

OBLIKOVANJE MODELA ZA PREDVIĐANJE BANKROTA PODUZEĆA U REPUBLICI HRVATSKOJ, BOSNI I HERCEGOVINI, SRBIJI I MAĐARSKOJ

Burić, Tina

Master's thesis / Diplomski rad

2016

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

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:124:174010>

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

Download date / Datum preuzimanja: **2024-04-23**

Repository / Repozitorij:

[REFST - Repository of Economics faculty in Split](#)



UNIVERSITY OF SPLIT





**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET SPLIT**

DIPLOMSKI RAD

**OBLIKOVANJE MODELA ZA PREDVIĐANJE
BANKROTA PODUZEĆA U REPUBLICI
HRVATSKOJ, BOSNI I HERCEGOVINI, SRBIJI I
MAĐARSKOJ**

Mentor:

Prof. dr. sc. Ivica Pervan

Student:

**Tina Burić, univ. bacc. oec.
Broj indeksa: 2132320**

Split, lipanj 2016.

SADRŽAJ:

1. UVOD	4
1.1. Problem istraživanja	4
1.2. Predmet istraživanja	4
1.3. Istraživačke teze	5
1.4. Ciljevi istraživanja	5
1.5. Metode istraživanja	6
1.6. Doprinos istraživanja	6
1.7. Struktura diplomskog rada	7
2. UTVRĐIVANJE POSLOVNOG NEUSPJEHA TEMELJEM	
RAČUNOVODSTVENIH INFORMACIJA	8
2.1. Računovodstvene informacije u modernom poslovnom okruženju	8
2.2. Temeljni financijski izvještaji	9
2.2.1. Bilanca	10
2.2.2. Račun dobiti i gubitka	11
2.2.3. Izvještaj o novčanom tijeku	13
2.2.4. Izvještaj o promjenama kapitala	15
2.2.5. Bilješke uz financijske izvještaje	16
2.3. Analiza financijskih izvještaja	17
2.3.1. Horizontalna analiza	17
2.3.2. Vertikalna analiza	18
2.3.3. Analiza putem financijskih pokazatelja	19
2.4. Pregled modela za predviđanje bankrota	23
2.4.1. Pregled najznačajnijih modela za predviđanje bankrota	23
2.4.2. Pregled najznačajnijih modela za predviđanje bankrota u Republici Hrvatskoj	30
3. RAZVOJ MODELA ZA PREDVIĐANJE BANKROTA PODUZEĆA .	36

3.1. Definiranje uzorka	36
3.2. Definiranje statističke metodologije	36
3.3. Definiranje varijabli u modelu.....	38
3.4. Model predviđanja poslovnog neuspjeha u Hrvatskoj	39
3.4.1. Priprema podataka za analizu.....	39
3.4.2. Formiranje modela pomoću binarne logističke regresije	42
3.4.3. Formiranje modela pomoću neuronskih mreža	44
3.5. Model predviđanja poslovnog neuspjeha u Bosni i Hercegovini	51
3.5.1. Priprema podataka za analizu.....	51
3.5.2. Formiranje modela pomoću binarne logističke regresije	53
3.5.3. Formiranje modela pomoću neuronskih mreža	55
3.6. Model predviđanja poslovnog neuspjeha u Srbiji.....	61
3.6.1. Priprema podataka za analizu.....	61
3.6.2. Formiranje modela pomoću binarne logističke regresije	63
3.6.3. Formiranje modela pomoću neuronskih mreža	65
3.7. Model predviđanja poslovnog neuspjeha u Mađarskoj.....	71
3.7.1. Priprema podataka za analizu.....	71
3.7.2. Formiranje modela pomoću binarne logističke regresije	73
3.7.3. Formiranje modela pomoću neuronskih mreža	75
4. ZAKLJUČAK.....	83
SAŽETAK.....	85
SUMMARY	86
LITERATURA	87

1. UVOD

1.1. Problem istraživanja

Bankrot je posljedica insolventnosti, odnosno situacija u kojoj poduzeće više ne može podmiriti svoje obveze prema vjerovnicima, nakon čega započinje sudski postupak stečaja nad poduzećem. U stečajne razloge spadaju nelikvidnost, nesposobnost za plaćanje i prezaduženost.

U razdoblju recesije poduzeća se suočavaju s većim rizicima poslovanja, nastaju problemi u ispunjenju njihovih novčanih obveza, te često postaju nesposobni za plaćanje. Stoga dolazi do problema gdje poduzeće postaje prezaduženo te njegova imovina ne pokriva postojeće obveze. Svi navedeni razlozi pokreću predstečajnu nagodbu, odnosno postupak stečaja. Nažalost postoje poduzeća koja se nisu dovoljno prilagodila dinamičnom okruženju na tržištu i s poteškoćama prate tržišnu utakmicu. Takva poduzeća unatoč razvijenim odnosima s kupcima, dobavljačima, kreditorima i ostalim poslovnim partnerima zbog neplaćanja dospjelih obveza i problema u naplati potraživanja dolaze u stanje nelikvidnosti. Nadalje nelikvidnost poduzeća povlači za sobom niz rizika s kojima su suočeni svi oni poslovni partneri i ona poduzeća koja su u poslovnoj mreži subjekta u teškoćama. Bankrot predstavlja jedan od najvećih poslovnih rizika današnjice pri čemu poduzeća trebaju upotrijebiti sve moguće procese kako bi izbjegli sam krah. U svezi s tim problemom suočavaju se mnogi današnji znanstvenici pokušavajući pronaći optimalno rješenje kako bi na vrijeme spriječila bankrot poduzeća. Ovaj problem će biti glavni predmet istraživanja diplomskog rada gdje će se pokušati pomoću statističkih metoda utvrditi model za predviđanje bankrota temeljem računovodstvenih informacija.

1.2. Predmet istraživanja

Oblikovanje modela za predviđanje bankrota poduzeća predstavlja predmet istraživanja diplomskog rada. Na temelju računovodstvenih informacija će se doći do optimalnog modela, temeljenog na financijskim pokazateljima dobivenim iz prikupljenih podataka financijskih izvještaja poduzeća. Putem različitih statističkih metoda obraditi će se informacije trgovačkih društava koja ne kotiraju na burzi, a obuhvaćaju zdrava i insolventna poduzeća iz Republike Hrvatske, Bosne i Hercegovine, Srbije i Mađarske.

Provedene su mnoge znanstvene studije na temu određivanja modela za predviđanje bankrota, no i dalje je bez premca najpoznatiji model Z-score Edwarda I. Altmana iz 1968. godine. On je došao do optimalnog modela korištenjem statističke metode diskriminacijske analize na temelju listanih proizvodnih trgovačkih poduzeća iz SAD-a. No, globalna recesija je utjecala na sve zemlje, te dok su se neke uspjele oporaviti, druge se i danas još bore za izlazak iz krize, posebice Hrvatska, Bosna i Hercegovina, Srbija i Mađarska, pa problem predviđanja bankrota postaje jako aktualan.

Altman je u svom radu koristio diskriminacijsku analizu, dok je danas zahvaljujući daljnjem razvoju matematičkih i statističkih metoda moguće koristiti mnogobrojne analize uključujući neuronske mreže koje će biti sastavni dio ovog diplomskog rada.

1.3. Istraživačke teze

Oblikovanje modela za predviđanje bankrota temelji se na računovodstvenim informacijama preuzetih iz financijskih izvještaja koji moraju pružati istinit i fer prikaz stanja poduzeća. Stoga će se postaviti tri hipoteze:

Hipoteza 1: Na bazi računovodstvenih informacija i financijskih pokazatelja moguće je oblikovati efikasan model za predviđanje bankrota poduzeća.

Hipoteza 2: Modeli za predviđanje bankrota po različitim državama razlikuju se po varijablama i točnosti predviđanja.

Hipoteza 3: Alternativne metode za predviđanje bankrota dovode do različitih rezultata.

1.4. Ciljevi istraživanja

Glavni cilj istraživanja diplomskog rada je putem računovodstvenih informacija, te financijskih pokazatelja oblikovati optimalan model za predviđanje bankrota poduzeća uključujući poslovne subjekte u Hrvatskoj, Bosni i Hercegovini, Srbiji i Mađarskoj.

Sljedeći cilj je prikazati kako modeli za predviđanje bankrota po različitim državama daju točna predviđanja bez obzira na razlike u varijablama. Naime, pravna regulativa, poslovno okruženje, bankarski sustav i ostali elementi poslovanja u navedenim državama se razlikuju, pa će se stoga varijable i njihov utjecaj na konačan model razlikovati.

Posljednji cilj je koristiti alternative metode za predviđanje bankrota temeljene na istim podacima, te usporediti točnost predviđanja bankrota korištenjem alternativnih metoda sa rezultatima dobivenim putem statističkih metoda. Alternativne metode u ovom radu predstavljaju metode neuronskih mreža.

1.5. Metode istraživanja

Znanstvene metode predstavljaju širok spektar postupaka kojim se znanstvenici služe u istraživanju i izradi znanstveno-istraživačkog rada kako bi što pouzdanije, efikasnije, točnije i efektivnije prenijeli čitatelju informacije i rezultate svog doprinosa istraživanju.

Od mnogobrojnih znanstvenih metoda u izradi i istraživanju diplomskog rada koristit će se: induktivna metoda kojom se na temelju pojedinačnih činjenica dolazi do zaključka o općem sudu, potom deduktivna metoda, kako bi se iz općih sudova došlo do pojedinačnog zaključka, metoda analize i sinteze čime se raščlanjivanjem složenih pojmova dolazi do jednostavnijih dijelova, odnosno elemenata i obrnuto. Metoda dokazivanja, koja je jedna od najvažnijih znanstvenih metoda, a služi kako bi se utvrdila istinitost neke spoznaje, metoda opovrgavanja koja je suprotna metodi dokazivanja, a njom se odbacuje, odnosno opovrgava neka hipoteza, metoda klasifikacije kojom se neki opći pojam raščlanjuje na pojedinačne, metoda deskripcije koja predstavlja jednostavno opisivanje činjenica, predmeta i procesa, te metoda kompilacije, odnosno postupak preuzimanja tuđih opažanja, stavova i rezultata znanstveno-istraživačkog rada na korektan i fer način.

Kod empirijskog dijela rada prilikom izrade i testiranja točnosti modela za predviđanje bankrota koristiti će se statističke i matematičke metode, metode modeliranja i metode neuronskih mreža. Temeljni instrument istraživanja i izrade modela, kao i kod donošenja konačnih i ostalih zaključaka biti će softverski paket SPSS - „Statistical package for social sciences“.

1.6. Doprinos istraživanja

Doprinos istraživanja ovog diplomskog rada biti će razvoj modela za predviđanje bankrota poduzeća. Temeljiti će se na prikupljenim računovodstvenim informacijama, koje će preko financijskih pokazatelja dati konačni matematički model sastavljen od istih, sa pripadajućim ponderima. Danas je u Hrvatskoj i prethodno navedenim državama vrlo teška financijska situacija, te će stoga rezultat ovog diplomskog rada doprinijeti boljoj mogućnosti predviđanja bankrota poduzeća. Isto tako ovo istraživanje koristiti će alternativne metode za predviđanje bankrota, odnosno metode neuronskih mreža, koje su u dosadašnjim istraživanjima bile rijetko prisutne.

1.7. Struktura diplomskog rada

Diplomski rad će se sastojati od 4 dijela. Prvi dio sastoji se od uvoda u problem i predmet istraživanja, njegove ciljeve i metode korištene u izradi i proučavanju.

Drugi dio rada pružiti će uvid u važnost računovodstvenih informacija, te financijskih izvještaja u poslovanju poduzeća, u donošenju poslovnih odluka internih korisnika i potencijalnih odluka vanjskih korisnika, o investiranju i financijskom položaju poduzeća. Komparativnom analizom izvještaja i analizom putem financijskih pokazatelja korisnici mogu doći do brojnih informacija o financijskoj uspješnosti i položaju poduzeća, te saznanja o kretanju trenda. Upoznavanje sa nekim od najpoznatijih modela za predviđanje bankrota u Hrvatskoj i svijetu isto tako se obrađuje u ovom dijelu rada. Kako bi se mogla shvatiti kompleksnost i struktura postupaka korištenih u izradi konačnog modela potrebno je pružiti informacije o podlozi na kojoj počiva ovaj diplomski rad.

Praktični dio u kojem se razvija i dolazi do konačnog modela za predviđanje bankrota u Hrvatskoj, Bosni i Hercegovini, Srbiji i Mađarskoj se obrađuje u trećem dijelu. Polazi se od uzorka poduzeća i pripadajućih varijabli kojima se izračunavaju određeni financijski pokazatelji. Na temelju statističkih metoda potom će se odrediti važnost određenih pokazatelja, te u konačnici formirati matematički model za predviđanje bankrota.

Posljednji dio rada odnosi se na konačni zaključak temeljen na rezultatima istraživanja, gdje će se iznijeti najvažnija rješenja postavljenog problema istraživanja, odnosno zaključci na temelju postavljenih hipoteza.

2. UTVRĐIVANJE POSLOVNOG NEUSPJEHA TEMELJEM RAČUNOVODSTVENIH INFORMACIJA

U današnjem dinamičnom okruženju informacija je najvažniji resurs kojim poduzeće raspolaže kako bi se moglo što brže i kvalitetnije adaptirati turbulentnom tržišnom okruženju. Najvažniji cilj računovodstva je pružanje računovodstvenih informacija kojima se koriste poduzetnici, investitori, menadžeri i svi oni akteri kojima je u interesu poslovni uspjeh, odnosno neuspjeh poduzeća. Ukoliko poduzeće ne iskoristi taj resurs posljedice mogu biti mnogobrojne, od gubitka potencijalnih ili postojećih kupaca, neispunjavanja obveza pa sve do mogućeg bankrota, odnosno stečaja poduzeća. Stoga je u cilju što boljeg utvrđivanja poslovne uspješnosti poduzeća potrebno razumijeti računovodstvene informacije koje pružaju: temeljni financijski izvještaji, tehnike mjerenja ispitivanja uspješnosti poslovanja poput komparativnih izvještaja i financijskih pokazatelja, te sve one informacije koje su relevantne za donošenje mnogih poslovnih odluka.

2.1. Računovodstvene informacije u modernom poslovnom okruženju

Računovodstvene informacije su značajna podloga za donošenje odluka u ekonomskom okruženju. Korisnici računovodstvenih informacija mogu biti potencijalni ulagači, zajmodavci, ili budući poslovni partneri. Svi oni se primarno oslanjaju na njih kako bi mogli donijeti odluke vezane za poslovanje poduzeća ili pak odluke o ulaganju u poduzeće. Kako bi računovodstvene informacije rezultirale dobrim poslovnim odlukama one moraju biti pravovremene i kvalitetne.

Prema FASB-u „SFAC No.2 – Kvalitativna obilježja računovodstvenih informacija“ u primarna kvalitativna obilježja računovodstvenih informacija spadaju relevantnost i pouzdanost. Ta obilježja čine računovodstvene informacije vrlo korisnim u donošenju poslovnih odluka. Da bi računovodstvena informacija bila relevantna, ona mora biti pravovremena, što znači da ako korisnik ne dobije potrebnu informaciju na vrijeme postoji opasnost od donošenja štetnih odluka ili pak nedonošenja pravih odluka na vrijeme. Isto tako da bi informacija mogla biti relevantna, ona mora omogućavati predviđanje u budućnosti, mora pružati povratne informacije ili oboje. Sekundarna kvalitativna obilježja računovodstvenih informacija su usporedivost i dosljednost. Usporedivost označava karakteristiku računovodstvenih informacija pri kojoj se one mogu komparirati među sličnim poduzećima unutar industrije ili unutar određenog poduzeća tijekom vremenskog razdoblja

čime značajno raste njihov utjecaj pri donošenju pravodobnih i kvalitetnih ekonomskih odluka u modernom poslovnom okruženju. Usporedivost informacija među poduzećima uključujući dosljednost u korištenju metoda tijekom vremenskog razdoblja uvelike povećava kvalitetu računovodstvenih informacija što olakšava utvrđivanje potencijalnih ekonomskih i financijskih mogućnosti, te što kvalitetnije određivanje performansi.

2.2. Temeljni financijski izvještaji

Glavni izvor računovodstvenih informacija su financijski izvještaji. Proces računovodstva obuhvaća prikupljanje, te obradu računovodstvenih informacija. Posljedica tog procesa su financijski izvještaji. Financijski izvještaji su strukturirani prikaz financijskog položaja i financijske uspješnosti subjekta. Cilj je financijskih izvještaja opće namjene pružiti informacije o financijskom položaju, financijskoj uspješnosti i novčanim tokovima poslovnog subjekta koje su korisne širokom krugu korisnika u donošenju ekonomskih odluka. Financijski izvještaji također prikazuju rezultate uprave u upravljanju resursima koji su joj povjereni. Radi ispunjavanja tih ciljeva financijski izvještaji pružaju informacije o imovini, obvezama, kapitalu, prihodima i rashodima uključujući dobitke i gubitke, uplate vlasnika i isplate vlasnicima po osnovi kapitala u njihovom svojstvu vlasnika, te novčanim tokovima subjekta.¹ Temeljni financijski izvještaji su bilanca, račun dobiti i gubitka, izvještaj o novčanom tijeku, izvještaj o promjenama kapitala, te bilješke uz financijske izvještaje.²

IASB je u rujnu 2007. godine objavio novi MRS 1 Prezentiranje financijskih izvještaja čime su se dogodile velike promjene u nazivu financijskih izvještaja kako je prikazano u sljedećoj tablici:

Tablica 1: Nazivi financijskih izvještaja prema novom MRS-u 1

Nazivi financijskih izvještaja prema novom MRS 1 (primjena od 01.01.2010.)
1) Izvještaj o financijskom položaju na kraju razdoblja
2) Izvještaj o sveobuhvatnoj dobiti razdoblja
3) Izvještaj o promjenama kapitala
4) Izvještaj o novčanim tokovima tijekom razdoblja
5) Bilješke

Izvor: Belak, V., Vudrić, N. (2012): Osnove suvremenog računovodstva, Belak Excellens d.o.o., Zagreb, str. 22

¹ Narodne novine (2009): Međunarodni računovodstveni standard 1: Prezentiranje financijskih izvještaja, točka 9, Narodne novine d.d., broj 136

² Narodne novine (2007): Zakon o računovodstvu, Narodne novine d.d., broj 109, čl. 15, st. 3

Poduzetnici se dijele na mikro, male, srednje i velike poduzetnike ovisno o: veličine aktive, iznosu prihoda, te prosječnom broju zaposlenih tijekom godine. Uvjeti razvrstavanja poduzetnika prikazani su u sljedećoj tablici:

Tablica 2: Razvrstavanje poduzetnika prema Zakonu o računovodstvu

	Mikro poduzetnici	Mali poduzetnici	Srednji poduzetnici	Veliki poduzetnici³
Uvjet	Ne prelaze 2 od 3 navedena uvjeta:	Prelaze 2 od 3 prethodna, a ne prelaze 2 od 3 navedena uvjeta:	Prelaze 2 od 3 prethodna, a ne prelaze 2 od 3 navedena uvjeta:	Prelaze 2 od 3 navedena uvjeta
Iznos aktive	2.600.000 kuna	30.000.000 kuna	150.000.000 kuna	150.000.000 kuna
Iznos prihoda	5.200.000 kuna	60.000.000 kuna	300.000.000 kuna	300.000.000 kuna
Prosječan broj zaposlenih tijekom godine	10	50	250	250

Izvor: Prilagođeno od: Narodne novine (2015): Zakon o računovodstvu, Narodne novine d.d., broj 78, čl. 5

S obzirom na veličinu poduzetnika njihovi financijski izvještaji se moraju sastavljati i prezentirati prema Hrvatskim standardima financijskog izvještavanja, ukoliko se radi o mikro, malim i srednjim poduzetnicima. Ukoliko se radi o velikim poduzetnicima, oni imaju obvezu sastavljanja i prezentiranja financijskih izvještaja prema Međunarodnim računovodstvenim standardima, te prema Međunarodnim standardima financijskog izvještavanja. Godišnji financijski izvještaji moraju pružiti istinit i objektivan prikaz financijskog položaja i uspješnosti poslovanja poduzetnika.⁴

2.2.1. Bilanca

Bilanca predstavlja računovodstveni prikaz stanja i strukture imovine i njezinih izvora promatranog subjekta u određenom trenutku, tj. na određeni dan, izraženih u financijskim terminima. Pretpostavlja se da riječ bilanca dolazi od latinske riječi bilanx što znači vaga s

³ Osim poduzetnika koji ispunjavaju uvjete navedene uvjete, u velike poduzetnike prema Zakonu o računovodstvu spadaju i banke, štedne banke, stambene štedionice, institucije za elektronički novac, društva za osiguranje, društva za reosiguranje, *leasing*-društva, društva za upravljanje UCITS fondovima, društva za upravljanje alternativnim investicijskim fondovima, UCITS fondovi, alternativni investicijski fondovi, mirovinska društva koja upravljaju obveznim mirovinskim fondovima, mirovinska društva koja upravljaju dobrovoljnim mirovinskim fondovima, dobrovoljni mirovinski fondovi, obvezni mirovinski fondovi te mirovinska osiguravajuća društva, društva za dokup mirovine, faktoring-društva, investicijska društva, burze, operatori MTP-a, središnja klirinška depozitarna društva, operatori središnjeg registra, operatori sustava poravnanja i/ili namire i operatori Fonda za zaštitu ulagatelja

⁴ Narodne novine (2014): Zakon o računovodstvu, Narodne novine d.d., broj 121, čl. 15, st. 6

dvije zdjelice ili od talijanske riječi bilancia što znači vaga. Vaga je u ovom smislu metafora koja oslikava ravnotežu između imovine i izvora ih kojih je ta imovina financirana. Računovodstvenim jezikom imovina se naziva aktiva, a izvori imovine pasiva.⁵

Temeljni elementi bilance su imovina, kapital i glavnica. Imovina je resurs kojeg kontrolira poduzetnik kao rezultat prošlih događaja i od kojeg se očekuje priljev budućih ekonomskih koristi kod poduzetnika. Obveza je sadašnja obveza poduzetnika, proizašla iz prošlih transakcija i prošlih događaja za čije se podmirenje očekuje da će doći do odljeva resursa iz poduzetnika koji utjelovljuju ekonomske koristi. Obveza je dužnost ili odgovornost da se postupi ili nešto izvrši na određeni način. Obveze mogu biti zakonski izvršive, a mogu proisteći iz poslovne prakse. Kapital je vlastiti izvor financiranja imovine poduzetnika i predstavlja ostatak imovine nakon podmirivanja obveza. Kapital se u pasivi bilance detaljnije raščlanjuje i to na: upisani kapital, kapitalne rezerve, rezerve, revalorizacijske rezerve, zadržana dobit ili preneseni gubitak i dobit ili gubitak tekuće godine.⁶

Tablica 3: Shema bilance u RH

AKTIVA	PASIVA
Potraživanja za upisani, a neuplaćeni kapital	Kapital i rezerve
Dugotrajna imovina	Rezerviranja
Kratkotrajna imovina	Dugoročne obveze
Plaćeni troškovi budućeg razdoblja i obračunati prihodi	Kratkoročne obveze
	Odgođeno plaćanje troškova i prihod budućega razdoblja
Ukupno aktiva	Ukupno pasiva
Izvanbilančni zapisi	Izvanbilančni zapisi

Izvor: Izrada autora prilagođeno prema: Belak, V., Vudrić, N. (2012): Osnove suvremenog računovodstva, Belak Excellens d.o.o., Zagreb, str. 524-525

2.2.2. Račun dobiti i gubitka

Poduzeće može poslovati u cilju ostvarivanja raznih ciljeva, primjerice s ciljem minimizacije troškova, minimizacije rizika poslovanja i slično. Međutim najčešći cilj poduzetnika je maksimizacija profita. Kakav je financijski rezultat poduzeće ostvarilo prikazuje se u financijskom izvještaju račun dobiti i gubitka. U ovom izvještaju sučeljavaju se ostvareni prihodi s rashodima te se na temelju njih dobije financijski rezultat poslovanja. Razlika

⁵ Prilagođeno od: Belak, V., Vudrić, N. (2012): Osnove suvremenog računovodstva, Belak Excellens d.o.o., Zagreb, str. 25

⁶ Narodne novine (2008): Hrvatski standardi financijskog izvještavanja – Okvir za primjenu hrvatskih standarda financijskog izvještavanja, Narodne novine d.d., broj 30, točka 1.6.

između bilance i računa dobiti i gubitka je što je bilanca statični financijski izvještaj koji prikazuje stanje imovine i kapitala na određeni datum, dok račun dobiti i gubitka prikazuje ostvaren financijski poslovni rezultat poduzeća kroz određeno razdoblje. Bilancu i račun dobiti i gubitka su obvezni sastavljati svi poduzetnici.

Temeljni elementi računa dobiti i gubitka su prihod, rashod, dobit prije oporezivanja, porez na dobit, te dobit poslije oporezivanja, odnosno neto dobit.

Prihodi su bruto priljev ekonomskih koristi tijekom obračunskog razdoblja koji proizlazi iz redovnih aktivnosti poduzetnika, kada ti priljevi imaju za posljedicu povećanje kapitala, osim povećanja kapitala koje se odnosi na uplate sudionika u kapitalu.

Rashodi su smanjenja ekonomskih koristi kroz obračunsko razdoblje u obliku odljeva ili iscrpljenja imovine ili stvaranja obveza što za posljedicu ima smanjenje kapitala, osim onog u svezi s raspodjelom sudionicima u kapitalu.⁷

Ukupni prihodi, te ukupni rashodi se sastoje od poslovnih, financijskih i izvanrednih prihoda, odnosno rashoda. Poslovni prihod predstavlja najznačajniji dio ukupnih prihoda poduzeća, a označava prihod ostvaren od prodaje proizvoda ili pružanja usluga, odnosno ono što spada u redovno poslovanje poduzeća. S druge strane poslovni rashod obuhvaća sve troškove vezane za redovno poslovanje. Financijski prihodi, odnosno rashodi su priljev, odnosno odljev novca od ulaganja u dionice, obveznice, pružanja zajmova drugim društvima i slično, na temelju čega poduzeće ostvaruje prihod od dividendi ili kamata.

Rezultat oduzimanja ukupnih rashoda od ukupnih prihoda je dobit prije oporezivanja. Dobit prije oporezivanja se može uvećati za porezno nepriznate rashode ili smanjiti, prema Zakonu o porezu na dobit. Na tu poreznu osnovicu se obračunava porez na dobit u iznosu od 20% čime se dobije dobit poslije oporezivanja. Ukoliko je poduzetnik ostvario gubitak prije oporezivanja, tada se ne obračunava porez na dobit. Dobit poslije oporezivanja postaje resurs trgovačkog društva koji se može uložiti natrag u društvo ili isplatiti vlasnicima u obliku dividendi ili u obliku isplate dobiti vlasnicima.

Uz promjene naziva financijskih izvještaja prema novom MRS-u 1 određeno je da subjekti, obveznici primjene MSFI-ja, uz izvještaj o realiziranoj dobiti odnosno uz račun dobiti i gubitka moraju uvesti i izvještaj o ostaloj sveobuhvatnoj dobiti. Subjekt može birati hoće li

⁷ Narodne novine (2008): Hrvatski standard financijskog izvještavanja 14 – Vremenska razgraničenja, Narodne novine d.d., broj 30, točka 14.3 – 14.4.

sve stavke prikazati u jednom izvještaju kao izvještaju o sveobuhvatnoj dobiti ili u dvama izvještajima, jedan kao zaseban račun dobiti i gubitka i drugi koji započinje dobiti ili gubitkom i sastoji se od stavki ostale sveobuhvatne dobiti. Elementi ostale sveobuhvatne dobiti su tečajne razlike iz preračuna inozemnog poslovanja, promjene revalorizacijskih rezervi dugotrajne materijalne i nematerijalne imovine, dobit ili gubitak s osnove ponovnog vrednovanja financijske imovine raspoložive za prodaju, dobit ili gubitak s osnove učinkovite zaštite novčanog toka, dobit ili gubitak s učinkovite zaštite neto ulaganja u inozemstvu, udio u ostaloj sveobuhvatnoj dobiti/gubitku pridruženih poduzetnika i aktuarski dobici/gubici po planovima definiranih primanja.⁸

2.2.3. Izvještaj o novčanom tijeku

Izvještaj o novčanom tijeku je temeljni financijski izvještaj kojim se iskazuju priljevi i odljevi novca i novčanih ekvivalenata. Novac obuhvaća novac u blagajni i depozite po viđenju. Novčani ekvivalenti jesu kratkotrajna, visoko likvidna ulaganja koja se mogu brzo konvertirati u poznate iznose novca i podložna su beznačajnom riziku promjena vrijednosti, kao na primjer državne obveznice, komercijalni zapisi i vrijednosni papiri s rokom dospijeca do 3 mjeseca. Posebnost izvještaja o novčanom tijeku u odnosu na bilancu koja isto tako iskazuje stavku novac i novčani ekvivalenti jest u tome što bilanca iako pokazuje stanje novca i novčanih ekvivalenata, ne pokazuje novčani tijek tog razdoblja, ni koje transakcije su uzrok tih promjena. Zato se izvještaj o novčanom tijeku smatra informativnijim za poduzetnike, tako na primjer u slučaju kada je kupcu prodan proizvod i izdan račun, to će se u bilanci pojaviti kao prihod iako kupac nije još platio račun (načelo nastanka događaja), dok će se kod izvještaja o novčanom tijeku priljev novca pojaviti tek kada kupac plati račun (načelo naplaćene realizacije).

Izvještaj o novčanim tokovima treba prezentirati novčane tokove tijekom razdoblja, klasificirane na novčane tokove od poslovnih, investicijskih i financijskih aktivnosti.

Poslovne aktivnosti jesu glavne prihodovno-proizvodne aktivnosti subjekta i druge aktivnosti, osim investicijskih i financijskih aktivnosti. Novčani tokovi od poslovnih aktivnosti prvenstveno proizlaze od glavnih proizvodnih aktivnosti subjekta koje stvaraju prihode. Oni uglavnom proizlaze iz transakcija i drugih poslovnih događaja koji se uključuju u određivanje dobiti ili gubitka.

⁸ TEB-poslovno savjetovanje (2011): Međunarodni standardi financijskog izvještavanja, prijevod s engleskog jezika, Tiskara Zelina d.d., Zagreb, str. 711

Tablica 4: Primjeri novčanih tokova od poslovnih aktivnosti

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

Izvor: Izrada autora prema: TEB-poslovno savjetovanje (2011): Međunarodni standardi financijskog izvještavanja, prijevod s engleskog jezika, Tiskara Zelina d.d., Zagreb, str. 42

Investicijske aktivnosti jesu stjecanje i otuđivanje dugotrajne imovine i drugih ulaganja, koja nisu uključena u novčane ekvivalente. Važno je odvojeno objaviti novčane tokove nastale investicijskim aktivnostima, budući da oni prikazuju veličinu nastalih izdataka za resurse koji su namijenjeni stvaranju buduće dobiti i novčanih tokova.

Tablica 5: Primjeri novčanih tokova od investicijskih aktivnosti

Novčani tokovi od investicijskih aktivnosti	- novčane isplate za stjecanje i novčani primici od prodaje nekretnina, postrojenja i opreme, nematerijalne imovine i druge dugotrajne imovine. Navedene isplate obuhvaćaju one koje se odnose na kapitalizaciju troškova razvoja i izgradnju nekretnina, postrojenja i opreme u vlastitoj izvedbi; - novčani izdaci za stjecanje i novčani primici od prodaje glavnih ili dužničkih instrumenata drugih subjekata i udjela u zajedničkim pothvatima (osim isplate temeljem instrumenata koji se smatraju novčanim ekvivalentima ili se drže za svrhe dilaanja ili trgovanja); - novčani predujmovi i zajmovi dani drugim osobama (osim predujmova i zajmova koje je dala financijska institucija); - novčani primici od otplate predujmova i zajmova danih drugim osobama (osim predujmova i zajmova financijske institucije); - novčane isplate i novčani primici temeljem ugovora za futures-e, forward-e, opcije i swapove, osim kada se ti ugovori drže za svrhe dilaanja ili trgovanja, ili su plaćanja klasificirana kao financijske aktivnosti;
--	---

Izvor: Izrada autora prema: TEB-poslovno savjetovanje (2011): Međunarodni standardi financijskog izvještavanja, prijevod s engleskog jezika, Tiskara Zelina d.d., Zagreb, str. 43

Financijske aktivnosti jesu aktivnosti koje rezultiraju promjenom veličine i sastava kapitala i zaduživanja subjekta. Odvojeno objavljivanje novčanih tokova nastalih financijskim aktivnostima je važno jer koristi onima koji osiguravaju kapital subjektu u predviđanju očekivanja vezanih uz buduće novčane tokove.⁹

⁹ TEB-poslovno savjetovanje (2011): Međunarodni standardi financijskog izvještavanja, prijevod s engleskog jezika, Tiskara Zelina d.d., Zagreb, str. 42

Tablica 6: Primjeri novčanih tokova od financijskih aktivnosti

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

Izvor: Izrada autora prema: Međunarodni standardi financijskog izvještavanja (2011): prijevod s engleskog jezika, TEB-poslovno savjetovanje d.o.o., Zagreb, str. 44

Izvještaj o novčanom tijeku se može sastaviti po direktnoj ili indirektnoj metodi. Prema direktnoj metodi ukupni novčani primici i izdaci iskazuju se prema aktivnostima, dok se kod indirektno metode neto novčani tok od poslovnih aktivnosti utvrđuje tako da se dobit odnosno gubitak korigira za sve iznose nenovčanih transakcija poput: amortizacije, rezerviranja, nerealizirane pozitivne ili negativne tečajne razlike, promjena zaliha i dobiti ili gubitka iz investicijskih ili financijskih aktivnosti, a kada su uključene u neto dobit. Mali poduzetnici su oslobođeni obveze sastavljanja izvještaja o novčanom tijeku, za razliku od srednjih i velikih poduzetnika koji su ga obvezni sastavljati po direktnoj ili indirektnoj metodi.

2.2.4. Izvještaj o promjenama kapitala

Izvještaj o promjenama kapitala prikazuje sve promjene na kapitalu koje su se dogodile između dva datuma bilance.¹⁰

Subjekt je dužan u izvještaju o promjenama glavnice iskazati:

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

¹⁰Belak, V., Vudrić, N. (2012): Osnove suvremenog računovodstva, Belak Excellens d.o.o., Zagreb, str. 22

Izveštaj o promjena kapitala su obvezni sastavljati srednji i veliki poduzetnici. Standardizirani oblik ovog izvještaja nije određen, pa se poduzetnici pri sastavljanju koriste odredbama Pravilnika o strukturi i sadržaju godišnjih financijskih izvještaja.

2.2.5. Bilješke uz financijske izvještaje

Bilješke uz financijske izvještaje služe kako bi korisnicima pružili dodatne informacije koje će im pomoći u boljem razumijevanju financijskih izvještaja određenog subjekta, a koje nisu prezentirane u bilanci, računu dobiti i gubitka, izvještaju o ostaloj sveobuhvatnoj dobiti, izvještaju o novčanom tijeku i izvještaju o promjenama kapitala. Bilješke prikazuju financijske i nefinancijske informacije. Prema Zakonu o računovodstvu bilješke uz financijske izvještaje su obvezni sastavljati svi poduzetnici, dakle bez obzira na veličinu. Nema propisane formalne strukture, već se poduzetnici koriste Pravilnikom o strukturi i sadržaju godišnjih financijskih izvještaja pri njegovom sastavljanju, pri čemu ga veliki poduzetnici sastavljaju sukladno Međunarodnim standardima financijskog izvještavanja, a mali i srednji sukladno Hrvatskim standardima financijskog izvještavanja.

Hrvatski standard financijskog izvještavanja 1 – Financijski izvještaji propisuje u 18 točaka informacije koje korisnici HSFI-a trebaju prezentirati u bilješkama, s tim da su mali poduzetnici obvezni u bilješkama prezentirati samo prvih 9 točaka.

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

1. Izjava o sukladnosti s MSFI-ima
2. Sažetak primijenjenih važnih računovodstvenih politika
3. Informacije koje potkrepljuju stavke prikazane u izvještaju o financijskom položaju te izvještaju o sveobuhvatnoj dobiti, u odvojenom računu dobiti i gubitka (ako je prezentiran), izvještaju o promjenama kapitala i izvještaju o novčanim tokovima, po redoslijedu prema kojemu su ti izvještaji i stavke prikazani i
4. Druga objavljivanja, uključujući:
 - a) nepredviđene obveze i nepriznate ugovorno preuzete obveze
 - b) nefinancijske informacije, primjerice, ciljeve i politike subjekta koji se odnose na upravljanje financijskim rizikom.¹¹

¹¹ TEB-poslovno savjetovanje (2011): Međunarodni standardi financijskog izvještavanja, prijevod s engleskog jezika, Tiskara Zelina d.d., Zagreb, str. 28

2.3. Analiza financijskih izvještaja

Financijski izvještaji predstavljaju glavni izvor informacija koje prikazuju stanje tvrtke, njenu imovinu, kapital ili rezultat poslovanja. Analiza financijskih izvještaja je vrlo bitna jer pruža dodatne informacije koje mogu značajno utjecati na donošenje ekonomskih odluka. Tehnikama analize financijskih izvještaja se može odrediti uspješnost i financijski položaj poduzeća u prošlosti i na temelju tih informacija može se procijeniti slika poduzeća u nekom budućem vremenskom razdoblju.

Takve informacije su važne internim i eksternim korisnicima. Interni korisnici, primjerice menadžment, može na temelju tih informacija donijeti bitne odluke o poslovanju poduzeća, a s druge strane te informacije mogu pomoći eksternim korisnicima poput dioničara kod donošenja odluke o kupnji vrijednosnih papira određenog subjekta. Dobivene informacije se mogu uspoređivati unutar istog poduzeća kroz različita vremenska razdoblja kako bi se procijenio trend, između različitih poduzeća koja se bave sličnom djelatnošću, te je moguća usporedba unutar industrije, u odnosu na industrijske prosjeke.

Metode analize financijskih izvještaja koje će se dalje obraditi u tekstu su: horizontalna analiza (komparativni financijski izvještaji), vertikalna analiza (strukturni financijski izvještaji), te analiza pomoću pokazatelja koji su najvažniji u oblikovanju modela za predviđanje bankrota poduzeća.

2.3.1. Horizontalna analiza

Horizontalna analiza pruža informacije o tome koliko se određena stavka u tekućem razdoblju promjenila u odnosu na vrijednost te stavke u određenoj baznoj godini (bazni indeksi) ili u odnosu na vrijednost u prethodnoj godini (verižni indeksi).

Da bi se provela ova vrsta analiza potrebno je sastaviti komparativne financijske izvještaje kojima se uspoređuju postotne promjene određenih stavki financijskih izvještaja kroz određeno vremensko razdoblje, odnosno za više uzastopnih godina. Što je više godina uključeno u analizu to je konačna informacija relevantnija i pouzdanija.

Horizontalna analiza nam služi kako bi uvidjeli pozitivna ili negativna odstupanja vrijednosti pojedinih stavki financijskih izvještaja kroz vremenska razdoblja. Na temelju dobivenih informacija korisnici mogu procijeniti vjerojatnost da će se takav trend rasta ili pada nastaviti i

u budućnosti. Isto tako im daje povod da se istraži uzrok tih promjena kako bi se eventualno dovelo do nekih promjena u daljnjem poslovanju.

Za izračun baznih indeksa, odnosno za izračun postotne promjene pojedine stavke u odnosu na određeno bazno razdoblje koristi se sljedeća formula:

$$\text{Postotna promjena} = \frac{\text{Stanje u tekućem razdoblju} - \text{Stanje u baznom razdoblju}}{\text{Stanje u baznom razdoblju}} * 100 \quad (1)$$

Za izračun verižnih indeksa, odnosno za izračun postotne promjene pojedine stavke u odnosu na prethodno razdoblje koristi se sljedeća formula:

$$\text{Postotna promjena} = \frac{\text{Stanje u tekućem razdoblju} - \text{Stanje u prethodnom razdoblju}}{\text{Stanje u prethodnom razdoblju}} * 100 \quad (2)$$

2.3.2. Vertikalna analiza

Vertikalna analiza je ona u kojoj se jedna pozicija iz financijskog izvještaja uzima kao konstanta, te se određuje postotni odnos svih ostalih varijabli tj. podataka iz izvještaja u odnosu na uzetu konstantnu varijablu. Dakle, to je usporedba pojedine pozicije iz financijskih izvještaja s povezanim pozicijama u istom izvještaju (uobičajeno se bazna pozicija izjednačava sa 100, a druga se izražava kao njen postotak).

Vertikalna analiza daje uvid u strukturu izvještaja. Uobičajena analitička sredstva u vertikalnoj analizi su strukturni financijski izvještaji. Oni su vrlo korisni kod uspoređivanja s drugim poduzećima jer se na taj način prevladavaju razlike u veličini poduzeća, te kod uspoređivanja podataka u vremenu kad je u gospodarstvu prisutna inflacija. Često se u analitičke svrhe izrađuje kombinacija strukturnih i komparativnih financijskih izvještaja.¹²

U kontekstu vertikalne financijske analize važno je napomenuti da su strukturni financijski izvještaji koji se temelje na bilanci, u osnovi, usmjereni na dva važna aspekta:

1) Razmatranje izvora imovine poduzeća koji mogu biti kratkoročne obveze, dugoročne obveze i vlastiti izvori (vlasnička glavnica)

¹² Aljinović Barać, Ž. (2014): Računovodstvo novčanih tijekova, autorski materijal, akademska godina 2013/14, Ekonomski fakultet Split, Split

2) Razmatranje strukture imovine koja se prije svega odnosi na odnos kratkotrajne i dugotrajne imovine koji je prije svega determiniran djelatnošću koje poduzeće obavlja.¹³

2.3.3. Analiza putem financijskih pokazatelja

Analiza putem pokazatelja sastoji se od toga da se u omjer stavljaju jedna ili više stavki iz bilance, računa dobiti i gubitka ili izvještaja o novčanom tijeku. Dobiveni rezultat predstavlja određenu vrijednost koja se potom uspoređuje s određenim očekivanim vrijednostima, unutar poduzeća tijekom vremenskom razdoblja ili sa industrijskim prosjekom. Financijski pokazatelji su veoma bitni jer mogu značajno utjecati na ekonomske odluke internih, a pogotovo eksternih korisnika. Eksterni korisnici se ponajviše koriste financijskim pokazateljima u donošenju odluke o ulaganju vlastitih sredstava u pojedino poduzeće.

Međutim, iako su financijski pokazatelji naizgled najjednostavniji i najrazumljiviji izvor informacija o stanju i uspješnosti poslovanja poduzeća, ujedno sadrže i neka važna ograničenja. To su:

1. Problem primjene različitih računovodstvenih politika - izbor različitih računovodstvenih alternativa u iskazivanju istih kategorija umanjuje usporedivost podataka među tvrtkama. Kada se primjenom analize putem pokazatelja iste veličine još i relativiziraju te se određene informacije "ispuste", neusporedivost podataka zbog primjene različitih računovodstvenih politika postaje još izraženija.
2. Ekonomija obujma - jedan od ciljeva analize putem pokazatelja je relativiziranjem informacija o tvrtki omogućiti usporedbu među tvrtkama različitih veličina. Međutim, u slučajevima postojanja ekonomije obujma, veličina tvrtke je objašnjavajuća varijabla za određene podatke, a ona se korištenjem pokazatelja zanemaruje. Isto tako, analiza putem pokazatelja podrazumijeva linearnu povezanost između brojnika i nazivnika pokazatelja, što kod ekonomije obujma nije slučaj.
3. Razdoblje izvještavanja - zbog sezonske prirode poslova, određene tvrtke primjenjuju razdoblje izvještavanja različito od kalendarske godine. Usporedbom pokazatelja među tvrtkama za isto izvještajno razdoblje zanemaruju se razlike koje nastaju zbog sezonske prirode posla.
4. Računska ograničenja - primjena matematičkih pravila u izračunu pokazatelja može dati pogrešne rezultate, posebice kada se radi o negativnim brojevima (negativni brojevi u

¹³ Žager, K., et al. (2008): Analiza financijskih Izvještaja, Masmedia d.o.o., Zagreb, str. 231

brojniku i nazivniku pokazatelja rezultirat će pozitivnim koeficijentom) i malim brojevima (posebice kada se nalaze u nazivniku pokazatelja).

5. Karakteristike distribucije - korištenje industrijskih prosjeka kao baze za usporedbu podrazumijeva zadovoljavanje određenih statističkih pretpostavki o vjerojatnosti distribucije u populaciji, koje ne moraju biti (i u pravilu nisu) zadovoljene.¹⁴

S obzirom na to kakvu vrstu podataka tražimo o određenom subjektu, primjerice podatke o njegovoj zaduženosti, profitabilnosti, načinu financiranja, itd., razlikujemo nekoliko skupina pokazatelja:

1. Pokazatelji likvidnosti – mjere sposobnost poduzeća da podmiri svoje dospjele kratkoročne obveze.
2. Pokazatelji zaduženosti – mjere koliko se poduzeće financira iz tuđih izvora sredstava.
3. Pokazatelji aktivnosti – mjere kako efikasno poduzeće upotrebljava svoje resurse.
4. Pokazatelji ekonomičnosti – mjere odnos prihoda i rashoda, tj. pokazuju koliko se prihoda ostvari po jedinici rashoda.
5. Pokazatelji profitabilnosti – mjere povrat uloženog kapitala, što se smatra najvišom upravljačkom djelotvornošću.
6. Pokazatelji investiranja – mjere uspješnost ulaganja u obične dionice.¹⁵

Pokazatelji likvidnosti mjere sposobnost poduzeća da u roku podmiri svoje kratkoročne obveze. Oni stavljaju u omjer tekuću aktivu i tekuću pasivu. Što je veća pokrivenost tekuće pasive aktivom znači da poduzeće može platiti svoje kratkoročne obveze i dalje financirati svoje redovne poslovne aktivnosti. Kod pokazatelja likvidnosti ne radi se samo o novcu u smislu pomirenja obveza već i o sposobnosti poduzeća da svoju drugu kratkotrajnu imovinu poput zaliha ili kratkoročnih potraživanja u kratkom roku može pretvoriti u novac.

Tablica 7: Pokazatelji likvidnosti

Naziv pokazatelja	Brojnik	Nazivnik
Koeficijent tekuće likvidnosti	Kratkotrajna imovina	Kratkoročne obveze
Koeficijent ubrzane likvidnosti	Kratkotrajna imovina – zalihe	Kratkoročne obveze
Koeficijent trenutne likvidnosti	Novac	Kratkoročne obveze
Koeficijent financijske stabilnosti	Dugotrajna imovina	Kapital + dugoročne obveze

Izvor: Žager, K. et al. (2008): Analiza financijskih izvještaja: Temeljni instrumenti i postupci analize financijskih izvještaja, Masmedia d.o.o., Zagreb, str. 248

¹⁴ Aljinović Barać, Ž. (2008): Doktorska disertacija: Model procjene uspješnosti tvrtke na temelju pokazatelja novčanog tijeka, Ekonomski fakultet Split, Split, str. 116

¹⁵ Žager, K., et al. (2008): Analiza financijskih izvještaja, Masmedia d.o.o., Zagreb, str. 244

Pokazatelji zaduženosti daju uvid u strukturu duga kompanije, odnosno koliko se poduzeće financira iz tuđih izvora sredstava, te koliko je imovine financirano iz vlastitog kapitala. Oni mjere ukupan financijski rizik s kojim se susreće poduzeće i njegovi dioničari. Daju signal menadžerima i dioničarima da se poduzeće može susresti sa potencijalnim financijskim poteškoćama. Poduzeća koja imaju visok stupanj zaduženosti smatraju se rizičnima za ulaganje. Mogu se susresti sa situacijom u kojoj će imati poteškoća u pronalaženju novih ulagača, te postoji mogućnost da budu suočena s rizikom bankrota. Stoga je bitno držati stupanj zaduženosti pod kontrolom i posuđena sredstva iskoristiti na adekvatan način, te tada zaduženost može rezultirati porastom povrata na investirano. Pokazatelji zaduženosti mogu pomoći investitorima i kreditorima da dobiju uvid u strukturu duga kompanije, stupnja zaduženosti poduzeća, njegove sposobnosti da otplati svoj dug, te daju informaciju o tome da li kompanija ima dovoljno resursa da pokrije sve svoje obveze.

Tablica 8: Pokazatelji zaduženosti

Naziv pokazatelja	Brojnik	Nazivnik
Koeficijent zaduženosti	Ukupne obveze	Ukupna imovina
Koeficijent vlastitog financiranja	Glavnica	Ukupna imovina
Koeficijent financiranja	Ukupne obveze	Glavnica
Pokriće troškova kamata	Dobit prije poreza i kamata	Kamate
Faktor zaduženosti	Ukupne obveze	Zadržana dobit + amortizacija
Stupanj pokrića I	Glavnica	Dugotrajna imovina
Stupanj pokrića II	Glavnica + dugoročne obveze	Dugotrajna imovina

Izvor: Žager, K. et al. (2008): Analiza financijskih izvještaja: Temeljni instrumenti i postupci analize financijskih izvještaja, Masmedia d.o.o., Zagreb, str. 251

Pokazatelji aktivnosti daju informacije o tome da li poduzeće efikasno koristi svoju imovinu, odnosno koliko poduzeće ostvari prihoda na jedinicu uložene imovine. Može se mjeriti u odnosu na ukupnu imovinu, kratkotrajnu imovinu, zalihe, kratkotrajna potraživanja, no bitno je da je pokazatelj što veći.

Tablica 9: Pokazatelji aktivnosti

Naziv pokazatelja	Brojnik	Nazivnik
Koeficijent obrta ukupne imovine	Ukupni prihodi	Ukupna imovina
Koeficijent obrta kratkotrajne imovine	Ukupni prihodi	Kratkotrajna imovina
Koeficijent obrta potraživanja	Prihodi od prodaje	Potraživanja
Trajanje naplate potraživanja	Broj dana u godini (365)	Koeficijent obrta potraživanja
Koeficijent obrta zaliha	Troškovi za prodano	Zalihe
Dani vezivanja zaliha	Broj dana u godini (365)	Koeficijent obrta zaliha

Izvor: Žager, K. et al. (2008): Analiza financijskih izvještaja: Temeljni instrumenti i postupci analize financijskih izvještaja, Masmedia d.o.o., Zagreb, str. 252

Pokazatelji ekonomičnosti govore koliko poduzeće ostvaruje prihoda po jedinici rashoda, odnosno mjere odnos prihoda i rashoda poduzeća. Pokazatelji ekonomičnosti se mogu mjeriti stavljanjem u odnos ukupnih prihoda i rashoda ili prihoda i rashoda pojedine skupine, dakle stavljanjem u odnos poslovnih, financijskih ili izvanrednih prihoda i rashoda. Poželjno je da je ovaj pokazatelj bude što veći, odnosno u pravilu treba biti veći od jedan.

Tablica 10: Pokazatelji ekonomičnosti

Naziv pokazatelja	Brojnik	Nazivnik
Ekonomičnost ukupnog poslovanja	Ukupni prihodi	Ukupni rashodi
Ekonomičnost prodaje/poslovanja	Poslovni prihodi	Poslovni rashodi
Ekonomičnost financiranja	Financijski prihodi	Financijski rashodi
Ekonomičnost izvanrednih aktivnosti	Izvanredni prihodi	Izvanredni rashodi

Izvor: Žager, K. et al. (2008): Analiza financijskih izvještaja: Temeljni instrumenti i postupci analize financijskih izvještaja, Masmedia d.o.o., Zagreb, str. 252

Pokazatelji profitabilnosti iskazuju koliko je kompanija efikasna u korištenju svojih resura u generiranju profita. Oni su jedan od najvažnijih dijelova financijske analize s obzirom da je svima, od managera do poslovnih partnera poduzeća, u interesu njegova profitabilnost. Pokazatelji profitabilnosti mjere učinkovitost poslovanja poduzeća, te njegovu sposobnost da ostvari dobit u odnosu na uloženu imovinu ili kapital.

Tablica 11: Pokazatelji profitabilnosti

Naziv pokazatelja	Brojnik	Nazivnik
Bruto marža profita	Dobit prije poreza i kamata	Ukupni prihodi
Neto marža profita	Neto dobit + kamate	Ukupni prihodi
Rentabilnost imovine	Dobit prije poreza i kamata	Ukupna imovina
Rentabilnost kapitala	Neto dobit	Vlastiti kapital

Izvor: Žager, K. et al. (2008): Analiza financijskih izvještaja: Temeljni instrumenti i postupci analize financijskih izvještaja, Masmedia d.o.o., Zagreb, str. 253

Pokazatelji investiranja daju informacije trenutačnim i potencijalnim dioničarima da li je njihovo ulaganje u pojedinu poduzeće isplativo. Mogu ih koristiti investitori u određivanju efikasnosti ulaganja u potencijalnu ili postojeću investiciju, te da procjene njihovu vrijednost.

Tablica 12: Pokazatelji investiranja

Naziv pokazatelja	Brojnik	Nazivnik
Dobit po dionici	Neto dobit	Broj redovnih dionica
Dividenda po dionici		Broj redovnih dionica
Odnos isplate dividendi	Dividenda po dionici	Dobit po dionici
Odnos cijene i dobiti po dionici	Tržišna cijena dionice	Dobit po dionici
Ukupna rentabilnost dionice	Dobit po dionici	Tržišna cijena dionice
Dividendna rentabilnost dionice	Dividenda po dionici	Tržišna cijena dionice

Izvor: Žager, L. et al. (2008): Analiza financijskih izvještaja: Temeljni instrumenti i postupci analize financijskih izvještaja, Masmedia d.o.o., Zagreb, str. 254

2.4. Pregled modela za predviđanje bankrota

Postavlja se pitanje dali je moguće predvidjeti bankrot? Naime, kada bi se bankrot mogao uspješno predvidjeti to bi značilo da poduzeće, investitori i financijske institucije raspolažu vrlo važnim informacijama koje bi im pomogle da zaobiđu bankrot. Tako bi poduzeća znala odgovor na više važnih pitanja kao što je donošenje odluke za odobravanje zajma nekom poduzeću, dali ulaziti u određene poslovne odnose itd. Dioničari bi također donosili lakše odluke o tome u što ulagati, kao i cijeli financijski sektor koji bi mogao odrediti kome i gdje odobriti kredit, kakvu kamatnu stopu i sl. Tako bi određivanje samog modela za utvrđivanje bankrota imalo niz pogodnosti za sve aktere u poslovnom okruženju. Sama istraživanja i uzroci bankrota te njegove procjene prisutne su kako u poslovnoj tako i akademskoj sferi. U nastavku će se ukratko navesti neki od najvažnijih i najutjecajnih modela za predviđanje bankrota poduzeća.

2.4.1. Pregled najznačajnijih modela za predviđanje bankrota

Prvi značajan model za predviđanje poslovnog neuspjeha predstavlja **William H. Beaver** 1966. godine. Beaver pod poslovnim neuspjehom podrazumijeva nesposobnost poslovnog subjekta da podmiri dospelje financijske obveze.¹⁶

Uzorak se sastojao od 158 proizvodnih poslovnih subjekata iz 38 različitih industrija, a čijim se dionicama javno trgovalo. Taj uzorak je zatim podijeljen na dvije jednake grupe, dakle svaka grupa se sastojala od 79 poslovnih subjekata, od kojih je jedna grupa poduzeća koja su ušla u stečajni postupak u razdoblju od 1954. do 1964. godine., a druga grupa financijski zdrava poduzeća. Prikupljeni su financijski izvještaji poslovnih subjekata za razdoblje od 5 godina prije pokretanja stečajnog postupka, te isto razdoblje za financijski zdrava poduzeća. Beaver je potom uparivao zdravo i nezdravo poduzeće prema vrsti industrije i veličini imovine. Izračunao je 30 financijskih pokazatelja koje je grupirao u 6 skupina.

¹⁶ Beaver, W. (1966): Financial Ratios as Predictors of Failure, Journal of Accounting Research, Supplement, Vol. 4 Issue 3, str. 71

Tablica 13: Popis testiranih omjera

GRUPA I (OMJERI TIJEKA NOVCA) 1. Tijek novca (dobit + deprecijacija + amortizacija) / prihod od prodaje 2. Tijek novca / ukupna imovina 3. Tijek novca / Neto vrijednost (Ukupna imovina – ukupne obveze) 4. Tijek novca / ukupan dug	GRUPA V (OMJERI TEKUĆE IMOVINE I KRATKOROČNIH OBVEZA) 1. Novac / kratkoročne obveze 2. Novac + potraživanja / kratkoročne obveze 3. Kratkotrajna imovina / kratkoročne obveze
GRUPA II (OMJERI NETO DOBITI) 1. Neto dobit / prihod od prodaje 2. Neto dobit / ukupna imovina 3. Neto dobit / neto vrijednost 4. Neto dobit / ukupan dug	GRUPA VI (OMJERI OBRTAJA) 1. Novac / prihodi od prodaje 2. Potraživanja / prihodi od prodaje 3. Zalihe / prihodi od prodaje 4. Novac + potraživanja / prihodi od prodaje 5. Kratkotrajna imovina / prihodi od prodaje 6. Radni kapital / prihodi od prodaje 7. Tržišna vrijednost / prihodi od prodaje 8. Ukupna imovina / prihodi od prodaje 9. Novac / Operativni troškovi – deprecijacija– amortizacija 10. Novac + potraživanja / Operativni troškovi – deprecijacija– amortizacija 11. Novac + potraživanja – kratkoročne obveze / Operativni troškovi – deprecijacija – amortizacija
GRUPA III (OMJERI DUGA I UKUPNE IMOVINE) 1. Kratkoročne obveze / ukupna imovina 2. Dugoročne obveze / ukupna imovina 3. Kratkoročne + dugoročne obveze / ukupna imovina 4. Kratkoročne + dugoročne obveze + povlaštene dionice / ukupna imovina	
GRUPA IV (OMJERI TEKUĆE I UKUPNE IMOVINE) 1. Novac / ukupna imovina 2. Novac + potraživanja / ukupna imovina 3. Kratkotrajna imovina / ukupna imovina 4. Radni kapital / ukupna imovina	

Izvor: Beaver, W. (1966): Financial Ratios as Predictors of Failure, Journal of Accounting Research, Supplement, Vol. 4 Issue 3, str. 78

Kriterij odabira financijskih pokazatelja bio je učestalost njihova spominjanja u literaturi, relevantnost pokazatelja u predviđanju poslovnog neuspjeha u dotadašnjim istraživanjima, te pripadnost pokazatelja skupini temeljenoj na novčanom tijeku.

Koristeći se univarijantnom analizom od navedenih 30 omjera dokazalo se da najbolje financijski neuspjeh predviđaju sljedeća 3 pokazatelja:

- Tijek novca / Ukupna imovina
- Čisti prihod / Ukupni dug
- Tijek novca / Ukupni dug.

Na kraju studije Beaver ističe kako se koristio univarijantnom analizom te preporuča korištenje višestruke diskriminacijske analize u budućim istraživanjima.

Edward I. Altman osmislio je model za predviđanje bankrota proizvodnih poduzeća korištenjem statističke metode višestruke diskriminacijske analize. Rad je objavljen 1968. godine, a i danas se smatra jednim od najznačajnijih modela koji se koristi u poslovnom i akademskom svijetu. Ukupna točnost predviđanja Altmanova modela iznosi 95% za jednu

godinu prije stečaja, 83% za dvije godine prije stečaja, 48% za tri godine prije stečaja, 29% za četiri godine prije stečaja, te 36% za pet godina prije stečaja. Uzorak poduzeća nad kojima je provedena analiza sastojao se od 66 proizvodnih poduzeća od kojih su 33 financijski zdrava, te 33 poduzeća koja su pokrenila stečajni postupak u razdoblju od 1946. do 1965. godine. Ta poduzeća su potom uparena prema vrsti industrije i veličini imovine kao kod Beavera.

Prikupljeni podaci činili su bilancu i račun dobiti i gubitka navedenih poduzeća. Na temelju tih financijskih izvještaja izračunata su 22 financijska pokazatelja. Pokazatelji su birani prema učestalosti ponavljanja u literaturi i potencijalnoj relevantnosti vezane sa temom studije, te je izračunato nekoliko novih pokazatelja. Altman je financijske pokazatelje grupirao u 5 skupina i to pokazatelje likvidnosti, profitabilnosti, zaduženosti, solventnosti i aktivnosti. Nakon provedene analize dobivena je konačna formula koja glasi:

$$Z = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,999X_5 \quad (3)$$

Objašnjenje oznaka:

X_1 – Radni kapital / Ukupna imovina

X_2 – Zadržani dobitak / Ukupna imovina

X_3 – Operativna dobit / Ukupna imovina

X_4 – Tržišna vrijednost glavnice / Ukupni dug

X_5 – Prihod od prodaje / Ukupna imovina.

Tablica 14: Interval Z-scorea i vjerojatnosti bankrota

Vrijednost Z pokazatelja	Zaključak o vjerojatnosti bankrota
$Z > 2,675$	Trgovačko društvo posluje jako dobro i bankrot nije vjerojatan
$2,675 > Z > 1,81$	„Siva zona“: postoji mogućnost bankrota, ali to nije u potpunosti sigurno
$Z < 1,81$	Vrlo vjerojatna mogućnost bankrota u narednim godinama

Izvor: Pervan, I., Filipović, D.(2010): „FP-rating – model za predviđanje insolventnosti poslovnih partnera“, RriF, br. 7, str. 93

Altman je 1993. godine originalni model za predviđanje bankrota za privatna poduzeća s obzirom na to da se originalni model odnosio samo na listana poduzeća. Zamijenio je u varijabli X_4 tržišnu vrijednost glavnice njenom knjigovodstvenom vrijednosti. Cijeli model je potom izmjenjen budući da su prilagođeni ponderi svih varijabli, pa konačna jednačba glasi:

$$Z' = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,420X_4 + 0,998X_5 \quad (4)$$

Tablica 15: Intervali Z' scorea i vjerojatnosti bankrota

Vrijednost Z' pokazatelja	Zaključak o vjerojatnosti bankrota
$Z' > 2,90$	Trgovačko društvo posluje jako dobro i bankrot nije vjerojatan
$2,90 > Z' > 1,21$	„Siva zona“: postoji mogućnost bankrota, ali to nije u potpunosti sigurno
$Z' < 1,21$	Vrlo vjerojatna mogućnost bankrota u narednim godinama

Izvor: Pervan, I., Filipović, D. (2010): „FP-rating – model za predviđanje insolventnosti poslovnih partnera“, RriF, br. 7, str. 93

Provedena je još jedna izmjena modela kako bi se namijenio predviđanju bankrota za neproizvodna poduzeća. Iz modela se isključuje varijabla X_5 , dok su ostale varijable jednake kao kod modela za privatna poduzeća, kao i vrijednosti intervala za predviđanje vjerojatnosti bankrota.

$$Z'' = 6,65X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4 \quad (5)$$

Cilj studije **Edwarda B. Deakina** bilo je predložiti alternativni model predviđanja bankrota poduzeća.¹⁷ On u svojem istraživanju zapravo kombinira studije Beavera i Altmana. Uzorak poduzeća sastojao se od 64 subjekta, od kojih su 32 bila financijski zdrava, a druga 32 poduzeća bila su ona koja su ušla u stečajni postupak u razdoblju od 1964. do 1970. godine. Po jedno poduzeće iz svake grupe je upareno prema vrsti industrije kojoj pripadaju, veličini imovine i godinama za koje su financijske informacije bile dostupne. Za razliku od Beavera Deakin poduzeća u stečaju smatra ona koja su bankrotirala, koja su insolventna ili su likvidirana s namjerom isplate obveza kreditorima. Odabrao je 14 financijskih pokazatelja koje je koristio Beaver u svojoj studiji. Analizom je došao do sljedeće funkcije:

¹⁷ Deakin, E. (1972): A discriminant analysis of predictors of business failure, Journal of accounting research, str. 167

Tablica 16: Omjeri Deakinova modela sa pripadajućim ponderima

Pokazatelji	Godina prije pokretanja stečaja				
	5	4	3	2	1
Novčani tijek / Ukupne obveze	-0,250	0,094	0,104	-0,046	0,005
Neto dobit / Ukupna imovina	0,122	0,219	-0,585	0,378	0,083
Uk. obveze / Ukupna imovina	0,220	-0,133	0,283	-0,225	-0,184
Kratkotrajna imovina / Ukupna imovina	0,406	-0,017	0,436	-0,410	-0,101
(Novac + utržiive vrijednosnice) / Ukupna imovina	0,230	-0,062	-0,479	0,394	0,212
Radni kapital / Ukupna imovina	0,487	-0,054	0,106	0,102	-0,176
Novac / Ukupna imovina	0,621	-0,701	-0,205	-0,626	-0,9
Kratkotrajna imovina / Kratkoročne obveze	0,003	-0,001	-0,069	0,020	0,052
(Novac + utržiive vrijednosnice) / Kratoročne obveze	0,068	0,017	0,034	-0,065	-0,068
Novac / Kraoročne obveze	-0,077	0,165	0,151	0,111	0,096
Kratkotrajna imovina / Prihodi od prodaje	-0,018	0,283	0,057	-0,060	-0,020
(Novac + utržiive vrijednosnice) / Prihodi od prodaje	0,123	0,139	0,176	-0,014	-0,074
Radni kapital / Prihodi od prodaje	-0,009	0,243	-0,159	0,123	0,069

Izvor: Deakin, E. B. (1972): "A Discriminant Analysis of Predictors of Business Failure", Journal of Accounting Research, Spring, str. 175.

Deakin je uočio da bi se poduzeća koja su klasificirana kao neuspješna, počela ubrzano širiti u četvrtoj i petoj godini prije neuspjeha. Kada se pogleda u strukturu kapitala, to širenje je uzrokovano povećanim dugom i povlaštenim dionicima, a ne običnim dionicima i zadržanom dobiti. Stoga su prikupljena sredstva uložena u tvornice i opremu, a ne u tekuću imovinu. Posljedica toga je što ta poduzeća nisu mogla generirati toliku veličinu prodaje i dobiti da bi pokrila taj veći dug, te bi stoga nakon treće godine, prije bankrota, ubrzano gubila imovinu. Deakin je isto tako primijetio da omjer novac / prihodi od prodaje, se konstantno i značajno razlikovao s usporedbom sa Beavorovom studijom, za razliku od drugih odmjera koji su bili prilično konzistentni.¹⁸

Provođenjem višestruke diskriminacijske analize Deakin je došao do spoznaje da eliminacijom varjabli koje imaju nizak ponder značajno se povećava pogreška klasifikacije. Uočio je da se relativan značaj varijabli tijekom vremena mijenja, te stoga sve varijable značajno utječu na diskriminacijsku sposobnost funkcije.¹⁹

Zaključio je da se stečaj može predvidjeti s velikom točnošću predviđanja do tri godine prije stečaja koristeći statističku metodu diskriminacijske analize, dok u četvrtoj i petoj godini vjerojatnost predviđanja značajno opada. On smatra da je to dovoljno vremena da menadžment poduzme adekvatne korake kako bi izbjegao stečaj poduzeća. Isto tako ističe da je njegov model temeljen na malom uzorku, te da ga je potrebno proširiti u daljnjim istraživanjima.

¹⁸ ibidem, str. 171

¹⁹ ibidem, str. 173

Za razliku od prethodnih modela koja su bazirana na srednjim i velikim poduzećima **Robert Edminster** odlučio je svoje istraživanje bazirati na malim poslovnim subjektima. Malim subjektima smatrao je ona poduzeća koja su u „Agenciji za mala poduzeća“ (Small Business Administration) podigla kredit ili kojima je agencija izdala garanciju. S obzirom na to da je bilo puno lakše doći do financijskih izvještaja i informacija velikih poduzeća, te onih čije su dionice bile javno dostupne, on je ipak među prvima pristupio takvom uzorku poduzeća. Uzorak se sastojao od 562 poslovnih subjekata za razdoblje od 1958. – 1965. godine. Isto tako za razliku od prijašnjih istraživanja, kod Edminstera je stečaj označavao nesposobnost poslovnog subjekta da podmiri dospjele rate kredita, odnosno nije bilo potrebno da stečajni postupak bude pokrenut.

Istraživanje je napravljeno na temelju 19 financijskih pokazatelja. Kriterij njihova odabira bilo je zagovaranje teoretičara i njihova značajnost kod predviđanja bankrota u prijašnjim istraživanjima. Provedena je multivarijantna diskriminacijska analiza koju je uveo Altman u svijet modela za predviđanje bankrota. No, za razliku od prijašnjih studija Edminster koristi trogodišnji prosjek pokazatelja, trogodišnji trend kretanja pokazatelja, odnos pokazatelja poslovnih subjekata sa prosječnim pokazateljem djelatnosti, te dummy varijable koje ovise o vrijednosti izračunatih pokazatelja. Ukupna točnost njegova modela iznosi 93%. Konačna jednadžba Edminsterova modela glasi:

$$Z = 0,951 - 0,423X_1 - 0,293X_2 - 0,482X_3 + 0,2774X_4 - 0,452X_5 - 0,352X_6 - 0,924X_7 \quad (6)$$

Objašnjenje oznaka:

X_1 – čisti novčani tok / kratkoročne obveze; $X_1 = 1$ ukoliko je omjer manji od 0.05, a u protivnom $X_1 = 0$

X_2 – glavnica / prihodi od prodaje; $X_2 = 1$ ukoliko je omjer manji od 0.07, u protivnom $X_2 = 0$

X_3 – (radni kapital / prihodi od prodaje) / (radni kapital djelatnosti / prihodi od prodaje djelatnosti); $X_3 = 1$ ukoliko je omjer manji od -0.02, u protivnom $X_3 = 0$

X_4 – (kratkoročne obveze / glavnica) / (kratkoročne obveze djelatnosti / glavnica djelatnosti); $X_4 = 1$ ukoliko je omjer manji od 0.48, u protivnom $X_4 = 0$

X_5 – (zalihe / prihodi od prodaje) / (zalihe djelatnosti / prihodi od prodaje djelatnosti); $X_5 = 1$ ukoliko je omjer manji od 0.04, u protivnom $X_5 = 0$

X_6 – omjer ubrzane likvidnosti / omjer ubrzane likvidnosti djelatnosti; $X_6 = 1$ ukoliko je omjer manji od 0.34, u protivnom $X_6 = 0$

X_7 – omjer ubrzane likvidnosti / omjer ubrzane likvidnosti djelatnosti; $X_7 = 1$ ukoliko omjer pokazuje uzlazni trend, u protivnom $X_7 = 0$

Oznaka za uspješno poduzeće je 1, a oznaka za neuspješno 0.

James Ohlson 1980. godine predstavlja model za predviđanje bankrota dobiven korištenjem statističke metode logističke regresije. Istraživanje je provedeno nad 2163 poslovnih subjekata od kojih su čak 2058 klasificirana kao financijski zdrava, a 105 poduzeća sa poslovnim poteškoćama. Financijski izvještaji navedenih poduzeća prikupljeni su za razdoblje od 1970. do 1976. godine, a odnosili su se na razdoblje od 3 godine prije pokretanja stečajnog postupka.

Ohlson je uočio da četiri faktora statistički značajno utječu na vjerojatnost stečaja. To su veličina poduzeća, pokazatelj zaduženosti, pokazatelj uspješnosti poslovanja i pokazatelj tekuće likvidnosti.²⁰ U svom istraživanju odlučio je upotrijebiti metodu logističke regresije kako bi izbjegao neke od problema multivarijantne diskriminacijske analize korištene u dotadašnjim istraživanjima. Kao neke od problema višestruke diskriminacijske analize navodi kako se zahtijevaju određene statističke pretpostavke poput jednakosti matrica varijanci i kovarijanci za obje skupine poduzeća, zatim output ove metode je broj koji ima vrlo usku intuitivnu interpretaciju iz razloga što je ta analiza zapravo metoda za ordinalno rangiranje, te sam rezultat nema inherentnu vrijednost, te nema izravne interpretacije, i kao posljednji problem navodi probleme kod uparivanja poduzeća.

Korištenjem navedene metode i podataka došao je do 3 modela, prvi model predviđa bankrot unutar jedne godine, drugi model predviđa bankrot unutar dvije godine pod uvjetom da poduzeće nije bankrotiralo u sljedećoj godini, te treći model koji predviđa bankrot unutar dvije godine. Ukupna točnost predviđanja prvog modela iznosi 96,12%, drugog modela 95,5%, te trećeg modela 92,84%. Ohlsonovi modeli glase:

Model 1:

$$-1.32 - 0.407X_1 + 6.03X_2 - 1.43X_3 + 0.08X_4 - 1.72X_5 - 2.71X_6 - 1.83X_7 + 0.285X_8 - 0.52X_9 \quad (7)$$

Model 2:

$$1.84 - 0.519X_1 + 4.76X_2 - 1.71X_3 - 0.3X_4 - 1.98X_5 - 2.74X_6 - 2.18X_7 - 0.780X_8 + 0.42X_9 \quad (8)$$

Model 3:

$$1.13 - 0.478 X_1 + 5.29 X_2 - 0.990 X_3 + 0.07 X_4 - 1.71 X_5 - 4.62 X_6 - 2.25 X_7 - 0.521X_8 + 0.21 X_9 \quad (9)$$

Objašnjenje oznaka:

X_1 – veličina poduzeća mjerena logaritmom odnosa ukupne imovine i indeksa BDP-a

X_2 – omjer ukupnih obveza i ukupne imovine

²⁰Ohlson, R. (1980): Financial Ratios and the Probabilistic Prediction of Bankruptcy, Journal of Accounting Research, Spring, Vol. 18., No. 1., str. 110.

X_3 – omjer radnog kapitala i ukupne imovine

X_4 – omjer kratkoročnih obveza i kratkotrajne imovine

X_5 – vrijednost 1 ako su ukupne obveze veće od ukupne imovine, u protivnom 0

X_6 – omjer neto dobiti i ukupne imovine

X_7 – omjer novca od poslovnih aktivnosti i ukupnih obveza

X_8 – vrijednost 1 ako je neto dobit negativna u posljednje dvije godine, u protivnom 0

$X_9 = (NIt - NIt-1) / (|NIt| + |NIt-1|)$, gdje je NIt neto dobit u posljednjem razdoblju.

2.4.2. Pregled najznačajnijih modela za predviđanje bankrota u Republici Hrvatskoj

Cilj studije **Pervan I., Pervan M., Vukoja** 2011. godine bio je odrediti model za predviđanje bankrota poduzeća koristeći samo javno dostupne informacije. Uzorak se sastojao od 156 poduzeća koja su spadala u sektor proizvodnje i trgovine. Prikupljeni su podaci za poduzeća koja su ušla u stečaj za razdoblje od siječnja do lipnja 2010. godine, te su uparena sa zdravim poduzećima za isto to razdoblje. Na temelju financijskih izvještaja izračunato je 15 financijskih pokazatelja prema učestalosti njihova spominjanja u literaturi predviđanja bankrota poduzeća. Da bi se izbjegao problem multikolinearnosti izračunali su Pearsonov koeficijent korelacija i faktor inflacije varijance čime je određeno konačnih 6 financijskih pokazatelja.

Tablica 17: Opis financijskih pokazatelja korištenih u modelu

Financijski pokazatelj	Opis
Tekuća likvidnost	Kratkotrajna imovina / Kratkoročne obveze
Neto radni kapital	(Kratkotrajna imovina – kratkoročne obveze) / Kratkotrajna imovina
Pokazatelj tekuće imovine	Tekuća imovina / Ukupna imovina
Poluga	Ukupne obveze / Ukupna imovina
Pokazatelj obrtaja imovine	Prihodi od prodaje / Ukupna imovina
EBIT	EBIT / Ukupna imovina

Izvor: Pervan, I., et al. (2011): Prediction of company bankruptcy using statistical techniques – case of Croatia, Croatian Operational Research Review (CRORR), Vol. 2, str. 163

U svom radu za analizu podataka koristili su metodu diskriminacijske analize i logističku regresiju. Rezultat modela korištenjem diskriminacijske analize jest da uspješno klasificira 80,8% zdravih tvrtki, te 79,5% tvrtki u stečaju, dok je model korištenjem logističke regresije uspješno klasificirao 80,8% zdravih poduzeća i 85,9% poduzeća u stečaju.

Autori ističu kako se korištenje diskriminacijske analize pokazalo problematičnim s obzirom da dvije glavne statističke pretpostavke nisu ispunjene, a to su jednakost matrice varijanci i kovarijanci i normalna distribucija. Na kraju je zaključeno kako javno dostupni financijski

izvještaji i izračunati financijski pokazatelji zapravo imaju informacijsku vrijednost s obzirom na to da se mogu efikasno koristiti u predviđanju bankrota poduzeća.

S ciljem procjene vjerojatnosti blokade žiro-računa poslovnog subjekta **Pervan i Filipović** 2010. godine objavljuju svoj model FP RATING®. Uzorak se sastojao od trgovačkih društava koja su kreditno zadužena u poslovnoj banci X d.d. Prikupljeni podaci su obuhvaćali informacije iz financijskih izvještaja društva, točnije bilance i računa dobiti i gubitka, te broj dana blokade žiro-računa zbog nepodmirivanja obveza po glavnici uzetih kredita u banci X d.d. Inicijalni uzorak sastojao se od 3.629 malih, srednjih i velikih trgovačkih društava koja su potom grupirana u solventne i insolventne klijente. Kriterij za grupiranje bila je granica od 90 dana neplaćanja dospjelih obveza po kreditima.

U konačnoj analizi uzorak se sveo na mala i srednje velika trgovačka društva, od kojih su 447 imala sve podatke potrebne za izračun financijskih pokazatelja. Velika trgovačka društva su eliminirana iz analize jer se pokazalo da su greške modela u tom slučaju previsoke. Model se pokazao najpreciznijim u procjeni vjerojatnosti (in)solventnosti u segmentu trgovačkih društava kojima prihod ne prelazi 65 milijuna kuna. Prema originalnim podacima od 447 trgovačkih društava 53 su bila insolventna, a 394 solventna. Kod obrade podataka korištena je statistička metoda diskriminacijske analize na temelju 33 izračunata financijska pokazatelja, te je dobiven konačni model koji glasi:

$$\text{FP RATING}^{\circledR} = -1,0937 + 2,0956X_1 - 0,005X_2 + 0,6220X_3 - 0,000005X_4 + 0,1116X_5 \quad (10)$$

Tablica 18: Opis varijabli korištenih u modelu FP RATING®

Opis varijable	Brojnik	Nazivnik
X_1 – Stupanj samofinanciranja	Ukupan kapital	Ukupna imovina
X_2 – Faktor zaduženosti	Ukupne dugoročne obveze + Ukupne kratkoročne obveze	Neto dobitak(gubitak) tekuće godine + Zadržani dobitak(Preneseni gubitak) + Amortizacija
X_3 – Obrtaj ukupne imovine	Ukupni prihod	Ukupna imovina
X_4 – Vrijeme naplate potraživanja	365	Koeficijent obrtaja kratkoročnih potraživanja
X_5 – Novčani operativni potencijal	EBITDA - Δ Obrtni kapital ²¹	Ukupni prihod

Izvor: Pervan, I., Filipović, D. (2010): FP-rating - Model za predviđanje (in)solventnosti poslovnih partnera, RRIF, br. 7, str. 94-95

²¹ Δ Obrtni kapital = $(Zalihe_t - Zalihe_{t-1}) + (Potraživanja\ od\ kupaca_t - Potraživanja\ od\ kupaca_{t-1}) + (Ostala\ potraživanja_t - Ostala\ potraživanja_{t-1}) - (Obveze\ prema\ dobavljačima_t - Obveze\ prema\ dobavljačima_{t-1}) - (Ostale\ kratkoročne\ obveze_t - Ostale\ kratkoročne\ obveze_{t-1})$.

Tako je putem FP RATING[®] modela u kategoriju solventnih klijenata klasificirano 327, dok je stvarni broj solventnih klijenata iznosio 394, što znači da točnost modela u predviđanju solventnih klijenata iznosi 83%. Nadalje model je u kategoriju insolventnih klijenata svrstao njih 37, dok je stvarni broj iznosio 53, što mu daje točnost klasifikacije od 69,8%.

Ivičić i Cerovac 2009. godine predstavljaju svoj rad čiji je glavni cilj bio modeliranje kreditnog rizika nefinancijskih poslovnih subjekata procjenom vjerojatnosti promjene rejtinga i prognoziranjem vjerojatnosti neurednog podmirivanja njihovih obveza u razdoblju od jedne godine. Uzorak se sastojao od 9.719 poduzeća tijekom 2007. i 2008. godine tvoreći neujednačenu skupinu koja se sastoji od 12.462 promatranja binarne ovisne varijable, odnosno poduzeća za koja su postojali podaci o tome jesu li tijekom određene godine podmirivala obveze ili ne. Poduzeća su grupirana u 3 sektora ovisno o Nacionalnoj klasifikaciji djelatnosti: industrija i poljoprivreda, građevina i nekretnine, te nefinancijske usluge. Koristili su 84 potencijalno relevantna financijska pokazatelja koja su odabrana prema kriteriju uspješnosti predviđanja neurednog podmirivanja obveza u prijašnjim istraživanjima.

Financijski pokazatelji su grupirani u pokazatelje likvidnosti, solventnosti, aktivnosti, ekonomičnosti, profitabilnosti i pokazatelje ulaganja. Korištenjem multivarijantne logističke regresije na temelju veličine poduzeća (mjerene ukupnom prodajom), ekonomske aktivnosti (građevina i nekretnine prema ostalim sektorima) i pet financijskih pokazatelja: pokazatelja likvidnosti (mjenoga kao gotovina prema ukupnoj imovini), pokazatelja vlastitog financiranja (dionički kapital prema ukupnoj imovini), pokazatelja aktivnosti (promet potraživanja od kupaca u danima) i dva pokazatelja profitabilnosti (zarada prije oporezivanja i kamata prema ukupnim obvezama te prodaja i amortizacija prema ukupnoj imovini) dobiven je konačni model predviđanja vjerojatnosti neurednog podmirivanja obveza tijekom sljedeće godine. Konačni model glasi:

$$F[X_i, \beta] = 1 / 1 + e^{-(0,17-0,28D_i,t-0,63w_{1_10i,t-1,96w_{2_2i,t+0,09w_{3_4i,t-0,14w_{5_16i,t-0,37w_{5_22i,t-0,01w_{7_5i,t}}}}}} \quad (11)$$

Nadalje, navode da su najvažniji pokazatelji rizika neurednog podmirivanja obveza omjer dioničkog kapitala prema ukupnoj imovini i omjer zarade prije kamata i oporezivanja prema ukupnim obvezama (oba su omjera u negativnom odnosu prema vjerojatnosti neurednog podmirivanja obveza). Veća likvidnost, profitabilnost i prodaja, kao i poslovanje u sektoru građevine i nekretnina, smanjuju vjerojatnost neurednog podmirivanja kreditnih obveza

poduzeća u sljedećoj godini. Model je točno klasificirao 74,4% poduzeća koja uredno podmiruju obveze i 71,2% poduzeća koja ih ne podmiruju uredno.

Model za predviđanje nelikvidnosti poduzeća u Hrvatskoj predstavljaju **Šarlija, et al.** 2009. godine. Rezultat modela je vjerojatnost da li će poduzeće u sljedećem jednogodišnjem razdoblju biti nelikvidno. Nelikvidnim poduzećem se smatra ono čiji je žiro-račun u blokadi kontinuirano 3 mjeseca i više. Uzorak podataka sastojao se od 75.145 poslovnih subjekata u Hrvatskoj, no nisu obuhvaćene banke, štedionice i društva za osiguranje. Prikupljeni su podaci iz bilance i računa dobiti i gubitka iz 2006. godine, kao i podaci o broju dana blokada u toj i idućoj godini. Skup podataka je podijeljen na uzorak za razvoj modela i na uzorak za testiranje modela u omjeru 80:20. Za oba uzorka su izračunati financijski pokazatelji, za svako podueće.

Izračunato je čak 29 financijskih pokazatelja, no konačan model se sastojao od 16 varijabli koje se odnose na pokazatelje i 2 varijable koje uključuju djelatnost i županiju. Financijski pokazatelji su grupirani u 5 osnovnih grupa: likvidnost, zaduženost, aktivnost, ekonomičnost i profitabilnost. Model je dobiven na temelju uzorka za razvoj modela korištenjem metode logističke regresije. Nakon toga je testiran na temelju uzorka za testiranje modela.

Tablica 19: Značajni prediktori nelikvidnosti u Hrvatskoj prema modelu Šarlija et al.

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

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

Ukupna točnost modela iznosi 68,16% za likvidna poduzeća, te 74,22% za nelikvidna poduzeća. U svom radu navode kako su najrizičnija poduzeća, odnosno ona kod kojih postoji relativno visoka vjerojatnost da postanu nelikvidna u Međimurskoj, Osječko-baranjskoj, Požeško-slavonskoj i Varaždinskoj županiji, a najmanje rizična su ona u Zadarskoj, Šibensko-kninskoj i Zagrebačkoj županiji te Gradu Zagrebu. Što se tiče djelatnosti najmanja vjerojatnost da postanu nelikvidna poduzeća u idućem razdoblju su ona koja se bave financijskim posredovanjem i javnom upravom, dok je najveća vjerojatnost kod djelatnosti prerađivačke industrije i hotela.

Zenzerović Robert daje svoj doprinos ovoj temi 2009. godine u svom radu. Poduzeća su podijeljena u financijski stabilna i nestabilna poduzeća. Uzorak se sastojao od 55 financijski stabilnih i jednak broj nestabilnih poduzeća koja su klasificirana prema veličini i djelatnosti. Financijski nestabilna poduzeća su ona koja su ušla u stečajni postupak ili koja su u svojim financijskim izvještajima objavila gubitak iznad visine kapitala. Podaci su prikupljeni za godinu prije nego što je poduzeće otišlo u stečaj ili objavilo višak gubitka nad kapitalom. Podaci za zdrava poduzeća su prikupljena za isto to razdoblje. Izračunato je 50 financijskih pokazatelja. Tu spadaju pokazatelji likvidnosti, solventnosti, aktivnosti, profitabilnosti,

pokazatelji koji stavljaju u odnos različite skupine prihoda i rashoda, te pokazatelji temeljeni na izvještaju o novčanom tijeku. Korištenjem višestruke diskriminantne analize dobiven je sljedeći model:

$$CGE_1 = -2,207 - 0,026 FS + 0,733 N/I + 1,905 RK/I - 1,086 Z - 0,626 SF - 0,008 FZ + 2,812 A + 2,989 EUP - 0,047 ROA - 0,548 RTIF - 0,124 TL + 0,433 EP \quad (12)$$

Tablica 20: Opis varijabli u CGE₁ modelu

Varijabla	Brojnik	Nazivnik
FS	Dugotrajna imovina	Dugoročne obveze + Kapital
N/I	Novac i novčani ekvivalenti	Kratkotrajna imovina
RK/I	Radni kapital	Ukupna imovina
Z	Ukupne obveze	Ukupna imovina
SF	Vlastiti kapital	Ukupna imovina
FZ	Ukupne obveze	Zadržani dobitak + deprecijacija
A	Zadržani dobitak	Ukupna imovina
EUP	Ukupni prihodi	Ukupni rashodi
ROA	Povrat na imovinu	
RTIF	Neto dobit + kamate	Ukupne obveze
TL	Pokazatelj likvidnosti	
EP	Poslovni prihodi	Poslovni rashodi

Izvor: Zenzerović, R. (2009): Business financial problem prediction – Croatian experience, Economic Research –Ekonomika istraživanja 22.4., 1-15, str. 8

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

Zenzerović potom razvija drugi i treći CGE model. Drugi se razlikuje u tome što je iz modela izbačeno 6 financijskih pokazatelja. Varijable FS, ROA i RTIF su izbačene zbog negativnih predznaka koji nisu u skladu s postulatima financijske teorije, dok su varijable N/I, TL i EP izbačene zbog toga što su bile manje značajne. Treći model se razlikuje od drugoga po tome što su iz drugog modela izostavljene dvije jedinice uzorka koje su imale najveću standardnu grešku, dok su varijable ostale jednake kao kod drugog modela.

Rezultat drugog modela pokazuje kako je 95,4% originalnih jedinica točno klasificirano, dok je analizom presjeka 93,5% jedinica točno klasificirano. Dakle vidljivo je da se rezultat poboljšao provođenjem navedenih promjena. Rezultat trećeg modela pokazuje kako je točno klasificirano 95,3% jedinica u oba slučaja. Jednažbe drugog i trećeg modela glase:

$$CGE_2 = -1,802 + 1,478 RK/I - 0,995 Z - 0,647 SF - 0,008 FZ + 3,048 A + 2,808 EUP \quad (13)$$

$$CGE_3 = -1,74 + 1,517 RK/I - 1,079 Z - 0,601 SF - 0,008 FZ + 3,151 A + 2,771 EUP \quad (14)$$

3. RAZVOJ MODELA ZA PREDVIĐANJE BANKROTA PODUZEĆA

3.1. Definiranje uzorka

Da bi oblikovali optimalan model za predviđanje bankrota poduzeća potrebno je prvo prikupiti računovodstvene informacije. Za potrebe ovog istraživanja podaci su prikupljeni iz baze podataka „Amadeus“. Amadeus je baza podataka koja raspolaže financijskim podacima javnih, te privatnih poduzeća diljem Europe. Prikupljene su financijske informacije iz bilance i računa dobiti i gubitka poduzeća koja se bave isključivo proizvodnjom. Isti je postupak za poduzeća iz Hrvatske, Bosne i Hercegovine, Srbije i Mađaske.

Uzorak za Hrvatsku sastoji se od 338 financijski nestabilnih i jednak broj stabilnih poduzeća. Uzorak za Bosnu i Hercegovinu sastoji se od 11 financijski nestabilnih i isto toliko stabilnih poduzeća. Uzorak za Srbiju sadrži podatke za 34 financijski nestabilna i jednako financijski stabilnih poduzeća, te uzorak za Mađarsku sastoji se od 12 financijski nestabilnih i isto toliko stabilnih poduzeća. Financijski nestabilna poduzeća se smatraju ona poduzeća koja su u stečaju ili nisu sposobna ispunjavati svoje obveze. Financijski podaci se odnose na 2012 i 2013. godinu, a poduzeća su uparena s obzirom na veličinu, odnosno veličinu prihoda te veličinu imovine. Pomoću ovih računovodstvenih informacija izračunati će se financijski pokazatelji koji su temelj modela predviđanja bankrota poduzeća.

3.2. Definiranje statističke metodologije

Za potrebe izrade modela predviđanja bankrota u ovom radu koristiti će se dvije statističke metode, a to su binarna logistička regresija i neuronske mreže. U obradi podataka i formiranju modela koristiti će se softverski paket SPSS - „Statistical package for social sciences“. Korištenje dviju metoda ujedno će nam omogućiti i usporedbu uspješnosti istih kod vjerojatnosti predviđanja bankrota.

Zadaća regresijske analize je da pronađe analitičko-matematički oblik veze između jedne ovisne ili regresand varijable i jedne ili više nezavisnih ili regresorskih varijabli. Osim objašnjavanja prirode ovisnosti promatranih pojava na temelju tog analitičkog oblika može se vršiti predviđanje vrijednosti ovisne varijable pri određenim vrijednostima neovisne-ih varijabli.²² Binarna logistička regresija predviđa vjerojatnost da će jedinica promatranja

²² Pivac, S. (2010): Statističke metode, e-nastavni materijal, Ekonomski fakultet u Splitu, str. 253.

pripasti u jednu od dvije kategorije dihotomne zavisne varijable, na temelju jedne ili više nezavisnih varijabli koje mogu biti kontinuirane ili kategorične varijable.²³

Originalna ideja za umjetnu neuronsku mrežu generirala se je iz niza pokušaja modeliranja biofiziologije mozga čovjeka, s ciljem razumijevanja i objašnjenja kako isti funkcionira. Ta ideja podrazumijeva kreiranje modela sposobnog da procesira (prihvaća, obrađuje, generira, pohranjuje i prenosi) informacije, analogno aktivnostima mozga čovjeka. Naime, ako se određena točka u mozgu čovjeka zamijeni neuronom, onda se aktivnost neurona može modelirati kao zbroj „otežanih“ ulaza neurona. Otežani ulazi jesu ulazi pomnoženi određenim faktorima koji se nazivaju težine neurona. Prema tome aktivnost umjetnog neurona ovisi o: broju ulaza (veza) iz okoline (okruženja) neurona, intenzitetu tih veza (iznosu težinskih faktora), te o pragu osjetljivosti koji stanje neurona mora dosegnuti prije nego što „ispali impuls“ preko svog izlaza u okolinu neurona. Okruženje neurona čine ostali neuroni umjetne neuronske mreže i/ili okruženje te mreže.

U principu se razlikuje supervizorno (uz nadzor) i nesupervizorno (bez nadzora) učenje neuronskih mreže. Supervizorno učenje zahtijeva vanjskog „učitelja“ neuronske mreže koji promatra ponašanje mreže korigirajući istu dok se ne dobije željeno ponašanje mreže. Naime, kod ovog načina učenja najprije se usvoji određena struktura mreže (broj ulaza, broj neurona, broj slojeva, broj izlaza, te broj težina mreže). Zatim se na ulaz mreže dovodi skup ulaznih varijabli. Mreža producira odgovarajući skup izlaznih varijabli. Skup izlaznih varijabli uspoređuje se sa željenim skupom izlaznih varijabli. Razlika željenih i stvarnih izlaza neuronske mreže gradi pogrešku mreže, koja se koristi za računanje novih težina (parametara) mreže preko određenog (usvojenog) algoritma. Cijeli postupak ponavlja se iteracijski dok pogreška mreže ne bude manja od unaprijed zadanog iznosa. Pritom se, prema potrebi mijenja struktura mreže (broj neurona, broj slojeva, broj težina). Nakon procesa učenja (treninga) slijedi proces testiranja neuronske mreže. To se radi s novim skupom ulaza mreže koji nije bio sadržan u ulaznom skupom za vrijeme procesa učenja. Mreža sada producira nove izlaze koji se uspoređuju sa željenim izlazima. Pritom se ne mijenjaju parametri (težine) mreže. Kod nesupervizornog učenja neuronske mreže ne koristi se vanjski učitelj. Ovdje se neuronska mreža sama organizira, pa se mreže učene ovom metodom nazivaju samoorganizirajuće neuronske mreže. Na ulaz mreže dovodi se skup ulaznih varijabli, a mreža se samoorganizira

²³ Lund Research Ltd (2015): Laerd Statistics, Binomial Logistic Regression using SPSS Statistics. Dostupno na: <https://statistics.laerd.com/spss-tutorials/binomial-logistic-regression-using-spss-statistics.php> [2.5.2016.]

podešavanjem svojih parametara (težina) po dobro-definiranom algoritmu. Budući da željeni izlaz mreže nije specificiran za vrijeme učenja mreže, rezultat učenja nije predvidiv.²⁴

3.3. Definiranje varijabli u modelu

Dosadašnja istraživanja o oblikovanju optimalnog modela za predviđanje bankrota poduzeća, pa tako i ovo, uključuje financijske pokazatelje. Temeljem računovodstvenih informacija iz bilance, te računa dobiti i gubitka dobiveni su određeni financijski pokazatelji. Treba napomenuti kako financijski pokazatelji korišteni u ovom istraživanju su ograničeni dostupnošću računovodstvenih informacija koje pruža baza podataka „Amadeus“.

Tablica 21: Financijski pokazatelji korišteni u istraživanju

	Financijski pokazatelj	Oznaka	Brojnik	Nazivnik
1.	Koeficijent tekuće likvidnosti	KTL	Kratkotrajna imovina	Kratkoročne obveze
2.	Koeficijent ubrzane likvidnosti	KUL	Kratkotrajna imovina – Zalihe	Kratkoročne obveze
3.	Koeficijent trenutne likvidnosti	KTRL	Novac i novčani ekvivalenti	Kratkoročne obveze
4.	Koeficijent financijske stabilnosti	KFS	Dugotrajna imovina	Glavnica + Dugoročne obveze
5.	Koeficijent zaduženosti	KZ	Ukupne obveze	Ukupna imovina
6.	Koeficijent vlastitog financiranja	KVF	Glavnica	Ukupna imovina
7.	Koeficijent financiranja	KF	Ukupne obveze	Glavnica
8.	Stupanj pokrića I.	SPI	Glavnica	Dugotrajna imovina
9.	Stupanj pokrića II.	SPII	Glavnica + Dugoročne obveze	Dugotrajna imovina
10.	Koeficijent obrta potraživanja	KOP	Prihod od prodaje	Potraživanja
11.	Trajanje naplate potraživanja	TNP	365	KOP
12.	Ekonomičnost financiranja	EF	Financijski prihod	Financijski rashod
13.	Povrat na imovinu	ROA	Neto dobit	Ukupna imovina
14.	Povrat na kapital	ROE	Neto dobit	Glavnica
15.	Omjer dugoročnih obveza i neto radnog kapitala	ODN	Dugoročne obveze	NRK
16.	Omjer duga i glavnice	ODG	Ukupne obveze	Glavnica + Dugoročne obveze
17.	Financijska snaga	FS	5*(Dobit+amortizacija+deprecijacija)	Ukupne obveze
18.	Gubitak poslovne godine	GUB	Vrijednost koja prikazuje u koliko je godina od posljednje dvije godine poslovanja ostvaren gubitak	
19.	Suma neto dobiti	SUM	Zbroj neto dobiti posljednje dvije godine poslovanja	
20.	Razlika ukupne imovine i ukupnih obveza	UKIO	Ukoliko je ukupna imovina veća od ukupnih obveza vrijednost je 1.00, u suprotnom vrijednost je 0.00	

Izvor: Izrada autora

²⁴ Novaković, B. et al. (1998): Umjetne neuronske mreže, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, str. 1-8

3.4. Model predviđanja poslovnog neuspjeha u Hrvatskoj

3.4.1. Priprema podataka za analizu

Prvi korak u formiranju modela predviđanja poslovnog neuspjeha poduzeća je odabir varijabli. Polazi se od toga da u model mogu biti uključene samo one varijable koje imaju razinu signifikantnosti manju od 5%.

Tablica 22: Rezultati testiranja nezavisnih uzoraka – Hrvatska

Independent Samples Test										
		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2- tailed)	Mean Difference	Std. Error Differenc e	95% Confidence Interval of the Difference	
									Lower	Upper
KTL	Equal variances assumed	66,980	,000	-8,137	674	,000	-3,66408	,45033	-4,54829	-2,77987
	Equal variances not assumed			-8,137	341,507	,000	-3,66408	,45033	-4,54984	-2,77832
KVF	Equal variances assumed	7,030	,008	-2,156	674	,031	-1,88748	,87553	-3,60658	-,16839
	Equal variances not assumed			-2,156	337,176	,032	-1,88748	,87553	-3,60968	-,16529
GUB	Equal variances assumed	255,64	,000	23,651	667	,000	1,11497	,04714	1,02241	1,208
	Equal variances not assumed			23,512	499,657	,000	1,11497	,04742	1,02180	1,208
SUM	Equal variances assumed	21,913	,000	-5,941	667	,000	-1029,258	173,236	-1369,41	-689,105
	Equal variances not assumed			-5,901	461,770	,000	-1029,258	174,41	-1372,013	-686,503

Izvor: Izrada autora u SPSS-u

Kao što se vidi iz prethodne tablice navedena 4 elementa mogu se koristiti u daljnjoj analizi. Kod korištenja metode binarne logističke regresije postoji problem multikolinearnosti nezavisnih varijabli. S obzirom na to da neki financijski pokazatelji koriste iste stavke financijskih izvještaja u njihovom izračunu (npr. imovina, neto dobit, obaveze itd.) postoji velika vjerojatnost postojanja problema multikolinearnosti u modelu predviđanja bankrota.

Problem multikolinearnosti procijenjenog modela uzrokuje neučinkovito biranje parametara konačne jednadžbe i visoki postotak pogreške. Koriste se dva pokazatelja za kontrolu mogućeg problema multikolinearnosti. Prvi pokazatelj je Pearsonov koeficijent korelacije, gdje korelacija veća od 0,8 označava problem multikolinearnosti.²⁵

Pearsonov koeficijent linearne korelacije je najpoznatija mjera linearne korelacije između slučajnih varijabli:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X}) * (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 * \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (15)$$

Vrijednost koeficijenta linearne korelacije kreće se u intervalu: $-1 \leq r \leq 1$. U skladu s veličinom ovog koeficijenta može se zaključiti smjer i intenzitet linearne korelacije među promatranim varijablama:

$r = -1$; $r = 1 \rightarrow$ funkcionalna negativna/pozitivna korelacija
 $-1 < r \leq -0,8$; $0,8 \leq r < 1 \rightarrow$ jaka negativna / pozitivna korelacija
 $-0,8 < r \leq 0,5$; $0,5 \leq r < 0,8 \rightarrow$ srednje jaka negativna / pozitivna korelacija
 $-0,5 < r < 0$; $0 < r < 0,5 \rightarrow$ slaba negativna / pozitivna korelacija
 $r = 0 \rightarrow$ nema korelacije

Drugi pokazatelj je faktor inflacije varijance VIF (Variance Inflation Factor) ili ekvivalentni pokazatelj tolerancija TOL (Tolerance):

$$VIF_j = \frac{1}{1 - R_j^2}, j = 1, 2, \dots, k; \quad (16)$$

$$TOL_j = \frac{1}{VIF_j} = 1 - R_j^2. \quad (17)$$

Ozbiljan problem multikolinearnosti je prisutan ako je $R_j^2 > 0.8$, odnosno $VIF_j > 5$, ili ekvivalentno $TOL_j < 0.2$.²⁶

²⁵ Pervan, I., et al. (2011): Prediction of Company Bankruptcy Using Statistical Techniques – Case of Croatia, CRORR, Vol. 2, str. 163

²⁶ Pivac, S. (2010): Statističke metode, e-nastavni materijal, Ekonomski fakultet Splitu, str. 238-281.

Tablica 23: Prikaz korelacija između varijabli – Hrvatska

		Correlations			
		KTL	KVF	GUB	SUM
KTL	Pearson Correlation	1	,037	-,233**	,066
	Sig. (2-tailed)		,336	,000	,088
	N	676	676	669	669
KVF	Pearson Correlation	,037	1	-,104**	,005
	Sig. (2-tailed)	,336		,007	,893
	N	676	676	669	669
GUB	Pearson Correlation	-,233**	-,104**	1	-,289**
	Sig. (2-tailed)	,000	,007		,000
	N	669	669	669	669
SUM	Pearson Correlation	,066	,005	-,289**	1
	Sig. (2-tailed)	,088	,893	,000	
	N	669	669	669	669

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

Izvor: Izrada autora u SPSS-u

Kao što se vidi u tablici 23. nakon provedenog testa korelacije varijable imaju slabu pozitivnu / negativnu korelaciju što ukazuje na to da nema problema multikolinearnosti. Da nema problema multikolinearnosti može se dokazati i putem vrijednosti tolerancije i faktora inflacije varijance.

Tablica 24: Vrijednost tolerancije i VIF-a – Hrvatska

Coefficients ^a			
Model		Collinearity Statistics	
		Tolerance	VIF
1	KTL	,945	1,058
	KVF	,988	1,012
	GUB	,861	1,161
	SUM	,916	1,092

a. Dependent Variable: Status

Izvor: Izrada autora u SPSS-u

Kao što se vidi tolerancija je kod sve 4 varijable veća od 0.2, te je faktor inflacije varijance kod svih varijabli manji od 5 što znači da nema problema multikolinearnosti. Nakon što je utvrđeno da nema problema multikolinearnosti može se provesti metoda binarne logističke regresije.

3.4.2. Formiranje modela pomoću binarne logističke regresije

Nakon provedene analize ustanovljeno je da varijable koje daju najbolji rezultat u predviđanju bankrota su koeficijent tekuće likvidnosti, koeficijent vlastitog financiranja, gubitak poslovne godine, te suma neto dobiti.

Tablica 25: Omnibus test koeficijenata modela – Hrvatska

Omnibus Tests of Model Coefficients			
	Chi-square	df	Sig.
Step	615,917	4	,000
Step 1 Block	615,917	4	,000
Model	615,917	4	,000

Izvor: Izrada autora u SPSS-u

Omnibus testom se vidi da je razina signifikantnosti manja od 5% što dokazuje da je model statistički signifikantan.

Tablica 26: Mjere prikladnosti modela – Hrvatska

Model Summary			
Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	311,441 ^a	,602	,802

a. Estimation terminated at iteration number 9 because parameter estimates changed by less than ,001.

Izvor: Izrada autora u SPSS-u

Nagelkerke R^2 je mjera koja daje informacije o prikladnosti modela. Zauzima vrijednosti od 0 do 1. U ovom primjeru Nagelkerke R^2 iznosi 80,2% što govori o snažnoj vezi između navedenih nezavisnih varijabli i predviđanja bankrota poduzeća.

Tablica 27: Hosmer-Lemeshow test – Hrvatska

Hosmer and Lemeshow Test			
Step	Chi-square	df	Sig.
1	11,257	8	,188

Izvor: Izrada autora u SPSS-u

Hosmer Lemeshow test daje informacije o tome kolika je prikladnost modela u odnosu na podatke. Ukoliko je signifikantnost manja od 5% smatra se da model nije prikladan u odnosu

na podatke. U ovom primjeru signifikantnost iznosi 18,8% što je veće od granice od 5% što znači da je model prikladan u odnosu na podatke.

Tablica 28: Prikaz varijabli i pripadajućih pondera – Hrvatska

Variables in the Equation						
	B	S.E.	Wald	df	Sig.	Exp(B)
KTL	1,778	,272	42,834	1	,000	5,920
KVF	2,862	,644	19,768	1	,000	17,489
Step 1 ^a GUB	-1,595	,265	36,146	1	,000	,203
SUM	,004	,001	15,951	1	,000	1,004
Constant	-2,519	,397	40,278	1	,000	,081

a. Variable(s) entered on step 1: KTL, KVF, GUB, SUM.

Izvor: Izrada autora u SPSS-u

Iz prethodne tablice može se izvući konačna jednadžba za predviđanje poslovnog neuspjeha poduzeća za Hrvatsku. Jednadžba glasi:

$$\mathbf{LRHr} = -2,519 + 1,778 X_1 + 2,862 X_2 - 1,595 X_3 + 0,004X_4 \quad (18)$$

Objašnjenje oznaka:

X_1 – Koeficijent tekuće likvidnosti

X_2 – Koeficijent vlastitog financiranja

X_3 – Gubitak poslovne godine

X_4 – Suma neto dobiti.

Tablica 29: Klasifikacijska točnost modela – Hrvatska

Classification Table ^a				
	Observed	Predicted		
		Status		Percentage Correct
		Active (insolvency proc.)	Active	
Step 1	Status Active (insolvency proc.)	294	37	88,8
	Status Active	26	312	92,3
	Overall Percentage			90,6

a. The cut value is ,500

Izvor: Izrada autora u SPSS-u

Konačno iz posljednje tablice se vidi da je model točno klasificirao 90,6% poduzeća, odnosno postotak točno klasificiranih poduzeća koja su u stečaju iznosi 88,8%, te postotak aktivnih, odnosno zdravih poduzeća 92,3%.

3.4.3. Formiranje modela pomoću neuronskih mreža

U formiranju neuronske mreže koristiti će se iste nezavisne varijable kao i kod binarne logističke regresije, kako bi se u konačnici moglo procijeniti koja metoda daje bolje rezultate u predviđanju bankrota poduzeća. Dakle, varijable su koeficijent tekuće likvidnosti, koeficijent vlastitog financiranja, gubitak poslovne godine, te suma neto dobiti. U ovom radu koristi se algoritam mreže širenja unatrag, odnosno višeslojni perceptron. Mreža funkcionira na način da se ulazne vrijednosti šire kroz skriveni sloj do izlaznog sloja, nakon čega se određuje greška koja se širi unatrag do ulaznog sloja i ugrađuje u formulu za učenje.²⁷

Tablica 30: Broj uzoraka i njihova namjena – Hrvatska

Case Processing Summary			
		N	Percent
Sample	Training	449	67,1%
	Testing	220	32,9%
Valid		669	100,0%
Excluded		7	
Total		676	

Izvor: Izrada autora u SPSS-u

Iz tablice 30. se vidi kako je u uzorak za formiranje neuronskih mreža uključeno 669 poduzeće, odnosno 98,96% originalnog uzorka od čega 67,12% opada na uzorak za testiranje, a 32,88% uzorak za testiranje. Postotak poduzeća koja su izuzeta iz analize je 1,04%, odnosno 7 poduzeća je isključeno iz analize.

²⁷ Dumančić, S. (2014): Diplomski rad: Neuronske mreže, Sveučilište Josipa Jurja Strossmayera u Osijeku, Osijek, str. 26

Tablica 31: Informacije o mreži – Hrvatska

Network Information			
Input Layer	Factors	1	GUB
		1	KTL
	Covariates	2	KVF
		3	SUM
Hidden Layer(s)	Number of Units ^a		6
	Rescaling Method for Covariates		Standardized
	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1 ^a		3
	Activation Function		Hyperbolic tangent
Output Layer	Dependent Variables	1	Status
	Number of Units		2
	Activation Function		Softmax
	Error Function		Cross-entropy

a. Excluding the bias unit

Izvor: Izrada autora u SPSS-u

Iz tablice 31. vide se informacije o neuronskoj mreži. Dakle sloj inputa sastoji se od 4 varijable, od čega su 3 varijable klasični financijski pokazatelji, koeficijent tekuće likvidnosti, koeficijent vlastitog financiranja i suma neto dobiti, a 1 varijabla je atributna, a to je gubitak poslovne godine. Varijabla gubitak poslovne godine može zauzeti 3 vrijednosti, vrijednost 0 ako je poduzeće poslovalo s dobitkom u posljednje dvije godine, vrijednost 1 ako je poduzeće jednu od dvije posljednje godine poslovalo s gubitkom, te vrijednost 2 ako je poduzeće obe godine poslovalo s gubitkom. Broj jedinica u sloju inputa iznosi 6 upravo iz tog razloga, jer varijabla gubitak poslovne godine zauzima 3 vrijednosti, te ostale 3 jedinice koeficijent tekuće likvidnosti, koeficijent vlastitog financiranja i suma neto dobiti. Broj skrivenih slojeva je 1, dok je broj jedinica u skrivenom sloju 3. S obzirom na to da su neuronske mreže u programu rađene po njegovom automatizmu, program sam odabire metode i funkcije aktivacije. Metoda za transformaciju nezavisnih numeričkih varijabli je standardizacija, funkcija aktivacije u skrivenom sloju je hiperbolična tangenta, dok je funkcija aktivacije u sloju outputa Softmax. Sloj outputa se sastoji od jedne zavisne varijable, a to je status, koji zauzima dvije vrijednosti, odnosno dvije jedinice, a to su aktivno poduzeće i aktivno poduzeće u procesu stečaja. Zavisna varijabla je kategorična odnosno zauzima dvije vrijednosti i stoga program po automatizmu uzima funkciju Softmax.

Tablica 32: Sažetak modela – Hrvatska

Model Summary		
Training	Cross Entropy Error	90,736
	Percent Incorrect Predictions	9,4%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00,47
	Cross Entropy Error	43,313
Testing	Cross Entropy Error	43,313
	Percent Incorrect Predictions	7,7%


Dependent Variable: Status

a. Error computations are based on the testing sample.

Izvor: Izrada autora u SPSS-u

Prema tablici 32. se vidi da je postotak netočnih predviđanja u uzorku za treniranje 9,4%, dok je postotak netočnih predviđanja u uzorku za testiranje 7,7%. Sažetak modela pokazuje pozitivne znakove u korištenju neronske mreže, a to su:

- 1) Postotak netočnih predviđanja u uzorku treniranje i uzorku za testiranje je podjednak
- 2) Algoritam procjene je zaustavljen jer se greška nije smanjila nakon koraka u algoritmu.



Slika 1: Grafički prikaz izgleda arhitekture neuronske mreže– Hrvatska

Izvor: Izrada autora u SPSS-u

Tablica 33: Procjene parametara neuronske mreže – Hrvatska

Parameter Estimates						
Predictor		Predicted				
		Hidden Layer 1			Output Layer	
		H(1:1)	H(1:2)	H(1:3)	[Status=,00]	[Status=1,00]
Input Layer	(Bias)	1,660	-,257	-1,569		
	[GUB=,00]	-1,384	-1,656	-,049		
	[GUB=1,00]	,619	-,079	-,236		
	[GUB=2,00]	2,080	1,488	-,892		
	KTL	-2,103	,565	-6,734		
	KVF	-,956	,138	-3,416		
	SUM	,793	-1,741	-1,837		
Hidden Layer 1	(Bias)				1,061	-1,296
	H(1:1)				2,170	-2,485
	H(1:2)				,612	-1,145
	H(1:3)				4,017	-3,346

Izvor: Izrada autora u SPSS-u


Tablica 34: Klasifikacijska tablica – Hrvatska

Classification				
Sample	Observed	Predicted		
		Active (insolvency proc.)	Active	Percent Correct
Training	Active (insolvency proc.)	207	23	90,0%
	Active	19	200	91,3%
	Overall Percent	50,3%	49,7%	90,6%
Testing	Active (insolvency proc.)	90	11	89,1%
	Active	6	113	95,0%
	Overall Percent	43,6%	56,4%	92,3%

Dependent Variable: Status

Izvor: Izrada autora u SPSS-u

Prema klasifikacijskoj tablici vidi se da je 90,6% poduzeća točno klasificirano prema uzorku za treniranje što korespondira postotku pogreške od 9,4% u tablici 32. Prema uzorku za testiranje točno je klasificirano 92,3% poduzeća što isto tako korespondira postotku pogreške od 7,7% što se može vidjeti u tablici 32.



Slika 2: Krivulja ROC – Hrvatska

Izvor: Izrada autora u SPSS-u

Roc krivulja daje grafički prikaz senzitivnosti i specifičnosti zavisne varijable. Specifičnost je zapravo vjerojatnost da poduzeće koje je aktivno model ne klasificira kao aktivno ako ono zaista i nije aktivno. Senzitivnost je vjerojatnost da poduzeće model klasificira kao aktivno ako ono zaista i jest aktivno. ROC krivulja je temeljena na uzorku za treniranje i testiranje.

Tablica 35: Površina ispod ROC krivulje – Hrvatska

Area Under the Curve	
	Area
Status Active (insolvency proc.)	,975
Status Active	,975

Izvor: Izrada autora u SPSS-u


Površina ispod ROC krivulje mjeri vjerojatnost, odnosno sposobnost neuronskih mreža da točno klasificira poduzeća na ona koja su aktivna i ona koja su aktivna ali u procesu stečaja. U ovom primjeru vjerojatnost je 97,5% što znači da je model izvrstan.

Tablica 36: Prikaz važnosti nezavisnih varijabli – Hrvatska

Independent Variable Importance		
	Importance	Normalized Importance
GUB	,096	27,5%
KTL	,347	100,0%
KVF	,311	89,5%
SUM	,247	71,2%

Izvor: Izrada autora u SPSS-u

Prema tablici 36. vidi se da je varijabla sa najvećom važnosti, odnosno ona koja najviše utječe na uspješnost točne klasifikacije poduzeća koeficijent tekuće likvidnosti. Važnost ove varijable iznosi 0,347, odnosno normalizirana važnost 100%.



Slika 3: Grafički prikaz važnosti nezavisnih varijabli – Hrvatska

Izvor: Izrada autora u SPSS-u

3.5. Model predviđanja poslovnog neuspjeha u Bosni i Hercegovini

3.5.1. Priprema podataka za analizu

Kao u primjeru Hrvatske prvi korak je odabir varijabli koje će ući u model. Dakle prvi kriterij za ulazak varijabli je razina signifikantnosti manja od 5%.

Tablica 37: Rezultati testiranja nezavisnih uzoraka – Bosna i Hercegovina

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2- tailed)	Mean Differenc e	Std. Error Differenc e	95% Confidence Interval of the Difference	
									Lower	Upper
KVF	Equal variances assumed	1,195	,287	-2,574	20	,018	-,32596	,12662	-,59009	-,06183
	Equal variances not assumed			-2,574	18,870	,019	-,32596	,12662	-,59111	-,06081
ROA	Equal variances assumed	,838	,371	-2,511	20	,021	-,26935	,10728	-,49313	-,04558
	Equal variances not assumed			-2,511	18,425	,022	-,26935	,10728	-,49436	-,04435
GUB	Equal variances assumed	12,755	,002	5,715	20	,000	1,27273	,22268	,80822	1,73723
	Equal variances not assumed			5,715	13,846	,000	1,27273	,22268	,79463	1,75083
SUM	Equal variances assumed	2,828	,108	-2,361	20	,028	-483,018	204,572	-909,749	-56,288
	Equal variances not assumed			-2,361	12,685	,035	-483,018	204,572	-926,088	-39,948

Izvor: Izrada autora u SPSS-u

Prema tablici vidi se da je svim navedenim varijablama razina signifikantnosti manja od 5% što znači da prolaze prvi kriterij i mogu ići u daljnju analizu. Sljedeći korak je testiranje mogućeg problema multikolinearnosti pomoću Pearsonovog koeficijenta korelacije, te tolerancije i faktora inflacije varijance VIF.

Tablica 38: Prikaz korelacija između varijabli – Bosna i Hercegovina

Correlations		KVF	ROA	GUB	SUM
KVF	Pearson Correlation	1	,526*	-,476*	,431*
	Sig. (2-tailed)		,012	,025	,045
	N	22	22	22	22
ROA	Pearson Correlation	,526*	1	-,404	,321
	Sig. (2-tailed)	,012		,062	,146
	N	22	22	22	22
GUB	Pearson Correlation	-,476*	-,404	1	-,604**
	Sig. (2-tailed)	,025	,062		,003
	N	22	22	22	22
SUM	Pearson Correlation	,431*	,321	-,604**	1
	Sig. (2-tailed)	,045	,146	,003	
	N	22	22	22	22

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

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

Izvor: Izrada autora u SPSS-u

Kao što se vidi u tablici nakon provedenog testa korelacije varijable imaju slabu do srednje jaku pozitivnu / negativnu korelaciju što ukazuje na to da nema problema multikolinearnosti. Da nema problema multikolinearnosti može se dokazati i prema vrijednostima tolerancije i faktora inflacije varijance.

Tablica 39: Vrijednost tolerancije i VIF-a – Bosna i Hercegovina

Coefficientsa			
Model		Collinearity Statistics	
		Tolerance	VIF
1	KVF	,620	1,614
	ROA	,692	1,445
	GUB	,561	1,782
	SUM	,608	1,645

a. Dependent Variable: Status

Izvor: Izrada autora u SPSS-u

Kao što se vidi tolerancija je kod sve 4 varijable veća od 0.2, te je faktor inflacije varijance kod svih varijabli manji od 5 što znači da nema problema multikolinearnosti. Nakon što je utvrđeno da nema problema multikolinearnosti može se provesti metoda binarne logističke regresije.

3.5.2. Formiranje modela pomoću binarne logističke regresije

Nakon provedene analize ustanovljeno je da varijable koje daju najbolji rezultat u predviđanju bankrota su koeficijent vlastitog financiranja, povrat na imovinu, gubitak poslovne godine, te suma neto dobiti.

Tablica 37: Omnibus test koeficijenata modela – Bosna i Hercegovina

Omnibus Tests of Model Coefficients			
	Chi-square	df	Sig.
Step	30,498	4	,000
Step 1 Block	30,498	4	,000
Model	30,498	4	,000

Izvor: Izrada autora u SPSS-u

Omnibus testom se vidi da je razina signifikantnosti manja od 5% što dokazuje da je model statistički signifikantan.

Tablica 38: Mjere prikladnosti modela – Bosna i Hercegovina

Model Summary			
Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	,000 ^a	,750	1,000

a. Estimation terminated at iteration number 20 because maximum iterations has been reached. Final solution cannot be found.

Izvor: Izrada autora u SPSS-u

Kao što je navedeno Nagelkerke R^2 zauzima vrijednosti od 0 do 1. Nagelkerke R^2 iznosi 100% što govori o snažnoj vezi između navedenih nezavisnih varijabli i predviđanja bankrota poduzeća.

Tablica 39: Hosmer-Lemeshow test – Bosna i Hercegovina

Hosmer and Lemeshow Test			
Step	Chi-square	df	Sig.
1	,000	8	1,000

Izvor: Izrada autora u SPSS-u

U ovom primjeru signifikantnost iznosi 100% što je daleko veće od granice od 5% što znači da je model prikladan u odnosu na podatke.

Tablica 40: Prikaz varijabli i pripadajućih pondera – Bosna i Hercegovina

Variables in the Equation						
	B	S.E.	Wald	df	Sig.	Exp(B)
Step 1 ^a	KVF	63,779	6011,623	,000	1	,992
	ROA	1722,943	100181,800	,000	1	,986
	GUB	-30,407	5259,513	,000	1	,995
	SUM	,029	14,279	,000	1	,998
	Constant	-38,359	2896,462	,000	1	,989

a. Variable(s) entered on step 1: KVF, ROA, GUB, SUM.

Izvor: Izrada autora u SPSS-u

Iz prethodne tablice može se izvući konačna jednačba za predviđanje bankrota poduzeća iz Bosne i Hercegovine. Jednačba glasi:

$$\text{LRBih} = -38,359 + 63,779 X_1 + 1.722,943 X_2 - 30,407 X_3 + 0,029 X_4 \quad (19)$$

Objašnjenje oznaka:

X_1 – Koeficijent vlastitog financiranja

X_2 – Povrat na imovinu

X_3 – Gubitak poslovne godine

X_4 – Suma neto dobiti.

Tablica 40: Klasifikacijska točnost modela – Bosna i Hercegovina

Classification Table ^a				
	Observed	Predicted		
		Status		Percentage Correct
		Active (insolvency proc.)	Active	
Step 1	Status Active (insolvency proc.)	11	0	100,0
	Status Active	0	11	100,0
	Overall Percentage			100,0

a. The cut value is ,500

Izvor: Izrada autora u SPSS-u

Konačno iz posljednje tablice vidi se da je model točno klasificirao sva poduzeća, odnosno postotak točno klasificiranih poduzeća koja su u stečaju iznosi 100%, te postotak aktivnih, odnosno zdravih poduzeća iznosi isto tako 100%.

3.5.3. Formiranje modela pomoću neuronskih mreža

U formiranju neuronske mreže koristiti će se iste nezavine varijable kao i kod binarne logističke regresije, kako bi se u konačnici moglo procijeniti koja metoda daje bolje rezultate u predviđanju bankrota poduzeća. Dakle, varijable su koeficijent vlastitog financiranja, povrat na imovinu, gubitak poslovne godine, te suma neto dobiti.

Tablica 41: Broj uzoraka i njihova namjena – Bosna i Hercegovina

Case Processing Summary			
		N	Percent
Sample	Training	18	81,8%
	Testing	4	18,2%
Valid		22	100,0%
Excluded		0	
Total		22	

Izvor: Izrada autora u SPSS-u

Iz tablice 41. vidi se da je u uzorak za formiranje neuronskih mreža uključeno 22 poduzeća, odnosno 100% originalnog uzorka od čega 81,81% opada na uzorak za testiranje, a 18,18% uzorak za testiranje. Niti jedno poduzeće nije izuzeto iz analize.

Tablica 42: Informacije o mreži – Bosna i Hercegovina

Network Information			
Input Layer	Factors	1	GUB
		1	KVF
	Covariates	2	ROA
		3	SUM
Hidden Layer(s)	Number of Units ^a		6
	Rescaling Method for Covariates		Standardized
	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1 ^a		2
Output Layer	Activation Function		Hyperbolic tangent
	Dependent Variables	1	Status
	Number of Units		2
	Activation Function		Softmax
	Error Function		Cross-entropy

a. Excluding the bias unit

Izvor: Izrada autora u SPSS-u

Iz tablice 42. vide se informacije o neuronskoj mreži. Dakle sloj inputa sastoji se od 4 varijable, od čega su 3 varijable klasični financijski pokazatelji, koeficijent vlastitog financiranja, povrat na imovinu i suma neto dobiti, a 1 varijabla je atributna, a to je gubitak poslovne godine. Varijabla gubitak poslovne godine može zauzeti 3 vrijednosti, vrijednost 0 ako je poduzeće poslovalo s dobitkom u posljednje dvije godine, vrijednost 1 ako je poduzeće jednu od dvije posljednje godine poslovalo s gubitkom, te vrijednost 2 ako je poduzeće obe godine poslovalo s gubitkom. Broj jedinica u sloju inputa iznosi 6 upravo iz tog razloga, jer varijabla gubitak poslovne godine zauzima 3 vrijednosti, te ostale 3 jedinice, koeficijent vlastitog financiranja, povrat na imovinu i suma neto dobiti. Broj skrivenih slojeva je 1, dok je broj jedinica u skrivenom sloju 2. S obzirom na to da su neuronske mreže u programu rađene po njegovom automatizmu, program sam odabire metode i funkcije aktivacije. Metoda za transformaciju nezavisnih numeričkih varijabli je standardizacija, funkcija aktivacije u skrivenom sloju je hiperbolična tangenta, dok je funkcija aktivacije u sloju outputa Softmax. Sloj outputa se sastoji od jedne zavisne varijable, a to je status, koji zauzima dvije vrijednosti, odnosno dvije jedinice, a to su aktivno poduzeće i aktivno poduzeće u procesu stečaja. Zavisna varijabla je kategorična odnosno zauzima dvije vrijednosti i stoga program po automatizmu uzima funkciju Softmax.

Tablica 43: Sažetak modela – Bosna i Hercegovina

Model Summary		
Training	Cross Entropy Error	,550
	Percent Incorrect Predictions	0,0%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00,00
	Cross Entropy Error	,356
Testing	Percent Incorrect Predictions	0,0%

Dependent Variable: Status


a. Error computations are based on the testing sample.

Izvor: Izrada autora u SPSS-u

Prema tablici 43. vidi se da je postotak netočnih predviđanja u uzorku za treniranje 0%, dok je postotak netočnih predviđanja u uzorku za testiranje isto tako 0%. Sažetak modela pokazuje pozitivne znakove u korištenju neronske mreže, a to su:

- 1) Postotak netočnih predviđanja u uzorku treniranje i uzorku za testiranje je podjednak

- 2) Algoritam procjene je zaustavljen jer se greška nije smanjila nakon koraka u algoritmu.



Slika 4: Grafički prikaz izgleda arhitekture neuronske mreže – Bosna i Hercegovina

Izvor: Izrada autora u SPSS-u

Tablica 44: Procjene parametara neuronske mreže – Bosna i Hercegovina

Parameter Estimates					
Predictor		Predicted			
		Hidden Layer 1		Output Layer	
		H(1:1)	H(1:2)	[Status=,00]	[Status=1,00]
Input Layer	(Bias)	1,336	-,468		
	[GUB=,00]	-,342	,240		
	[GUB=1,00]	,823	,156		
	[GUB=2,00]	,720	,342		
	KVF	-,525	-,256		
	ROA	-4,340	-,317		
	SUM	-1,037	-,097		
Hidden Layer 1	(Bias)			-,009	-,158
	H(1:1)			3,839	-3,461
	H(1:2)			-,022	-,492

Izvor: Izrada autora u SPSS-u


Tablica 45: Klasifikacijska tablica – Bosna i Hercegovina

Classification				
Sample	Observed	Predicted		
		Active (insolvency proc.)	Active	Percent Correct
Training	Active (insolvency proc.)	11	0	100,0%
	Active	0	7	100,0%
	Overall Percent	61,1%	38,9%	100,0%
Testing	Active (insolvency proc.)	0	0	0,0%
	Active	0	4	100,0%
	Overall Percent	0,0%	100,0%	100,0%

Dependent Variable: Status

Izvor: Izrada autora u SPSS-u

Prema klasifikacijskoj tablici vidi se da je 100% poduzeća točno klasificirano prema uzorku za treniranje što korespondira postotku pogreške od 0% u tablici 43. Prema uzorku za testiranje točno je klasificirano isto tako 100% poduzeća što korespondira postotku pogreške od 0% što se može vidjeti u tablici 43.



Slika 5: Krivulja ROC – Bosna i Hercegovina

Izvor: Izrada autora u SPSS-u

Tablica 46: Površina ispod ROC krivulje – Bosna i Hercegovina

Area Under the Curve		
		Area
Status	Active (insolvency proc.)	1,000
	Active	1,000

Izvor: Izrada autora u SPSS-u


Površina ispod ROC krivulje mjeri vjerojatnost, odnosno sposobnost neuronskih mreža da točno klasificira poduzeća na ona koja su aktivna i ona koja su aktivna ali u procesu stečaja. U ovom primjeru vjerojatnost je 100% što znači da je model izvrstan. Isto to se može vidjeti i prema grafičkom prikazu ROC krivulje.

Tablica 47: Prikaz važnosti nezavisnih varijabli – Bosna i Hercegovina

Independent Variable Importance		
	Importance	Normalized Importance
GUB	,130	26,7%
KVF	,159	32,5%
ROA	,488	100,0%
SUM	,223	45,7%

Izvor: Izrada autora u SPSS-u

Prema tablici 47. vidi se da je varijabla sa najvećom važnosti, odnosno ona koja najviše utječe na uspješnost točne klasifikacije poduzeća koeficijent povrat na imovinu. Važnost ove varijable iznosi 0,488, odnosno normalizirana važnost 100%.



Slika 6: Grafički prikaz važnosti nezavisnih varijabli – Bosna i Hercegovina

Izvor: Izrada autora u SPSS-u

3.6. Model predviđanja poslovnog neuspjeha u Srbiji

3.6.1. Priprema podataka za analizu

Prvi korak da bi varijable zadovoljile ulazak u konačnu jednadžbu za predviđanje bankrota poduzeća je razina signifikantnosti manja od 5%.

Tablica 48: Rezultati testiranja nezavisnih uzoraka – Srbija

Independent Samples Test									
	Levene's Test for Equality of Variances		t-test for Equality of Means						
	F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
								Lower	Upper
KVF	2,889	,094	-7,793	66	,000	-,41143	,05280	-,51684	-,30602
			-7,793	63,450	,000	-,41143	,05280	-,51692	-,30594
ROA	6,356	,014	-6,299	66	,000	-,17258	,02740	-,22729	-,11788
			-6,299	55,626	,000	-,17258	,02740	-,22748	-,11769
GUB	13,358	,001	10,493	65	,000	1,33957	,12766	1,08461	1,59454
			10,432	55,468	,000	1,33957	,12841	1,08227	1,59687
SUM	19,550	,000	-3,264	65	,002	-1530,221	468,775	-2466,429	-594,011
			-3,217	33,167	,003	-1530,221	475,669	-2497,793	-562,648

Izvor: Izrada autora u SPSS-u

Prema tablici vidi se da je svim navedenim varijablama razina signifikantnosti manja od 5% što znači da prolaze prvi kriterij i mogu ići u daljnju analizu. Sljedeći korak je testiranje mogućeg postojanja problema multikolinearnosti pomoću Pearsonovog koeficijenta korelacije, te tolerancije i faktora inflacije varijance VIF.

Tablica 49: Prikaz korelacija između varijabli – Srbija

Correlations		KVF	ROA	GUB	SUM
KVF	Pearson Correlation	1	,493**	-,516**	,362**
	Sig. (2-tailed)		,000	,000	,003
	N	68	68	67	67
ROA	Pearson Correlation	,493**	1	-,701**	,432**
	Sig. (2-tailed)	,000		,000	,000
	N	68	68	67	67
GUB	Pearson Correlation	-,516**	-,701**	1	-,449**
	Sig. (2-tailed)	,000	,000		,000
	N	67	67	67	67
SUM	Pearson Correlation	,362**	,432**	-,449**	1
	Sig. (2-tailed)	,003	,000	,000	
	N	67	67	67	67

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

Izvor: Izrada autora u SPSS-u

Kao što se vidi u tablici nakon provedenog testa korelacije varijable imaju slabu do srednje jaku pozitivnu / negativnu korelaciju što ukazuje na to da nema problema multikolinearnosti. Da nema problema multikolinearnosti može se dokazati i prema vrijednostima tolerancije i faktora inflacije varijance.

Tablica 50: Vrijednost tolerancije i VIF-a – Srbija

Coefficients ^a			
Model		Collinearity Statistics	
		Tolerance	VIF
1	KVF	,686	1,459
	ROA	,473	2,116
	GUB	,455	2,198
	SUM	,757	1,320

a. Dependent Variable: Status

Izvor: Izrada autora u SPSS-u

Kao što se vidi tolerancija je kod sve 4 varijable veća od 0.2, te je faktor inflacije varijance kod svih varijabli manji od 5 što znači da nema problema multikolinearnosti. Nakon što je utvrđeno da nema problema multikolinearnosti može se provesti metoda binarne logističke regresije.

3.6.2. Formiranje modela pomoću binarne logističke regresije

Varijable koje će biti korištene u modelu su koeficijent vlastitog financiranja, povrat na imovinu, gubitak poslovne godine, te suma neto dobiti.

Tablica 51: Omnibus test koeficijenata modela – Srbija

Omnibus Tests of Model Coefficients			
	Chi-square	df	Sig.
Step	77,145	4	,000
Step 1 Block	77,145	4	,000
Model	77,145	4	,000

Izvor: Izrada autora u SPSS-u

Omnibus testom se vidi da je razina signifikantnosti manja od 5% što dokazuje da je model statistički signifikantan.

Tablica 52: Mjere prikladnosti modela – Srbija

Model Summary			
Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	15,721 ^a	,684	,912

a. Estimation terminated at iteration number 13 because parameter estimates changed by less than ,001.

Izvor: Izrada autora u SPSS-u

Nagelkerke R^2 iznosi 91,2% što govori o snažnoj vezi između navedenih nezavisnih varijabli i predviđanja bankrota poduzeća.

Tablica 53: Hosmer-Lemeshow test – Srbija

Hosmer and Lemeshow Test			
Step	Chi-square	df	Sig.
1	,285	8	1,000

Izvor: Izrada autora u SPSS-u

U ovom primjeru signifikantnost iznosi 100% što je daleko veće od granice od 5% što znači da je model prikladan u odnosu na podatke.

Tablica 54: Prikaz varijabli i pripadajućih pondera – Srbija

Variables in the Equation						
	B	S.E.	Wald	df	Sig.	Exp(B)
Step 1 ^a	KVF	7,753	4,950	1	,026	2329,078
	ROA	29,690	1,076	1	,300	7,839E+12
	GUB	-2,910	3,756	1	,053	,054
	SUM	,018	,460	1	,498	1,018
	Constant	-,130	,014	1	,905	,878

a. Variable(s) entered on step 1: KVF, ROA, GUB, SUM.

Izvor: Izrada autora u SPSS-u

Iz prethodne tablice može se izvući konačna jednadžbu za predviđanje bankrota poduzeća iz Srbije. Jednadžba glasi:

$$\mathbf{LRSrb} = -0,130 + 7,753 X_1 + 29,690 X_2 - 2,910 X_3 + 0,018 X_4 \quad (20)$$

Objašnjenje oznaka:

X_1 – Koeficijent vlastitog financiranja

X_2 – Povrat na imovinu

X_3 – Gubitak poslovne godine

X_4 – Suma neto dobiti.

Tablica 55: Klasifikacijska točnost modela – Srbija

Classification Table ^a				
	Observed	Predicted		
		Status		Percentage Correct
		Active (insolvency proc.)	Active	
Step 1	Status Active (insolvency proc.)	32	1	97,0
	Status Active	1	33	97,1
	Overall Percentage			97,0

a. The cut value is ,500

Izvor: Izrada autora u SPSS-u

Konačno iz posljednje tablice vidi se da je model točno klasificirao 97% poduzeća, odnosno postotak točno klasificiranih poduzeća koja su u stečaju iznosi 97%, te postotak aktivnih, odnosno zdravih poduzeća iznosi 97,1%.

3.6.3. Formiranje modela pomoću neuronskih mreža

U formiranju neuronske mreže koristiti će se iste nezavisne varijable kao i kod binarne logističke regresije, kako bi se u konačnici procijenilo koja metoda daje bolje rezultate u predviđanju poslovnog neuspjeha poduzeća. Dakle, varijable su koeficijent vlastitog financiranja, povrat na imovinu, gubitak poslovne godine, te suma neto dobiti.

Tablica 56: Broj uzoraka i njihova namjena – Srbija

Case Processing Summary			
		N	Percent
Sample	Training	47	70,1%
	Testing	20	29,9%
Valid		67	100,0%
Excluded		1	
Total		68	

Izvor: Izrada autora u SPSS-u

Iz tablice 56. vidi se da je u uzorak za formiranje neuronskih mreža uključeno 67 poduzeća, odnosno 98,52% originalnog uzorka od čega 65,67% opada na uzorak za testiranje, a 34,33% uzorak za testiranje. Samo jedno poduzeće je izuzeto iz analize.

Tablica 57: Informacije o mreži – Srbija

Network Information			
Input Layer	Factors	1	GUB
		1	KVF
	Covariates	2	ROA
		3	SUM
Hidden Layer(s)	Number of Units ^a		6
	Rescaling Method for Covariates		Standardized
	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1 ^a		5
	Activation Function		Hyperbolic tangent
Output Layer	Dependent Variables	1	Status
	Number of Units		2
	Activation Function		Softmax
	Error Function		Cross-entropy

a. Excluding the bias unit

Izvor: Izrada autora u SPSS-u

Iz tablice 57. vide se informacije o neuronskoj mreži. Dakle sloj inputa sastoji se od 4 varijable, od čega su 3 varijable klasični financijski pokazatelji, koeficijent vlastitog financiranja, povrat na imovinu i suma neto dobiti, a 1 varijabla je atributna, a to je gubitak poslovne godine. Varijabla gubitak poslovne godine može zauzeti 3 vrijednosti, vrijednost 0 ako je poduzeće poslovalo s dobitkom u posljednje dvije godine, vrijednost 1 ako je poduzeće jednu od dvije posljednje godine poslovalo s gubitkom, te vrijednost 2 ako je poduzeće obe godine poslovalo s gubitkom. Broj jedinica u sloju inputa iznosi 6 upravo iz tog razloga, jer varijabla gubitak poslovne godine zauzima 3 vrijednosti, te ostale 3 jedinice koeficijent vlastitog financiranja, povrat na imovinu i suma neto dobiti. Broj skrivenih slojeva je 1, dok je broj jedinica u skrivenom sloju 5. S obzirom na to da su neuronske mreže u programu rađene po njegovom automatizmu, program sam odabire metode i funkcije aktivacije. Metoda za transformaciju nezavisnih numeričkih varijabli je standardizacija, funkcija aktivacije u skrivenom sloju je hiperbolična tangenta, dok je funkcija aktivacije u sloju outputa Softmax. Sloj outputa se sastoji od jedne zavisne varijable, a to je status, koji zauzima dvije vrijednosti, odnosno dvije jedinice, a to su aktivno poduzeće i aktivno poduzeće u procesu stečaja. Zavisna varijabla je kategorična odnosno zauzima dvije vrijednosti i stoga program po automatizmu uzima funkciju Softmax.

Tablica 58: Sažetak modela – Srbija

Model Summary		
Training	Cross Entropy Error	5,461
	Percent Incorrect Predictions	6,4%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00,09
	Cross Entropy Error	2,539
Testing	Percent Incorrect Predictions	5,0%

Dependent Variable: Status


a. Error computations are based on the testing sample.

Izvor: Izrada autora u SPSS-u

Prema tablici 58. vidi se da je postotak netočnih predviđanja u uzorku za treniranje 6,4%, dok je postotak netočnih predviđanja u uzorku za testiranje 5%. Sažetak modela pokazuje pozitivne znakove u korištenju neronske mreže, a to su:

- 1) Postotak netočnih predviđanja u uzorku treniranje i uzorku za testiranje je podjednak

- 2) Algoritam procjene je zaustavljen jer se greška nije smanjila nakon koraka u algoritmu.



Slika 7: Grafički prikaz izgleda arhitekture neuronske mreže – Srbija

Izvor: Izrada autora u SPSS-u

Tablica 59: Procjene parametara neuronske mreže – Srbija

Parameter Estimates								
Predictor		Predicted						
		Hidden Layer 1					Output Layer	
		H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	[Status=,00]	[Status=1,00]
Input Layer	(Bias)	,419	-,135	,625	,110	-,487		
	[GUB=,00]	-,855	,338	-,699	-,595	,021		
	[GUB=1,00]	-,150	,226	-,002	-,519	,221		
	[GUB=2,00]	,478	-,399	,704	,831	,331		
	KVF	-,180	,556	-,751	-,219	-,405		
	ROA	-,835	,751	-1,317	-,556	,464		
	SUM	-,661	,478	-,099	-,305	,327		
Hidden Layer 1	(Bias)						,346	,049
	H(1:1)						1,110	-,761
	H(1:2)						-,830	,555
	H(1:3)						1,150	-1,365
	H(1:4)						,867	-1,045
	H(1:5)						,393	-,187


Izvor: Izrada autora u SPSS-u

Tablica 60: Klasifikacijska tablica – Srbija

Classification				
Sample	Observed	Predicted		
		Active (insolvency proc.)	Active	Percent Correct
Training	Active (insolvency proc.)	24	1	96,0%
	Active	2	20	90,9%
	Overall Percent	55,3%	44,7%	93,6%
Testing	Active (insolvency proc.)	7	1	87,5%
	Active	0	12	100,0%
	Overall Percent	35,0%	65,0%	95,0%

Dependent Variable: Status
 Izvor: Izrada autora u SPSS-u

Prema klasifikacijskoj tablici vidi se da je 93,6% poduzeća točno klasificirano prema uzorku za treniranje što korespondira postotku pogreške od 6,4% u tablici 58. Prema uzorku za testiranje točno je klasificirano 95,0% poduzeća što korespondira postotku pogreške od 5% što se vidi u tablici 58.



Slika 8: Krivulja ROC – Srbija

Izvor: Izrada autora u SPSS-u

Tablica 61: Površina ispod ROC krivulje – Srbija

Area Under the Curve		
		Area
Status	Active (insolvency proc.)	,990
	Active	,990

Izvor: Izrada autora u SPSS-u


Površina ispod ROC krivulje mjeri vjerojatnost, odnosno sposobnost neuronskih mreža da točno klasificira poduzeća na ona koja su aktivna i ona koja su aktivna ali u procesu stečaja. U ovom primjeru vjerojatnost je 99% što znači da je model izvrstan. Isto se vidi i prema grafičkom prikazu ROC krivulje.

Tablica 62: Prikaz važnosti nezavisnih varijabli – Srbija

Independent Variable Importance		
	Importance	Normalized Importance
GUB	,195	48,2%
KVF	,191	47,1%
ROA	,405	100,0%
SUM	,209	51,4%

Izvor: Izrada autora u SPSS-u

Prema tablici 62. vidi se da je varijabla sa najvećom važnosti, odnosno ona koja najviše utječe na uspješnost točne klasifikacije poduzeća koeficijent povrat na imovinu. Važnost ove varijable iznosi 0,405, odnosno normalizirana važnost 100%.



Slika 9: Grafički prikaz važnosti nezavisnih varijabli – Srbija

Izvor: Izrada autora u SPSS-u

3.7. Model predviđanja poslovnog neuspjeha u Mađarskoj

3.7.1. Priprema podataka za analizu

Prvi korak da bi varijable zadovoljile ulazak u konačnu jednadžbu za predviđanje bankrota poduzeća je razina signifikantnosti manja od 5%.

Tablica 63: Rezultati testiranja nezavisnih uzoraka – Mađarska

Independent Samples Test										
		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2- tailed)	Mean Difference	Std. Error Differenc e	95% Confidence Interval of the Difference	
									Lower	Upper
KVF	Equal variances assumed	3,388	,079	-4,326	22	,000	-,71218	,16462	-1,05358	-,37078
	Equal variances not assumed			-4,326	16,042	,001	-,71218	,16462	-1,06108	-,36328
ROA	Equal variances assumed	5,466	,029	-4,322	22	,000	-,37631	,08707	-,55688	-,19573
	Equal variances not assumed			-4,322	12,434	,001	-,37631	,08707	-,56529	-,18733
GUB	Equal variances assumed	40,732	,000	6,157	21	,000	1,45455	,23626	,96322	1,94587
	Equal variances not assumed			5,882	10,000	,000	1,45455	,24730	,90353	2,00556
SUM	Equal variances assumed	15,593	,001	-2,531	21	,019	-2629,203	1038,876	-4789,664	-468,742
	Equal variances not assumed			-2,428	10,862	,034	-2629,203	1082,962	-5016,482	-241,925

Izvor: Izrada autora u SPSS-u

Prema tablici vidi se da je svim navedenim varijablama razina signifikantnosti manja od 5% što znači da prolaze prvi kriterij i mogu ići u daljnju analizu. Sljedeći korak je testiranje mogućeg postojanja problema multikolinearnosti pomoću Pearsonovog koeficijenta korelacije, te tolerancije i faktora inflacije varijance VIF.

Tablica 64: Prikaz korelacija između varijabli – Mađarska

Correlations					
		KVF	ROA	GUB	SUM
KVF	Pearson Correlation	1	,258	-,595**	,200
	Sig. (2-tailed)		,224	,003	,360
	N	24	24	23	23
ROA	Pearson Correlation	,258	1	-,713**	,707**
	Sig. (2-tailed)	,224		,000	,000
	N	24	24	23	23
GUB	Pearson Correlation	-,595**	-,713**	1	-,611**
	Sig. (2-tailed)	,003	,000		,002
	N	23	23	23	23
SUM	Pearson Correlation	,200	,707**	-,611**	1
	Sig. (2-tailed)	,360	,000	,002	
	N	23	23	23	23

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

Izvor: Izrada autora u SPSS-u

Kao što se vidi u tablici nakon provedenog testa korelacije varijable imaju slabu do srednje jaku pozitivnu / negativnu korelaciju što ukazuje na to da nema problema multikolinearnosti. Da nema problema multikolinearnosti može se dokazati i prema vrijednostima tolerancije i faktora inflacije varijance.

Tablica 65: Vrijednost tolerancije i VIF-a – Mađarska

Coefficients ^a			
Model		Collinearity Statistics	
		Tolerance	VIF
1	KVF	,602	1,662
	ROA	,373	2,681
	GUB	,317	3,154
	SUM	,458	2,186

a. Dependent Variable: Status

Izvor: Izrada autora u SPSS-u

Kao što se vidi tolerancija je kod sve 4 varijable veća od 0.2, te je faktor inflacije varijance kod svih varijabli manji od 5 što znači da nema problema multikolinearnosti. Nakon što je utvrđeno da nema problema multikolinearnosti može se provesti metoda binarne logističke regresije.

3.7.2. Formiranje modela pomoću binarne logističke regresije

Varijable koje će biti korištene u modelu su koeficijent vlastitog financiranja, povrat na imovinu, gubitak poslovne godine, te suma neto dobiti.

Tablica 66: Omnibus test koeficijenata modela – Mađarska

Omnibus Tests of Model Coefficients			
	Chi-square	df	Sig.
Step	31,841	4	,000
Step 1 Block	31,841	4	,000
Model	31,841	4	,000

Izvor: Izrada autora u SPSS-u

Omnibus testom se vidi da je razina signifikantnosti manja od 5% što dokazuje da je model statistički signifikantan.

Tablica 67: Mjere prikladnosti modela – Mađarska

Model Summary			
Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	,000 ^a	,750	1,000

a. Estimation terminated at iteration number 20 because maximum iterations has been reached. Final solution cannot be found.

Izvor: Izrada autora u SPSS-u

Nagelkerke R^2 iznosi 100% što govori o snažnoj vezi između navedenih nezavisnih varijabli i predviđanja bankrota poduzeća.

Tablica 68: Hosmer-Lemeshow test – Mađarska

Hosmer and Lemeshow Test			
Step	Chi-square	df	Sig.
1	,000	3	1,000

Izvor: Izrada autora u SPSS-u

U ovom primjeru signifikantnost iznosi 100% što je daleko veće od granice od 5% što znači da je model prikladan u odnosu na podatke.

Tablica 69: Prikaz varijabli i pripadajućih pondera – Mađarska

Variables in the Equation						
	B	S.E.	Wald	df	Sig.	Exp(B)
Step 1 ^a	KVF	260,456	8236,912	,001	1	,975
	ROA	4743,104	120172,358	,002	1	,969
	GUB	-455,377	12903,410	,001	1	,972
	SUM	-,208	5,008	,002	1	,967
	Constant	-25,105	914,276	,001	1	,978
						1,303E+113
						.
						,000
						,812
						,000

a. Variable(s) entered on step 1: KVF, ROA, GUB, SUM.

Izvor: Izrada autora u SPSS-u

Iz prethodne tablice može se izvući konačna jednadžba za predviđanje bankrota poduzeća iz Mađarske. Jednadžba glasi:

$$\text{LRMađ} = -25,105 + 260,456 X_1 + 4.743,104 X_2 - 455,377 X_3 - 0,208 X_4 \quad (21)$$

Objašnjenje oznaka:

X_1 – Koeficijent vlastitog financiranja

X_2 – Povrat na imovinu

X_3 – Gubitak poslovne godine

X_4 – Suma neto dobiti.

Tablica 70: Klasifikacijska točnost modela – Mađarska

Classification Table ^a				
	Observed	Predicted		
		Status		Percentage Correct
		Active (insolvency proc.)	Active	
Step 1	Status Active (insolvency proc.)	11	0	100,0
	Status Active	0	12	100,0
	Overall Percentage			100,0

a. The cut value is ,500

Izvor: Izrada autora u SPSS-u

Konačno iz posljednje tablice se vidi da je model točno klasificirao sva poduzeća, odnosno postotak točno klasificiranih poduzeća koja su u stečaju iznosi 100%, te postotak aktivnih, odnosno zdravih poduzeća iznosi isto tako 100%.

3.7.3. Formiranje modela pomoću neuronskih mreža

U formiranju neuronske mreže koristiti će se iste nezavisne varijable kao i kod binarne logističke regresije, kako bi se u konačnici procijenilo koja metoda daje bolje rezultate u predviđanju bankrota poduzeća. Dakle, varijable su koeficijent vlastitog financiranja, povrat na imovinu, gubitak poslovne godine, te suma neto dobiti.

Tablica 71: Broj uzoraka i njihova namjena – Mađarska

Case Processing Summary			
		N	Percent
Sample	Training	19	82,6%
	Testing	4	17,4%
Valid		23	100,0%
Excluded		1	
Total		24	

Izvor: Izrada autora u SPSS-u

Iz tablice 71. vidi se da je u uzorak za formiranje neuronskih mreža uključeno 23 poduzeća, odnosno 95,83% originalnog uzorka od čega 82,61% opada na uzorak za testiranje, a 17,39% uzorak za testiranje. Samo jedno poduzeće je izuzeto iz analize.

Tablica 72: Informacije o mreži – Mađarska

Network Information			
Input Layer	Factors	1	GUB
		1	KVF
	Covariates	2	ROA
		3	SUM
Hidden Layer(s)	Number of Units ^a		6
	Rescaling Method for Covariates		Standardized
	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1 ^a		3
	Activation Function		Hyperbolic tangent
Output Layer	Dependent Variables	1	Status
	Number of Units		2
	Activation Function		Softmax
	Error Function		Cross-entropy

a. Excluding the bias unit

Izvor: Izrada autora u SPSS-u

Iz tablice 72. vide se informacije o neuronskoj mreži. Dakle sloj inputa sastoji se od 4 varijable, od čega su 3 varijable klasični financijski pokazatelji, koeficijent vlastitog financiranja, povrat na imovinu i suma neto dobiti, a 1 varijabla je atributna, a to je gubitak poslovne godine. Varijabla gubitak poslovne godine može zauzeti 3 vrijednosti, vrijednost 0 ako je poduzeće poslovalo s dobitkom u posljednje dvije godine, vrijednost 1 ako je poduzeće jednu od dvije posljednje godine poslovalo s gubitkom, te vrijednost 2 ako je poduzeće obe godine poslovalo s gubitkom. Broj jedinica u sloju inputa iznosi 6 upravo iz tog razloga, jer varijabla gubitak poslovne godine zauzima 3 vrijednosti, te ostale 3 jedinice koeficijent vlastitog financiranja, povrat na imovinu i suma neto dobiti. Broj skrivenih slojeva je 1, dok je broj jedinica u skrivenom sloju 3. S obzirom na to da su neuronske mreže u programu rađene po njegovom automatizmu, program sam odabire metode i funkcije aktivacije. Metoda za transformaciju nezavisnih numeričkih varijabli je standardizacija, funkcija aktivacije u skrivenom sloju je hiperbolična tangenta, dok je funkcija aktivacije u sloju outputa Softmax. Sloj outputa se sastoji od jedne zavisne varijable, a to je status, koji zauzima dvije vrijednosti, odnosno dvije jedinice, a to su aktivno poduzeće i aktivno poduzeće u procesu stečaja. Zavisna varijabla je kategorična odnosno zauzima dvije vrijednosti i stoga program po automatizmu uzima funkciju Softmax.

Tablica 73: Sažetak modela – Mađarska

Model Summary		
Training	Cross Entropy Error	,295
	Percent Incorrect Predictions	0,0%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00,01
	Cross Entropy Error	9,770E-015
Testing	Percent Incorrect Predictions	0,0%

Dependent Variable: Status


a. Error computations are based on the testing sample.

Izvor: Izrada autora u SPSS-u

Prema tablici 73. vidi se da je postotak netočnih predviđanja u uzorku za treniranje 0%, dok je postotak netočnih predviđanja u uzorku za testiranje isto tako 0%. Sažetak modela pokazuje pozitivne znakove u korištenju neronske mreže, a to su:

- 1) Postotak netočnih predviđanja u uzorku treniranje i uzorku za testiranje je podjednak

- 2) Algoritam procjene je zaustavljen jer se greška nije smanjila nakon koraka u algoritmu.



Slika 10: Grafički prikaz izgleda arhitekture neuronske mreže – Mađarska

Izvor: Izrada autora u SPSS-u

Tablica 74: Procjene parametara neuronske mreže – Mađarska

Parameter Estimates						
Predictor		Predicted				
		Hidden Layer 1			Output Layer	
		H(1:1)	H(1:2)	H(1:3)	[Status=,00]	[Status=1,00]
Input Layer	(Bias)	8,801	,482	,009		
	[GUB=,00]	-8,008	-,141	-,016		
	[GUB=1,00]	,523	-,349	,249		
	[GUB=2,00]	16,098	,383	-,215		
	KVF	-1,946	-,258	,001		
	ROA	-15,711	,078	,423		
	SUM	8,225	-,422	-,354		
Hidden Layer 1	(Bias)				,054	,134
	H(1:1)				16,835	-16,581
	H(1:2)				,477	-,202
	H(1:3)				-,015	,144

Izvor: Izrada autora u SPSS-u


Tablica 75: Klasifikacijska tablica – Mađarska

Classification				
Sample	Observed	Predicted		
		Active (insolvency proc.)	Active	Percent Correct
Training	Active (insolvency proc.)	9	0	100,0%
	Active	0	10	100,0%
	Overall Percent	47,4%	52,6%	100,0%
Testing	Active (insolvency proc.)	2	0	100,0%
	Active	0	2	100,0%
	Overall Percent	50,0%	50,0%	100,0%

Dependent Variable: Status

Izvor: Izrada autora u SPSS-u

Prema klasifikacijskoj tablici vidi se da je 100% poduzeća točno klasificirano prema uzorku za treniranje što korespondira postotku pogreške od 0% u tablici 73. Prema uzorku za testiranje točno je klasificirano isto tako 100% poduzeća što korespondira postotku pogreške od 0% što se vidi u tablici 73.



Slika 11: Krivulja ROC – Mađarska

Izvor: Izrada autora u SPSS-u

Tablica 76: Površina ispod ROC krivulje – Mađarska

Area Under the Curve	
	Area
Status Active (insolvency proc.)	1,000
Status Active	1,000

Izvor: Izrada autora u SPSS-u


Površina ispod ROC krivulje mjeri vjerojatnost, odnosno sposobnost neuronskih mreža da točno klasificira poduzeća na ona koja su aktivna i ona koja su aktivna ali u procesu stečaja. U ovom primjeru vjerojatnost je 100% što znači da je model izvrstan. Isto se vidi i prema grafičkom prikazu ROC krivulje.

Tablica 77: Prikaz važnosti nezavisnih varijabli – Mađarska

Independent Variable Importance		
	Importance	Normalized Importance
GUB	,292	74,4%
KVF	,171	43,6%
ROA	,392	100,0%
SUM	,145	37,0%

Izvor: Izrada autora u SPSS-u

Prema tablici 77. vidi se da je varijabla sa najvećom važnosti, odnosno ona koja najviše utječe na uspješnost točne klasifikacije poduzeća koeficijent povrat na imovinu. Važnost ove varijable iznosi 0.392, odnosno normalizirana važnost 100%.



Slika 12: Grafički prikaz važnosti nezavisnih varijabli – Mađarska

Izvor: Izrada autora u SPSS-u

Nakon provedenih analiza binarne logističke regresije i neuronskih mreža, slijedi analiza postavljenih hipoteza:

Hipoteza 1: „*Na bazi računovodstvenih informacija i financijskih pokazatelja moguće je oblikovati efikasan model za predviđanje bankrota poduzeća.*“

Temelj klasifikacije poduzeća na aktivna poduzeća i aktivna u procesu stečaja su računovodstvene informacije. Na bazi računovodstvenih informacija izračunati su financijski pokazatelji i nefinancijski pokazatelji poput gubitka poslovne godine, sume neto dobiti, te razlike između ukupne imovine i ukupnih obveza. Temeljem tih informacija provedena je analiza putem metode binarne logističke regresije koja je pokazala izvrstan rezultat, kao i metoda neuronskih mreža. Konačna uspješnost klasifikacije pomoću metode neuronskih mreža izračunata je kao prosjek dvaju rezultata klasificiranja, uzorka za treniranje i uzorka za testiranje.

Tablica 78: Točnost klasifikacije modela

Država	Binarna logistička regresija	Neuronske mreže
Hrvatska	90,6%	91,45%
Bosna i Hercegovina	100%	100%
Srbija	97%	94,3%
Mađarska	100%	100%

Izvor: Izrada autora

Kao što se vidi u prethodnoj tablici uspješnost predviđanja bankrota pomoću obje metode je od 90-100% što dokazuje da je moguće oblikovati efikasan model za predviđanje bankrota poduzeća temeljem računovodstvenih informacija i financijskih pokazatelja. Dakle, **hipoteza 1 se prihvaća.**

Hipoteza 2: „*Modeli za predviđanje bankrota po različitim državama razlikuju se po varijablama i točnosti predviđanja.*“

Prema tablici 78. se vidi kako se modeli za predviđanje bankrota ne razlikuju mnogo po točnosti predviđanja, svaki model je vrlo uspješan u predviđanju bankrota s uspješnosti koja se kreće između 90 i 100%. Što se tiče varijabli kao što se vidi u tablici 79. modeli se bitno ne razlikuju. Naime modeli za Bosnu i Hercegovinu, Srbiju i Mađarsku ne razlikuju se prema varijablama, odnosno sastoje se od istih varijabli, a to su koeficijent vlastitog financiranja, povrat na imovinu, gubitak poslovne godine, te suma neto dobiti. Dok se model za Hrvatsku

razlikuje samo u jednoj varijabli, a to je koeficijent tekuće likvidnosti. Stoga se **hipoteza 2 odbacuje**.

Tablica 79: Varijable korištene u modelima po državama

	Hrvatska	Bosna i Hercegovina	Srbija	Mađarska
Varijable	Koeficijent vlastitog financiranja	Koficijent vlastitog financiranja	Koeficijent vlastitog financiranja	Koeficijent vlastitog financiranja
	Koeficijent tekuće likvidnosti	Povrat na imovinu	Povrat na imovinu	Povrat na imovinu
	Gubitak poslovne godine	Gubitak poslovne godine	Gubitak poslovne godine	Gubitak poslovne godine
	Suma neto dobiti	Suma neto dobiti	Suma neto dobiti	Suma neto dobiti

Izvor: Izrada autora

Hipoteza 3: „*Alternativne metode za predviđanje bankrota dovode do različitih rezultata.*“

U ovom radu pod alternativnom metodom smatraju se neuronske mreže. Kao što se vidi u tablici 78. rezultati klasifikacije su izvrsni kod obje metode. U slučaju Hrvatske uspješnost modela korištenjem binarne logističke regresije iznosila je 90,6% dok je uspješnost korištenjem neuronskih mreža iznosila 91,45%. Dakle u slučaju Hrvatske nešto bolji rezultat daju neuronske mreže. Model predviđanja bankrota u slučaju Bosne i Hercegovine korištenjem binarne logističke regresije i neuronskih mreža dao je jednaku uspješnost u predviđanju bankrota od 100%. U slučaju Srbije binarna logistička regresija dala je uspješnost od 97%, dok je neuronska mreža ispravno klasificirala 94,3% poduzeća. U ovom slučaju se vidi da je nešto bolji rezultat dala binarna logistička regresija iako su oba modela izvrsna. Konačno, kod Mađarske binarna logistička regresija pružila je točnost predviđanja od 100% kao i neuronska mreža. Stoga se može reći kako alternativne metode, odnosno neuronske mreže ne dovode do bitno različitih rezultata. U slučaju Bosne i Hercegovine te Mađarske uspješnost modela je jednaka, dok u slučaju Hrvatske te Srbije razlika je neznatna. Dakle **hipoteza 3 se odbacuje**.

4. ZAKLJUČAK

Financijska kriza i recesija su, kako u svijetu, tako i kod nas, uzrokovale bankrot mnogih poduzeća. Dinamično tržišno okruženje, te mnogobrojna konkurencija uvelike otežavaju borbu za uspjeh poduzeća i zauzimanje svog tržišnog udjela. Uz neispunjavanje obveza dobavljačima i nedospjela potraživanja kupaca, mogućnost uspješnog predviđanja poslovnog neuspjeha poduzeća pomaže u donošenju relevantnih odluka.

Započeto Beaverovim istraživanjem 60-ih godina prošlog stoljeća, predviđanje bankrota poduzeća postaje česta tema mnogih istraživanja i znanstvenih radova. I dalje je u tom području najuspješniji i najutjecajniji Altman sa svojim modelom predviđanja bankrota poduzeća iz 1968. godine. Situacija u Hrvatskoj i okolnim zemljama nije dala mnogo znanstvenih radova na tu temu. Razlog tome je što je u Hrvatskoj tek 2008. godine započeta obveza javne objave financijskih izvještaja poduzeća. Dakle bilo je teško doći do računovodstvenih informacija koje su se u dotadašnjim istraživanjima pokazale kao temelj za uspješno oblikovanje modela za predviđanje bankrota.

Mnogobrojna dosadašnja istraživanja na ovu temu dala su različite rezultate, odnosno klasifikacijsku točnost. Ta točnost ovisi o brojnim faktorima, poput veličine uzorka, djelatnosti poduzeća, odnosno grani industrije iz koje poduzeće potječe, zatim vrstama korištenih statističkih metoda, pa sve do broja i vrsti varijabli, odnosno financijski i nefinancijskih pokazatelja.

Cilj ovog istraživanja je odrediti optimalan model za predviđanje bankrota u Hrvatskoj, Bosni i Hercegovini, Srbiji i Mađarskoj. Računovodstvene informacije iz bilance i računa dobiti i gubitka za 2012. i 2013. godinu preuzeti su iz baze podataka „Amadeus“. Na temelju tih računovodstvenih informacija i korištenjem dviju statističkih metoda, binarne logističke regresije i neuronskih mreža, došlo se do odličnih rezultata. Binarna logistička regresija dala je izvrstan rezultat za sve četiri države s uspješnosti klasifikacije od 90,6% za poduzeća iz Hrvatske, 100% za poduzeća iz Bosne i Hercegovine, 97% za poduzeća iz Srbije, te 100% za poduzeća iz Mađarske. Metoda neuronskih mreža je i dalje diskutabilna u primjeni predviđanja bankrota, no u ovom radu dala je izvrsne rezultate: 91,45% za poduzeća iz Hrvatske, 100% za poduzeća iz Bosne i Hercegovine, 94,3% za poduzeća iz Srbije, te 100% za poduzeća iz Mađarske.

Na kraju dolazi se do zaključka kako iako su neuronske mreže bile vrlo uspješne, nisu u potpunosti dale bolje rezultate od binarne logističke regresije. No, ovim radom dobivena su 4 uspješna modela za sve države i to na temelju obje metode, dakle s izvrsnim rezultatima. Računovodstvene informacije financijske i nefinancijske i dalje pružaju najbolji temelj za uspješno predviđanje bankrota poduzeća.

SAŽETAK

Ključne riječi: Bankrot, Predviđanje, Hrvatska

Tema mnogobrojnih znanstvenih radova i istraživanja predviđanje je bankrota poduzeća. Njihova uspješnost je od velikog značaja i za praksu posebno u današnjim trenucima financijske krize i dinamičnog tržišnog okruženja. U ovom radu oblikovani su modeli predviđanja bankrota poduzeća za Hrvatsku, Bosnu i Hercegovinu, Srbiju i Mađarsku na temelju računovodstvenih informacija iz financijskih izvještaja za 2012. i 2013.godinu. Podaci su preuzeti iz baze podataka „Amadeus“. Za svaku su zemlju poduzeća uparena s obzirom na djelatnost, te veličinu poduzeća, odnosno veličinu prihoda i imovine. Uzorak poduzeća za Hrvatsku sastojao se od 676 poduzeća, odnosno 338 parova poduzeća na temelju kojih su izračnati omjeri, te je provedena metoda binarne logističke regresije sa uspjehom klasifikacije poduzeća od 90,6%. Također je provedena metoda neuronskih mreža korištenjem algoritma „višeslojni perceptron“, te je dobivena još bolja uspješnost klasifikacije od 91,45%. Uzorak poduzeća za Bosnu i Hercegovinu se sastojao od 11 parova poduzeća, odnosno ukupno 22 poduzeća te je putem binarne logističke regresije, te neuronskih mreža dobivena uspješnost klasifikacije poduzeća od 100%. Uzorak poduzeća za Srbiju sastojao se od 68 poduzeća, odnosno 34 para poduzeća. Temeljem najsignifikantnijih računovodstvenih omjera putem binarne logističke regresije dobivena je točnost klasifikacije od 97%, što je bolji rezultat u odnosu na rezultat dobiven korištenjem neuronskih mreža koji je iznosio 94,3%. Uzorak poduzeća za Mađarsku sastojao se od 34 poduzeća ukupno, odnosno 12 poduzeća parova, te je na temelju financijskih pokazatelja korištenjem binarne logističke regresije, te neuronskih mreža postignuta savršena klasifikacija od 100%. Uspješno predviđanje bankrota moguće je ostvariti korištenjem obiju metoda gdje su razine točnosti za sve modele iznimno visoke što znači da je moguće izraditi efikasan model na temelju računovodstvenih informacija.

SUMMARY

Keywords: Bankruptcy, Prediction, Croatia

Bankruptcy prediction is a topic of numerous scientific papers and research. Successful bankruptcy prediction is of great importance for every-day practice, especially considering the financial crisis and dynamic market environment. In this paper models for bankruptcy prediction have been designed for Croatia, Bosnia and Herzegovina, Serbia and Hungary based on accounting information from financial statements from 2012. and 2013. Data was taken from the „Amadeus“ database. Companies were paired for each country, based on their business activities and the size of the company, or size of the operating revenue and total assets. Sample for Croatia consisted of 676 companies, or 338 paired companies on the basis of which ratios have been computed and a binary logistic regression has been conducted with the classification success of 90,6%. Also, the method of neural networks was conducted using multilayer perceptron which gave an even better performance in classification of 91,45%. Sample for Bosnia and Herzegovina consisted of 11 paired companies, or 22 companies in total following the use of binary logistic regression and neural network which gave a success in classification of 100%. Sample for Serbia consisted of 68 companies, or 34 paired companies. Based on the most significant accounting ratios using binary logistic regression classification accuracy of 97% has been obtained, which is a better result compared to the one obtained using neural network which amounted to 94,3%. Sample model for Hungary consisted of 34 companies, or 12 paired companies and, based on accounting ratios using binary logistic regression and neural networks, a perfect classification of 100% was achieved. Successful bankruptcy prediction can be achieved using binary logistic regression and neural networks where the level of accuracy for all models is extremely high, which means that it is possible to create an efficient model based on accounting information.

LITERATURA

1. Altman, E.I. (1968): Financial ratios, discriminant analysis and the prediction of corporate bankruptcy, *The Journal of Finance*, Vol.XXIII, No.4, str. 589-609.
2. Alfaro, E., et al. (2008): Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks, *Decision Support Systems* 45, Elsevier Ltd., str. 1846-1853.
3. Aljinović Barać, Ž. (2014): Računovodstvo novčanih tijekova, autorski materijal, akademska godina 2013/14, Ekonomski fakultet Split, Split
4. Aljinović Barać, Ž. (2008): Doktorska disertacija: Model procjene uspješnosti tvrtke na temelju pokazatelja novčanog tijeka, Ekonomski fakultet, Split
5. Baixauli, J.S., Modica-Milo, A. (2010): The bias of unhealthy SMEs in bankruptcy prediction models, *Journal of Small Business and Enterprise Development*, Vol. 17, No.1, Emerald Group Publishing Limited, str. 60-77
6. Balcaen, S., Ooghe, H. (2006): 35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems, *The British Accounting Review* 38, str. 63-93.
7. Beaver, W.H. (1966): Financial ratios as predictors of failure, *Journal of Accounting Research*, str. 71-111.
8. Belak, V., Vudrić, N. (2012): Osnove suvremenog računovodstva, Belak Excellens d.o.o., Zagreb
9. Bhargava, M., et al. (1998): Predicting bankruptcy in the retail sector: an examination of the validity of key measures of performance, *Journal of Retailing and Consumer Services*, Vol. 5, No.2, str. 105-117.
10. Carter, R., Van Auken, H. (2006): Small Firm Bankruptcy, *Journal of Small Business Management* 44, str. 493-512.
11. Chauhan, N., et al. (2009): Differential evolution trained wavelet neural networks: Application to bankruptcy prediction in banks, *Expert Systems with Applications* 36, Elsevier Ltd., str. 7659-7665.
12. Chen, H.J., et al. (2009): Alternative diagnosis of corporate bankruptcy: A neuro fuzzy approach, *Expert Systems with Applications* 36, Elsevier Ltd., str. 7710-7720.
13. Cybinski, P. (2001): Description, Explanation, Prediction – The Evolution of Bankruptcy Studies?, *Managerial Finance*, Vol.27, No.4, str. 29-44.

14. Deakin, E.B. (1972): A Discriminant Analysis of Predictors of Business Failure, *Journal of Accounting Research*, str. 167-179.
15. Dumančić, S. (2014): Diplomski rad: Neuronske mreže, Sveučilište Josipa Jurja Strossmayera u Osijeku, Osijek, str. 26
16. Hall, G. (1992): Reasons for Insolvency Amongst Small Firms — A Review and Fresh Evidence, *Small Business Economics* 4, Kluwer Academic Publishers, str. 237-250.
17. Ivičić, L., Cerovac, S. (2009): Procjena kreditnog rizika poduzeća u Hrvatskoj, *Financijska teorija i praksa* 33 (4), str. 385-413.
18. Kim, M.J., Kang, D.K. (2010): Ensemble with neural networks for bankruptcy prediction, *Expert Systems with Applications* 30, Elsevier Ltd., str. 3373-3379.
19. Kuruppu, N., Laswad, F., Oyelere, P. (2003): The efficacy of liquidation and bankruptcy prediction models for assessing going concern, *Managerial Auditing Journal*, str. 577-590.
20. Lee, K., et al. (2005): A comparison of supervised and unsupervised neural networks in predicting bankruptcy of Korean firms, *Expert Systems with Applications* 29, Elsevier Ltd., str. 1-16.
21. Lee, S., Choi, W.S. (2013): A multi-industry bankruptcy prediction model using back-propagation neural network and multivariate discriminant analysis, *Expert Systems with Applications* 40, Elsevier Ltd., str. 2941-2946.
22. Lund Research Ltd (2015): Laerd Statistics, Binominal Logistic Regression using SPSS Statistics. Dostupno na: <https://statistics.laerd.com/spss-tutorials/binomial-logistic-regression-using-spss-statistics.php> [2.5.2016.]
23. Min, J.H., Jeong, C. (2009): A binary classification method for bankruptcy prediction, *Expert Systems with Applications* 36, Elsevier Ltd., str. 5256-5263.
24. Narodne novine (2009): Međunarodni računovodstveni standard 1: Prezentiranje financijskih izvještaja, Narodne novine d.d., broj 136
25. Narodne novine (2007): Zakon o računovodstvu, Narodne novine d.d., broj 109,121
26. Narodne novine (2008): Hrvatski standardi financijskog izvještavanja, Narodne novine d.d., broj 30
27. Novak, B. (2003): Predviđanje poslovnih teškoća banaka u Republici Hrvatskoj na osnovi javno dostupnih financijskih pokazatelja, Ekonomski fakultet Sveučilišta u Osijeku, Osijek
28. Novaković, B., et al. (1998): Umjetne neuronske mreže, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, str. 1-8

29. Ohlson, R. (1980): Financial Ratios and the Probabilistic Prediction of Bankruptcy, *Journal of Accounting Research*, Spring, Vol. 18, No. 1, str. 110
30. Pervan, I., Pervan, M., Vukoja, B. (2011): Prediction of company bankruptcy using statistical techniques – Case of Croatia, *Croatian Operational Research Review (CRORR)*, Vol.2, str. 158-167.
31. Pervan, I., Kuvek, T. (2013): The relative importance of financial ratios and nonfinancial variables in predicting of insolvency, *Croatian Operational Research Review (CRORR)*, Vol.3, str. 187-197.
32. Pervan, I., Filipović, D. (2010): „FP rating – Model za predviđanje (in)solventnosti poslovnih partnera“, *RRIF* br. 7, str. 92-96.
33. Pivac, S. (2010): Statističke metode, e-nastavni materijal, *Ekonomski fakultet u Splitu*, Split, str. 253
34. Pompe, P.P.M., Bilderbeek, J. (2005): The prediction of bankruptcy of small- and medium-sized industrial firms, *Journal of Business Venturing* 20, str. 847-868.
35. Skupina autora (2010): *Računovodstvo poduzetnika*, *RRIF-plus d.o.o.*, Zagreb
36. Šarlija, N., et al. (2009): Predviđanje nelikvidnosti poduzeća u Hrvatskoj, *Zbornik Ekonomskog fakulteta u Zagrebu*, godina 7, br. 2, str. 33
37. TEB-poslovno savjetovanje (2011): *Međunarodni standardi financijskog izvještavanja*, prijevod s engleskog jezika, *Tiskara Zelina d.d.*, Zagreb
38. Tsai, C.F., Wu, J.W. (2008): Using neural network ensembles for bankruptcy prediction and credit scoring, *Expert Systems with Applications* 34, Elsevier Ltd., str. 2639-2649.
39. Tsakonas, A., et al. (2006): Bankruptcy prediction with neural logic networks by means of grammar-guided genetic programming, *Expert Systems with Applications* 30, Elsevier Ltd., str. 449-461.
40. Tseng, F.M., Hu, Y.C. (2010): Comparing four bankruptcy prediction models: Logit, quadratic interval logit, neural and fuzzy neural networks, *Expert Systems with Applications* 37, Elsevier Ltd., str. 1846-1853.
41. Zenzerović, R. (2009): Business financial problem prediction – Croatian experience, *Economic Research – Ekonomska istraživanja* 22.4., 1-15, str. 8
42. Žager, K., et al. (2008): *Analiza financijskih izvještaja*, *Masmedia d.o.o.*, Zagreb

POPIS TABLICA:

Tablica 1: Nazivi financijskih izvještaja prema novom MRS-u 1	9
Tablica 2: Razvrstavanje poduzetnika prema Zakonu o računovodstvu.....	10
Tablica 3: Shema bilance u RH.....	11
Tablica 4: Primjeri novčanih tokova od poslovnih aktivnosti.....	14
Tablica 5: Primjeri novčanih tokova od investicijskih aktivnosti	14
Tablica 6: Primjeri novčanih tokova od financijskih aktivnosti.....	15
Tablica 7: Pokazatelji likvidnosti	20
Tablica 8: Pokazatelji zaduženosti	21
Tablica 9: Pokazatelji aktivnosti	21
Tablica 10: Pokazatelji ekonomičnosti.....	22
Tablica 11: Pokazatelji profitabilnosti	22
Tablica 12: Pokazatelji investiranja	22
Tablica 13: Popis testiranih omjera	24
Tablica 14: Interval Z-scorea i vjerojatnosti bankrota	25
Tablica 15: Intervali Z' scorea i vjerojatnosti bankrota.....	26
Tablica 16: Omjeri Deakinova modela sa pripadajućim ponderima.....	27
Tablica 17: Opis financijskih pokazatelja korištenih u modelu	30
Tablica 18: Opis varijabli korištenih u modelu FP RATING®	31
Tablica 19: Značajni prediktori nelikvidnosti u Hrvatskoj prema modelu Šarlija et al.	34
Tablica 20: Opis varijabli u CGE ₁ modelu.....	35
Tablica 21: Financijski pokazatelji korišteni u istraživanju.....	38
Tablica 22: Rezultati testiranja nezavisnih uzoraka – Hrvatska	39
Tablica 23: Prikaz korelacija između varijabli – Hrvatska	41
Tablica 24: Vrijednost tolerancije i VIF-a – Hrvatska.....	41
Tablica 25: Omnibus test koeficijenata modela – Hrvatska.....	42
Tablica 26: Mjere prikladnosti modela – Hrvatska.....	42
Tablica 27: Hosmer-Lemeshow test – Hrvatska	42
Tablica 28: Prikaz varijabli i pripadajućih pondera – Hrvatska.....	43
Tablica 29: Klasifikacijska točnost modela – Hrvatska	43
Tablica 30: Broj uzoraka i njihova namjena – Hrvatska.....	44
Tablica 31: Informacije o mreži – Hrvatska.....	45
Tablica 32: Sažetak modela – Hrvatska	46

Tablica 33: Procjene parametara neuronske mreže – Hrvatska	48
Tablica 34: Klasifikacijska tablica – Hrvatska.....	48
Tablica 35: Površina ispod ROC krivulje – Hrvatska	49
Tablica 36: Prikaz važnosti nezavisnih varijabli – Hrvatska	50
Tablica 37: Rezultati testiranja nezavisnih uzoraka – Bosna i Hercegovina	51
Tablica 38: Prikaz korelacija između varijabli – Bosna i Hercegovina	52
Tablica 39: Vrijednost tolerancije i VIF-a – Bosna i Hercegovina.....	52
Tablica 40: Klasifikacijska točnost modela – Bosna i Hercegovina.....	54
Tablica 41: Broj uzoraka i njihova namjena – Bosna i Hercegovina.....	55
Tablica 42: Informacije o mreži – Bosna i Hercegovina.....	55
Tablica 43: Sažetak modela – Bosna i Hercegovina	56
Tablica 44: Procjene parametara neuronske mreže – Bosna i Hercegovina	58
Tablica 45: Klasifikacijska tablica – Bosna i Hercegovina.....	58
Tablica 46: Površina ispod ROC krivulje – Bosna i Hercegovina	59
Tablica 47: Prikaz važnosti nezavisnih varijabli – Bosna i Hercegovina	60
Tablica 48: Rezultati testiranja nezavisnih uzoraka – Srbija	61
Tablica 49: Prikaz korelacija između varijabli – Srbija	62
Tablica 50: Vrijednost tolerancije i VIF-a – Srbija.....	62
Tablica 51: Omnibus test koeficijenata modela – Srbija.....	63
Tablica 52: Mjere prikladnosti modela – Srbija.....	63
Tablica 53: Hosmer-Lemeshow test – Srbija	63
Tablica 54: Prikaz varijabli i pripadajućih pondera – Srbija.....	64
Tablica 55: Klasifikacijska točnost modela – Srbija.....	64
Tablica 56: Broj uzoraka i njihova namjena – Srbija.....	65
Tablica 57: Informacije o mreži – Srbija	65
Tablica 58: Sažetak modela – Srbija	66
Tablica 59: Procjene parametara neuronske mreže – Srbija	68
Tablica 60: Klasifikacijska tablica – Srbija.....	68
Tablica 61: Površina ispod ROC krivulje – Srbija.....	69
Tablica 62: Prikaz važnosti nezavisnih varijabli – Srbija	70
Tablica 63: Rezultati testiranja nezavisnih uzoraka – Mađarska	71
Tablica 64: Prikaz korelacija između varijabli – Mađarska	72
Tablica 65: Vrijednost tolerancije i VIF-a – Mađarska.....	72
Tablica 66: Omnibus test koeficijenata modela – Mađarska	73

Tablica 67: Mjere prikladnosti modela – Mađarska.....	73
Tablica 68: Hosmer-Lemeshow test – Mađarska	73
Tablica 69: Prikaz varijabli i pripadajućih pondera – Mađarska	74
Tablica 70: Klasifikacijska točnost modela – Mađarska.....	74
Tablica 71: Broj uzoraka i njihova namjena – Mađarska.....	75
Tablica 72: Informacije o mreži – Mađarska	75
Tablica 73: Sažetak modela – Mađarska.....	76
Tablica 74: Procjene parametara neuronske mreže – Mađarska	78
Tablica 75: Klasifikacijska tablica – Mađarska	78
Tablica 76: Površina ispod ROC krivulje – Mađarska.....	79
Tablica 77: Prikaz važnosti nezavisnih varijabli – Mađarska	80
Tablica 78: Točnost klasifikacije modela.....	81
Tablica 79: Varijable korištene u modelima po državama.....	82

POPIS SLIKA:

Slika 1: Grafički prikaz izgleda arhitekture neuronske mreže – Hrvatska.....	47
Slika 2: Krivulja ROC – Hrvatska.....	49
Slika 3: Grafički prikaz važnosti nezavisnih varijabli – Hrvatska	50
Slika 4: Grafički prikaz izgleda arhitekture neuronske mreže – Bosna i Hercegovina.....	57
Slika 5: Krivulja ROC – Bosna i Hercegovina	59
Slika 6: Grafički prikaz važnosti nezavisnih varijabli – Bosna i Hercegovina.....	60
Slika 7: Grafički prikaz izgleda arhitekture neuronske mreže – Srbija.....	67
Slika 8: Krivulja ROC – Srbija	69
Slika 9: Grafički prikaz važnosti nezavisnih varijabli – Srbija.....	70
Slika 10: Grafički prikaz izgleda arhitekture neuronske mreže – Mađarska	77
Slika 11: Krivulja ROC – Mađarska	79
Slika 12: Grafički prikaz važnosti nezavisnih varijabli – Mađarska.....	80