Ohlson2012	Dobra	30	0,44	0,34	0,038	$p > 0,05$
	Loša	30	0,46	0,38		
	Ukupno	60	0,45	0,36		
Zmijewski2012	Dobra	30	-1,85	1,61	1,014	$p > 0,05$

	Loša	30	-1,21	3,12		
	Ukupno	60	-1,53	2,48		
Altman2013	Dobra	30	2,27	1,33	2,106	p>0,05
	Loša	30	1,58	2,26		
	Ukupno	60	1,92	1,87		
Ohlson2013	Dobra	30	0,41	0,35	0,344	p>0,05
	Loša	30	0,47	0,41		
	Ukupno	60	0,44	0,38		
Zmijewski2013	Dobra	30	-2,00	1,55	2,196	p>0,05
	Loša	30	1,04	11,11		
	Ukupno	60	-0,48	8,01		
Altman2014	Dobra	30	2,61	1,19	0,114	p>0,05
	Loša	30	2,86	3,84		
	Ukupno	60	2,74	2,82		
Ohlson2014	Dobra	30	0,42	0,30	0,000	p>0,05
	Loša	30	0,42	0,37		
	Ukupno	60	0,42	0,34		
Zmijewski2014	Dobra	30	-2,07	1,39	3,260	p>0,05
	Loša	30	-1,01	2,91		
	Ukupno	60	-1,54	2,33		
Altman2015	Dobra	30	2,99	1,94	1,400	p>0,05
	Loša	30	1,76	5,37		
	Ukupno	60	2,38	4,05		
Ohlson2015	Dobra	30	0,39	0,27	0,149	p>0,05
	Loša	30	0,42	0,40		
	Ukupno	60	0,40	0,33		
Zmijewski2015	Dobra	30	-2,38	1,20	1,383	p>0,05
	Loša	30	6,63	41,97		
	Ukupno	60	2,13	29,79		

Građevinska industrija i poslovanje nekretninama

U sklopu ove promatrane industrije obuhvaćeno je 183 poduzeća, od kojih su 103 okarakterizirana kao dobra, a 80 kao loša. Rezultati analize pokazatelja uspješnosti unutar industrije ukazuju na značajne razlike u pojedinim razdobljima i prema pojedinim metodologijama izračuna pokazatelja uspješnosti na razini signifikantnosti od 1%.

Tablica 20. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća građevinske industrije i poslovanja nekretninama

Pokazatelj	Kriterij	Broj poduzeća	Medijan	St. devijacija	F-omjer	p-vrijednost
Altman2010	Dobra	103	2,54	1,63	59,424	p<0,01
	Loša	80	0,86	1,21		
	Ukupno	183	1,81	1,68		
Zmijewski2010	Dobra	103	-1,58	1,64	60,794	p<0,01
	Loša	80	0,40	1,78		
	Ukupno	183	-0,72	1,96		
Altman2011	Dobra	103	2,57	1,57	67,849	p<0,01
	Loša	80	0,77	1,32		
	Ukupno	183	1,78	1,71		
Ohlson2011	Dobra	103	0,57	0,27	9,217	p<0,01
	Loša	80	0,69	0,29		
	Ukupno	183	0,62	0,29		
Zmijewski2011	Dobra	103	-1,36	1,78	57,800	p<0,01
	Loša	80	0,65	1,78		
	Ukupno	183	-0,48	2,04		
Altman2012	Dobra	103	2,34	1,13	52,851	p<0,01
	Loša	80	0,72	1,86		
	Ukupno	183	1,63	1,69		
Ohlson2012	Dobra	103	0,55	0,31	10,105	p<0,01
	Loša	80	0,70	0,30		
	Ukupno	183	0,62	0,31		
Zmijewski2012	Dobra	103	-1,26	1,56	40,396	p<0,01
	Loša	80	1,33	3,74		
	Ukupno	183	-0,13	3,02		
Altman2013	Dobra	103	2,51	1,03	109,709	p<0,01
	Loša	80	0,58	1,46		
	Ukupno	183	1,67	1,56		
Ohlson2013	Dobra	103	0,53	0,30	24,666	p<0,01
	Loša	80	0,75	0,29		
	Ukupno	183	0,63	0,31		
Zmijewski2013	Dobra	103	-1,54	1,34	59,309	p<0,01
	Loša	80	1,85	4,20		
	Ukupno	183	-0,05	3,39		
Altman2014	Dobra	103	2,79	1,17	159,650	p<0,01
	Loša	80	0,57	1,19		
	Ukupno	183	1,82	1,61		
Ohlson2014	Dobra	103	0,48	0,29	44,500	p<0,01
	Loša	80	0,77	0,28		

	Ukupno	183	0,60	0,32		
Zmijewski2014	Dobra	103	-1,84	1,37	133,018	p<0,01
	Loša	80	1,90	2,90		
	Ukupno	183	-0,20	2,86		
Altman2015	Dobra	103	2,71	1,39	77,717	p<0,01
	Loša	80	0,49	2,00		
	Ukupno	183	1,74	2,01		
Ohlson2015	Dobra	103	0,49	0,30	44,238	p<0,01
	Loša	80	0,78	0,29		
	Ukupno	183	0,62	0,33		
Zmijewski2015	Dobra	103	-1,66	1,99	51,524	p<0,01
	Loša	80	2,84	5,95		
	Ukupno	183	0,31	4,75		

Trgovina, prijevoz i skladištenje

U sklopu industrije trgovine, prijevoza i skladištenja obuhvaćena su 686 poduzeća, od kojih su 457 okarakterizirana kao dobra, a 229 kao loša. Rezultati analize pokazatelja uspješnosti unutar industrije također ukazuju na značajne razlike u pojedinim razdobljima i prema pojedinim metodologijama izračuna pokazatelja uspješnosti na razini signifikantnosti od 1%.

Tablica 21. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća trgovine, prijevoza i skladištenja

Pokazatelj	Kriterij	Broj poduzeća	Medijan	St. devijacija	F-omjer	p-vrijednost
Altman2010	Dobra	457	3,17	1,67	68,297	p<0,01
	Loša	229	1,93	2,16		
	Ukupno	686	2,76	1,94		
Zmijewski2010	Dobra	457	-1,34	1,64	149,258	p<0,01
	Loša	229	0,81	2,97		
	Ukupno	686	-0,62	2,40		
Altman2011	Dobra	457	3,21	1,84	64,438	p<0,01
	Loša	229	1,97	2,03		
	Ukupno	686	2,80	1,99		
Ohlson2011	Dobra	457	0,60	0,27	35,629	p<0,01
	Loša	229	0,74	0,27		

	Ukupno	686	0,65	0,28		
Zmijewski2011	Dobra	457	-1,23	1,64	167,181	p<0,01
	Loša	229	0,90	2,66		
	Ukupno	686	-0,52	2,27		
Altman2012	Dobra	457	3,05	1,75	60,468	p<0,01
	Loša	229	1,88	2,06		
	Ukupno	686	2,66	1,94		
Ohlson2012	Dobra	457	0,59	0,29	34,877	p<0,01
	Loša	229	0,73	0,30		
	Ukupno	686	0,64	0,30		
Zmijewski2012	Dobra	457	-1,14	1,55	151,679	p<0,01
	Loša	229	1,28	3,59		
	Ukupno	686	-0,33	2,68		
Altman2013	Dobra	457	3,18	1,86	84,233	p<0,01
	Loša	229	1,80	1,88		
	Ukupno	686	2,72	1,97		
Ohlson2013	Dobra	457	0,54	0,30	68,655	p<0,01
	Loša	229	0,74	0,30		
	Ukupno	686	0,60	0,31		
Zmijewski2013	Dobra	457	-1,40	1,50	191,035	p<0,01
	Loša	229	1,51	3,98		
	Ukupno	686	-0,43	2,95		
Altman2014	Dobra	457	3,31	1,89	75,835	p<0,01
	Loša	229	1,92	2,13		
	Ukupno	686	2,85	2,08		
Ohlson2014	Dobra	457	0,50	0,30	90,882	p<0,01
	Loša	229	0,72	0,30		
	Ukupno	686	0,57	0,31		
Zmijewski2014	Dobra	457	-1,61	1,47	248,458	p<0,01
	Loša	229	1,50	3,67		
	Ukupno	686	-0,57	2,84		
Altman2015	Dobra	457	3,37	1,88	105,775	p<0,01
	Loša	229	1,64	2,43		
	Ukupno	686	2,79	2,24		
Ohlson2015	Dobra	457	0,47	0,30	99,031	p<0,01
	Loša	229	0,72	0,32		
	Ukupno	686	0,56	0,33		
Zmijewski2015	Dobra	457	-1,68	1,41	72,165	p<0,01
	Loša	229	2,85	11,21		
	Ukupno	686	-0,17	6,91		

Altmanov Z' score u prosjeku se 2010. statistički značajno razlikuje između dobrih i loših poduzeća ($F1=68,29$; $p<0,01$). Zmijewski score je također statistički značajan pri

usporedbi prosječnih vrijednosti ($F3=149,26$; $p<0,01$). U 2011. godini statistički značajne razlike prisutne su kod metodologije Altman i Zmijewski ($F1=63,44$; $p<0,01$, $F3=167,18$; $p<0,01$), dok su statistički značajne razlike u prosječnim vrijednostima pokazatelja pronađene i kod metodologije Ohlson, ali pri nižim vrijednostima empirijskog F-omjera ($F1=35,63$; $p<0,01$). U razdoblju od 2012. – 2015. godine pokazatelji uspješnosti poduzeća u prosjeku se statistički značajno razlikuju u sve tri metodologije kada se uspoređuju dobra i loša poduzeća, na razini signifikantnosti od 1%.

Stručne, znanstvene, tehničke djelatnosti, obrazovanje, umjetnost, zabava, rekreacija i djelatnosti zdravstvene zaštite

U sklopu analizirane industrije obuhvaćena su 102 poduzeća, od kojih su 66 okarakterizirana kao dobra, a 46 kao loša. Rezultati analize pokazatelja uspješnosti unutar ove industrije također ukazuju na značajne razlike u pojedinim razdobljima i prema pojedinim metodologijama izračuna pokazatelja uspješnosti na razini signifikantnosti od 1% u svim godinama, osim u 2011. na razini signifikantnosti od 5% kod Ohlsona.

Tablica 22. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća industrije stručne, znanstvene i ostale djelatnosti

Pokazatelj	Kriterij	Broj poduzeća	Medijan	St. devijacija	F-omjer	p-vrijednost
Altman2010	Dobra	66	3,21	1,75	18,564	p<0,01
	Loša	46	1,68	1,99		
	Ukupno	112	2,58	1,99		
Zmijewski2010	Dobra	66	-1,92	1,95	17,738	p<0,01
	Loša	46	0,36	3,73		
	Ukupno	112	-0,99	3,02		
Altman2011	Dobra	66	3,57	2,18	21,866	p<0,01
	Loša	46	1,61	2,18		
	Ukupno	112	2,76	2,38		
Ohlson2011	Dobra	66	0,55	0,29	6,812	p<0,05
	Loša	46	0,70	0,30		
	Ukupno	112	0,61	0,30		

Zmijewski2011	Dobra	66	-2,16	2,13	24,680	p<0,01
	Loša	46	0,73	3,99		
	Ukupno	112	-0,97	3,34		
Altman2012	Dobra	66	3,43	2,38	20,724	p<0,01
	Loša	46	1,39	2,25		
	Ukupno	112	2,59	2,53		
Ohlson2012	Dobra	66	0,54	0,32	12,808	p<0,01
	Loša	46	0,75	0,28		
	Ukupno	112	0,62	0,32		
Zmijewski2012	Dobra	66	-2,07	2,04	30,329	p<0,01
	Loša	46	1,15	4,08		
	Ukupno	112	-0,75	3,42		
Altman2013	Dobra	66	3,61	2,13	47,393	p<0,01
	Loša	46	1,00	1,74		
	Ukupno	112	2,54	2,35		
Ohlson2013	Dobra	66	0,46	0,31	25,579	p<0,01
	Loša	46	0,76	0,30		
	Ukupno	112	0,58	0,34		
Zmijewski2013	Dobra	66	-2,45	1,97	39,299	p<0,01
	Loša	46	2,27	5,66		
	Ukupno	112	-0,51	4,55		
Altman2014	Dobra	66	3,75	2,18	39,024	p<0,01
	Loša	46	1,22	1,98		
	Ukupno	112	2,71	2,44		
Ohlson2014	Dobra	66	0,44	0,32	21,966	p<0,01
	Loša	46	0,73	0,32		
	Ukupno	112	0,56	0,35		
Zmijewski2014	Dobra	66	-2,54	2,07	21,167	p<0,01
	Loša	46	2,87	9,24		
	Ukupno	112	-0,32	6,66		
Altman2015	Dobra	66	4,16	2,85	43,611	p<0,01
	Loša	46	1,08	1,64		
	Ukupno	112	2,89	2,86		
Ohlson2015	Dobra	66	0,41	0,32	33,913	p<0,01
	Loša	46	0,77	0,31		
	Ukupno	112	0,56	0,36		
Zmijewski2015	Dobra	66	-2,58	1,93	51,249	p<0,01
	Loša	46	2,19	4,90		
	Ukupno	112	-0,62	4,18		

Djelatnost pružanja smještaja i restorana te ostale uslužne djelatnosti

U sklopu analizirane industrije obuhvaćeno je 89 poduzeća, od kojih su 38 okarakterizirana kao dobra, a 51 kao loša. Rezultati analize pokazatelja uspješnosti unutar ove industrije ukazuju na značajne razlike u pojedinim razdobljima i prema pojedinim metodologijama izračuna pokazatelja uspješnosti na razini signifikantnosti od 1% ili 5%.

Tablica 23. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća industrije djelatnosti pružanja smještaja i restorana te ostalih uslužnih djelatnosti

Pokazatelj	Kriterij	Broj poduzeća	Medijan	St. devijacija	F-omjer	p-vrijednost
Altman2010	Dobra	38	3,06	3,19	11,554	p<0,01
	Loša	51	1,07	2,34		
	Ukupno	89	1,92	2,90		
Zmijewski2010	Dobra	38	-1,72	1,83	16,957	p<0,01
	Loša	51	0,86	3,52		
	Ukupno	89	-0,24	3,18		
Altman2011	Dobra	38	3,31	3,29	11,785	p<0,01
	Loša	51	1,03	2,92		
	Ukupno	89	2,00	3,27		
Ohlson2011	Dobra	38	0,58	0,30	5,199	p<0,05
	Loša	51	0,73	0,32		
	Ukupno	89	0,67	0,32		
Zmijewski2011	Dobra	38	-1,76	2,09	18,066	p<0,01
	Loša	51	1,49	4,35		
	Ukupno	89	0,10	3,89		
Altman2012	Dobra	38	3,23	2,76	15,093	p<0,01
	Loša	51	1,05	2,51		
	Ukupno	89	1,98	2,82		
Ohlson2012	Dobra	38	0,52	0,35	11,065	p<0,01
	Loša	51	0,76	0,33		
	Ukupno	89	0,65	0,36		
Zmijewski2012	Dobra	38	-1,88	2,09	14,919	p<0,01
	Loša	51	2,55	6,83		
	Ukupno	89	0,66	5,76		
Altman2013	Dobra	38	3,61	3,05	3,876	p>0,05
	Loša	51	2,02	4,21		

	Ukupno	89	2,70	3,82		
Ohlson2013	Dobra	38	0,51	0,30	7,092	p<0,01
	Loša	51	0,69	0,35		
	Ukupno	89	0,61	0,34		
Zmijewski2013	Dobra	38	-2,14	1,51	18,949	p<0,01
	Loša	51	1,25	4,61		
	Ukupno	89	-0,20	3,99		
Altman2014	Dobra	38	3,41	3,36	7,869	p<0,01
	Loša	51	1,20	3,90		
	Ukupno	89	2,15	3,82		
Ohlson2014	Dobra	38	0,51	0,32	5,012	p<0,05
	Loša	51	0,68	0,37		
	Ukupno	89	0,61	0,36		
Zmijewski2014	Dobra	38	-2,02	1,52	10,745	p<0,01
	Loša	51	2,52	8,43		
	Ukupno	89	0,58	6,82		
Altman2015	Dobra	38	3,06	2,31	3,140	p<0,05
	Loša	51	1,81	3,83		
	Ukupno	89	2,34	3,31		
Ohlson2015	Dobra	38	0,43	0,29	19,608	p<0,05
	Loša	51	0,74	0,35		
	Ukupno	89	0,61	0,36		
Zmijewski2015	Dobra	38	-2,11	1,49	6,649	p<0,05
	Loša	51	4,42	15,54		
	Ukupno	89	1,63	12,19		

Informacije i komunikacije, financijske djelatnosti i djelatnosti osiguranja i administrativne djelatnosti

U sklopu industrije Informacije i komunikacije (ICT), financijske djelatnosti i djelatnosti osiguranja i administrativne djelatnosti obuhvaćena su 130 poduzeća, od kojih su 76 okarakterizirana kao dobra, a 54 kao loša. Rezultati analize pokazatelja uspješnosti unutar ove industrije ukazuju na značajne razlike u pojedinim razdobljima i prema pojedinim metodologijama izračuna pokazatelja uspješnosti na razini signifikantnosti od 1% osim kod Ohlson pokazatelja u 2011. godini gdje nije dokazana statistička razlika između poduzeća koja dobro posluju i oni loših.

Tablica 24. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća ICT i financijske industrije

Pokazatelj	Kriterij	Broj poduzeća	Medijan	St. devijacija	F-omjer	p-vrijednost
Altman2010	Dobra	76	3,44	2,04	10,844	p<0,01
	Loša	54	2,16	2,34		
	Ukupno	130	2,91	2,25		
Zmijewski2010	Dobra	76	-1,63	2,06	34,753	p<0,01
	Loša	54	1,00	3,03		
	Ukupno	130	-0,54	2,82		
Altman2011	Dobra	76	3,40	2,01	10,818	p<0,01
	Loša	54	2,15	2,29		
	Ukupno	130	2,88	2,21		
Ohlson2011	Dobra	76	0,62	0,30	3,640	p>0,05
	Loša	54	0,73	0,31		
	Ukupno	130	0,67	0,31		
Zmijewski2011	Dobra	76	-1,52	1,94	25,043	p<0,01
	Loša	54	0,94	3,62		
	Ukupno	130	-0,50	3,01		
Altman2012	Dobra	76	3,19	1,87	13,280	p<0,01
	Loša	54	1,95	1,97		
	Ukupno	130	2,68	2,00		
Ohlson2012	Dobra	76	0,61	0,31	7,470	p<0,01
	Loša	54	0,76	0,28		
	Ukupno	130	0,67	0,31		
Zmijewski2012	Dobra	76	-1,32	1,73	34,731	p<0,01
	Loša	54	1,04	2,83		
	Ukupno	130	-0,34	2,53		
Altman2013	Dobra	76	3,36	2,13	22,402	p<0,01
	Loša	54	1,64	1,89		
	Ukupno	130	2,64	2,20		
Ohlson2013	Dobra	76	0,59	0,32	12,430	p<0,01
	Loša	54	0,78	0,31		
	Ukupno	130	0,67	0,33		
Zmijewski2013	Dobra	76	-1,64	1,80	48,924	p<0,01
	Loša	54	1,61	3,45		
	Ukupno	130	-0,29	3,06		
Altman2014	Dobra	76	3,53	2,43	15,639	p<0,01
	Loša	54	1,56	3,27		
	Ukupno	130	2,71	2,97		
Ohlson2014	Dobra	76	0,55	0,30	22,008	p<0,01

	Loša	54	0,80	0,28		
	Ukupno	130	0,66	0,31		
Zmijewski2014	Dobra	76	-1,78	1,58		
	Loša	54	3,70	11,24	17,623	p<0,01
	Ukupno	130	0,50	7,79		
Altman2015	Dobra	76	3,51	2,08		
	Loša	54	1,59	2,37	24,007	p<0,01
	Ukupno	130	2,71	2,39		
Ohlson2015	Dobra	76	0,55	0,30		
	Loša	54	0,78	0,31	17,481	p<0,01
	Ukupno	130	0,65	0,32		
Zmijewski2015	Dobra	76	-1,76	1,56		
	Loša	54	3,16	6,54	39,897	p<0,01
	Ukupno	130	0,29	4,99		

Popis tablica

1. Sažetak i ocjene osnovnih karakteristika modela Altman, Ohlson i Zmijewski	34
2. Zbirni pregled predmeta prema iznosu prijavljenih obveza	58
3. Udio poduzeća s negativnim poslovanjem u udjelu srednjih i velikih poduzeća, na primjeru 2010. i 2013. godine	59
4. Distribucija uzorka poduzeća prema grupama industrija	60
5. Usporedba pokazatelja uspješnosti dobrih i loših poduzeća prema Altmanu, Ohlsonu i Zmijewskom u razdoblju između 2010. – 2015. godine.	67
6. Korelacijska matrica komponenata pokazatelja uspješnosti Altman Z'-scorea i Altman Z'-score-a kroz promatrano razdoblje između dobrih i loših poduzeća	71
7. Korelacijska matrica komponenata Ohlsonovih pokazatelja uspješnosti i Ohlsonovog pokazatelja uspješnosti kroz promatrano razdoblje između dobrih i loših poduzeća	74
8. Korelacijska matrica komponenata Zmijewski pokazatelja uspješnosti i Zmijewski pokazatelja uspješnosti kroz promatrano razdoblje između dobrih i loših poduzeća	77
9. Izračun Pogreške tipa 1 i 2 Altmanovog Z' score pokazatelja na uzorku hrvatskih poduzeća	80
10. Izračun Pogreške tipa 1 i 2 Ohlsonovog O score pokazatelja na uzorku hrvatskih poduzeća	81
11. Izračun Pogreške tipa 1 i 2 Zmijewski pokazatelja na uzorku hrvatskih poduzeća	82
12. Sažetak odabira metoda selekcije varijabli za izradu modela temeljenih na umjetnim neuronskim mrežama	100
13. Popis dijela istraživačkih radova i pokazatelja korištenih u odabiru ulaznih varijabli u modeliraju prediktivnog modela	102
14. Najučestaliji financijski pokazatelji pri procjeni boniteta klijenta	106
15. Najznačajnije kvalitativne informacije („soft facts“) o klijentima korištene u bankama	107

16. Odabrane financijske varijable za input vektore u definiciji modela	115
17. Odabrane nefinancijske varijable za input vektore u definiciji modela	117
18. Usporedba pokazatelja uspješnosti dobrih i loših poduzeća industrije: poljoprivreda, rudarstvo i vađenje i prerađivačka industrija	152
19. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća industrije opskrbe električnom energijom i vodom	154
20. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća građevinske industrije i poslovanja nekretninama	156
21. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća trgovine, prijevoza i skladištenja	157
22. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća industrije stručne, znanstvene i ostale djelatnosti	159
23. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća industrije djelatnosti pružanja smještaja i restorana te ostalih uslužnih djelatnosti	161
24. Usporedba prosječnih vrijednosti pokazatelja uspješnosti dobrih i loših poduzeća ICT i financijske industrije	163

Popis slika

1. Izračun primjenjivosti uzorka prema Sample Size Calculator	61
2. Građa biološkog neurona	88
3. Shematski prikaz perceptrona	89
4. Mreža perceptrona	90
5. Sigmoidalna funkcija	92
6. Pojednostavljeni prikaz arhitekture umjetne neuronske mreže	93
7. Snimka (eng. Screenshot) glavne skripte koda u programskom jeziku Python	119
8. Snimka (eng Screenshot) pojedinih blokova koda s objašnjenjima	121
9. Ispis rezultata modela logističke regresije i umjetne neuronske mreže	129
10. Prikaz dijela rezultata testiranja podataka na modelu logističke regresije i umjetne neuronske mreže (iz Python-a)	130

Biografija

Dejana Dojčinović Drilo je diplomirala 2003. godine na Ekonomskom fakultetu u Rijeci s temom Suvremeni pristup analizi uspješnosti poslovanja pod mentorstvom prof.dr.sc. Nede Vitezić, te je tijekom studija dobila Rektorovu nagradu za najboljeg studenta generacije (prosjek ocjena 4,8) te Dekanove nagrade. Magistrirala je 2008. godine na Ekonomskom fakultetu u Zagrebu obranivši temu Sustav ranih znakova upozorenja na krizu te stekla titulu magistra znanosti (prosjek ocjena 4,9). Od 2006. do 2013. godine radila je u međunarodnoj konzultantskoj kući Roland Berger Strategy Consultants na pozicijama od junior konzultanta do project managera na projektima restrukturiranja i reorganizacije poslovanja, spajanja i akvizicija, te definiranja strategija poslovanja velikih svjetskih kompanija i EU institucija. Od 2013. godine radi u Erste banci, na početku u Sektoru gospodarstva kao zamjenik direktora Direkcije Podrške prodaji, a od 2017. godine kao Zamjenik direktora Sektora razvoja i podrške poslovanju korporativnim klijentima i financijskim tržištima. Tijekom konzultantske karijere sudjelovala je na brojnim stručnim usavršavanjima. Aktivno je sudjelovala na dvije konferencije s temom Sustava ranih znakova upozorenja, te je autorica dva znanstvena članka koji obrađuju temu sustava upozorenja na krizu. Aktivno govori engleski i njemački jezik.