

# Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stečaja u Republici Hrvatskoj

## Testing the applicability of the Altman's Z-score model for predicting bankruptcy in the Republic of Croatia

### Sažetak

Altman Z-score jedan je od najpoznatijih modela za predviđanje poslovnih poteškoća odnosno stečaja. Cilj ovog rada je testirati Altmanov Z-score model i utvrditi u kojoj je mjeri primjenjiv u predviđanju stečaja u Republici Hrvatskoj. Testirani ukupni uzorak sa Zagrebačke burze sastojao se od 52 poslovna subjekta, od čega 26 koji su otvorili stečaj i 26 sa stabilnim poslovanjem, te je isti promatrano u ukupnom vremenskom razdoblju 2007.-2016. Budući da se testirani uzorak sastojao i od poslovnih subjekata koji ne pripadaju proizvodnom sektoru, u istraživanju je korišten Altmanov revidirani Z"-score model. Osim testiranja uspješnosti istog, u radu su se nastojali prilagoditi ponderi Z"-score modela primjenom višestruke diskriminantne analize u cilju dobivanja modela koji će biti prilagođeniji hrvatskom tržištu. Radi prisutnosti multikolinearnosti nisu sve varijable zadržane u modelu, te je dobiven model koji ima slabiju uspješnost od Z"-score modela. Rezultati ovog istraživanja ukazuju da je Altmanov Z"-score primjenjiv na hrvatskom tržištu, ali se preporuča koristiti ga kao dodatni, a nikako kao osnovni pokazatelj za predviđanje stečaja.

**Ključne riječi:** finansijska analiza, poslovni neuspjeh, bankrot, stabilno poslovanje, finansijski pokazatelji

**JEL klasifikacija:** G32; G33

### Abstract

Altman's Z-score model is one of the well-known financial ratios whose purpose is reflected in the possibility of predicting bankruptcy for businesses. The aim of this paper was to test Altman's Z-score model in order to determine whether the model is applicable in the bankruptcy forecasting on the example of Croatian companies. The analysed and tested sample from the Zagreb Stock Exchange was consisted of 52 companies which were divided into two samples: 26 companies which were financially stable and 26 companies that went bankrupt. Sample was observed over the time period 2007–2016 and it was consisted of businesses that do not belong only to the manufacturing sector, therefore it was used Altman's revised Z"-score model. Beside analysing its performance, authors in this paper tried to adjust the weights of the Z"-score model by applying multiple discriminant analysis in order to obtain a model that would be more tailored to the Croatian market. Due to the presence of multicollinearity, not all variables could be retained, and a model with lower performance was obtained. The results of this research indicates that Altman's Z"-score is applicable in the Croatian market, but it is recommended to use it only as an additional, not basic indicator for predicting bankruptcy.

**Keywords:** financial analysis, business failure, bankruptcy, financial stability, financial indicators

**JEL classification:** G32; G33

Doc. dr. sc. **Siniša Bogdan**

Fakultet za menadžment u turizmu i ugostiteljstvu Sveučilišta u Rijeci  
E-mail: sinisab@fthm.hr

Doc. dr. sc. **Suzana Bareša**

Fakultet za menadžment u turizmu i ugostiteljstvu Sveučilišta u Rijeci  
E-mail: suzanab@fthm.hr

**Velimir Hadina, mag. oec.**

Fakultet za menadžment u turizmu i ugostiteljstvu Sveučilišta u Rijeci  
E-mail: velimir.hadina@gmail.com

Asst. prof. **Siniša Bogdan, PhD**

Faculty of Tourism and Hospitality Management, University of Rijeka  
E-mail: sinisab@fthm.hr

Asst. prof. **Suzana Bareša, PhD**

Faculty of Tourism and Hospitality Management, University of Rijeka  
E-mail: suzanab@fthm.hr

**Velimir Hadina, MSc**

Faculty of Tourism and Hospitality Management, University of Rijeka  
E-mail: velimir.hadina@gmail.com

## 1. Uvod

Predviđanje poslovnih poteškoća i stečaja poslovnih subjekata u znanstvenim krugovima, poslovnom svijetu, te u javnosti općenito, posljednjih 50-ak godina pobuduje sve veći interes i pozornost. Mogu li se i kako unaprijed uočiti nadolazeće finansijske teškoće, može li se sa sigurnošću predviđjeti stečaj poslovnog subjekta kao događaj u budućnosti? Takva i slična pitanja otvarala su istraživačke horizonte i poticala razne znanstvene rasprave i istraživanja na ovu temu. Značajniji korak u istraživanju ove problematike postigao je Altman (1968.) koji je u traženju odgovora o mogućnosti predviđanja nadolazećih poslovnih poteškoća ponudio model Z-score, što je pobudilo interes velikog broja znanstvenika koji su nastojali razviti što uspješniji model koji omogućava testiranje vjerojatnosti nastanka stečaja poslovnog subjekta. U modelima za predviđanje stečaja istraživači su nastojali implementirati niz statističkih i matematičkih metoda i uključiti one varijable koje su smatrali signifikantnim za predviđanje stečaja, odnosno čijom bi se kombinacijom postiglo što preciznije predviđanje. „Mnoge su studije bile posvećene potrazi za najboljim modelom korporativnog predviđanja koji se temelji na javno dostupnim podacima i statističkim tehnikama“ (Ooghe i sur, 2009:7).

Originalni Altmanov Z-score model (1968.) stvoren za potrebe američkog tržišta prvo je bio namijenjen poslovnim subjektima koji kotiraju na burzi, te se nalaze unutar sektora proizvodnje. Kasnijim revidiranjem originalnog modela konstruiran je Z-score model (1983.) namijenjen poslovnim subjektima koji ne kotiraju na burzi, te Z'-score model (1983.) koji je namijenjen analizi poslovnih subjekata izvan sektora proizvodnje. Budući da je navedeni model pozitivno prihvaćen od strane akademske zajednice, a i privatnog sektora cilj ovog istraživanja, za razliku od dosadašnjih istraživanja bio je testirati uspješnost Altmanovog Z'-score modela koji je prilagođen poslovnim subjektima koji nisu nužno unutar proizvodnog sektora. Osim navedenog cilja, u radu će se nastojati korištenjem originalne metodologije (višestruke diskriminante analize) prilagoditi pondere Z'-score modela (zadržavajući pritom iste varijable) kako bi se dobio model

prilagođeniji hrvatskom tržištu.

Slična istraživanja vezana uz provjeravanje uspješnosti predviđanja Altmanovim modelom provedena su na primjeru poslovnih subjekata u Jordanu (Alareeni i Branson, 2013.), Pakistanu (Hussain i sur, 2014.), Italiji (Celli, 2015.), te su potaknula autore u ovome radu da također odgovore na pitanje može li se Altmanov Z-score model primijeniti kao instrument za predviđanje stečaja i u kojoj mjeri se može ocijeniti njegova pouzdanost. Aktualnost i relevantnost navedene problematike proizlazi i iz trenutno loše situacije unutar privatnog sektora Republike Hrvatske. Naime, prema posljednjim podacima hrvatske finansijske agencije (FINA, 2019.) od srpnja 2019. godine, ukupan iznos neizvršenih osnova za plaćanje poslovnih subjekata u Hrvatskoj iznosi je gotovo 6,2 milijarde kuna, što upućuje na visok iznos sredstava temeljem kojega su otvoreni ili će u budućnosti biti otvoreni novi stečajevi.

U životnom ciklusu poslovnog subjekta izmjenjuju se pozitivna (uspješna) i negativna (neuspješna) razdoblja, međutim „kad se negativno razdoblje prebaci s privremenog na strukturno i kronično (i tako se nastavlja s vremenom), tvrtka je često osuđena bankrotirati“ (Altman i sur., 2013.). Stvaranje modela koji bi mogao pravodobno signalizirati finansijske poteškoće i predviđjeti vjerojatnost stečaja poslovnog subjekta od velike je važnosti za detekciju problema, kao i za otvaranje mogućnosti pravodobnog poduzimanja mera i aktivnosti kako bi se smanjile i/ili sprječile njegove posljedice.

Rad je, uz uvod i zaključak, podijeljen u tri glavna poglavљa. U drugom poglavljju rada dan je pregled najvažnijih dosadašnjih istraživanja na temu predviđanja stečaja poslovnih subjekata, posebice onih u Hrvatskoj, te su definirani svi postojeći oblici Altmanovog pokazatelja. U trećem poglavljju objašnjena je i prikazana metodologija provođenja istraživanja, te su definirani podaci temeljem kojih je provedeno istraživanje. Shodno cilju istraživanja, nakon ispitivanja primjenjivosti i ispravnosti predviđanja stečaja primjenom Altmanovog Z'-score modela na primjeru poslovnih subjekata u Hrvatskoj, u četvrtom dijelu su iznijeti rezultati i nalazi istraživanja, jednako kao i rezultati dobiveni temeljem višestruke diskriminantne analize nakon

prilagodbe pondera na Z"-score modelu u cilju dobivanja prilagođenijeg modela za hrvatsko tržište. U završnom dijelu slijede sintetizirani stavovi autora o primjenjivosti Altmanove metodologije na primjeru hrvatskih poslovnih subjekata, uz navođenje ograničenja istraživanja i preporuke za buduća istraživanja.

## 2. Dosadašnja istraživanja

Problematika predviđanja poslovnog neuspjeha i traženje modela koji sa što većom vjerojatnošću predviđa finansijske poteškoće poslovnih subjekata razvija se od kasnih 60-tih godina, te se i danas mnoga istraživanja bave ovom problematikom. Sam razvoj predviđanja stečaja poslovnih subjekata pojavio se na prijelazu iz 19. u 20. stoljeće s korištenim jednim pokazateljem, da bi krajem 60-ih godina bila objavljena istraživanja koja su tezu mogućnosti predviđanja stečaja opravdavali s nekoliko finansijskih pokazatelja.

Početkom 20. stoljeća primjenjeni su prvi ekonometrijski pokazatelji predloženi za opisivanje predviđanja poslovnog neuspjeha što je predstavljalo prve pokušaje formalnog predviđanja stečaja. Tada su razvijeni modeli koji su služili kao pomoć bankama u donošenju odluka hoće li odobriti ili odbiti zahtjeve za kredit (Ramser i Foster, 1931.; Fitzpatrick, 1932.; Winakor i Smith, 1935.; Wall, 1936.).

Prva studija o predviđanju poslovnih teškoća upotrebom finansijskih pokazatelja objavljena je 1942. godine od strane Charles L. Merwina, te se smatrala najboljom studijom do 60-tih godina 20. st., odnosno do istraživanja Beavera (1966.). Navedena studija donijela je prekrenicu u istraživanju ranog prepoznavanja simptoma poslovnog neuspjeha i evoluciju modela predviđanja stečaja. Beaver je proučavao stečaj 79 poslovnih subjekata koja su bankrotirala unutar vremenskog razdoblja 1954.–1964., a čiji su finansijski izvještaji bili dostupni godinu dana prije bankrota. Navedenih 79 poslovnih subjekata bilo je raspoređeno prema SIC-u (eng. *Standard Industrial Classification*) u 38 različitih industrijskih grana. Poslovnim subjektima koji su bankrotirali prema industrijskoj grani u veličini, upareni su poslovni subjekti sličnih karakteristika koji imaju stabilno poslovanje kako bi se univarijatnom analizom ispitala prediktivna

moć finansijskih pokazatelja. Njegov rad smatra se jednim od najznačajnijih radova koji proučava problematiku predviđanja vjerojatnosti finansijskih teškoća, odnosno vjerojatnosti poslovnog neuspjeha i stečaja.

Rane studije koje su se odnosile na analizu omjera za predviđanje stečaja bile su univarijatne studije, te su bile usmjerene na pojedinačne omjere i između ostalog uspoređivale su omjere neuspješnih poslovnih subjekata s uspjehšnim. „Univarijatne studije imale su važne implikacije za razvoj budućih modela s obzirom da su postavile temelje za multivarijatne modele predviđanja stečaja“ (Bellovary i sur, 2007:2).

Prvu multivarijatnu studiju objavio je Edward I. Altman (1968.), koji je koristio diskriminantnu analizu kako bi razvio pet-faktorski model za predviđanje stečaja proizvodnih poslovnih subjekata. Model koji je nazvao "Z-score", predviđao je stečaj ukoliko se dobiveni rezultat za analizirani poslovni subjekt nalazio ispod granične vrijednosti koja ukazuje na stečaj. Ovaj model imao je visoku sposobnost predviđanja stečaja. Analizirani uzorak godinu dana prije proglašenja istog imao je 95%-tnu točnost. Međutim, sposobnost ispravnog predviđanja znatno se smanjila s vremenskim pomakom, tako je iznosila 72% dvije godine prije proglašenja stečaja, 48%, 29% i 36% točnosti predviđanja za tri, četiri i pet godina prije stečaja. Uzorak na kojemu je Altman temeljio svoje istraživanje sastojao se od 66 poslovnih subjekata u sektoru proizvodnje. Uzorak je bio podijeljen u dvije skupine, odnosno 33 poslovna subjekta koja su bankrotirala i 33 finansijski stabilna poslovna subjekta. Poslovni subjekti koji su imali finansijske poteškoće, a nisu službeno otvorili stečaj – nisu bili uvršteni u promatrani uzorak. Višestrukom diskriminantnom analizom koja je izabrana kao odgovarajuća statistička tehniku odabранo je pet finansijskih pokazatelja koje je Altman smatrao najprikladnijim za predviđanje bankrota, odnosno stečaja poslovnog subjekta, stoga se i originalna rastuća diskriminantna funkcija zapisuje na sljedeći način:

$$Z = 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 + 1,0X_5$$

1

Bogdan, S., Bareša, S.,  
Hadina, V.

Testiranje primjenjivosti  
Altmanovog Z-score modela za  
predviđanje stečaja u Republici  
Hrvatskoj

Varijable su definirane na sljedeći način:

- X<sub>1</sub> Obртни капитал/ukupna imovina
- X<sub>2</sub> Zadržana dobit/ukupna imovina
- X<sub>3</sub> Dobit prije kamata i poreza/ukupna imovina
- X<sub>4</sub> Tržišna vrijednost kompanije  
knjigovodstvena vrijednost ukupnih obveza
- X<sub>5</sub> Prodaja/ukupna imovina

Granične vrijednosti Z-score modela bile su definirane na način da poslovni subjekti koji ostvaruje Z-score ispod granične vrijednosti 1,81 imaju visoki rizik bankrota dok oni koji ostvaruju koeficijent iznad vrijednosti 2,99 pripadaju skupini „zdravih“ odnosno finansijski stabilnih. „Sivoj zoni“ odnosno zoni nesigurnosti pripadaju poslovni subjekti čiji se Z-score nalazi unutar raspona vrijednosti 1,81 i 2,99. Kako se Z-score model pojavljuje u tri forme, osim već prikazanog baznog modela, u nastavku rada biti će predstavljene preostale dvije forme modela.

Budući da se je prethodno navedeni bazni Z-score model mogao primijeniti isključivo na poslovne subjekte koji se nalaze u proizvodnom sektoru, te čije dionice kotiraju na burzi, Edward I. Altman dalje razvija model i prikazuje revidirani Z-score (Caouette i sur., 2008:148) koji je imao mogućnost primjene na poslovne subjekte koji ne kotiraju na burzi. Navedeni model može se primijeniti na privatne poslovne subjekte budući da je u novom modelu modificirana varijabla X<sub>4</sub>, odnosno tržišna vrijednost kompanije supstituirana je s knjigovodstvenom vrijednošću kompanije. Budući da su i ponderi izmijenjeni, revidirani model je zaprimio sljedeću formu:

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

pripada tzv. „sivoj zoni“.

Treći model na osnovi kojeg se izračunava Z"-score namijenjen je privatnim poslovnim subjektima koji se mogu nalaziti i izvan proizvodnog sektora. Navedeni model ima sljedeći oblik:

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

3

Ukoliko je izračunata Z" vrijednost veća od 2,6 smatra se da je poslovni subjekt stabilan, a ukoliko se nalazi između 2,6 i 1,1 tada pripada „sivoj zoni“. Dakle, ne može se reći da je poslovni subjekt stabilan niti da je pred bankrotom, odnosno predstavlja granično područje između stabilnosti i bankrota. Ukoliko je Z" vrijednost manja od 1,1 tada se predviđa bankrot poslovnog subjekta. Navedeni pokazatelj imao je i dodatak formuli u iznosu +3,25 što je omogućavalo usporedbu rezultata modela s rezultatima rangiranja američkih obveznica. Svakako je nužno napomenuti da je riječ o modelu koji je namijenjen predviđanju stečaja za poslovne subjekte koji se nalaze na tržištima koja su u nastajanju, stoga se modelu često puta pripisuje kratica „EM-Score Model“ odnosno „Emerging Market Score Model“ Altman (1995.). Prilagođeni model zapisuje se na sljedeći način:

$$Z''' = 3,25 + 6,56X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4$$

4

Dobiveni rezultat vrijednosti Z''' score-a iznad 5,85 označava poslovne subjekte kao stabilne, dok „sivoj zoni“ predstavlja raspon između 5,85 i 4,35, a područje bankrota rezultat manji od vrijednosti 4,35.

Jedan od autora koji je obilježio proučavanje problematike predviđanja stečaja poslovnih subjekata je Edward B. Deakin (1972.). On je na uzorku od 64 poslovnih subjekata testirao 14 varijabli za predviđanje stečaja koristeći multivarijatnu diskriminantnu analizu. Autor u radu zaključuje da, iako je prediktivna mogućnost modela na visokih 90%, model bi trebalo koristiti s oprezom.

James Ohlson (1980.) u svome radu koristi logističku regresiju u cilju izbjegavanja problema

povezanih s multivarijatnom diskriminantnom analizom. Analizirajući 105 poslovnih subjekata koji su doživjeli bankrot i 2058 poslovnih subjekata koji imaju stabilno poslovanje, razvija nekoliko modela s visokim postotkom predviđanja bankrota (>90%).

Mark E. Zmijewski (1984.) u svome radu formira model za predviđanje bankrota na uzorku od 41 poslovnog subjekta koji su doživjeli bankrot i od 800 poslovnih subjekata sa stabilnim poslovanjem. U modelu uključene varijable mjere uspješnost poslovanja, zaduženost i likvidnost poslovnih subjekata.

Budući da je Altmanov Z-score jednako kao i problematika predviđanja stičaja bila predmetom mnogih drugih istraživanja, osim već navedenih autora, razvoju znanstvene spoznaje u ovom području pridonijeli su sljedeći autori: Edmister, 1972.; Wilcox, 1973.; Altman i McGough, 1974.; Blum, 1974.; Sinkey, 1975.; Libby, 1975.; Argenti, 1976.; Altman i Loris, 1976.; Altman i sur., 1977.; Martin, 1977.; Santomero i Vinso, 1977.; Ketz, 1978.; Pettway i Sinkey, 1980.; Taffler, 1982.; Lawrence i Bear, 1986.; Aziz i sur., 1988.; Koh i Killough, 1990.; Laitinen, 1991.; Flagg i sur., 1991.; Baldwin i Glezen, 1992.; Altman i Hotchkiss, 1993.; Rujoub i sur., 1995.; Shumway, 2001.; Hillegeist i sur., 2004.; kao i mnogi drugi.

Pregled istraživačkih radova vezanih uz proučavanje problematike stičaja, pojedinih autora od 1930-tih godina i rezultate do kojih su došli, prikazali su autori Bellovary i sur. (2007.), koji su naveli postojanje 165 studija predviđanja stičaja do 2004. godine, te Aziz i Dar (2006.) koji su temeljem analiziranih rezultata iz 46 članaka u kojima se izvještavalo o 89 empirijskih studija o predviđanju bankrota iznijeli detaljan pregled sažetaka prethodno korištenih istraživačkih metoda i nalaza tih istraživanja.

I u novijim radovima, brojni autori koriste Altmanov Z-score model u kontekstu predviđanja stičaja. Janda i Rakicova (2014.) u svome radu kompariraju bankrote u Češkoj, Srbiji, Slovačkoj i Hrvatskoj s ekonomsko i pravne perspektive. Temeljem međunarodnih studija autori zaključuju da je stičajni postupak pretrpo značajne promjene i pobjoljšao usvajanje novog zakona u sve četiri zemlje, te da je Češka najviše napredovala po

pitanju zakona o bankrotu. Altman i sur. (2014.) nastoje istražiti literaturu vezanu uz primjenu Altmanovog Z-score modela na globalnoj razini. Svoj pregled temelje na 33 znanstvena rada koja su objavljena u vodećim finansijskim i računovodstvenim časopisima. Autori također testiraju uspješnost originalne verzije Z-score modela u različitim zemljama koristeći različite statističke metode, te različite varijable. Autori zaključuju da Z-score model daje izvanredne učinke kada je riječ o međunarodnom kontekstu, te sugeriraju da je moguće postići učinkovitiji model za većinu europskih zemalja koristeći četiri izvorne varijable zajedno s nizom dodatnih varijabli. Prusak (2018) istražuje procjenu napretka u području istraživanja modela za predviđanje bankrota u zemljama bivšeg istočnog bloka (Poljska, Latvija, Litva, Estonija, Ukrajina, Mađarska, Rusija, Slovačka, Češka, Rumunjska, Bugarska i Bjelorusija) u usporedbi s poslijednjim istraživačkim trendovima. Autor zaključuje da su u navedenim zemljama postojali pokušaji razvijanja nacionalnih modela primjenom najjednostavnijih statističkih tehnika i korištenjem isključivo finansijskih indikatora kao eksplanatornih varijabli.

Korištenje Altmanovog Z-score modela je u velikoj mjeri zastupljeno u svijetu znanosti ali i izvan njega. Altman (2018.) navodi da se tijekom 50-ak godina od objave Z-score modela pojavio veliki broj aplikacija za praktičare, te je veliki broj i znanstvenih radova koji su koristili Z-score model kao pouzdan i lako primjenjiv alat za predviđanje bankrota poslovnih subjekata, što ukazuje na veliki interes istraživača za navedenu problematiku i aktualnost teme. Osim mnogobrojnih istraživanja provedenih u svijetu i objavljenih radova stranih autora, u Hrvatskoj postoje brojni radovi domaćih autora koji su istraživali i bavili se temama vezanim uz predviđanje bankrota odnosno stičaja. U Tablici 1. se kronološki navode neki od značajnih radova domaćih autora koji su posredno ili neposredno istraživali problematiku stičaja u Hrvatskoj.

Jedan od svakako značajnih domaćih radova u kojem je konstruiran model za ocjenu trenutačne i očekivane poslovne izvrsnosti pod nazivom BEX (eng. *Business excellence model*) je rad autora Belak i Aljinović Barać (2007.). Navedeni model uključuje četiri pokazatelja s određenim ponderima

Bogdan, S., Bareša, S., Hadina, V.

Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stičaja u Republici Hrvatskoj

**Tablica 1.** Pregled istraživanja o stečaju domaćih autora

Autori	Cilj istraživanja	Rezultati
Pejić-Bach (1997)	Definirati i prikazati način primjene diskriminacijske analize u cilju predviđanja bankrota poslovnih subjekata.	Istaknute su brojne prednosti u primjeni diskriminacijske analize kao što su: manji utjecaj subjektivnog suda, bolje razumijevanje problematike, opravdani odabir određene odluke što rezultira i većim povjerenjem.
Novak (2003)	Ispitati korisnost finansijskih pokazatelja za procjenu poslovnih teškoća banaka u Republici Hrvatskoj na uzorku od 38 banaka. U prvoj fazi istraživanja primijenjena je metoda višedimenzijskih skala (MDS). Cilj je bio utvrditi imaju li banke s poslovnim teškoćama u odnosu na uspješne banke tendenciju grupiranja u različitim područjima na karti. U drugoj fazi istraživanja, višestrukom su diskriminantnom analizom i logit modelom definirane funkcije klasifikacije dviju skupina banaka, pri čemu su se finansijskim omjerima koristili kao varijablama klasifikacije, da bi se utvrdilo koji omjeri najviše pridonose klasifikaciji.	Diskriminantna analiza i logit model pokazali su da su varijable (omjeri) profitabilnosti i likvidnosti najznačajniji za procjenu poslovnih teškoća banaka u Hrvatskoj. Autor jednako tako argumentira svoje načine sličnim nalazima iz drugih zemalja.
Zenzerović i Peruško (2006)	Istaknuti važnost anticipiranja varijabli kojima je moguće predvidjeti stečaj. Na sveobuhvatnu način prezentirane su razne kvantitativne metode u predviđanju stečaja kao što su: diskriminantna analiza, modeli linearne vjerojatnosti, logit i probit analiza, višenominalne logit modeli, stablo odlučivanja i neuronske mreže. Autori su najznačajnijih ističu modela: Beawera, Altmara, Deakina, Ohlsona, Edmista, Zagvreda i Kraliceka.	Prikazani modeli za predviđanje stečaja sastoje se uglavnom od kombinacije finansijskih pokazatelja na kojima se temelje izračuni za predviđanje stečaja. Takvim pokazateljima nije moguće u potpunosti obuhvatiti kompleksnost poslovanja, stoga autori kao nadopunu sugeriraju korištenje kvalitativnih varijabli posebice što u tranzicijskim gospodarstvima kvaliteta finansijskog izvještavanja nije dosegla zadovoljavajuću razinu. Autori između ostalog ističu da prethodno prikazane analize i metode nisu dale zadovoljavajuću osnovu za daljnja istraživanja.
Novak i Crnković (2007)	Ispitati korisnost finansijskih pokazatelja u procjeni poslovnih problema dužnika banke kako bi klasificirali dužnike banke prema razini poslovnih problema. U istraživanju je korišteno 15 omjera dobivenih iz finansijskih izvješća. U radu je primijenjena višestruka diskriminantna analiza, logit model i metoda višedimenzijskih skala za razvrstavanje poslovnih subjekata na one koji imaju i na one koji nemaju problemu u poslovanju.	Istraživanje je potvrdilo zadanu hipotezu da u finansijskim iskazima o poslovanju dužnika banaka postoje određeni informacijski sadržaj koji omogućuje da se na osnovi dobivenih modela s visokim stupnjem pouzdanoći razlikuju oni dužnici koji nemaju, od onih koje imaju određenih poslovnih problema. Pokazatelji koje su autori koristili korespondentni su s Altmanovim Z-score modelom.
Ivičić i Cerovac (2009.)	Istražiti mogućnosti prognoziranja izloženosti kreditnom riziku, uz istodobno identificiranje raspodjele rizika u bankarskom sektoru i predviđanje vjerojatnosti promjene adekvatnosti kapitala. Cilj je modeliranje kreditnog rizika nefinansijskih poslovnih subjekata procjenom vjerojatnosti promjene reitinga i prognoziranjem vjerojatnosti neurednog podmirivanja njihovih obveza u razdoblju od jedne godine, na temelju finansijskog računovodstva poduzeća.	Model ispravno klasificira 74% svih poduzeća, 71% poduzeća koja neuredno podmiruju obveze i 75% poduzeća koja ih uredno podmiruju. Zaključak je autora da su najvažniji pokazatelji rizika neurednog podmirivanja obveza omjer dioničkog kapitala prema ukupnoj imovini i omjer zarade prije kamata i oporezivanja prema ukupnim obvezama.
Pervan, Pervan i Vukojić (2011.)	Ispitati koliko javno dostupne informacije o bankrotu i finansijski izvještaji mogu biti korisni za razvoj modela koji predviđa bankrot. Studija se temelji na 78 poslovnih subjekata koji su bankrotirali i jednako toliko onih koji imaju stabilno poslovanje. U radu je primijenjena diskriminantna analiza i logistička regresija.	Zaključak je autora da kratkoročne obveze, poluga i EBIT mogu biti efektivno korišteni u predviđanju bankrota. Model dobiven diskriminantnom analizom iskazao je 79,5% točnosti u predviđanju bankrotiranih kompanija, s time da su prilikom izrade modela diskriminantne analize povrijedene pretpostavke normalnosti podataka i jednakosti kovarijančnih matrica. U odnosu na diskriminantnu analizu model logističke regresije iskazao je veću preciznost u predviđanju u iznosu 85,9%.
Šarlja i Jeger (2011.)	Izraditi tri modela predviđanja finansijskih poteškoća kojih će pratiti promjene finansijskih omjera poslovnih subjekata tijekom tri uzastopne godine. Modeli su razvijeni logističkom regresijom, te se razlikuju prema korištenim finansijskim varijablama za svaku godinu.	Stope predviđanja za sva tri modela u periodu od tri godine kretale su se u rasponu 79,15–84,32%. Autori iznose zaključak da ukoliko su ekonomski uvjeti stabilni, model može postići adekvatnu preciznost kroz nekoliko godina. Pokazatelji koji su imali manju značajnost u jednoj godini pokazali su se više značajnim u sljedećoj godini. Ukoliko se uvjeti mijenjaju, potrebno je generirati novi model te sugeriraju uključivanje makroekonomskih varijabli.
Pervan i Kuvek (2013.)	Testirati sposobnosti predviđanja buduće insolventnosti poslovnih subjekata komparirajući model koji uključuje isključivo finansijske podatke, te model koji uključuje kombinaciju finansijskih i nefinansijskih podataka. Autori u radu koriste logističku regresiju.	Nalazi istraživanja sugeriraju da kombinirani model (koji uključuje finansijske i nefinansijske podatke) ispravno klasificira 88,1% poslovnih subjekata dok model koji koristi isključivo finansijske parametre na ispravan način klasificira 82,8% poslovnih subjekata. Empirijski nalaz je pokazao da se predviđanje insolventnosti i upravljanje kreditnih rizika može poboljšati uključivanjem nefinansijskih podataka.
Keglević Kozjak, Šestan-Jerić i Bešvić (2014.)	Testirati u kojoj mjeri korištenje poznatih modela za predviđanje stečaja (Altmanovog Z-score-a, Springate modela, FP rating modela, BEX indexa, Kralicekova Quicktesta i Bonitest-a) može predviđjeti bankrot hrvatskih poslovnih subjekata.	Temeljem provedenog istraživanja i analizom uzorka od 10 proizvodnih poslovnih subjekata u stečaju, te jednog broja poslovnih subjekata sa stabilnim poslovanjem kroz vremensko razdoblje 2012.–2013., autori zaključuju da su strani modeli mnogo bolji prediktori u odnosu na domaće modele, pri čemu ističu sljedeće modele s najvećom mogućnošću predviđanja bankrota: Springate model, Bonitest i Z-score model.
Šverko Grdić, Krstinić Nižić i Mamula (2017.)	Analizirati finansijsku uspješnost poduzeća i predviđjeti njihovu finansijsku solventnost koristeći višestruku regresijsku analizu. Testiraju se dvije hipoteze: (1) Insolventnost hrvatskih kompanija povećala se s globalnom finansijskom krizom, te (2) Većina radnji koje je Republika Hrvatska poduzela u smislu zakonodavstva i finansijskih poticaja bile su neučinkovite.	Autori potvrđuju da se insolventnost hrvatskih poduzeća povećala s globalnom finansijskom krizom, da hrvatska ekonomija ima problem s rastućom insolventnošću, te su dani prijedlozi na koji način smanjiti nepovoljnu situaciju glede insolventnosti hrvatskih poslovnih subjekata.

Izvor: izrada autora.

utjecaja koji se odnose na: profitabilnost, likvidnost, stvaranje vrijednosti i snagu financiranja.

Za razliku od svih prethodno navedenih istraživanja koja su se bavila problematikom stečaja u Hrvatskoj, u ovom radu će se ispitati može li Z"-score model predviđjeti neuspjeh poslovnih subjekta sa stupnjem točnosti i pouzdanosti usporedivim s onim koji je Altman dobio u testovima, te da li je moguće konstruirati model s prilagođenim ponderima (pritom zadržavajući jednake varijable) Altmanovog Z"-score modela koristeći se diskriminantnom analizom, koji bi bio primjenjiv, te ujedno uspješniji od njegovog originalnog modela za hrvatsko tržište.

### 3. Podaci i metodologija

Iako je Altmanov Z-score model vrlo pouzdan model predviđanja u SAD-u, u cilju ovoga istraživanja testirana je točnost predviđanja Altmanovog modela na poslovnim subjektima iz različitih sektora koji kotiraju ili su kotirali na hrvatskom tržištu kapitala u ukupnom vremenskom razdoblju 2007.-2016. Ukupan istraživački uzorak sastojao se od 52 poslovna subjekta, od čega je 26 subjekata službeno otvorilo stečaj dok se druga polovica uzorka odnosila na poslovne subjekte koji imaju stabilno poslovanje.

S obzirom da su se u uzorku nalazili poslovni subjekti različitih sektora, za izračunavanje Z"-

score vrijednosti korištena je formula 3., temeljem koje je moguće testirati poslovne subjekte izvan proizvodnog sektora koji ne kotiraju na burzi. Iako su se analizirani poslovni subjekti nalazili na burzi, upravo radi problema s likvidnošću (Bogdan i sur., 2012.) primijenjen je model koji umjesto tržišne vrijednosti kompanije koristi knjigovodstvenu vrijednost. Analiza je izvršena ex-post pristupom budući da se temeljem povjesnih podataka testirao model u cilju dobivanja informacije – da li je stečaj mogao biti predviđen.

Altmanov Z"-score računao se za posljedne tri godine od proglašenja stečaja poslovnog subjekta, te je za usporedbu izračunat i kod poslovnih subjekata koja imaju stabilno poslovanje u istom vremenskom periodu unutar istog ili približno istog sektora. Za izračun Z"-score vrijednosti korišteni su podaci iz finansijskih izvještaja (bilanca i račun dobiti ili gubitka) poslovnih subjekta javno dostupnih na službenim stranicama Zagrebačke burze.

U istraživačkom postupku postavljena su dva zadatka: 1) testirati mogućnost primjene, te ispitati postotak ispravnosti predviđanja Z"-score modela na hrvatskom tržištu, odnosno istražiti da li navedeni model može predviđeti bankrot poslovnog subjekta u razdoblju od 3 godine prije službenog proglašenja stečaja. Budući da nije riječ

Bogdan, S., Bareša, S., Hadina, V.

Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stečaja u Republici Hrvatskoj

**Tablica 2.** Pregled sektora prema kojima su razvrstani poslovni subjekti koji su otvorili stečaj

Sektor	Broj poslovnih subjekata	Udio u uzorku
Poljoprivreda, šumarstvo i ribarstvo	2	7.7%
Proizvodnja prehrambenih proizvoda, pića i duhanskih proizvoda	3	11.5%
Proizvodnja tekstila, odjeće, kože i srodnih proizvoda	2	7.7%
Proizvodnja kemikalija i kemijskih proizvoda	3	11.5%
Proizvodnja opere, crijepa i ostalih proizvoda od pećene gline za građevinarstvo	1	3.8%
Proizvodnja osnovnih metala i proizvodnja izrađenih metalnih proizvoda, osim strojeva i opreme	1	3.8%
Proizvodnja transportne opreme	1	3.8%
Ostala prerađivačka industrija, popravak i instaliranje strojeva i opreme	1	3.8%
Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom	1	3.8%
Gradićinarnstvo	2	7.7%
Trgovina na veliko i na malo, popravak motornih vozila i motocikala	2	7.7%
Prijevoz i skladištenje	3	11.5%
Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	3	11.5%
Pravne, računovodstvene, upravljačke, arhitektonске djelatnosti i inženjerstvo te tehničko ispitivanje i analiza	1	3.8%
<b>Ukupno</b>	<b>26</b>	<b>100.0%</b>

Izvor: izrada autora.

o istim kalendarskim godinama, uzorak poslovnih subjekata je promatrani u ukupnom vremenskom periodu 2007.-2016. godine; te 2) izraditi i testirati uspješnost Altmanovog Z'-score modela s prilagođenim ponderima za hrvatsko tržište.

Uzorak temeljem kojega je provedeno istraživanje razvrstan je po sektorima na način kako je prikazano u Tablici 2.

Slična metodologija ispitivanja mogućnosti primjene Altmanovog modela, te ocjenjivanja njegove uspješnosti primijenjena je i u istraživanjima drugih autora, kao primjerice Alareeni i Branson (2012.), Hussain i sur. (2014.), Celli (2015.), te drugi.

#### 4. Rezultati i diskusija

Nakon definiranja istraživačkog uzorka, prikazanog u prethodnom poglavljiju, pristupilo se ispitivanju mogućnosti primjene Z'-score modela na hrvatskom tržištu. Najprije je testiran uzorak poslovnih subjekata koji su službeno otvorili stečaj, odnosno subjekti za čije se dionice donijela službena odluka o prestanku uvrštenja na Zagrebačkoj burzi. Postotak uspješnosti predviđanja Z'-score koeficijenata je izračunat na način da se broj ispravno predviđenih poslovnih subjekata u stečaju dijeli s ukupnim brojem poslovnih subjekata koji su službeno otvorili stečaj. Na sličan način izračunata je pogreška tipa I, odnosno broj pogrešno klasificiranih poslovnih subjekata u stečaju ( $I_{steč}$ ) dijelio se s ukupnim brojem poslovnih subjekata koji su službeno otvorili stečaj ( $PS_{steč}$ ) prema sljedećoj formuli:

$$Pogreška \text{ tipa } I = 1 - \frac{I_{steč}}{PS_{steč}}$$

5

**Tablica 3.** Statistika ispravno klasificiranih poslovnih subjekata koji su službeno otvorili stečaj, temeljem testiranja gornje i donje granice Z'-score modela

	Ispravno klasificirani $Z' < 2,6$	Pogreška tipa I $Z' > 2,6$	Ispravno klasificirani $Z' < 1,1$	Pogreška tipa I $Z' > 1,1$	Ukupan uzorak
T-1	24	2	23	3	26
	92,3%	7,7%	88,5%	11,5%	100,0%
T-2	24	2	23	3	26
	92,3%	7,7%	88,5%	11,5%	100,0%
T-3	25	1	21	5	26
	96,2%	3,8%	80,8%	19,2%	100,0%

Izvor: izrada autora.

Uzorak je analiziran za posljedne tri godine od otvaranja stečaja s time da je godina otvaranja stečaja označena simbolom T, te je isti analiziran za prvu (T-1), drugu (T-2) i treću (T-3) godinu prije službenog otvaranja stečajnog postupka. Rezultati analize, prikazani su u Tablici 3.

Kod uzorka poslovnih subjekta koji su otvorili stečaj, jedini je uzrok stečaja bio poslovni neuspjeh, što je vrlo važno napomenuti, jer upravo na tome konceptu Altmanov Z'-score može predvidjeti poslovni neuspjeh. Temeljem dobivenih rezultata (Tablica 3.) zaključuje se da Z'-score model može s vrlo visokom vjerojatnošću predvidjeti stečaj poslovnog subjekta u prvoj godini (92,3%), dok je pogreška tipa I izražena sa 7,7% prilikom testiranja gornje granične vrijednosti, dok je prilikom testiranja donje granične vrijednosti nešto veća pogreška tipa I, te iznosi 11,5%. U drugoj godini rezultati su identični onima iz prve godine pri čemu se ponovo zaključuje da je model opravdano koristiti. U trećoj godini rezultati su nešto drugačiji, naime prilikom testiranja gornje granice izračunata je manja pogreška tipa I (3,8%) dok je prilikom testiranja donje granice pogreška tipa I u znatnoj mjeri veća i iznosi 19,2% temeljem čega se može zaključiti da je veći broj poslovnih subjekata prema izračunatim koeficijentima bio pozicioniran u „sivoj zoni“.

Nakon testiranja prvog uzorka poslovnih subjekata koji su otvorili stečaj, testiran je drugi uzorak kojeg čine poslovni subjekti koji imaju stabilno poslovanje, i to iz istog ili barem približno istog sektora kao i poslovni subjekti koji su otvorili stečaj. Također su, analogno tomu, promatrane i iste godine kod poslovnih subjekata sa stabilnim poslovanjem. Postotak uspješnosti predviđanja

Z"-score koeficijenata je izračunat na način da se broj ispravno ocijenjenih poslovnih subjekata sa stabilnim poslovanjem dijelio s ukupnim brojem takvih subjekata, nakon čega se dobiveni postotak koristio kao stopa ispravno ocijenjenih poslovnih subjekata sa stabilnim poslovanjem. Na sličan način izračunata je i pogreška tipa II, odnosno dijeljenjem pogrešno klasificiranih stabilnih poslovnih subjekata ( $I_{stab}$ ) s ukupnim brojem poslovnih subjekata ( $PS_{stab}$ ) koji imaju stabilno poslovanje, prema sljedećoj formuli:

$$Pogreška tipa II = 1 - \frac{I_{stab}}{PS_{stab}} \quad 6$$

Rezultati analize prikazani su u Tablici 4.

Temeljem dobivenih rezultata prikazanih u Tablici 4, može se zaključiti da su rezultati prilikom testiranja gornje granične vrijednosti ( $Z'' > 2,6$ ) nedovoljno pouzdani. Prema izračunatom Altmanovom Z"-score modelu za prvu, drugu i treću godinu, pogreške tipa II iznose 46,2%, 50%, te 53,8%. Ukoliko se zaključci izvode prema testiranju donje granične vrijednosti

( $Z'' > 1,1$ ) tada su pogreške tipa II znatno manje u odnosu na testiranje gornje granične vrijednosti, te iznose 19,2%, 15,4% i 23,1% za prvu, drugu i treću godinu. Velike razlike u pogreškama između testiranja gornje i donje granične vrijednosti prisutne su iz razloga što se za prvu godinu u „sivoj zoni“ pozicioniralo 7, za drugu 9, te treću 8 poslovnih subjekata. Iako su postotci ispravno klasificiranih poslovnih subjekata koji su službeno otvorili stečaj mnogo pouzdaniji u odnosu na ispravnu klasifikaciju poslovnih subjekata koje karakterizira stabilno poslovanje, svakako je nužno Z"-score model koristiti s oprezom.

Sveukupna ocjena, odnosno postotak ispravnosti predviđanja Z"-score modela na ukupno promatranoj uzorku, izračunat je kao postotak ispravno klasificiranih poslovnih subjekata u stečaju i onih koji imaju stabilno poslovanje, što se dijelilo s ukupnim brojem promatranih poslovnih subjekata za svaku godinu. Rezultati testiranja, prikazani su u Tablici 5.

Analizirajući i promatrajući sveukupnu ocjenu primjenjivosti i ispravnosti korištenja Z"-score modela na odabranom uzorku poslovnih subjekata u Hrvatskoj, može se zaključiti da je

Bogdan, S., Bareša, S., Hadina, V.

Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stečaja u Republici Hrvatskoj

**Tablica 4.** Statistika ispravno klasificiranih poslovnih subjekata koji imaju stabilno poslovanje, temeljem testiranja gornje i donje granice Z"-score modela

	Ispravno klasificirani $Z'' < 2,6$	Pogreška tipa I $Z'' > 2,6$	Ispravno klasificirani $Z'' < 1,1$	Pogreška tipa I $Z'' > 1,1$	Ukupan uzorak
T-1	14	12	21	5	26
	53,8%	46,2%	80,8%	19,2%	100,0%
T-2	13	13	22	4	26
	50,0%	50,0%	84,6%	15,4%	100,0%
T-3	12	14	20	6	26
	46,2%	53,8%	76,9%	23,1%	100,0%

**Izvor:** izrada autora.

**Tablica 5.** Statistika ispravno ocijenjenih predviđanja temeljem Z"-score modela za ukupni uzorak

	Ispravno klasificirani	Neispravno klasificirani	Ispravno klasificirani	Neispravno klasificirani	Ukupan uzorak
	Granična vrijednost 2,6		Granična vrijednost 1,1		
T-1	38	14	44	8	52
	73,08%	26,92%	84,62%	15,38%	100,00%
T-2	37	15	45	7	52
	71,15%	28,85%	86,54%	13,46%	100,00%
T-3	37	15	41	11	52
	71,15%	28,85%	78,85%	21,15%	100,00%

**Izvor:** izrada autora.

Tablica 6. Korelacijska matrica

	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>
X <sub>1</sub>	1,000	0,847	0,454	0,199
X <sub>2</sub>	0,847	1,000	0,371	0,152
X <sub>3</sub>	0,454	0,371	1,000	0,131
X <sub>4</sub>	0,199	0,152	0,131	1,000

Izvor: izrada autora.

Tablica 7. Test jednakosti sredina

	Wilks' Lambda	F	df1	df2	Sig.
X <sub>2</sub>	0,707	20,720	1	50	0,000
X <sub>3</sub>	0,595	34,071	1	50	0,000
X <sub>4</sub>	0,887	6,356	1	50	0,015

Izvor: izrada autora.

njegova sposobnost predviđanja relativno visoka. Utvrđivanje ispravnosti predviđanja modela, odnosno testiranje na gornju granicu za prvu, drugu i treću godinu iznosi 73,8%, 71,15% i 71,15%, dok testiranje na donju granicu sugerira nešto veću uspješnost predviđanja za prvu, drugu i treću godinu u iznosu 84,62%, 86,54%, 78,85%. Prema dobivenim rezultatima može se opravdati svrhotost korištenja Z'-score modela, no svakako je nužno navedeni model koristiti u kombinaciji s drugim modelima za predviđanje stecaja, te je uputno također ne koristiti ga kao osnovni pokazatelj, već kao dodatni.

U drugom dijelu istraživanja nastojati će se prilagoditi Altmanov Z'-score model hrvatskom tržištu, te će se testirati njegova prediktivna sposobnost. U istraživačkom dijelu koristiti će se jednake varijable koje su korištene i kod Z'-score modela samo će se kalibrirati ponderi u modelu primjenom iste metodologije kao i u originalnom radu, odnosno korištenjem višestruke diskriminantne analize.

Prilikom izračunavanja modela višestruke diskriminantne analize korišten je isti uzorak kao i u prethodnoj analizi, odnosno 26 poslovnih subjekata koji su proglašili stečaj i 26 poslovnih subjekata koji imaju stabilno poslovanje. Model je izrađen prema finansijskim pokazateljima dobivenim iz finansijskih izvještaja godinu dana prije otvaranja službenog stecaja, te je, analogno tomu, ista godina korištena i kod poslovnih subjekata koji imaju stabilno poslovanje. Budući da će se nastavak istraživanja odnositi na kalibraciju

pondera primjenom višestruke diskriminantne analize, u nastavku je prikazana diskriminantna funkcija Z<sub>k</sub> koja će imati če sljedeći oblik:

$$Z_k = \alpha + v_1 X_1 + v_2 X_2 + v_3 X_3 + v_4 X_4$$

7

Varijable su definirane na sljedeći način:

Z<sub>k</sub> Diskriminantna vrijednost

$\alpha$  Konstanta

v<sub>i</sub> Diskriminantni koeficijent, gdje je i = 1, 2, 3, 4

X<sub>1</sub> Obrtni kapital/ukupna imovina

X<sub>2</sub> Zadržana dobit/ukupna imovina

X<sub>3</sub> Dobit prije kamata i poreza/ukupna imovina

X<sub>4</sub> Knjigovodstvena vrijednost kompanije/  
knjigovodstvena vrijednost ukupnih obveza

Prije izračuna samog modela napravljeno je nekoliko predtestova. Prvi test se odnosio na izračun korelacijskih koeficijenata koji su prikazani u Tablici 6.

Temeljem prikazanih koeficijenata može se naslutiti problem multikolinearnosti zbog visokog koeficijenta korelacije (0,847) između varijabli X<sub>1</sub> i X<sub>2</sub>, temeljem čega je ispravno ukloniti jednu od navedenih varijabli. Budući da je diskriminantna analiza osjetljiva na multikolinearnost nezavisnih varijabli, u dalnjem istraživačkom postupku ukloniti će se varijabla X<sub>1</sub>. Sljedeći najviši koeficijent korelacije, koji se može uočiti, iznosi 0,371 između varijabli X<sub>3</sub> i X<sub>2</sub>. Budući da nije riječ o visokom

**Tablica 8.** Eigenvalues

Function	Eigenvalue	% of Variance	Cumulative %	Canonical Correlation
1	0,858 <sup>a</sup>	100,0	100,0	0,679

Izvor: izrada autora.

a. U analizi je korištena prva kanonička diskriminativna funkcija

**Tablica 9.** Wilks' Lambda

Test of Function(s)	Wilks' Lambda	Chi-square	df	Sig.
1	0,538	30,039	3	0,000

Izvor: izrada autora.

koeficijentu, nastavilo se s dalnjim testiranjem modela kojega čine varijable  $X_2, X_3$  i  $X_4$ .

Također je proveden test jednakosti sredina (Tablica 7) temeljem čega su postavljene dvije hipoteze:

$H_0$  : Sve sredine su jednake

$H_1$  : Najmanje jedna sredina je različita od ostalih

Prema prezentiranim rezultatima u Tablici 7. može se zaključiti da se odbacuje za sve prediktore hipoteza  $H_0$ , a statistički su značajne ( $p<0,05$ ) varijable  $X_2, X_3$  i  $X_4$ , nakon čega se pristupilo izračunu kanoničke korelacije. Rezultati kanoničke korelacije i statističke značajnosti modela prikazani su u Tablicama 8. i 9.

Temeljem dobivenog rezultata prikazanog u Tablici 8., s obzirom da postoje samo dvije grupe, procijenjena je jedna diskriminativna funkcija. Svojstvena, odnosno karakteristična vrijednost funkcije iznosi 0,858 i odnosi se na 100% objašnjene varijance. Budući da je kanonička korelacija 0,679, može se zaključiti da je 46,10% varijance zavisne varijable objašnjeno modelom. Prema rezultatima prikazanim u Tablici 9., može se zaključiti da je model statistički značajan ( $p<0,05$ ). U nastavku je prezentiran diskriminantni model (za

novi kalibrirani  $Z_k$ -score model):

$$Z_k = 0,376 + 0,586X_2 + 6,731X_3 + 0,08X_4 \quad 8$$

U posljednjem istraživačkom postupku procijenjena je uspješnost  $Z_k$ -score modela temeljem dobivenih graničnih vrijednosti -0,908 i 0,908.

Na osnovi dobivenih rezultata prikazanih u Tablici 10. može se zaključiti o nešto većoj uspješnosti klasificiranja poslovnih subjekata u stečaju i onih koji imaju stabilno poslovanje prilikom testiranja gornje granične vrijednosti od 0,908. Isto tako bitno je napomenuti da predstavljeni rezultati iz Tablice 10. za  $Z_k$ -score model ne nadmašuju rezultate dobivene primjenom originalnog Altmanovog Z'-score modela iz Tablice 5. Prilikom izračuna kalibriranog modela zbog problema multikolinearnosti, korištene su 3 varijable ( $X_2, X_3$  i  $X_4$ ) iz originalnog Altmanovog Z'-score modela, dok je varijabla ( $X_1$ ) obrtni kapital/ukupna imovina izostavljena. Povećanjem broja finansijskih varijabli odstupilo bi se od originalnog Z'-score modela, ali bi se testiranjem većeg broja finansijskih varijabli, primjenom različitih metodologija i testiranjem

Bogdan, S., Bareša, S., Hadina, V.

Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stečaja u Republici Hrvatskoj

**Tablica 10.** Statistika ispravno ocijenjenih predviđanja temeljem Zk-score modela za ukupni uzorak

	Granična vrijednost -0,908		Granična vrijednost 0,908		Ukupan uzorak
	Ispravno klasificirani	Neispravno klasificirani	Ispravno klasificirani	Neispravno klasificirani	
T-1	35 67,31%	17 32,69%	36 69,23%	16 30,77%	52 100,00%
T-2	33 63,46%	19 36,54%	37 71,15%	15 28,85%	52 100,00%
T-3	30 57,69%	22 42,31%	37 71,15%	15 28,85%	52 100,00%

Izvor: izrada autora.

većeg broja poslovnih subjekata povećala šansa pronalaska modela s uspješnijim mogućnostima klasifikacije poslovnih subjekata od sadašnjih. Na temelju dobivenih rezultata istraživanja može se zaključiti da se Altmanov Z'-score ne preporučuje koristiti kao osnovni pokazatelj za predviđanje stečaja na hrvatskom tržištu, već kao dopunski. Dobiveni rezultati temeljem originalnog Z'-score modela sugeriraju veću mogućnost predviđanja, dok kalibrirani model (Z<sub>k</sub>-score) ima nešto slabije rezultate, ali niti jedan od modela nije preporučljivo koristiti samostalno.

## 5. Zaključak

Problematika stečaja na hrvatskom tržištu smatra se aktualnom, posebice što je u Hrvatskoj od srpnja 2019. godine, ukupan iznos neizvršenih osnova za plaćanje poslovnih subjekata u Hrvatskoj iznosi gotovo 6,2 milijarde kuna (prema posljednjim podacima hrvatske finansijske agencije). Jedan od prvih i ujedno najpopularnijih modela za predviđanje stečaja bio je Altmanov Z-score. Navedeni model prvotno je bio konstruiran za industrijske poslovne subjekte u SAD-u, nakon čega model za predviđanje stečaja postaje interesno područje proučavanja brojnih autora u različitim zemljama. U radu su definirani svi postojeći oblici Altmanovog Z-score modela, nakon čega je testirana i ispitana točnost predviđanja Z'-score modela koji je prilagođen poslovnim subjektima koji ne moraju nužno biti u sektoru proizvodnje, a u svrhu primjenjivosti i provjeravanja pouzdanosti predviđanja stečaja na primjeru poslovnih subjekata iz različitih sektora koji kotiraju ili su kotirali na hrvatskom tržištu kapitala kroz vremensko razdoblje 2007. – 2016. Istraživanje je provedeno na uzorku od 52 poslovnih subjekata, od čega 26 poslovnih subjekata koji su službeno otvorili stečaj, te su izvršeni sa Zagrebačke burze i 26 poslovnih subjekata sa stabilnim poslovanjem. Analiza primjenjivosti Altmanovog Z'-score testirana je za posljednje tri godine od proglašenja stečaja poslovnog subjekta, te je za usporedbu Altmanov Z'-score računat i kod poslovnih subjekata koji imaju stabilno poslovanje u istom vremenskom periodu, izabranih unutar istih ili barem približno istih sektora. Nakon provedene analize, dobiveni su visoki postoci predviđanja, te se može zaključiti da je Altmanov Z'-score model primjenjiv na

hrvatskom tržištu. Naime, kod poslovnih subjekata koji su otvorili stečaj postotak uspješnosti predviđanja za godinu dana ranije iznosi 73,08% i 84,62% što je testirano na gornju i donju granicu. Rezultati dvije godine prije proglašenja stečaja sugeriraju uspješnost modela od 71,15% i 86,54% prilikom testiranja gornje i donje granice, dok su rezultati uspješnosti za treću godinu isti prilikom testiranja gornje granice 71,15%, te nešto slabiji u odnosu na drugu godinu prilikom testiranja donje granice 78,85%. U cilju prilagodbe Altmanovog Z'-score modela hrvatskom tržištu, primjenom višestruke diskriminantne analize nastojali su se prilagoditi ponderi u originalnom Z'-score modelu. Budući da je jedna od važnih prepostavki višestruke diskriminantne analize odsutnost multikolinearnosti, iz modela je uklonjena varijabla  $X_1$ , dok su zadržane  $X_2$ ,  $X_3$  i  $X_4$ . Nakon što je utvrđena signifikantnost modela, analizirana je njegova uspješnost. Prilikom analize rezultata utvrđeno je da prilagođeni model ( $Z$ ) ima slabiji postotak uspješnosti predviđanja od originalnog Z'-score modela, što bi se moglo opravdati isključivanjem varijable  $X_1$  (obrtni kapital/ukupna imovina). Temeljem provedenog istraživanja, može se zaključiti da pokušaj prilagodbe postojećeg Altmanovog Z'-score modela hrvatskom tržištu korištenjem jednakе metodologije nije pružio bolji rezultat, budući da radi zadovoljavanja osnovnih prepostavki višestruke diskriminantne analize nisu mogle biti zadržane originalne varijable. Za buduća istraživanja bilo bi korisno ispitati primjenjivost i uspješnost ostalih poznatih modela na hrvatskom tržištu (Beaver, Zmijewski i sl.), te u cilju pronaalaženja originalnog modela, uključiti veći broj finansijskih varijabli jednako kao i veći broj poslovnih subjekata, te primijeniti nekoliko različitih metodologija u izračunu modela za predviđanje stečaja. Ukoliko se obrati pozornost na dobivene postotke ispravno klasificiranih poslovnih subjekata, svakako se može zaključiti da Z'-score model može biti koristan prilikom analize i ukazivanja na vjerojatnost finansijske (ne)stabilnosti, ali ga je preporučljivo koristiti u kombinaciji s ostalim modelima i finansijskim pokazateljima kako bi se dobila realna prosudba o finansijskom stanju promatranih poslovnog subjekta. Kao ograničenje svakako treba istaknuti činjenicu da je testirani Z'-score model originalno

konstruiran temeljem poslovnih subjekata na američkom tržištu. Isto tako ne preporuča se korištenje navedenog Altmanovog Z"-score modela kao jedinog ili osnovnog pokazatelja prilikom donošenja poslovnih odluka.

Bogdan, S., Bareša, S., Hadina, V.

Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stečaja u Republici Hrvatskoj

## Literatura

Alareeni, B., Branson, J. (2013) Predicting Listed Companies' Failure in Jordan Using Altman Models: A Case Study. *International Journal of Business and Management*, 8(1): 113–126.

Altman, E. I. (2018) Applications of distress prediction models: What have we learned after 50 years from the Z-Score models? *International Journal of Financial Studies*, 6(3): 1–15.

Altman, E. I. (1983) *Corporate Financial Distress A Complete Guide to Predicting, Avoiding, and Dealing with Bankruptcy*. New York: Wiley Interscience, John Wiley and Sons.

Altman, E. I. (1968) Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4): 589–609.

Altman, E. I., Danović, A., Falini, A. (2013) Z-Score Models' application to Italian companies subject to extraordinary administration. *Journal of Applied Finance*, 23(1): 128–137.

Altman, E. I., Haldeman, R. G., Narayanan, P. (1977) ZETA Analysis: A New Model to Identify Bankruptcy Risk of Corporations. *Journal of Banking and Finance*, 1(1): 29–54.

Altman, E. I., Hartzell, J., Peck, M. (1995) *Emerging Markets Corporate Bonds: A Scoring System*. New York: Salomon Brothers.

Altman, E. I., Hotchkiss, E. (1993) *Corporate financial distress and bankruptcy*. Hoboken, New Jersey: John Wiley & Sons, Inc.

Altman, E. I., Iwanicz-Drozowska, M., Laitinen, E. K., Suvas, A. (2014) Distressed firm and bankruptcy prediction in an international context: A review and empirical analysis of Altman's Z-score model. *SSRN Electronic Journal*. Doi: 10.2139/ssrn.2536340.

Altman, E. I., Loris, B. (1976) A financial early warning system for over-the-counter broker-dealers. *The Journal of Finance*, 31(4): 1201–1217.

Altman, E. I., McGough, T. P. (1974) Evaluation of a Company as a Going Concern. *Journal of Accountancy*, (December): 50–57.

Argenti, J. (1976) *Corporate Collapse: The Causes and Symptoms*. New York: McGraw-Hill.

Aziz, A., Emanuel, D. C., Lawson, G. H. (1988) Bankruptcy prediction - An investigation of cash flow based models. *Journal of Management Studies*, 25(5): 419–437.

Aziz, M. A., Dar, H. A. (2006) Predicting corporate bankruptcy: Where we stand? *Corporate Governance*, 6(1): 18–33.

Baldwin, J., Glezen, G. W. (1992) Bankruptcy prediction using quarterly financial statement data. *Journal of Accounting, Auditing & Finance*, 7(3): 269–285.

Beaver, W. H. (1966) Financial ratios as predictors of failure. *Journal of accounting research*, 4: 71–111.

Belak, V., Aljinović Barać, Ž. (2007) Business excellence (BEX) indeks-za procjenu poslovne izvrsnosti tvrtki na tržištu kapitala u Republici Hrvatskoj. *Računovodstvo, revizija i financije*, 10: 15–25.

Bellovary, J. L., Giacomo, D. E., Akers, M. D. (2007) A review of bankruptcy prediction studies: 1930 to

- present. *Journal of Financial education*, 33 (Winter): 1–42.
- Blum, M. (1974) Failing company discriminant analysis. *Journal of Accounting Research*, 12(1): 1–25.
- Bogdan, S., Bareša, S., Ivanović, S. (2012) Measuring liquidity on stock market: Impact on liquidity ratio. *Tourism and hospitality management*, 18(2): 183–193.
- Caouette, J. B., Altman, E. I., Narayanan, P., Nimmo, R. (2008) *Managing Credit Risk: The Great Challenge for the Global Financial Markets*. Hoboken, New Jersey: John Wiley & Sons, Inc.
- Celli, M. (2015) Can Z-Score Model Predict Listed Companies' Failures in Italy? An Empirical Test. *International Journal of Business and Management*, 10(3): 57–66.
- Deakin, E. B. (1972) A discriminant analysis of predictors of business failure. *Journal of accounting research*, 10(1): 167–179.
- Edmister, R. O. (1972) An empirical test of financial ratio analysis for small business failure prediction. *Journal of Financial and Quantitative analysis*, 7(2): 1477–1493.
- FINA (2019) Informacija o neizvršenim osnovama za plaćanje poslovnih subjekata i građana za srpanj 2019. godine. Dostupno na: [https://www.fina.hr/novosti/-/asset\\_publisher/pXc9EGB2gb7C/content/informacija-o-neizvršenim-osnovama-za-plaćanje-poslovnih-subjekata-i-gra-ana-za-srpanj-2019-godine](https://www.fina.hr/novosti/-/asset_publisher/pXc9EGB2gb7C/content/informacija-o-neizvršenim-osnovama-za-plaćanje-poslovnih-subjekata-i-gra-ana-za-srpanj-2019-godine) [20.08.2019].
- Fitzpatrick, P. J. (1932) A comparison of ratios of successful industrial enterprises with those of failed firms. *Certified Public Accountant* (October): 598–605.
- Flagg, J. C., Giroux, G. A., Wiggins Jr, C. E. (1991) Predicting corporate bankruptcy using failing firms. *Review of financial Economics*, 1(1): 67–75.
- Hillegeist, S. A., Keating, E. K., Cram, D. P., Lundstedt, K. G. (2004) Assessing the probability of bankruptcy. *Review of accounting studies*, 9(1): 5–34.
- Hussain, F., Ali, I., Ullah, S., Ali, M. (2014) Can Altman Z-score Model Predict Business Failures in Pakistan? Evidence from Textile Companies of Pakistan. *Journal of Economics and Sustainable development*, 5(13): 110–115.
- Ivičić, L., Cerovac, S. (2009) Procjena kreditnog rizika poduzeća u Hrvatskoj. *Financijska teorija i praksa*, 33(4): 385–413.
- Janda, K., Rakicova, A. (2014) Corporate Bankruptcies in Czech Republic, Slovakia, Croatia and Serbia. MPRA Paper 54109, University of Economics, Prague, Charles University in Prague, Prag.
- Keglević Kozjak, S., Šestanji-Perić, T., Bešvir, B. (2014) Assessment of Bankruptcy Prediction Models Applicability in Croatia. In: Proceedings of 7th International Conference: An Enterprise Odyssey: Leadership, Innovation and Development for Responsible Economy. Zagreb: Faculty of Economics & Business Zagreb.
- Ketz, J. E. (1978) The effect of general price-level adjustments on the predictive ability of financial ratios. *Journal of Accounting Research*, 16: 273–284.
- Koh, H. C., Killough, L. N. (1990) The use of multiple discriminant analysis in the assessment of the going-concern status of an audit client. *Journal of Business Finance & Accounting*, 17(2): 179–192.
- Laitinen, E. K. (1991) Financial ratios and different failure processes. *Journal of Business Finance & Accounting*, 18(5): 649–673.
- Lawrence, E. C., Bear, R. M. (1986) Corporate bankruptcy prediction and the impact of leases. *Journal of Business Finance & Accounting*, 13(4): 571–585.
- Libby, R. (1975) Accounting ratios and the prediction of failure: Some behavioral evidence. *Journal of Accounting Research*, 13(1): 150–161.
- Martin, D. (1977) Early warning of bank failures: A logit regression approach. *Journal of Banking and Finance*, 1(3): 249–276.

Merwin, C. L. (1942) Financing Small Corporations in Five Manufacturing Industries in 1926–1936. New York: National Bureau of Economic Research.

Novak, B. (2003) Predviđanje poslovnih teškoća banaka u Republici Hrvatskoj na osnovi javno dostupnih finansijskih pokazatelje. *Ekonomski pregled*, 54(11–12): 904–924.

Novak, B., Crnković, I. (2007) Klasifikacija dužnika banke prema razini poslovnih problema na osnovi podataka iz osnovnih finansijskih izvješća. *Ekonomski pregled*, 58(1–2): 41–71.

Ohlson, J. A. (1980) Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*, 18(1): 109–131.

Ooghe, H., Spaenjers, C., Vandemoere, P. (2009) Business failure prediction: Simple-intuitive models versus statistical models. *The IUP Journal of Business Strategy*, 6(3–4): 7–44.

Pejić-Bach, M. (1997) Primjena modela diskriminacijske analize i finansijskih pokazatelja u prognoziranju bankrota poduzeća. *Računovodstvo i financije*, 1(11): 515–532.

Pervan, I., Kuvek, T. (2013) The relative importance of financial ratios and nonfinancial variables in predicting of insolvency. *Croatian Operational research review*, 4(1): 187–197.

Pervan, I., Pervan, M., Vukoja, B. (2011) Prediction of company bankruptcy using statistical techniques—Case of Croatia. *Croatian Operational Research Review*, 2(1): 158–167.

Pettway, R. H., Sinkey, J. F. (1980) Establishing on-site bank examination priorities: An early-warning system using accounting and market information. *Journal of Finance*, 35(1): 137–150.

Prusak, B. (2018) Review of research into enterprise bankruptcy prediction in selected central and eastern European countries. *International Journal of Financial Studies*, 6(3): 1–28.

Ramser, J. R., Foster, L. O. (1931) A demonstration of ratio analysis. Bureau of Business Research, Bulletin 4, Urbana, University of Illinois.

Rujoub, M. A., Cook, D. M., Hay, L. E. (1995) Using cash flow ratios to predict business failures. *Journal of Managerial Issues*, 7(1): 75–90.

Santomero, A., Vinso, J. D. (1977) Estimating the probability of failure for commercial banks and the banking system. *Journal of Banking and Finance*, 1(2): 185–205.

Shumway, T. (2001) Forecasting bankruptcy more accurately: A simple hazard model. *The journal of business*, 74(1): 101–124.

Sinkey, J. F. (1975) A multivariate statistical analysis of the characteristics of problem banks. *The Journal of Finance*, 30(1): 21–36.

Šarlija, N., Jeger, M. (2011) Comparing financial distress prediction models before and during recession. *Croatian Operational Research Review*, 2(1): 133–142.

Šverko Grdić, Z., Krstinić Nižić, M., Mamula, M. (2017) Insolvency in the Republic of Croatia. *Ekonomski istraživanja*, 30(1): 1693–1704.

Taffler, R. J. (1982) Forecasting company failure in the UK using discriminant analysis and financial ratio data. *Journal of the Royal Statistical Society: Series A (General)*, 145(3): 342–358.

Wall, A. (1936) How to evaluate financial statements. New York: Harper.

Wilcox, J. W. (1973) A prediction of business failure using accounting data. *Journal of Accounting Research*, 11: 163–179.

Winakor, A. H., Smith R. (1935) Changes in financial structure of unsuccessful industrial companies. Bureau of Business Research, Bulletin 51, Urbana, University of Illinois.

Zenzerović, R., Peruško, T. (2006) Kratki osvrt na modele za predviđanje stečaja. *Ekonomski istraživanja*, 19(2): 132–151.

Bogdan, S., Bareša, S., Hadina, V.

Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stečaja u Republici Hrvatskoj

Zmijewski, M. E. (1984) Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting research*, 22: 59–82.

Bogdan, S., Bareša, S.,  
Hadina, V.

Testiranje primjenjivosti  
Almanovog Z-score modela za  
predviđanje stečaja u Republici  
Hrvatskoj