ANALIZA EFIKASNOSTI MODELA ZA PREDVIĐANJE FINANCIJSKE NESTABILNOSTI PODUZEĆA U REPUBLICI HRVATSKOJ

Smodlaka, Tea

Master's thesis / Specijalistički diplomski stručni

2017

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:127919

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

ZAVRŠNI RAD

ANALIZA EFIKASNOSTI MODELA ZA PREDVIĐANJE FINANCIJSKE NESTABILNOSTI PODUZEĆA U REPUBLICI HRVATSKOJ

Mentor:
doc. dr. sc. Slavko Šodan

Student:
Tea Smodlaka

Split, lipanj 2017.

SADRŽAJ:

1. UVOD 4

1.1. Problem istraživanja 4

1.2. Cilj istraživanja 5

1.3. Znanstvene metode rada 5

1.4. Struktura rada 5

2. REGULATORNI OKVIR ZA FINANCIJSKO IZVJEŠTAVANJE I TEMELJNI FINANCIJSKI IZVJEŠTAJI 7

2.1. Regulatorni okvir za financijsko izvještavanje u Republici Hrvatskoj 7

2.2. Temeljni financijski izvještaji 9

2.2.1. Bilanca 10

2.2.2. Račun dobiti i gubitka 11

2.2.3. Izvještaj o promjenama kapitala 12

2.2.4. Izvještaj o novčanom toku 14

2.2.5. Bilješke uz financijske izvještaje 19

3. TEORIJSKI OKVIR MODELA ZA PREDVIĐANJE FINANCIJSKIH NESTABILNOSTI 20

3.1. William H. Beaver model 21

3.2. Edward I. Altman model 22

3.3. Mark E. Zmijewski model 25

3.4. Peter Kralicek model 25

3.5. Vinko Belak i Željana Aljinović Barać – Business excellence model 26

3.6. Ivica Pervan i Dalibor Filipović model 27

4. ANALIZA MODELA ZA PROCJENU FINANCIJSKE NESTABILNOSTI NA PRIMJERU ODABRANIH PODUZEĆA U REPUBLICI HRVATSKOJ 30

4.1. Definiranje uzorka 30

4.2. Definiranje statističke metodologije 30

4.3. Definiranje varijabli u modelu 31

4.4. Altmanov Z'-score model 33

4.5. Zmijewski model 36

4.6. Kralicek DF model 38

4.7. Belak i Aljinović Barać BEX indeks 42

4.8. Pervan i Filipović FP Rating model 45

4.9. Sinteza rezultata i analiza efikasnosti modela za predviđanje financijske nestabilnosti poduzeća u RH 47

5. ZAKLJUČAK 51

LITERATURA 52

POPIS TABLICA 55

POPIS SLIKA 57

SAŽETAK 58

SUMMARY 59

1. UVOD

1.1. Problem istraživanja

Zadnje desetljeće je obilježeno razornim fenomenom: globalnom ekonomskom krizom koja je generirala financijsku nestabilnost mnogih poduzeća u cijelom svijetu. Globalna ekonomska kriza 2008. se smatra najgorom i najrazornijom krizom još od vremena velike američke depresije iz tridesetih godina prošlog stoljeća. Ova je kriza prijetila kolapsom velikih financijskih institucija diljem svijeta, a veliku ulogu u spašavanju su u tom procesu odigrale nacionalne banke. Međutim nacionalne banke nisu mogle spriječiti pad burzi, brojne stečajeve koji su prouzrokovali veliku nezaposlenost. Republika Hrvatska je dugi niz godina izlazila iz ove krize te se još uvijek ne može sa sigurnošću tvrditi da su nestabilna vremena završila.

Sve je veća potreba za ranim signalima upozorenja koji mogu detektirati rizike prije nego nastupi financijska nestabilnost tako da se mogu primijeniti procesi i modeli koji uklanjaju ili minimiziraju nepovoljne događaje.

Svako poduzeće u svijetu svakodnevno se susreće sa različitim rizicima koji predstavljaju sastavni dio poslovanja od valutnog rizika, rizika prodaje, rizika nabave, rizika gubitka imovine i tako dalje. Od pojedinih rizika poduzeće se može zaštiti preko osiguravajućih kuća dok na pojedine rizike nije moguće utjecati pa se razlikuju kontrolabilni i nekontrolabilni rizici. Da bi se rizicima moglo upravljati oni prvo trebaju biti prepoznati kako bi poduzeće moglo upotrijebiti različite metode minimiziranja posljedica od identificiranih rizika. Jedan od značajnijih rizika je prestanak mogućnosti poslovanja. Prestanak poslovanja odnosno stečaj vuče za sobom izravne posljedice za sve djelatnike i upravu poduzeća zatim posljedice prema direktnim i indirektnim dobavljačima kao i posljedice za društvo u cjelini.

Postavlja se pitanje koji model izabrati za ovu svrhu i koji modeli pružaju dostatno informacija menadžerima i dioničarima kako bi na vrijeme detektirali nepovoljna kretanja unutar poduzeća. Poduzeća koja na vrijeme identificiraju rizike i upravljaju njima imaju dobar poslovni model te će vjerojatno biti uspješnija od onih koji istima ne upravljaju.

Ovaj problem će biti glavni predmet istraživanja završnog rada gdje će se pokušati utvrditi optimalni model za predviđanje stečaja temeljem povijesnih računovodstvenih informacija s ciljem potpunog sprječavanja nastanka nepovoljnog događaja ili minimiziranja posljedica od istog.

1.2. Cilj istraživanja

Glavni cilj istraživanja završnog rada je putem povijesnih računovodstvenih informacija i izračunatih financijskih pokazatelja odabrati optimalan model za predviđanje financijske nestabilnosti odnosno stečaja poduzeća u Republici Hrvatskoj.

1.3. Znanstvene metode rada

Pri analizi i primjeni pojedinih metoda u znanstveno-istraživačkom radu najefektivniji znanstveni rezultati se ne postižu primjenom samo jedne određene znanstvene metode već se različite metode kombiniraju i nadovezuju jedna na drugu. Korištenje svake pojedinačne metode ovisi o samoj vrsti istraživanja što znači da nije moguće svaku metodu koristiti na svakom pojedinom istraživanju. U izradi ovog rada koristit će se induktivna metoda kojom se na temelju pojedinačnih činjenica dolazi do zaključka o općem sudu, zatim deduktivna metoda, kako bi se iz općih sudova došlo do pojedinačnog zaključka, metoda analize i sinteze čime se raščlanjivanjem složenih pojmova dolazi do jednostavnijih i obrnuto. Metoda klasifikacije kojom se neki opći pojam raščlanjuje na pojedinačne, metoda deskripcije koja predstavlja jednostavno opisivanje činjenica, predmeta i procesa, metoda apstrakcije radi odvajanja bitnih od nebitnih elementa, metoda kompilacije, odnosno postupak preuzimanja tuđih opažanja, stavova i rezultata znanstveno-istraživačkog rada na korektan i fer način. (Verčić Tkalac et al, 2011). Metode i tehnike financijske analize pomoću excel tablica i funkcija će se koristiti u empirijskom dijelu rada na temelju kojih će se izračunati pojedini pokazatelji. Rezultati će se sintetizirati u obliku tablica i grafova te će se koristiti metoda komparacije pomoću koje će se vršiti komparacija modela za predviđanje stečaja te donošenje zaključka.

1.4. Struktura rada

Završni rad se sastoji od pet poglavlja. Prvo poglavlje obuhvaća uvod u kojem je definiran problem istraživanja te se navode znanstvene metode korištene u istraživanju. Isto tako opisana je struktura ovog rada. Teoretski dio rada je prezentiran u drugom i trećem poglavlju. Drugo poglavlje daje regulatorni okvir financijskog izvještavanja u kojem se objašnjavaju temeljni financijski izvještaji dok se u trećem poglavlju daje teoretski okvir izabranih

poznatih modela za predviđanje financijske nestabilnosti u svijetu kao i hrvatski modeli kojima se prognozira buduća blokada žiro-računa odnosno (in)solventnost i procjena poslovne uspješnosti odnosno neuspješnosti. Empirijski dio rada se daje u četvrtom poglavlju u kojem se analizira uspješnost izabranih modela za predviđanje financijske nestabilnosti na uzorku od 44 poduzeća. Posljednji dio rada odnosi se na zaključak u kojem se iznose glavni rezultati i spoznaje temeljene na rezultatima istraživanja.

2. REGULATORNI OKVIR ZA FINANCIJSKO IZVJEŠTAVANJE I TEMELJNI FINANCIJSKI IZVJEŠTAJI

2.1. Regulatorni okvir za financijsko izvještavanje u Republici Hrvatskoj

Zakonom o računovodstvu [ZOR](NN 78/15) uređuje se među ostalim računovodstvo poduzetnika, razvrstavanje samih poduzetnika i grupa poduzetnika, knjigovodstvene isprave i poslovne knjige kao i primjena standarda financijskog izvještavanja te tijelo za donošenje standarda financijskog izvještavanja. Odredbe ovoga Zakona dužni su primjenjivati poduzetnici.

Poduzetnici u smislu članka 4. ZOR-a (NN 78/15) su:

„1. trgovačko društvo i trgovac pojedinac određeni propisima kojima se uređuju trgovačka društva

2. poslovna jedinica poduzetnika sa sjedištem u drugoj državi članici ili trećoj državi ako prema propisima te države ne postoji obveza vođenja poslovnih knjiga i sastavljanja financijskih izvještaja, te poslovna jedinica poduzetnika iz države članice ili treće države koji su obveznici poreza na dobit sukladno propisima kojima se uređuju porezi

3. podružnica inozemnih poduzetnika u Republici Hrvatskoj, ako ista nije poslovna jedinica, kako je određeno propisima kojima se uređuju trgovačka društva.“

Poduzetnici u smislu ovoga Zakona razvrstavaju se na mikro, male, srednje i velike ovisno o pokazateljima utvrđenim na zadnji dan poslovne godine koja prethodi poslovnoj godini za koju se sastavljaju financijski izvještaji.

Člankom 5. ZOR-a (NN 78/15) definirani su slijedeći pokazatelji na temelju kojih se razvrstavaju poduzetnici:

– iznos ukupne aktive

– iznos prihoda

– prosječan broj radnika tijekom poslovne godine.

Na temelju zakonskih pokazatelja, poduzetnik je dužan sastavljati i prezentirati godišnje financijske izvještaje primjenom Hrvatskih standarda financijskog izvještavanja ili Međunarodnih standarda financijskog izvještavanja, ovisno da li se razvrstava u mikro, male, srednje ili velike poduzetnike. Ostali poduzetnici koji se ne mogu razvrstati po navedenim kriterijima, dužni su sastavljati i prezentirati godišnje financijske izvještaje primjenom Hrvatskih standarda financijskog izvještavanja.

Veliki poduzetnici i subjekti od javnog interesa su prema ZOR-u dužni sastavljati i prezentirati godišnje financijske izvještaje primjenom Međunarodnih standarda financijskog izvještavanja.

Ovisno društvo, odnosno društvo kći koje je obveznik primjene Hrvatskih standarda financijskog izvještavanja, a čije matično društvo sastavlja i prezentira konsolidirane financijske izvještaje primjenom Međunarodnih standarda financijskog izvještavanja, može odlučiti da svoje godišnje financijske izvještaje sastavlja i prezentira primjenom Međunarodnih standarda financijskog izvještavanja (ZOR, NN 78/15).

Razvrstavanje poduzetnika sukladno Zakonu o računovodstvu je dano u tablici 1.

Tablica 1. Razvrstavanje poduzetnika sukladno Zakonu o računovodstvu

VELIČINA PODUZEĆA	POKAZATELJI	
Mikro poduzetnici (oni koji ne prelaze dva od tri navedena kriterija)	Ukupna aktiva	2.600.000 kn
	Ukupan prihod	5.200.000 kn
	Prosječan broj zaposlenih tijekom godine	10
Mali poduzetnici (oni koji ne prelaze dva od tri navedena kriterija)	Ukupna aktiva	30.000.000 kn
	Ukupan prihod	60.000.000 kn
	Prosječan broj zaposlenih tijekom godine	50
Srednji poduzetnici (oni koji ne prelaze dva od tri navedena kriterija)	Ukupna aktiva	150.000.000 kn
	Ukupan prihod	300.000.000 kn
	Prosječan broj zaposlenih tijekom godine	250
Veliki poduzetnici (oni koji prelaze granične pokazatelje u najmanje dva od tri navedena kriterija)	Ukupna aktiva	150.000.000 kn
	Ukupan prihod	300.000.000 kn
	Prosječan broj zaposlenih tijekom godine	250

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

U velike poduzetnike među ostalima sukladno ZOR-u klasificiraju se i banke, štedne banke, stambene štedionice, institucije za elektronički novac, društva za osiguranje, društva za reosiguranje, leasing-društva, obvezni mirovinski fondovi te mirovinska osiguravajuća društva, faktoring-društva, investicijska društva, burze, središnja klirinška depozitarna društva i dr.

2.2. Temeljni financijski izvještaji

Financijski izvještaji (Međunarodni standardi financijskog izvještavanja, 2009) su strukturirani prikaz financijskog položaja i financijske uspješnosti subjekta. Cilj financijskih izvještaja je pružanje informacija o financijskom položaju, financijskoj uspješnosti i novčanim tokovima poslovnog subjekta koje su korisne širokom krugu korisnika u donošenju

ekonomskih odluka. Financijski izvještaji prikazuju rezultate uprave u upravljanju resursima, a 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 i
- novčanim tokovima subjekta.

Ove informacije, zajedno s drugim informacijama u bilješkama, pomažu korisnicima u predviđanju budućih novčanih tokova subjekta te osobito u određivanju vremena njihovog nastanka i njihove izvjesnosti. U tablici 2. su dati osnovni financijski izvještaji prema MRS1.

Tablica 2. Financijski izvještaji sukladno MRS 1 (u primjeni od 1.1.2010.)

POTPUNI SET FINANCIJSKIH IZVJEŠTAJA PREMA MRS1
1. Izvještaj o financijskom položaju na kraju razdoblja (bilanca)
2. Izvještaj o sveobuhvatnoj dobiti razdoblja
3. Izvještaj o promjenama kapitala tijekom razdoblja
4. Izvještaj o novčanim tokovima tijekom razdoblja
5. Bilješke, koje obuhvaćaju sažetak važnih računovodstvenih politika i druga objašnjenja i
6. Izvještaj o financijskom položaju na početku najranijeg usporednog razdoblja ako subjekt neku računovodstvenu politiku primjenjuje retroaktivno ili ako retroaktivno prepravlja stavke u svojim financijskim izvještajima ili ako stavke u financijskim izvještajima reklasificira

Izvor: Prilagođeno od: Narodne novine (2009): Međunarodni standardi financijskog izvještavanja, Narodne novine d.d., broj 136, Međunarodni računovodstveni standard 1, Prezentiranje financijskih izvještaja

Hrvatski standardi financijskog izvještavanja (2015) nastali su sukladno Zakonu o računovodstvu, a donosi ih Odbor za standarde financijskog izvještavanja. Temelje se na domaćoj računovodstvenoj teoriji i praksi i Direktivi 2013/34/EU Europskog parlamenta i Vijeća od 26. lipnja 2013. o godišnjim financijskim izvještajima, konsolidiranim financijskim izvještajima i povezanim izvješćima. Sadrže zahtjeve priznavanja, mjerenja, procjenjivanja, prezentiranja i objavljivanja transakcija i događaja važnih za financijske izvještaje te su posebno prilagođeni potrebama srednjih, malih i mikro poduzetnika koji prevladavaju u hrvatskom gospodarstvu.

Pregled financijskih izvještaja sukladno HSFI1 je dan u tablici 3.

Tablica 3. Financijski izvještaji sukladno HSFI 1 (u primjeni od 1.1.2016.)

FINANCIJSKI IZVJEŠTAJI PREMA HSFI	OBAVEZNICI
1. Bilanca	Mikro, mali i srednji poduzetnici
2. Račun dobiti i gubitka	Mikro, mali i srednji poduzetnici
3. Izvještaj o promjenama kapitala	Srednji poduzetnici
4. Izvještaj o novčanom toku	Srednji poduzetnici
5. Bilješke uz financijske izvještaje	Mikro, mali i srednji poduzetnici

Izvor: Prilagođeno od: Narodne novine (2015): Zakon o računovodstvu, Narodne novine d.d., broj 78; Narodne novine (2015): Hrvatski standardi financijskog izvještavanja, Narodne novine d.d., broj 86

2.2.1. Bilanca

Bilanca (engl. Balance sheet, njem. Bilanz) predstavlja sustavni prikaz imovine i njezinih izvora u određenom trenutku, tj. na određeni dan, izraženih u financijskim terminima. Osnovni elementi bilance su aktiva i pasiva koje su uvijek u ravnoteži. Aktiva prikazuje imovinu po njenim vrstama i likvidnosti dok pasiva prikazuje vlastite i tuđe izvore imovine. Bilanca je podloga za financijsku analizu, analizu zaduženosti, analizu profitabilnosti, likvidnosti i aktivnosti. Prema Belak et al (2014) bilanca je nositelj računovodstvenih podataka i računovodstvenih informacija te mora pružiti: istinit, fer, pouzdan i nepristran pregled imovine, glavnice i dugova, promijene financijskog položaja i dobitka ili gubitka. Kao takva predstavlja iznimno važnu informacijsku podlogu pri donošenju poduzetničkih odluka.
Razumijevanje bilance vrlo je važno za upravljanje poduzećem, jer imovina i izvori imovine utječu na financijski rezultat i novčane tokove. Bilanca objedinjava rezultate računa dobiti i gubitka i izvješća o novčanim tokovima, budući uz stanje pokazuje i financijski rezultat i likvidnost. Kvaliteta strukture imovine ocjenjuje se kroz odnos dugotrajne i kratkotrajne imovine, ali i prema vrstama unutar ovih skupina. Jednako tako, kvaliteta izvora financiranja ovisi o odnosu vlastitog kapitala i dugoročnih i kratkoročnih obveza (Žager et al, 2008).
U Narodnim novinama br. 95/16 objavljen je novi Pravilnik o strukturi i sadržaju godišnjih financijskih izvještaja za poduzetnike iz realnoga sektora u sklopu kojega su date pozicije bilance za 2016. godinu pa nadalje (tablica 4.).

Tablica 4. Bilanca u RH prema GFI-POD (u primjeni od 1.1.2016.)

BILANCA	
AKTIVA	**PASIVA**
A) POTRAŽIVANJA ZA UPISANI A NEUPLAĆENI KAPITAL	A) KAPITAL I REZERVE
B) DUGOTRAJNA IMOVINA	I. Temeljni (upisani) kapital
I. Nematerijalna imovina	II. Kapitalne rezerve
II. Materijalna imovina	III. Rezerve iz dobiti
III. Dugotrajna financijska imovina	IV. Revalorizacijske rezerve
IV. Potraživanja	V. Rezerve fer vrijednosti
V. Odgođena porezna imovina	VI. Zadržana dobit ili preneseni gubitak
C) KRATKOTRAJNA IMOVINA	VII. Dobit ili gubitak poslovne godine
I. Zalihe	VIII. Manjinski (nekontrolirajući) interesi
II. Potraživanja	B) REZERVIRANJA
III. Kratkotrajna financijska imovina	C) DUGOROČNE OBVEZE
IV. Novac u banci i blagajni	D) KRATKOROČNE OBVEZE
D) PLAĆENI TROŠKOVI BUDUĆEG RAZDOBLJA	E) ODGOĐENO PLAĆANJE TROŠKOVA
I OBRAČUNATI PRIHODI	I PRIHOD BUDUĆEGA RAZDOBLJA
E) UKUPNA AKTIVA	E) UKUPNA PASIVA
F) IZVANBILANČNI ZAPISI	F) IZVANBILANČNI ZAPISI

Izvor: Prilagođeno od: Narodne novine (2016): Pravilnik o strukturi i sadržaju godišnjih financijskih izvještaja, Narodne novine d.d., Zagreb, broj 95

2.2.2. Račun dobiti i gubitka

Račun dobiti i gubitka (engl. Profit and loss account / The Income statement, njem. Gewinn- und Verlustrechnung) pokazuje uspješnost poslovanja društva u određenom razdoblju. On je ujedno i instrument kontrole i upravljanja poslovanjem, a odgovara na pitanja: koliki je prihod ostvaren, koliki su rashodi, koliko je društvo bilo profitabilno tijekom razdoblja, koliki je udio troškova osoblja u prihodu, koliko je povećana ili smanjena prodaja u odnosu na prethodnu godinu itd. Analizom računa dobiti i gubitka, odnosno usporedbom ostvarenog s planom ili konkurencijom, može se doći do dragocjenih zaključaka i na osnovi njih se mogu donositi odgovarajuće poslovne odluke (Belak et al, 2014). Račun dobiti i gubitka u financijskim se izvještajima prema MSFI naziva i Izvještaj o sveobuhvatnoj dobiti. Razlika između bilance i

računa dobiti i gubitka je što je bilanca statični financijski izvještaj koji prikazuje stanje imovine i kapitala na određeni datum (najčešće 31.12.), dok račun dobiti i gubitka prikazuje ostvaren financijski poslovni rezultat poduzeća u određenom periodu. Tablica 5. prikazuje skraćeni oblik pozicija računa dobiti i gubitka koji je u primjeni od 1. siječnja 2016. godine, a prema Pravilniku o strukturi i sadržaju godišnjih financijskih izvještaja. Prema MRS 1 (t. 85) u računu dobiti i gubitka ili u bilješkama ne smije se prikazivati nijedna stavka prihoda i rashoda kao izvanredna stavka.

Tablica 5. Račun dobiti i gubitka u RH prema GFI-POD (u primjeni od 1.1.2016.)

RAČUN DOBITI I GUBITKA
I. POSLOVNI PRIHODI
II. POSLOVNI RASHODI
III. FINANCIJSKI PRIHODI
IV. FINANCIJSKI RASHODI
V. UDIO U DOBITI OD DRUŠTAVA POVEZANIH SUDJELUJUĆIM INTERESOM
VI. UDIO U DOBITI OD ZAJEDNIČKIH POTHVATA
VII. UDIO U GUBITKU OD DRUŠTAVA POVEZANIH SUDJELUJUĆIM INTERESOM
VIII. UDIO U GUBITKU OD ZAJEDNIČKIH POTHVATA
IX. UKUPNI PRIHODI
X. UKUPNI RASHODI
XI. DOBIT ILI GUBITAK PRIJE OPOREZIVANJA
XII. POREZ NA DOBIT
XIII. DOBITAK ILI GUBITAK RAZDOBLJA

Izvor: Prilagođeno od: Narodne novine (2016): Pravilnik o strukturi i sadržaju godišnjih financijskih izvještaja, Narodne novine d.d., Zagreb, broj 95

2.2.3. Izvještaj o promjenama kapitala

Izvještaj o promjenama kapitala (eng. The Statement of changes in shareholders' equity, njem. Entwicklung des Eigenkapitals) evidentira sve promijene na kapitalu između dva datuma bilanciranja. Prema t. 1.36. i 1.37. HSFI-ja 1, izvještaj o promjenama kapitala sastavlja se tako da sadržava promjene između uloženog i zarađenog kapitala te izravne promjene u kapitalu (izvan računa dobitka i gubitka). Obveznici MSFI-ja i obveznici HSFI-ja trebaju u izvještaj o promjenama kapitala uključiti sve stavke sveobuhvatnog dobitka

razdoblja, odnosno neto-dobitak (gubitak) tekuće godine, i stavke ostaloga sveobuhvatnog dobitka. Pritom se svaka promjena navedenih stavaka unutar dobitka ili gubitka razdoblja i ostaloga sveobuhvatnog dobitka treba iskazati odvojeno. Zasebno se iskazuju i učinci retroaktivnih primjena promjene računovodstvenih politika kao i učinci retroaktivnog prepravljanja ili ispravaka pogrešaka. Uz navedene informacije, u izvještaj o promjenama kapitala mogu se uključiti i svote dividendi koje su priznate za raspodjelu vlasnicima tijekom razdoblja te pripadajuće svote po dionici. Promjene koje izravno utječu na vrijednost kapitala su redom: revalorizacija dugotrajne nematerijalne i materijalne imovine, rezerve fer vrijednosti financijske imovine raspoložive za prodaju, tekući i odgođeni porezi (dio), učinkovita zaštita novčanog toka, promjene računovodstvenih politika, ispravak značajnih pogrešaka prethodnog razdoblja, tečajna razlika s naslova neto ulaganja u inozemno poslovanje i ostale promjene kapitala.

Obveznici sastavljanja ovog izvještaja su prema ZOR (NN 78/15) srednji i veliki poduzetnici kao i subjekti od javnog interesa. Isti je dan u tablici 6.

Tablica 6. Izvještaj o promjenama kapitala u RH prema GFI-POD (u primjeni od 1.1.2016.)

IZVJEŠTAJ O PROMJENAMA KAPITALA
Prethodno / Tekuće razdoblje
1. Stanje 1. siječnja
2. Promjene računovodstvenih politika
3. Ispravak pogreški
4. Stanje 1. siječnja (1+2+3)
5. Dobit/gubitak razdoblja
6. Tečajne razlike iz preračuna inozemnog poslovanja
7. Promjene revalorizacijskih rezervi dugotrajne materijalne i nematerijalne imovine
8. Dobitak ili gubitak s osnove naknadnog vrednovanja financijske imovine raspoložive za prodaju
9. Dobitak ili gubitak s osnove učinkovite zaštite novčanog toka
10. Dobitak ili gubitak s osnove učinkovite zaštite neto ulaganja u inozemstvu
11. Udio u ostaloj sveobuhvatnoj dobiti/gubitku društava povezanih sudjelujućim interesom
12. Aktuarski dobici/gubici po planovima definiranih primanja
13. Ostale nevlasničke promjene kapitala
14. Porez na transakcije priznate direktno u kapitalu
15. Povećanje/smanjenje temeljnog (upisanog) kapitala (osim reinvstiranjem dobiti i u postupku predstečajne nagodbe
16. Povećanje temeljnog (upisanog) kapitala reinvestiranjem dobiti
17. Povećanje temeljnog (upisanog) kapitala u postupku predstečajne nagodbe
18. Otkup vlastitih dionica/udjela
19. Isplata udjela u dobiti/dividende
20. Ostale raspodjele vlasnicima
21. Prijenos u pozicije rezervi po godišnjem rasporedu
22. Povećanje rezervi u postupku predstečajne nagodbe
23. Stanje 31. prosinca (4+5+…+21+22)

Izvor: Prilagođeno od: Narodne novine (2016): Pravilnik o strukturi i sadržaju godišnjih financijskih izvještaja, Narodne novine d.d., Zagreb, broj 95

2.2.4. Izvještaj o novčanom toku

Izvještaj o novčanom toku (eng. The Cash Flow Statement, njem. Geldflussrechnung) daje prikaz priljeva i odlijeva novca i novčanih ekvivalenata u obračunskom razdoblju. Novčani primici su novac i novčani ekvivalenti koji pritječu u društvo – priljev, dok novčani izdaci

predstavljaju isplate novca – odljev. Novac u ovom smislu predstavlja sva novčana sredstva koja se nalaze na transakcijskim računima poduzetnika, u blagajni društva kao i depozite po viđenju (a-vista) dok su novčani ekvivalenti kratkoročna visoko likvidna ulaganja koja se mogu u roku kraćem od tri mjeseca konvertirati u poznate svote novca i koja su podložna beznačajnom riziku promjene vrijednosti (Odluka o objavljivanju međunarodnih standarda financijskog izvještavanja, NN 136/2009). Specifičnost ovog izvještaja u odnosu na bilancu jest u tome što bilanca pokazuje stanje novca i novčanih ekvivalenata na određeni datum te nije iskazan novčani tijek u danom razdoblju kao što se iz nje ne mogu iščitati ni koje su transakcije uzročnici promjena. Žager et al (2008) ističe da su prihodi i rashodi obračunske kategorije koje se evidentiraju prema načelu nastanka događaja odnosno u trenutku njihova nastanka. Za priznavanje prihoda i rashoda nije potreban stvarni priljev i odljev novca. Za priznavanje prihoda nije potreban stvarni primitak novca kao ni što za priznavanje rashoda nije potreban odliv novca. Zato izvještaj o novčanom tijeku objedinjuje ove informacije. Za razliku od ostalih izvještaja ovaj izvještaj kombinira efekte investicijskih, poslovnih i financijskih odluka. Ukoliko se analizira zajedno račun dobiti i gubitka u određenom periodu, bilanca na početku i na kraju razdoblja i izvještaj o novčanom toku dobiva se puno više informacija nego kada promatramo svaki od navedenih izvještaja zasebno.

Helfert (2001) pak ističe da menadžerske odluke ne utječu direktno samo na profit u određenom periodu već uzrokuju popratne promjene u većini stavaka imovine i obveza, posebno na stavkama radnog kapitala kao što su gotovina, potraživanja, zalihe i kratkoročne obveze. Izvještaj koji učinkovito bilježi trenutni rezultat poslovanja u smislu operativnog rezultata i prateće promjene u bilanci je izvještaj o novčanom toku. Obveznici sastavljanja ovog izvještaja prema ZOR (NN 78/15) su veliki i srednji poduzetnici.

Menadžeri koriste izvješće o novčanom toku odnosno o gotovinskim tijekovima za analizu tijekova prošlog razdoblja i planiranje budućih tijekova. Naime, izvješće o novčanom toku osim što daje informaciju o izvorima i uporabi gotovine tijekom izvještajnog razdoblja, predstavlja bazu podataka za planiranje budućih gotovinskih tijekova i potreba za financiranjem (Vidučić, 2012).

Izvještaj o novčanim tokovima prezentira novčane tokove u određenom razdoblju, klasificirane prema aktivnosti društva na novčane tokove od poslovnih, investicijskih i financijskih aktivnosti (Vuk, 2013).

Poslovne aktivnosti su prema HSFI (NN 86/2016) glavne i druge aktivnosti poduzetnika, osim investicijskih i financijskih aktivnosti. Novčani tokovi od poslovnih aktivnosti prvenstveno proizlaze iz osnovne djelatnosti društva (proizvodnja, trgovina ili pružanje usluga) koje stvaraju prihode, a osiguravaju novčana sredstva za održavanje i unaprjeđenje poslovanja. Novčani tijekovi od poslovnih aktivnosti dani su u tablici 7.

Tablica 7. Novčani tijekovi od poslovnih aktivnosti

POSLOVNE AKTIVNOSTI
I. NOVČANI PRIMICI OD:
- kupaca za prodanu robu, proizvode i pružene usluge
- tantijema, naknada i provizija
- osiguranja za naknadu šteta (odštetni zahtjevi i dr. koristi)
- povrata poreza i povrata novca od dobavljača
- primljenih predujmova za isporuke roba, proizvoda i pružanje usluga
- davanja imovine u zakup i prodaje imovine dane u zakup
- trgovanja vrijednosnim papirima klasificiranih za trgovanje
II. NOVČANI IZDACI ZA:
- isplate dobavljačima za isporučenu robu i pružene usluge
- kamate i poreze
- isplate zaposlenima i za račun zaposlenih
- isplate premija osiguranja prema policama osiguranja
- isplate prema ugovorima koji uređuju poslovne aktivnosti
- dani predujmovi za poslovne aktivnosti
III. NETO NOVČANI TIJEK OD POSLOVNIH AKTIVNOST = NOVČANI PRIMICI - NOVČANI IZDACI

Izvor: Prilagođeno od: Vuk (2013): IX. Izvještaj o novčanom tijeku, RRIF, Zagreb, broj 1, str.194

Investicijske aktivnosti poduzetnika su prema HSFI (NN 86/2016) vezane za stjecanje i otuđivanje dugotrajne imovine i drugih ulaganja, koja nisu uključena u novac i novčane ekvivalente. Ovi novčani tijekovi su bitni jer prikazuju veličinu nastalih izdataka za resurse koji su namijenjeni stvaranju budućeg dobitka i generiranja budućih novčanih tijekova. Novčani tijekovi od investicijskih aktivnosti dani su u tablici 8.

Tablica 8. Novčani tijekovi od investicijskih aktivnosti

INVESTICIJSKE AKTIVNOSTI
I. NOVČANI PRIMICI OD:
- prodaje nekretnina, postrojenja i opreme, nematerijalne imovine i dr. dugotrajne imovine
- prodaje vlasničkih ili dužničkih instrumenata te udjela u zajedničkim pothvatima
- naplate danih zajmova (povrat glavnice)
- ugovora za futurse, forwarde, opcije i swapove
- kamata i dividendi
II. NOVČANI IZDACI ZA:
- stjecanje nekretnina, postrojenja i opreme, nematerijalne imovine i dr. dugotrajne imovine
- stjecanje vlasničkih i dužničkih financijskih instrumenata te udjela u zajedničkim pothvatima
- dani predujmovi i zajmovi
- ulaganje u futurse, forwarde, opcije i swapove
III. NETO NOVČANI TIJEK OD INVEST. AKTIVNOSTI = NOVČANI PRIMICI - NOVČANI IZDACI

Izvor: Prilagođeno od: Vuk (2013): IX. Izvještaj o novčanom tijeku, RRIF, Zagreb, broj 1, str.194

Financijske aktivnosti poduzetnika su sve aktivnosti koje za posljedicu imaju promjenu veličine i sastava kapitala i zaduživanja poduzetnika. Izvještavanje o novčanim tokovima iz ovih aktivnosti je važno jer koristi onima koji osiguravaju kapital poduzetniku u smislu predviđanja očekivanja vezanih uz buduće novčane tokove (Vuk, 2013). Novčani tijekovi od financijskih aktivnosti prikazani su u tablici 9.

Tablica 9. Novčani tijekovi od financijskih aktivnosti

FINANCIJSKE AKTIVNOSTI
I. NOVČANI PRIMICI OD:
- emisije vlasničkih vrijednosnih papira (dionice) ili dužničkih vrijednosnih papira (obveznice)
- od izdavanja zadužnica, zajmova, pozajmica, hipoteka, i dr. kratkoročnih ili dugoročnih posudbi
- dokapitalizacija
- primljenih zajmova i kredita
II. NOVČANI IZDACI ZA:
- isplate vlasnicima za stjecanje ili iskup dionica društva
- povrat primljenih zajmova i kredita
- otplatu glavnice kod financijskog najma
- isplatu dividendi i otkup vlastitih dionica
III. NETO NOVČANI TIJEK OD FINAN. AKTIVNOSTI = NOVČANI PRIMICI - NOVČANI IZDACI

Izvor: Prilagođeno od: Vuk (2013): IX. Izvještaj o novčanom tijeku, RRIF, Zagreb, broj 1, str.194

Izvještaj o novčanom toku može se sastaviti primjenom (Odluka o objavljivanju međunarodnih standarda financijskog izvještavanja, NN 136/2009):

- Direktne (izravne) metode – ova metoda pokazuje bruto novčane primitke i bruto novčane izdatke novca zasebno za svaku aktivnost (poslovne, investicijske, financijske). Ove informacije se dobivaju iz računovodstvenih evidencija koje prate stanje i kretanje sredstava na novčanim računima i računima novčanih ekvivalenata.
- Indirektne (neizravne) metode - ova metoda novčani tok od poslovnih aktivnosti prikazuje kao usklađenje dobiti ili gubitka za nenovčane rashode i nenovčane prihode, te promijene u kratkotrajnoj imovini, izuzev novca i novčanih ekvivalenata, i kratkoročnim obvezama. U tom smislu usklađenje neto novčanog toka obavlja se za učinke promjena zaliha, potraživanja i obveza kao i za nenovčane stavke (primjerice amortizacija, odgođeni porez, nerealizirani dobici i gubici, neraspoređeni dobitak i manjinski udjeli). Novčani tok od investicijskih i financijskih aktivnosti prikazuje primitke i izdatke po ovim aktivnostima i identičan je novčanom toku koji se utvrđuje po direktnoj metodi.

2.2.5. Bilješke uz financijske izvještaje

Bilješke su nestandardiziran financijski izvještaj koji korisnicima financijskih izvještaja pruža dodatne informacije, a koje nisu prezentirane u bilanci, računu dobiti i gubitka, izvještaju o ostaloj sveobuhvatnoj dobiti, izvještaju o novčanom tijeku i izvještaju o promjenama kapitala (Žager et al, 2008).

Računovodstvena regulativa propisuje minimalnu razinu informacija koje poduzeće mora objaviti. MSFI 1 i HSFI 1 propisuju objavljivanje u bilješkama za obveznike primjene MSFI-ja i HSFI-ja , a uobičajeno se iste objavljuju u slijedećem obliku:

1. Društvo koje je predmet izvještavanja

2. Osnove sastavljanja izvještaja (HSFI ili MSFI)

3. Značajne računovodstvene politike

4. Informacije koje pobliže objašnjavaju stavke prikazane u financijskim izvještajima

5. Druga objavljivanja kao vanbilančnu evidenciju, ugovorne obveze, planirane emisije dionica, događaje nakon datuma bilance i dr.

U bilješkama uz financijske izvještaje menadžeri bi trebali objasniti osnovne računovodstvene politike i pretpostavke. Može se reći da kvaliteta računovodstvenih objava predstavlja važan segment kvalitete računovodstvenih informacija (Žager et al, 2008).

3. TEORIJSKI OKVIR MODELA ZA PREDVIĐANJE FINANCIJSKIH NESTABILNOSTI

Stečaj kao rezultat insolventnosti i prezaduženosti poduzeća uzrokuje čitav niz rizika prema drugim poduzetnicima koji su direktno ili indirektno vezani za poslovanje tog poduzetnika kao i ostalih dionika. Može se reći da stečaj ima posljedicu za cijelo društvo stoga modeli za predviđanje financijske nestabilnosti postaju sve značajnije područje interesa. U današnjem turbulentnom okruženju jako je važno razumjeti i predvidjeti razloge koji dovode do financijske nestabilnosti poduzeća.

Poduzeće se suočava s kreditnim rizikom svaki put prilikom prodaje proizvoda, robe ili usluga ukoliko nije ugovoreno avansno plaćanje proizvoda, robe ili usluga jer postoji veća ili manja vjerojatnost da kupac u budućnosti neće moći podmiriti potraživanje. Najčešće se analiza kreditnog rizika veže uz proces odobravanja kredita ili zajmova prilikom kojeg se utvrđuje kreditna sposobnost zajmoprimca. Kreditna sposobnost je sposobnost i spremnost dužnika da izvrši povrat financijskih sredstava pod uvjetima predviđenim u ugovoru. Prema tome, kreditna analiza predstavlja ocjenu rizičnosti poduzeća, odnosno procjenu vjerojatnosti urednog vraćanja ugovornih obveza iz perspektive zajmodavaca, kreditora i dobavljača (Šodan, 2016).

Postavlja se pitanje je li uopće moguće sa današnjim tehnikama i modelima uspješno predvidjeti nastanak financijskih neprilika? Takve metode i tehnike bi značajno unaprijedile sustav zaštite od financijskih neprilika na način da bi se pravovremeno mogli otkloniti sami uzročnici stečaja ili bi se isti modificirali na način da se rizik od financijskih neprilika ublaži u svojoj najvećoj mjeri na korist svih dionika polazeći od samog poduzeća, zaposlenika, dobavljača, fondova, države, kreditora kao i društva u cjelini.

Danas postoje razvijeni modeli za predviđanje financijskih neprilika, a koji su nastali implementacijom statističkih i matematičkih metoda te su koncipirani na način da središnje mjesto zauzimaju financijski pokazatelji svaki sa određenim ponderom značajnosti. Modeli su izvedeni na temelju stvarnih financijskih podataka promatranih subjekata u određenom periodu te se razlikuju ovisno o svojim obilježjima. Atraktivnost ove uvijek aktualne tematike rezultirala je razvojem niza modela iz ovog područja od strane različitih znanstvenika među kojima će se u ovom radu obraditi modeli sljedećih autora:

1. Wiliam H. Beaver (1966)
2. Edward I. Altman (1968)
3. Mark E. Zmijewski (1984)
4. Peter Kralicek (2007)
5. Vinko Belak i Željana Aljinović Barać (2007)
6. Ivica Pervan i Dalibor Filipović (2010)

3.1. William H. Beaver model

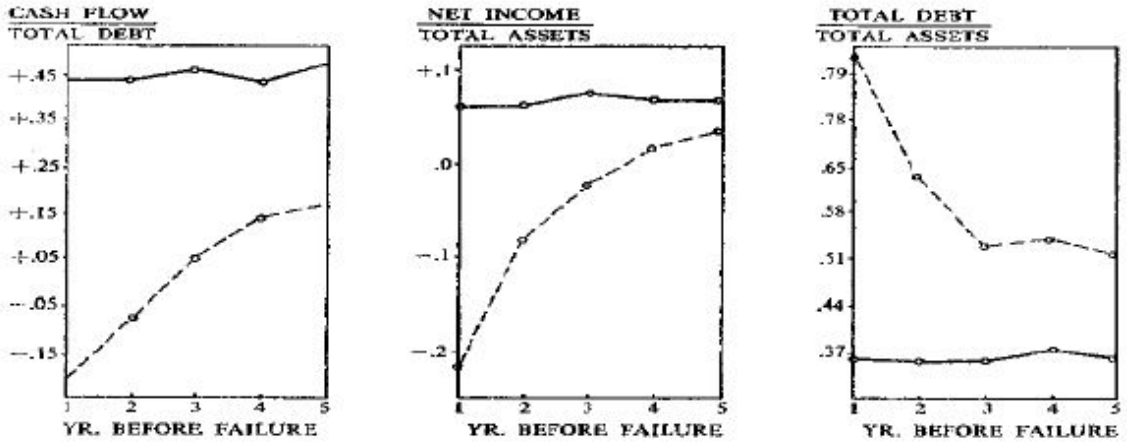
1965. godine, profesor William H. Beaver (1966) je zaključio da simultana analiza više različitih financijskih pokazatelja može povećati mogućnost predviđanja stečaja, što je bila točka prekretnica u ovom području te je time započelo novo doba primjene statističkih i matematičkih metoda unutar procjene financijske pozicije poslovnih korisnika. Korisnost više financijskih pokazatelja je testirao na primjeru financijskog neuspjeha poslovnog subjekta gdje je neuspjeh predstavljao nesposobnost subjekta da podmiri dospjele financijske obveze. Beaver je proveo istraživanje na uzorku 158 proizvodnih korporacija iz 38 različitih djelatnosti i to 79 korporacija koje su bankrotirale i 79 zdravih korporacija u periodu 1954. do 1964. godine. Analizirao je 30 pokazatelja od kojih su se najtočniji za predviđanje stečaja pokazali pokazatelji unutar tablice 10. Tablica 10 prikazuje pokazatelje i pripadajuće pogreške klasifikacije svakog od njih počevši od najpreciznijeg pokazatelja do najmanje preciznog pokazatelja (Zenzerović i Peruško, 2006).

Tablica 10. Pogrešno klasificiranje poslovnih subjekata u šest najtočnijih pokazatelja u postotku

RANG	POKAZATELJ	GODINE PRIJE STEČAJA				
		1	2	3	4	5
1	Novčani tok / Ukupne obveze	13	21	23	24	22
2	Neto dobit / Ukupna imovina	13	20	23	29	28
3	Ukupne obveze / Ukupna imovina	19	25	34	27	28
4	Kratkotrajna imovina / Kratkoročne obveze	20	32	36	38	45
5	Radni kapital / Ukupna imovina	24	34	33	45	41

Izvor: Prilagođeno od: Beaver (1966) u Zenzerović i Peruško (2006): Kratki osvrt na modele za predviđanje stečaja, Economic research - Ekonomska istraživanja, 19 (2), str. 132 – 151.

Kretanje pokazatelja u periodu od pet godina prije nastanka stečaja mogu se prikazati i grafički (slika 1) na način da puna linija označava zdrave korporacije dok isprekidana linija predstavlja korporacije koje su bankrotirale (Šodan, 2016).



Slika 1. Beaverov sustav pokazatelja

Izvor: Beaver (1966) u Šodan (2016): Financijska analiza poslovanja, Sveučilište u Splitu, Ekonomski fakultet, ak. godina 2015/2016, predavanja br.10.

3.2. Edward I. Altman model

Edward I. Altman (1968) osmislio je model za predviđanje stečaja proizvodnih poduzeća korištenjem statističke metode višestruke diskriminacijske analize i danas se smatra jednim od najznačajnih modela koji se koristi u poslovnom i akademskom svijetu. Uzorak poduzeća nad kojima je provedena analiza sastojao se od 66 proizvodnih poduzeća od kojih su 33 financijski zdrava, te 33 poduzeća koja su pokrenula stečajni postupak u razdoblju od 1946. do 1965. godine. 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 (Zenzerović i Peruško, 2006).

Razvijeni model je poznat pod nazivom Z-score te se iskazuje slijedećom jednadžbom (Zenzerović i Peruško, 2006):

$$Z = 0{,}012\ X_1 + 0{,}014\ X_2 + 0{,}033\ X_3 + 0{,}006\ X_4 + 0{,}999\ X_5 \quad (1)$$

Gdje je:

X_1 = radni kapital / ukupna aktiva

X_2 = zadržana dobit / ukupna aktiva

X_3 = operativna dobit (EBIT) / ukupna aktiva

X_4 = tržišna vrijednost glavnice / ukupne obveze

X_5 = prihod od prodaje / ukupna aktiva

Pet pokazatelja je objašnjeno na slijedeći način (Šodan, 2016):

X_1 pokazatelj se smatra najznačajnijim od pokazatelja likvidnosti, a računa se kao omjer neto obrtnog kapitala i ukupne imovine.

X_2 pokazatelj indicira kumulativnu profitabilnost uzimajući u obzir samo reinvestirana sredstava tijekom životnog vijeka poduzeća.

X_3 pokazatelj koji je sličan pokazatelju ROA, a pokazuje profitabilnost poduzeća neovisno o stupnju korištenja financijske poluge i utjecaju poreza.

X_4 pokazatelj je kombinacija tržišne vrijednosti glavnice i ukupnih obveza te pokazuje koliko imovina poduzeća može izgubiti na vrijednosti prije nego poduzeće postane insolventno.

X_5 pokazatelj je pokazatelj obrtaja imovine.

Daljnjom analizom Altman je utvrdio kritične vrijednosti diskriminantne funkcije na način da vrijednost Z-scora niža od 1,81 ukazuje na veliku opasnost od pokretanja stečajnog postupka. Druga kritična vrijednost je 2,99 koja označava stabilno financijsko poduzeće dok sve vrijednosti unutar intervala 1,88 – 2,99 predstavljaju „sivu zonu“ što znači da je njihova financijska stabilnost ugrožena, ali postoji potencijal ozdravljenja (Zenzerović i Peruško, 2006).

Točnost predviđanja stečaja modelom Z-score prikazana je u tablici 11.

Tablica 11. Točnost predviđanja stečaja Z-score

GODINE PRIJE POKRETANJA STEČAJNOG POSTUPKA	POSTOTAK TOČNOSTI RAZVRSTAVANJA
1	95
2	72
3	48
4	29
5	36

Izvor: Altman (1966) u Zenzerović i Peruško (2006): Kratki osvrt na modele za predviđanje stečaja, Economic research - Ekonomska istraživanja, 19 (2), str. 132 – 151.

S obzirom da je objašnjeni model izveden korištenjem podataka proizvodnih poduzeća koja su kotirala na burzi, u kasnijim revizijama modela izvršene su dvije korekcije. Prva prilagodba modela se odnosila na predviđanje financijske nestabilnosti za ona poduzeća koja ne kotiraju na burzi, a druga prilagodba modela uzela je u obzir i neproizvodna poduzeća te mogućnost predviđanja financijskih nestabilnosti za poduzeća koja nisu u proizvodnom sektoru (Zenzerović i Peruško, 2006).

Prva modifikacija ovog modela, koja je napravljena za poduzeća čije dionice ne kotiraju na burzi, glasi (Zenzerović i Peruško, 2006):

$$Z' = 0{,}717\ X_1 + 0{,}847\ X_2 + 3{,}107\ X_3 + 0{,}420\ X_4 + 0{,}998\ X_5 \quad (2)$$

Kod pokazatelja X_4 brojnik varijable je zamijenjen sa knjigovodstvenom vrijednosti glavnice umjesto tržišne vrijednosti iz prethodnog Z-score modela te su isto tako prilagođeni i svi ponderi ostalih varijabli. Kod prve modifikacije definirane su nove kritične vrijednosti koje više ne iznose 2,99 i 1,81 već 2,90 i 1,23.

Druga modifikacija ovog modela je prilagođena predviđanju financijskih nestabilnosti za neproizvodna poduzeća na način da je iz modela isključena varijabla X_5, pokazatelj aktivnosti jer se taj pokazatelj bitno razlikuje od djelatnosti do djelatnosti. Isto tako, kao i s prvom modifikacijom prilagođeni su svi ponderi te su definirane nove kritične vrijednosti.

Diskriminacijska funkcija drugog modela glasi (Zenzerović i Peruško, 2006):

$$Z'' = 6{,}56\ X_1 + 3{,}26\ X_2 + 6{,}72\ X_3 + 1{,}05\ X_4 \quad (3)$$

sa kritičnim vrijednostima koje sada iznose 2,60 i 1,10.

3.3. Mark E. Zmijewski model

Zmijewski model za predviđanje stečaja razvijen je 1984. godine. U svom izračunu uključuje pokazatelje koji mjere uspješnost poslovanja, zaduženost i likvidnost poduzeća. Zmijewski model temelji se na podacima 800 poduzeća koja pripadaju financijski stabilnim poduzećima i 40 poduzeća čije je poslovanje završilo stečajem (Šodan, 2016).

Osnovna jednadžba modela glasi (Šodan, 2016):

$$X = - 4{,}3 – 4{,}5\ X_1 + 5{,}7\ X_2 – 0{,}004\ X_3 \quad (4)$$

gdje su varijable sljedeće:

X_1 = neto dobit / ukupna imovina,

X_2 = ukupni dug / ukupna imovina,

X_3 = kratkotrajna imovina / kratkoročne obveze

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

$$\text{Vjerojatnost stečaja} = 1/(1+\exp^{(\text{-Zmijevski score})})$$

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

3.4. Peter Kralicek model

Peter Kralicek je provodeći multivarijantnu analizu 2007. godine izveo model za predviđanje financijske nestabilnosti. Koristio je podatke njemačkih, švicarskih i austrijskih poslovnih subjekata te je model prilagođen europskom okruženju. (Zenzerović i Peruško, 2006).

Formula za DF model glasi (Zenzerović i Peruško, 2006):

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

Gdje su varijable:

X_1 = čisti novčani tok / ukupne obveze

X_2 = ukupna imovina / ukupne obveze

X_3 = dobit prije kamata i poreza (EBIT) / ukupna imovina

X_4 = dobit prije kamata i poreza (EBIT) / ukupni prihodi

X_5 = zalihe / ukupni prihodi

X_6 = poslovni prihodi / ukupna imovina

DF vrijednost Kralicekovog modela poprima ili negativne ili pozitivne vrijednosti pri čemu negativne vrijednosti ukazuju na insolventnost prema predefiniranim stupnjevima insolventnosti dok pozitivne vrijednosti ukazuju na solventnost subjekta što je prikazano u tablici 12 (Zenzerović i Peruško, 2006).

Tablica 12. Kritične vrijednosti DF pokazatelja

VRIJEDNOST DF POKAZATELJA	FINANCIJSKA STABILNOST
> 3.0	izvrsna
> 2.2	vrlo dobra
> 1.5	dobra
> 1.0	osrednja
> 0.3	loša
<=0.3	početak insolventnosti
<=0.0	umjerena insolventnost
<=-1.0	izrazita insolventnost

Izvor: prilagođeno od Koban (1978) u Zenzerović i Peruško (2006): Kratki osvrt na modele za predviđanje stečaja, Economic research - Ekonomska istraživanja, 19 (2), str. 132 – 151.

3.5. Vinko Belak i Željana Aljinović Barać – Business excellence model

Business excelence (BEX) indeks je konstruiran primjenom statističko-matematičkih metoda na podatcima hrvatskih tvrtki koje kotiraju na tržištu kapitala – Zagrebačkoj burzi na način da su Belak i Aljinović Barać (2007) kreirali vlastitu bazu podataka iz financijskih izvješća za period od 2000. do 2006. godine. Logičkom selekcijom je odabrano 14 pokazatelja: 5 strukturnih, 5 pokazatelja financijskih perfomansi i 4 pokazatelja efikasnosti investiranja dioničara na tržištu kapitala. Primjenom višestruke diskriminacijske analize izračunat je agregatni pokazatelj poslovne izvrsnosti – BEX indeks.

Formula za BEX indeks glasi (Belak i Aljinović, 2007):

$$BEX = 0{,}388\ ex_1 + 0{,}579\ ex_2 + 0{,}153\ ex_3 + 0{,}316\ ex_4 \quad (6)$$

gdje je:

ex_1 = EBIT / ukupna aktiva

ex_2 = dobit nakon oporezivanja / (vlastiti kapital x cijena)

ex_3 = radni kapital / ukupna aktiva

ex_4 = (5 x (dobit + amortizacija + deprecijacija)) / ukupne obveze.

s tim da ex_1 predstavlja mjeru profitabilnosti, ex_2 mjeru stvaranja vrijednosti, ex_3 mjeru likvidnosti, a ex_4 mjeru financijske snage. Pokazatelj ex_2 je godine 2008. izmijenjen unutar originalne formule (6) kad je u nazivniku dobit nakon oporezivanja zamijenjena sa neto poslovnom dobiti (Belak i Aljinović, 2008).

Belak i Aljinović (2007) ističu da je namjena BEX indeksa brza i jednostavna procjena poslovne izvrsnosti, a isti mjeri poslovnu izvrsnost u dvije dimenzije: trenutačna poslovna izvrsnost i očekivana poslovna izvrsnost. Ističe se da BEX indeks nije ovisan o pokazateljima s tržišta kapitala pa se može računati za tvrtke koje ne kotiraju na tržištu kapitala.

Rangiranje poslovne izvrsnosti prema ovom modelu dano je u tablici 13 (Belak i Aljinović, 2007)

Tablica 13. Kritične vrijednosti BEX indeksa

VRIJEDNOST BEX INDEKSA	RANG POSLOVNE IZVRSNOSTI	PROGNOZA ZA BUDUĆNOST
veći od 6,01	svjetska klasa	Tvrtka posluje s vrhunskim rezultatima što se može očekivati i u iduće 4 godine, ako menadžment nastavi s unaprjeđenjima.
4,01 - 6,00	izvrsno	Tvrtka posluje izvrsno što se može očekivati i u sljedeće 3 godine, ako menadžment nastavi s unaprjeđenjima
2,01 - 4,00	vrlo dobro	Tvrtka posluje vrlo dobro što se može očekivati i u sljedeće 2 godine ako menadžment nastavi s unaprijeđenijima
1,01 - 2,00	dobro	Tvrtka posluje dobro, ali se poboljšanje može očekivati samo ako se pristupi unaprjeđenjima.
0,00 - 1,00	granično područje između dobrog i lošeg	Poslovna izvrsnost je pozitivna, ali nije zadovoljavajuća. Potrebno je pristupiti ozbiljnim unaprjeđenjima.
manji od 0 (negativan)	loše	Ugrožena je egzistencija. Potrebno je žurno pristupiti restrukturiranju i unaprjeđenjima, inače će se loše poslovanje nastaviti pa postoji opasnost od propasti (vjerojatnost je preko 90%)

Izvor: prilagođeno od Belak i Aljinović Barać (2007): Business excellence (Bex) indeks – za procjenu poslovne izvrsnosti tvrtki na tržištu kapitala u Republici Hrvatskoj, Računovodstvo, revizija i financije, br. 10., str. 15. – 25.

3.6. Ivica Pervan i Dalibor Filipović model

Pervan i Filipović 2010. godine objavljuju model FP RATING® razvijen s ciljem procjene insolventnosti odnosno vjerojatnosti blokade žiro-računa poduzetnika. Kod oblikovanja ovog

modela korištena je diskriminacijska analiza gdje je kao zavisna varijabla uzeta insolventnost odnosno neplaćanje obveza po glavnici kredita dulje od 90 dana. (Pervan i Filipović, 2010).

Uzorak se sastojao od trgovačkih društava koja su kreditno zadužena u poslovnoj banci X d.d. u Republici Hrvatskoj. Prikupljeni podaci su obuhvaćali informacije iz financijskih izvještaja društva, bilance i računa dobiti i gubitka kao i 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. Kao kriterij za grupiranje solventnih i nesolventnih klijenata određena je granica od 90 dana neplaćanja dospjelih obveza po kreditima. U konačnoj analizi uzorak se sveo na 447 malih i srednje velikih trgovačka društva od kojih su 53 društva bila insolventna dok su 394 bila solventna. 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 malih i srednje velikih poduzeća kojima prihod ne prelazi 65 milijuna kuna Kod obrade podataka korištena je statistička metoda diskriminacijske analize na temelju 33 izračunata financijska pokazatelja, te je dobiven konačni model koji glasi (Pervan i Filipović, 2010):

$$\text{FP RATING}^{®} = -1{,}0937 + 2{,}0956\,X_1 - 0{,}005\,X_2 + 0{,}6220\,X_3 - 0{,}000005\,X_4 + 0{,}1116\,X_5 \qquad (7)$$

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 - ΔObrtni kapital) / ukupan prihod

ΔObrtni kapital = (zalihe_t – zalihe_{t-1}) + (Potraživanja od kupaca_t – Potraživanja od kupaca_{t-1}) + (Ostala potraživanja_t – Ostala $\text{potraživanja}_{t-1}$) - (Obveze prema dobavljačima_t – Obveze prema $\text{dobavljačima}_{t-1}$) – (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%. Ukupna točna klasifikacija putem ovog modela iznosi 81,4% (Pervan i Filipović, 2010).

S obzirom da nije dana referentna vrijednost pokazatelja isti se neće uspoređivati s ostalim modelima koji su obrađeni u ovom radu.

4. ANALIZA MODELA ZA PROCJENU FINANCIJSKE NESTABILNOSTI NA PRIMJERU ODABRANIH PODUZEĆA U REPUBLICI HRVATSKOJ

4.1. Definiranje uzorka

Istraživanje u ovom radu je usmjereno na određivanje optimalnog modela za predviđanje stečaja u Republici Hrvatskoj. Za potrebe analize modela opisanih u ovom radu izabran je namjerni uzorak iz baze podataka Amadeus te su prikupljeni sekundarni podatci iz bilance i računa dobiti i gubitka. Amadeus je baza podataka koja raspolaže financijskim podacima javnih i privatnih poduzeća europskih zemalja. Za potrebe analize prikupljene su financijske informacije iz bilance i računa dobiti i gubitka poduzeća iz Republike Hrvatske u periodu 2011. – 2015. godine, a koja pripadaju sektoru proizvodnih poduzeća. Kao kriterij financijske nestabilnosti pojedinog poduzeća uzet je pokrenut stečaj (eng. Insolvency proceeding) tijekom 2015. godine. Najprije su odabrana poduzeća iz prehrambene industrije za koje je pokrenut stečaj u 2015. godini. Zatim je svako od dobivenih poduzeća upareno prema veličini odnosno prema poslovnim prihodima i prema sektoru djelatnosti (na temelju dvije znamenke NKD-a) s odgovarajućim poduzećem koje nije u stečaju. Ukupni odabrani uzorak sastoji se od 44 poduzeća od kojih su 22 zdrava, stabilna poduzeća i 22 financijski nestabilna poduzeća. Pomoću računovodstvenih informacija iz tako dobivenog uzorka se računaju financijski pokazatelji koji su temelj modela predviđanja stečaja poduzeća.

4.2. Definiranje statističke metodologije

Za potrebe određivanja optimalnog modela predviđanja stečaja u ovom radu koriste se analitičko-matematički postupci pomoću excel tablica te funkcija pivot, vlookup i sumif. Pojedini pokazatelji se zatim računaju matematičkim formulama. Dobiveni rezultati se sintetiziraju u obliku tablica i grafova kako bi se isti usporedili.

4.3. Definiranje varijabli u modelu

U ovom istraživanju su korištene računovodstvene informacije dostupne u bazi podataka Amadeus. Podatci koji su raspoloživi unutar Amadeus baze su dijelom različiti od podataka koji su dostupni na stranicama Financijske agencije (FINA). Tablica broj 14. povezuje računovodstvene informacije Amadeus baze sa računovodstvenim informacijama koje zahtijeva ZOR.

Tablica 14. Usporedba formata unutar Amadeus baze podataka sa hrvatskim formatom za bilancu

BALANCE SHEET	
GLOBAL FORMAT	**CROATIAN FORMAT**
FIXED ASSET	TOTAL FIXED ASSET
Intangible fixed asset	Intangible fixed asset
Tangible fixed asset	Tangible fixed asset
Other fixed asset (inc.financial fixed asset)	Long term financial asset + Long term receivables
CURRENT ASSET	TOTAL CURRENT ASSET
Stocks	Invetories
Debtors	Short term receivables (total)
Other current asset (*cash and cash equivalent are seperate category)	Short term financial asset + cash at banks & in hand + Accruals + Loss over the capital value
TOTAL ASSET	TOTAL ASSET
SHAREHOLDERS FUNDS	EQUITY
CAPITAL	SUBSCRIBED CAPITAL
Other Sharefolders Funds (inc. Reserves)	Capital reservs + Reserves from profit + Revalori-sational reserves + Profit/loss brught forward + Profit/Loss of the period + Minority interests
NON-CURRENT LIABILITIES	LONG TERM LIBAILITIES+PROVISIONS
Long Term debt	Long Term debt
Other non-current liabilities (inc.provisions)	Provisions
CURRENT LIABILITIES	SHORT TERM LIABILITIES+DEFERRED ITEMS
Loans	Short tern loans
Creditors	Trade creditors
Other current Liabilities	Other short term liabilities
TOTAL SHAREHOLDERS FUNDS AND LIABILI-TIES	Total Liabilities
WORKING CAPITAL	CALCULATED
NET CURRENT ASSET	CALCULATED
ENTERPRISE VALUE	CALCULATED
NUMBER OF EMPLOYEES	NUMBER OF EMPLOYEES

Izvor: prilagođeno od Bureau von Dijk (2017): Amadeus – User guide raspoloživo na: https://help.bvdinfo.com/mergedProjects/64_es/Home.htm, pristupljeno 19.6.2017.

Tablica 15. Usporedba formata unutar Amadeus baze podataka sa hrvatskim formatom za račun dobiti i gubitka

PROFIT AND LOSS ACCOUNT	
GLOBAL FORMAT	**CROATIAN FORMAT**
Operating revenue / turnover	Operating revenue
Sales	Sales
Cost of goods sold	n/a
Gross profit	n/a
Other operating expenses	n/a
Operating profit (loss)	Operating revenue - operating expenses (consisting of material expenses, cost of employees, depreciation, other operating expenses)
Financial revenue	Financial revenue
Financial expenses	Financial expenses
Financial profit / loss	Calculated as FIRE - FIEX
Profit (loss) before taxation	Calculated as OPPL + FIPL (P/L before taxation in Croatian format is calculated after extraordinary revenues and expenses)
Extraordinary and other revenue	Extraordinary revenues
Extraordinary and other expenses	Extraordinary expenses
Extraordinary and other profit (loss)	Calculated
Profit (loss) for period	Profit of the period
Export turnover	Raw material costs + sold goods costs
Material costs	Short term liabilities + deferred items
Cost of employees	Staff costs
Depreciation	Depreciation
Interest paid	n/a
R&D expenses	n/a
Cash flow	Calculated
Added value	Calculated
EBIT	Calculated
EBITDA	Calculated

Izvor: prilagođeno od Bureau von Dijk (2017): Amadeus – User guide raspoloživo na: https://help.bvdinfo.com/mergedProjects/64_es/Home.htm, pristupljeno 19.6.2017.

Prikupljeni podatci su obrađeni te su za svako poduzeće i za sve periode izračunati financijski pokazatelji unutar definiranih modela. Financijski podatci uzeti iz Amadeus baze podataka nisu trebali biti prilagođeni hrvatskim standardima kako bi bili usporedivi s obzirom da je točno definiran format izvještavanja te su podatci prikupljeni na ovaj način već standardizirani. Uzorak od 44 poduzeća je uzet u obliku excel tablice te su iz sirovih podataka izrađene pivot tablice koje sadrže zasebno zdrava financijski stabilna poduzeća kao kontrolna poduzeća te financijski nestabilna poduzeća.

Pomoću excel formula izračunati su financijski pokazatelji te su isti stavljeni u različite modele za predviđanje stečaja.

4.4. Altmanov Z'-score model

Financijski podatci potrebni za izračun prve modifikacije Z'-score modela su: radni kapital (eng. Working capital), ukupna imovina (eng. Total asset), zadržana dobit (eng. Retained earnings), EBIT, knjigovodstvena vrijednost glavnice (eng. Book value of equity), ukupne obveze (eng. Total liabilities) i prihodi od prodaje (eng. Sales revenues).

S obzirom da unutar dostupnih podataka u Amadeus bazi nema pozicije zadržane dobiti ista će se za potrebe ovog rada aproksimirati sa neto dobiti (eng. Net profit).

Z'-score je konačno rezultat formule (2).

Uzorak je promatran u razdoblju od 5 godina prije nastupa stečaja (eng. Insolvency proceeding) u periodu od 2011. do 2015. godine. Dobiveni podatci su iskazani na slici 2 ispod.

Uzorak hrvatskih poduzeća	2011	2012	2013	2014	2015
AMADEUS M.A.J., D.O.O.	1.473	1.308	1.481	1.259	0.781
FENJER D.O.O.	1.332	1.013	1.420	0.867	0.783
INOX BRAMAR D.O.O.	0.062	0.373	0.239	0.367	0.305
INOX CENTAR SESVETE D.O.O.	0.633	0.442	0.347	-0.315	-0.543
INSTRUMENTARIA, D.D.	0.891	0.680	0.643	0.540	0.295
INTERUGOS D.O.O.	1.515	1.629	1.419	0.955	0.542
JADRAN D.D.	1.173	0.730	0.813	0.777	0.370
KAMELEON D.O.O.	2.881	2.728	2.030	0.287	0.758
KUMAL S D.O.O.	0.940	-0.259	-0.382	-0.624	-0.366
METAL REŠETAR D.O.O.	1.373	0.894	0.813	0.683	0.724
NAVALIA D.O.O.	1.631	0.754	-0.004	0.270	-1.886
OPRUGA D.D.	0.587	0.427	0.308	0.203	0.321
PHOENIX CAPITIS D.O.O.	0.951	0.901	0.963	0.573	0.861
PROIZVODNJA JAVOR D.O.O.	1.046	1.143	1.537	1.262	2.064
TEHNO FILTER D.O.O.	1.043	-0.154	1.088	-0.121	1.908
ULJANIK TESU, D. D.	-0.212	-0.078	0.211	-0.923	-1.198
UNO-MARKETING - D.O.O.	1.896	2.577	1.830	-1.220	0.351
V & V D.O.O.	2.114	1.608	1.190	-0.677	0.381
VITEK D.O.O.	2.480	2.467	1.473	-0.746	-1.318
ZIT D.O.O.	0.890	-0.426	0.716	0.728	0.685
ZM-ELEMES D.O.O.	2.138	1.180	0.792	-0.634	-3.490
ZRINSKI AG D.O.O.	2.124	1.691	2.351	0.792	0.399
PROSJEČNA VRIJEDNOST	**1.316**	**0.983**	**0.967**	**0.196**	**0.124**

Slika 2. Rezultati Altmanovog Z'-score modela

Izvor: izrada Autora

Kod prve modifikacije definirane su kritične vrijednosti od 2,90 i 1,23 (Altman, 1993 u Altman i Hotchkiss 2006) koje su objašnjene na slijedeći način:

„Alarm area“ ili rizična zona koja uključuje sva poduzeća koja imaju Z'-score ispod 1,23. Ove kompanije imaju jako visok rizik stečaja.

„Grey area“ ili siva zona koja se nalazi između vrijednosti 1,23 – 2,90. Poduzeća unutar ovog raspona se smatraju hibridnim kompanijama radi visokog postotka nesigurnosti.

„Safe area“ ili sigurna zona obuhvaća poduzeća referentne vrijednosti poviše 2,90. Kompanije poviše ove referentne vrijednosti imaju jako mali rizik stečaja odnosno pripadaju zoni niskog rizika.

Na uzorku od 22 financijski nestabilna poduzeća može se lako zaključiti da je model Z'-score u 91% slučajeva u godini stečaja predvidio financijsku nestabilnost odnosno stečaj jer su čak 20 poduzeća ostvarila Z'-score ispod 1,23 odnosno nalaze se unutar tzv. rizične zone. Samo u 9% slučajeva detektirana je ugrožena financijska nestabilnost sa mogućnošću stečaja. Ta poduzeća pripadaju sivoj zoni te postoji mogućnost stečaja. Niti jedno poduzeće nije dobilo rezultat veći od 2,90 pa se niti jedno od navedenih poduzeća ne smatra zdravim poduzećem. Može se vidjeti da je i godinu dana prije nego je stečaj nastupio, u 2014. godini, također u 91% slučajeva ovim modelom predviđen stečaj što predstavlja izuzetno dobro predviđanje. Dvije godine prije stečaja (2013. godine) 14 od 22 poduzeća se nalazi u rizičnoj zoni što predstavlja postotak od 64% dok se tri godine prije stečaja (2012. godine) čak njih 15 nalazi u zoni visokog rizika od stečaja, odnosno njih 68%. Četiri godine prije nastupa stečaja (2011. godine) model predviđa stečaj u 50% slučajeva dok za ostalih 50% predviđa financijsku nestabilnost sa mogućnosti stečaja. Zanimljivo je da u niti jednoj godini u cijelom promatranom periodu od 2011 – 2015 nije zabilježen Z'-score veći od 2,90 stoga se može tvrditi uzimajući u obzir referentne vrijednosti ovog modela da sva poduzeća unutar ovog uzorka imaju veći ili manji rizik stečaja. Cijela analiza dobivenih rezultata ovog modela u apsolutnim vrijednostima i postocima dana je u tablici 16.

Tablica 16. Postotak točnosti razvrstavanja Altmanovog modela na uzorku od 22 financijski nestabilna poduzeća

ALTMANOV MODEL (Z'-SCORE)	GODINE PRIJE STEČAJA				
	2011	2012	2013	2014	2015
Financijski stabilno poduzeće	0	0	0	0	0
Ugrožena financijska stabilnost s potencijalom ozdravljenja	11	7	8	2	2
Poduzeće pred stečajem	11	15	14	20	20
Ukupno	22	22	22	22	22
Financijski stabilno poduzeće	0%	0%	0%	0%	0%
Ugrožena financijska stabilnost s potencijalom ozdravljenja	50%	32%	36%	9%	9%
Poduzeće pred stečajem	50%	68%	64%	91%	91%
Ukupno	100%	100%	100%	100%	100%

Izvor: izrada Autora

Kontrolna skupina zdravih poduzeća unutar uzorka pokazala je slijedeće rezultate (tablica 17):

Tablica 17. Postotak točnosti razvrstavanja Altmanovog modela na uzorku od 22 financijski stabilna poduzeća

ALTMANOV MODEL (Z'-SCORE)	GODINE PRIJE STEČAJA				
	2011	2012	2013	2014	2015
Financijski stabilno poduzeće	8	10	11	11	10
Ugrožena financijska stabilnost s potencijalom ozdravljenja	9	7	8	8	7
Poduzeće pred stečajem	5	5	3	3	5
Ukupno	22	22	22	22	22
Financijski stabilno poduzeće	36%	45%	50%	50%	45%
Ugrožena financijska stabilnost s potencijalom ozdravljenja	41%	32%	36%	36%	32%
Poduzeće pred stečajem	23%	23%	14%	14%	23%
Ukupno	100%	100%	100%	100%	100%

Izvor: izrada Autora

Unutar ove skupine detektiran je Z'-score vrijednosti veće od 2,90 u 2015. godini te je od ukupno 22 analizirana poduzeća njih 10 financijski stabilno odnosno njih 45% dok je iste godine u „sivoj zoni“ 7 poduzeća odnosno njih 32%. Unutar kritične zone se nalazi 5

poduzeća ili 23%. Raspon zdravih poduzeća se za cijelo promatrano razdoblje kreće u postocima od 36% do 50% odnosno u prosijeku njih 45%. U „sivoj zoni“ se u prosjeku nalazi 35% poduzeća dok je velika mogućnost stečaja pomoću ovog modela predviđena za prosječno 19% promatranih poduzeća.

4.5. Zmijewski model

Financijski podatci potrebni za izračun Zmijewski modela su: neto dobit (eng. Net profit), ukupna imovina (eng. Total asset), ukupne obveze (eng. Total liabilities), ukupna kratkotrajna imovina (eng. Total current asset) i kratkoročne obveze (eng. Current liabilities).

Jednadžba ovog modela (4) glasi:

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

Dobiveni podatci su zatim uvršteni u izraz za dobivanje odluke prema modelu:

$\text{Vjerojatnost stečaja} = 1/(1+\exp^{(\text{-Zmijevski score})})$

te su rezultati iskazani na slici 3. Ovaj model ima granicu od 0,5 odnosno 50%. Ako je dobivena vjerojatnost manja od 0,5 riječ je o zdravoj firmi, a ako je vjerojatnost veća od 0,5 riječ je o poduzeću koje ima velike šanse za stečaj.

Uzorak hrvatskih poduzeća	2011	2012	2013	2014	2015
AMADEUS M.A.J., D.O.O.	**0.180**	**0.240**	**0.213**	**0.240**	**0.347**
FENJER D.O.O.	**0.465**	**0.466**	**0.433**	**0.491**	**0.531**
INOX BRAMAR D.O.O.	**0.438**	**0.296**	**0.296**	**0.351**	**0.425**
INOX CENTAR SESVETE D.O.O.	**0.518**	**0.497**	**0.518**	**0.629**	**0.753**
INSTRUMENTARIA, D.D.	**0.189**	**0.324**	**0.286**	**0.433**	**0.535**
INTERUGOS D.O.O.	**0.278**	**0.271**	**0.249**	**0.207**	**0.384**
JADRAN D.D.	**0.147**	**0.241**	**0.230**	**0.291**	**0.393**
KAMELEON D.O.O.	**0.634**	**0.584**	**0.544**	**0.832**	**0.548**
KUMAL S D.O.O.	**0.315**	**0.770**	**0.873**	**0.819**	**0.829**
METAL REŠETAR D.O.O.	**0.654**	**0.665**	**0.672**	**0.611**	**0.590**
NAVALIA D.O.O.	**0.057**	**0.129**	**0.371**	**0.294**	**0.895**
OPRUGA D.D.	**0.239**	**0.444**	**0.451**	**0.429**	**0.248**
PHOENIX CAPITIS D.O.O.	**0.088**	**0.090**	**0.091**	**0.125**	**0.092**
PROIZVODNJA JAVOR D.O.O.	**0.820**	**0.800**	**0.789**	**0.790**	**0.153**
TEHNO FILTER D.O.O.	**n.a.**	**0.711**	**0.695**	**0.884**	**0.394**
ULJANIK TESU, D. D.	**0.827**	**0.866**	**0.835**	**0.980**	**0.993**
UNO-MARKETING - D.O.O.	**0.193**	**0.136**	**0.135**	**0.878**	**0.388**
V & V D.O.O.	**0.536**	**0.476**	**0.506**	**0.988**	**0.981**
VITEK D.O.O.	**0.524**	**0.558**	**0.619**	**0.987**	**1.000**
ZIT D.O.O.	**0.146**	**0.989**	**0.319**	**0.414**	**0.422**
ZM-ELEMES D.O.O.	**0.257**	**0.624**	**0.624**	**0.795**	**1.000**
ZRINSKI AG D.O.O.	**0.054**	**0.083**	**0.094**	**0.214**	**0.363**
PROSJEČNA VRIJEDNOST	**0.360**	**0.466**	**0.447**	**0.576**	**0.557**

Slika 3. Rezultati Zmijewskog modela

Izvor: izrada Autora

Postotak točnosti razvrstavanja poduzeća pomoću Zmijewski modela dan je u tablici 18.

Tablica 18. Postotak točnosti razvrstavanja Zmijewski modela na uzorku od 22 financijski nestabilna poduzeća

ZMIJEWSKI MODEL	GODINE PRIJE STEČAJA				
	2011	2012	2013	2014	2015
Stabilno poduzeće	14	13	12	11	11
Poduzeće kojem prijeti stečaj	8	9	10	11	11
Ukupno	22	22	22	22	22
Stabilno poduzeće	64%	59%	55%	50%	50%
Poduzeće kojem prijeti stečaj	36%	41%	45%	50%	50%
Ukupno	100%	100%	100%	100%	100%

Izvor: izrada Autora

Ovaj model je nešto lošije predvidio stečaj od prethodno analiziranog Altmanovog modela. Naime, 2015. godine kada je nastupio stečaj za poduzeća iz uzorka Zmijewski model je predvidio velike šanse za stečaj za 11 od 22 poduzeća što predstavlja postotak od 50%. Isto toliko je predvidio stabilnih poduzeća. Kao i slučaju prethodnog modela i Zmijewski model daje iste rezultate za 2014. i 2015. godinu odnosno za godinu u kojoj je nastupio stečaj i za godinu koja prethodi stečaju. U 2011. godini je predviđen stečaj za 8 poduzeća odnosno za njih 36%.

Kontrolna grupa zdravih poduzeća ima slijedeću točnost razvrstavanja prikazanu u tablici 19.

Tablica 19. Postotak točnosti razvrstavanja Zmijewski modela na uzorku od 22 financijski stabilna poduzeća

ZMIJEWSKI MODEL	GODINE PRIJE STEČAJA				
	2011	2012	2013	2014	2015
Stabilno poduzeće	16	15	17	19	17
Poduzeće kojem prijeti stečaj	6	7	5	3	5
Ukupno	22	22	22	22	22
Stabilno poduzeće	73%	68%	77%	86%	77%
Poduzeće kojem prijeti stečaj	27%	32%	23%	14%	23%
Ukupno	100%	100%	100%	100%	100%

Izvor: izrada Autora

Unutar kontrolne skupine 77% poduzeća je svrstano u skupinu zdravih poduzeća u 2015. godini dok je taj postotak za 2014. godinu čak i veći za 9 postotnih poena odnosno iznosi 86%. Slijedom navedenog da se zaključiti da Zmijewski model ima nešto slabije kriterije za određivanje mogućnosti stečaja od prethodnog modela. Razlog tome među ostalim može biti i manji broj parametara odnosno financijskih pokazatelja koje ovaj model promatra prilikom izračuna jednadžbe.

4.6. Kralicek DF model

Kralicekov DF model koristi slijedeće financijske podatke potrebne za izračun: čisti novčani tok (eng. Net cash flow), Ukupne obveze (eng. Total liabilities), ukupna imovina (eng. Total asset), EBIT, Ukupni prihodi (eng. Total revenues), Zalihe (eng. Stocks), Poslovni prihodi

(eng. Operating revenues). Za potrebe izračuna čistog novčanog toka korištena je slijedeća formula (Šodan, 2016):

Čisti novčani tok = EBIT + amortizacija = EBITDA

Jednadžba DF modela (5) glasi:

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

Dobivene vrijednosti su iskazane na slici 4.

Uzorak hrvatskih poduzeća	2011	2012	2013	2014	2015
AMADEUS M.A.J., D.O.O.	0.684	0.637	1.278	0.755	-1.529
FENJER D.O.O.	0.532	-1.326	1.507	0.207	1.138
INOX BRAMAR D.O.O.	-2.677	-0.636	-2.034	-0.617	-0.194
INOX CENTAR SESVETE D.O.O.	0.915	0.478	0.233	-0.487	-1.649
INSTRUMENTARIA, D.D.	1.273	2.330	1.719	2.508	-0.260
INTERUGOS D.O.O.	0.796	1.236	0.746	-0.586	-2.009
JADRAN D.D.	0.278	-1.248	-0.810	-0.411	-1.479
KAMELEON D.O.O.	1.995	2.198	1.876	-1.316	-0.411
KUMAL S D.O.O.	0.828	-3.329	-3.091	-8.836	-5.060
METAL REŠETAR D.O.O.	0.815	0.853	0.405	-0.459	0.472
NAVALIA D.O.O.	2.084	-0.250	-1.995	0.874	-13.180
OPRUGA D.D.	0.252	0.571	-0.212	-0.761	-1.232
PHOENIX CAPITIS D.O.O.	1.552	1.236	1.867	-1.884	0.628
PROIZVODNJA JAVOR D.O.O.	0.061	0.434	1.040	2.026	0.466
TEHNO FILTER D.O.O.	1.410	0.538	0.533	-1.956	3.371
ULJANIK TESU, D. D.	-0.793	0.236	1.252	-2.731	-3.021
UNO-MARKETING - D.O.O.	0.875	2.885	1.169	-7.925	0.353
V & V D.O.O.	0.776	0.710	0.714	-6.250	-2.295
VITEK D.O.O.	1.130	1.111	0.829	-6.319	-8.103
ZIT D.O.O.	1.306	-0.007	0.250	1.399	0.531
ZM-ELEMES D.O.O.	2.923	0.629	1.117	-6.139	-21.911
ZRINSKI AG D.O.O.	2.747	1.226	3.841	-0.399	-1.477
PROSJEČNA VRIJEDNOST	**0.898**	**0.478**	**0.556**	**-1.787**	**-2.584**

Slika 4. Rezultati Kralicek DF modela

Izvor: izrada Autora

Ukoliko se dobiveni podatci razvrstaju prema kritičnim vrijednostima za DF pokazatelj dobiva se slijedeći postotak točnosti iskazan u tablici 20.

Tablica 20. Postotak točnosti razvrstavanja Kralicek modela na uzorku od 22 financijski nestabilna poduzeća

KRALICEK MODEL	GODINE PRIJE STEČAJA				
	2011	2012	2013	2014	2015
Izvrsna	0	0	1	0	1
Vrlo dobra	2	2	0	1	0
Dobra	2	1	4	1	0
Osrednja	5	4	5	1	1
Loša	8	8	5	2	5
Početak insolventnosti	3	1	2	1	0
Umjerena insolventnost	1	3	2	7	3
Izrazita insolventnost	1	3	3	9	12
Ukupno	22	22	22	22	22

Izvrsna	0%	0%	5%	0%	5%
Vrlo dobra	9%	9%	0%	5%	0%
Dobra	9%	5%	18%	5%	0%
Osrednja	23%	18%	23%	5%	5%
Loša	36%	36%	23%	9%	23%
Početak insolventnosti	14%	5%	9%	5%	0%
Umjerena insolventnost	5%	14%	9%	32%	14%
Izrazita insolventnost	5%	14%	14%	41%	55%
Ukupno	100%	100%	100%	100%	100%

Izvor: izrada Autora

S obzirom da su kritične vrijednosti za DF model stupnjevane na 8 razina za potrebe analize ovog pokazatelja odnosno usporedbe s drugim modelima podatke dobivene za vrijednosti pokazatelja koji se kreću od početka insolventnosti do izrazite insolventnosti će se grupirati kako bi modeli bili usporedivi. Uzimajući u obzir tu činjenicu dobiva se podatak da je za 15 poduzeća u 2015. godini predviđena insolventnost ili početak insolventnosti odnosno za njih 68%. Isti podatak za 2014. godinu koja prethodi stečaju iznosi 17 odnosno čak 77%. Što je veća udaljenost od godine stvarnog stečaja postotak opada te je u 2011. godini predviđena izrazita insolventnost odnosno početak insolventnosti za samo 5 promatranih poduzeća odnosno za njih 23%. Usporedba s kontrolnom skupinom zdravih poduzeća dana je u tablici 21.

Tablica 21. Postotak točnosti razvrstavanja Kralicek modela na uzorku od 22 financijski stabilna poduzeća

KRALICEK MODEL	GODINE PRIJE STEČAJA				
	2011	2012	2013	2014	2015
Izvrsna	7	7	7	4	5
Vrlo dobra	1	0	1	4	2
Dobra	2	0	3	4	6
Osrednja	3	6	4	2	1
Loša	3	5	3	5	6
Početak insolventnosti	1	2	2	0	0
Umjerena insolventnost	3	1	2	1	2
Izrazita insolventnost	2	1	0	2	0
	22	22	22	22	22

Izvrsna	32%	32%	32%	18%	23%
Vrlo dobra	5%	0%	5%	18%	9%
Dobra	9%	0%	14%	18%	27%
Osrednja	14%	27%	18%	9%	5%
Loša	14%	23%	14%	23%	27%
Početak insolventnosti	5%	9%	9%	0%	0%
Umjerena insolventnost	14%	5%	9%	5%	9%
Izrazita insolventnost	9%	5%	0%	9%	0%
	100%	100%	100%	100%	100%

Izvor: izrada Autora

Unutar ove skupine promatranih poduzeća njih 23% ima izvrsnu financijsku stabilnost u 2015. godini. Ukoliko se proširi pojam zdravog poduzeća na financijsku stabilnost od izvrsne do loše jer je ipak riječ o financijski stabilnim poduzećima dobivamo broj od 20 financijski stabilnih poduzeća što iznosi visokih 91%. Prosječno je 18,2 zdravih poduzeća unutar cijelog promatranog perioda od 2011. – 2015. godine što iznosi 82,7%.

4.7. Belak i Aljinović Barać BEX indeks

BEX indeks koristi slijedeće financijske podatke potrebne za izračun: Neto poslovna dobit (eng. Net operating profit), Vlastiti kapital (eng. Equity), cijena kapitala (eng. Capital cost) koja je za potrebe BEX modela aproksimirana stopom kamate na vezanu štednju u bankama od 4% (Šodan, 2016). Ukupne obveze (eng. Total liabilities), ukupna aktiva (eng. Total asset), radni kapital (eng. Working capital), EBIT, EBITDA.

Uvrštavanjem navedenih parametara u jednadžba BEX indeksa (6) dobivaju se vrijednosti koje su iskazane na slici 5.

Uzorak hrvatskih poduzeća	2011	2012	2013	2014	2015
AMADEUS M.A.J., D.O.O.	-0.479	-0.494	0.299	-0.240	-3.363
FENJER D.O.O.	1.070	-0.418	2.190	0.099	-0.032
INOX BRAMAR D.O.O.	-3.462	-2.099	-3.437	-2.350	-1.726
INOX CENTAR SESVETE D.O.O.	-0.990	-1.497	-1.790	-4.964	-10.766
INSTRUMENTARIA, D.D.	0.095	0.425	-0.361	0.976	-1.773
INTERUGOS D.O.O.	0.271	0.760	0.331	-1.059	-3.662
JADRAN D.D.	-0.408	-2.708	-2.153	-1.865	-3.593
KAMELEON D.O.O.	12.827	12.504	7.498	-48.105	11.350
KUMAL S D.O.O.	-0.009	-14.044	-390.450	-21.045	-28.951
METAL REŠETAR D.O.O.	0.140	0.944	-1.035	-2.863	-0.452
NAVALIA D.O.O.	1.132	-1.274	-3.481	-0.179	-30.279
OPRUGA D.D.	-0.603	0.396	-0.750	-1.432	-1.424
PHOENIX CAPITIS D.O.O.	0.427	0.158	0.191	-1.171	0.317
PROIZVODNJA JAVOR D.O.O.	164.311	365.251	12.664	6.556	-0.321
TEHNO FILTER D.O.O.	1.907	0.392	0.730	109.571	15.711
ULJANIK TESU, D. D.	-30.455	35.708	2.377	11.896	5.573
UNO-MARKETING - D.O.O.	0.456	2.749	0.474	-23.790	0.013
V & V D.O.O.	0.202	0.156	0.157	88.334	9.443
VITEK D.O.O.	0.906	0.562	0.142	35.713	9.115
ZIT D.O.O.	0.203	-8.311	-3.152	1.269	-0.560
ZM-ELEMES D.O.O.	7.517	0.412	0.372	-17.401	17.081
ZRINSKI AG D.O.O.	2.931	0.871	3.502	-1.725	-3.671
PROSJEČNA VRIJEDNOST	**7.181**	**17.747**	**-17.076**	**5.738**	**-0.999**

Slika 5. Rezultati BEX indeksa

Izvor: izrada Autora

Ukoliko se dobiveni podatci razvrstaju prema kritičnim vrijednostima za ovaj pokazatelj dobiva se slijedeći postotak točnosti iskazan u tablici 22.

Tablica 22. Postotak točnosti razvrstavanja BEX indeksa na uzorku od 22 financijski nestabilna poduzeća

BEX INDEKS	GODINE PRIJE STEČAJA				
	2011	2012	2013	2014	2015
Svjetska klasa	0	0	0	0	0
Kandidat za svjetsku klasu	3	3	2	5	5
Izvrsno	0	0	0	0	1
Vrlo dobro	1	1	3	0	0
Dobro	3	0	0	1	0
Granično područje	8	10	8	2	2
Loše	7	8	9	14	14
Ukupno	22	22	22	22	22

Svjetska klasa	0%	0%	0%	0%	0%
Kandidat za svjetsku klasu	14%	14%	9%	23%	23%
Izvrsno	0%	0%	0%	0%	5%
Vrlo dobro	5%	5%	14%	0%	0%
Dobro	14%	0%	0%	5%	0%
Granično područje	36%	45%	36%	9%	9%
Loše	32%	36%	41%	64%	64%
Ukupno	100%	100%	100%	100%	100%

Izvor: izrada Autora

Evidentno je da je BEX indeks identificirao 64% promatrana poduzeća kao loša odnosno poduzeća kojima je ugrožena egzistencija te se ovaj model prema prognozi točnosti može svrstati neposredno iza Altmanovog modela. I kod ovog modela prognoza za godinu prije samog stečaja (2014) je identična prognozi na sam dan stečaja i također iznosi 64%.

Ukoliko se promatraju pojedinačno godine unutar cijelog perioda od 2011. do 2015. godine, BEX indeks je za svaku godinu predvidio postotak financijske nestabilnosti u rasponu od 32% do 64% što predstavlja uspješan rezultat predviđanja. Nesporno je da se u ovoj skupini poduzeća nalaze i ona koja pripadaju prema ovom modelu u kandidate za svjetsku klasu i to u rasponu od 14% do 23% za cijelo promatrano razdoblje. Razlog se može djelomično objasniti i postavkama varijable ex_2 koja stavlja u odnos neto poslovnu dobit / (vlastiti kapital x cijena) te će se u slučaju neto poslovnog gubitka i negativnog vlastitog kapitala dobiti pozitivna vrijednost koja će utjecati na konačan rezultat BEX indeksa.

U svom radu Keglević Kozjak et al. (2014) daju kritiku na BEX indeks u dva aspekta. Smatraju da je uzorak razvijen na uzorku velikih poduzeća koja kotiraju na Zagrebačkoj burzi te nije primjenjiv na sva poduzeća. Drugo, ističu da utjecaj varijable ex_2 nije jasan kod

poduzeća koja posluju s gubicima i imaju negativan vlastiti kapital te je konačni utjecaj na BEX indeks pozitivan i samim tim pogrešan.

Treba istaći da je model BEX indeks prvenstveno namijenjen procjeni poslovne izvrsnosti, a u ovom radu se koristi za procjenu financijske nestabilnosti.

Kontrolna skupina zdravih poduzeća je prikazana u tablici 23.

Tablica 23. Postotak točnosti razvrstavanja BEX indeksa na uzorku od 22 financijski stabilna poduzeća

BEX INDEKS	GODINE PRIJE STEČAJA				
	2011	2012	2013	2014	2015
Svjetska klasa	0	0	0	1	1
Kandidat za svjetsku klasu	4	6	7	2	2
Izvrsno	4	1	3	3	2
Vrlo dobro	2	4	1	6	8
Dobro	3	4	5	2	2
Granično područje	6	2	4	5	6
Loše	3	5	2	3	1
Ukupno	22	22	22	22	22

Svjetska klasa	0%	0%	0%	5%	5%
Kandidat za svjetsku klasu	18%	27%	32%	9%	9%
Izvrsno	18%	5%	14%	14%	9%
Vrlo dobro	9%	18%	5%	27%	36%
Dobro	14%	18%	23%	9%	9%
Granično područje	27%	9%	18%	23%	27%
Loše	14%	23%	9%	14%	5%
Ukupno	100%	100%	100%	100%	100%

Izvor: izrada Autora

Rezultati kontrolne skupine poduzeća su rezultirala klasificiranjem čak 96% poduzeća kao financijski stabilnih u 2015. godini što je iznimno uspješna klasifikacija. Od promatranih poduzeća u toj godini čak 3 poduzeća pripadaju ili svjetskoj klasi ili kandidatu za svjetsku klasu što iznosi 14%. Ostala poduzeća su klasificirana po skupinama od izvrsne do granične financijske stabilnosti. Samo 5% poduzeća u 2015. godini su klasificirana kao financijski nestabilna poduzeća dok je u godinama prije od 2011. do 2014. taj postotak nešto veći i kreće se u rasponu od 9% do 23%.

4.8. Pervan i Filipović FP RATING model

U ovom radu je također trebao biti testiran i hrvatski model predviđanja (in)solventnosti, FP RATING®, autora Pervana i Filipovića. Međutim, s obzirom da referentne vrijednosti modela nisu javno dostupne niti je iste moguće dobiti od autora, FP rating nije moguće usporediti s odabranim analiziranim modelima. Sam izračun modela FP rating na uzorku od 22 insolventna poduzeća je napravljen te su rezultati dani na slici broj 6. Model je izračunat jednadžbom (7) izuzev što je podatak zadržane dobiti u varijabli X_2 aproksimiran sa neto dobiti kao kod Altmanovog modela. Godina 2011. se ne uzima u razmatranje s obzirom da financijski pokazatelj X_5 unutar modela u brojniku ima promjenu obrtnog kapitala (X_5 – Novčani operativni potencijal = EBITDA - ΔObrtni kapital / ukupan prihod), a isti nije dostupan za tu godinu.

Uzorak hrvatskih poduzeća	2012	2013	2014	2015
AMADEUS M.A.J., D.O.O.	**1.616**	**0.103**	**-0.436**	**0.130**
FENJER D.O.O.	**-0.008**	**-0.126**	**-0.533**	**-14.583**
INOX BRAMAR D.O.O.	**-0.237**	**-0.379**	**-0.312**	**-1.918**
INOX CENTAR SESVETE D.O.O.	**-1.280**	**-0.144**	**-0.019**	**-0.753**
INSTRUMENTARIA, D.D.	**-0.109**	**-0.333**	**-0.343**	**-0.111**
INTERUGOS D.O.O.	**-0.001**	**-0.069**	**-0.148**	**-0.079**
JADRAN D.D.	**0.368**	**0.412**	**0.809**	**0.033**
KAMELEON D.O.O.	**0.349**	**0.063**	**-0.498**	**-0.442**
KUMAL S D.O.O.	**-0.631**	**-1.009**	**-1.110**	**-1.169**
METAL REŠETAR D.O.O.	**-0.318**	**-0.671**	**-8.683**	**-0.768**
NAVALIA D.O.O.	**0.151**	**0.162**	**-0.215**	**-0.534**
OPRUGA D.D.	**-1.041**	**-1.062**	**-0.745**	**0.148**
PHOENIX CAPITIS D.O.O.	**0.102**	**0.055**	**0.432**	**0.232**
PROIZVODNJA JAVOR D.O.O.	**-3.933**	**-0.433**	**-0.889**	**0.616**
TEHNO FILTER D.O.O.	**n/a**	**-0.197**	**-0.608**	**-0.158**
ULJANIK TESU, D. D.	**-0.704**	**-1.409**	**-1.472**	**-2.025**
UNO-MARKETING - D.O.O.	**0.758**	**0.552**	**-0.740**	**-2.566**
V & V D.O.O.	**-0.239**	**-1.039**	**-0.116**	**-0.774**
VITEK D.O.O.	**0.365**	**-0.573**	**-0.925**	**-2.146**
ZIT D.O.O.	**-0.502**	**-0.249**	**-0.408**	**-0.282**
ZM-ELEMES D.O.O.	**-0.848**	**-0.952**	**-0.498**	**-2.817**
ZRINSKI AG D.O.O.	**0.693**	**0.766**	**0.637**	**0.175**
PROSJEČNA VRIJEDNOST	**-0.260**	**-0.297**	**-0.765**	**-1.354**

Slika 6. Rezultati FP RATING®

Izvor: izrada Autora

Uspoređujući ovaj model s prethodnima iz formule se da zaključiti da će veća negativna vrijednost značiti veću vjerojatnost blokade računa odnosno veću mogućnost insolventnosti poduzeća. Za potrebe ove analize kao referentna vrijednost modela FP rating se može postaviti nula (0). Ukoliko je ta hipoteza točna tada se rezultati ovog modela mogu promatrati na način da pozitivne vrijednosti sugeriraju financijski stabilno poduzeće dok negativne vrijednosti predviđaju insolventnost. Ovo je isključivo presumpcija autora ovog rada te ne isključuje mogućnost da referentna vrijednost za donošenje odluke o razvrstavanju poduzeća unutar ovog modela ne može biti neka druga vrijednost. Imajući na umu ovu činjenicu i uz navedenu pretpostavku o referentnoj vrijednosti model predviđa točnu klasifikaciju za 19 poduzeća odnosno 86% u 2014. godini neposredno prije stečaja te 16 poduzeća u 2015. godini odnosno 73% u godini kada je za ova poduzeća pokrenut stečajni postupak.

Ukupna frekvencija predviđene financijske nestabilnosti u periodu 2011-2015 za 22 poduzeća koja su pokrenula stečaj 2015. godine pomoću FP ratinga uz pretpostavljenu referentnu vrijednost iznosi 63 točno klasificirana poduzeća što daje ukupan postotak uspješnosti od 72%. Rezultati FP rejtinga su dani u tablici 24.

Tablica 24. Postotak točnosti razvrstavanja Pervan i Filipović modela na uzorku od 22 financijski nestabilna poduzeća

FP RATING®	GODINE PRIJE STEČAJA			
	2012	2013	2014	2015
Solventna poduzeća	9	7	3	6
Insolventna poduzeća	13	15	19	16
Ukupno	22	22	22	22
Solventna poduzeća	41%	32%	14%	27%
Insolventna poduzeća	59%	68%	86%	73%
Ukupno	100%	100%	100%	100%

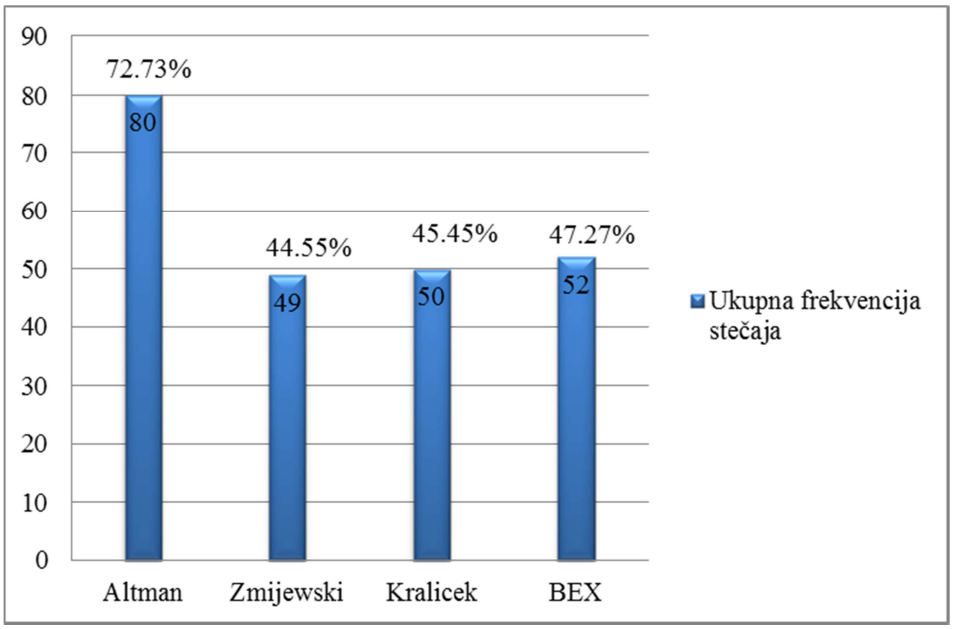
Izvor: izrada Autora

Keglević Kozjak et al. (2014) u svom radu među ostalim analiziraju i FP rating model te smatraju da postoji određena dilema unutar same postavke varijable X_2 odnosno faktora zaduženosti koji se kalkulira kao ukupne obveze / (neto dobitak (gubitak) tekuće godine + zadržani dobitak (preneseni gubitak) + amortizacija). Navodi se da je učinak ove varijable u samom modelu nejasan, što znači da će za poduzeće koje ima negativni pokazatelj X_2 (financijski nestabilnije poduzeće) konačni učinak na vrijednost FP ratinga biti pozitivan zbog

negativnog predznaka u formuli. Nadalje, ističu se da postavljanje ove varijable na nulu u slučaju da je pokazatelj manji od nule nije rješenje jer bi u tom slučaju učinak na vrijednost FP rating bio nula, dok bi za financijski stabilnije poduzeće s pozitivnim pokazateljem učinak na FP rating bio negativan. S obzirom da se ukupna iznesena analiza temelji na presumpciji referentne vrijednosti te u dostupnoj literaturi nije objašnjena ova situacija, u ovom radu se neće uspoređivati vrijednost ovih nalaza sa ostalim odabranim modelima za predviđanje financijske nestabilnosti.

4.9. Sinteza rezultata i analiza efikasnosti modela za predviđanje financijske nestabilnosti poduzeća u Republici Hrvatskoj

Ukupna frekvencija predviđene financijske nestabilnosti po pojedinom modelu za 22 poduzeća koja su pokrenula stečajni postupak 2015. godine je dana na slici broj 7. Najviša frekvencija odnosno najveći rezultat pripada modelu koji je najbolje prognozirao financijsku nestabilnost pojedinog poduzeća u pojedinom razdoblju. Najviši stupanj točne klasifikacije iznosi 80 od 110 mogućih (5 godina pomnoženo sa 22 promatrana poduzeća) odnosno 72,73% za cijeli period od 5 godina prije nastupa stečaja i pripada Altmanovom Z'-score modelu za predviđanje stečaja. BEX indeks ima točan stupanj klasifikacije za 52 od 110 mogućih poduzeća odnosno 47,27%. Između Znijewski modela i Kralicekovog DF modela ovaj potonji ima nešto bolji rezultat predviđanja i to za 0,9 postotnih poena.



Slika 7. Ukupna frekvencija predviđene financijske nestabilnosti u periodu 2011-2015 za 22 poduzeća koja su pokrenula stečaj 2015. godine

Izvor: izrada Autora

Iz ukupnih rezultata dobivenih testiranjem odabranih modela za predviđanje financijskih nestabilnosti na uzorku hrvatskih poduzeća (slika 8) evidentno je da je Altmanova prva modifikacija najprimjerenija za procjenu stečaja odabranog uzorka jer ista daje i najtočniju klasifikaciju za svaku godinu prije nastupa stečaja. U prosjeku svake godine ima 6 točnih procjena više od ostala tri modela. Gledajući Zmijewski i Kralicekov DF model i BEX indeks u prosjeku svaki od njih ima 10 točnih procjena za svaku godinu promatranog perioda. BEX indeks ima prosječno 0,4 točne procjene više u odnosu na Kralicekov model i 0,6 točne procjene više u odnosu na Zmijevski model. Kralicekov DF model ima prosječno 0,2 točne procjene više od Zmijewskog modela. Ova razlika se može smatrati nematerijalnom pa se može tvrditi da sva tri modela imaju jednaku uspješnost klasifikacije solventnih i insolventnih poduzeća.

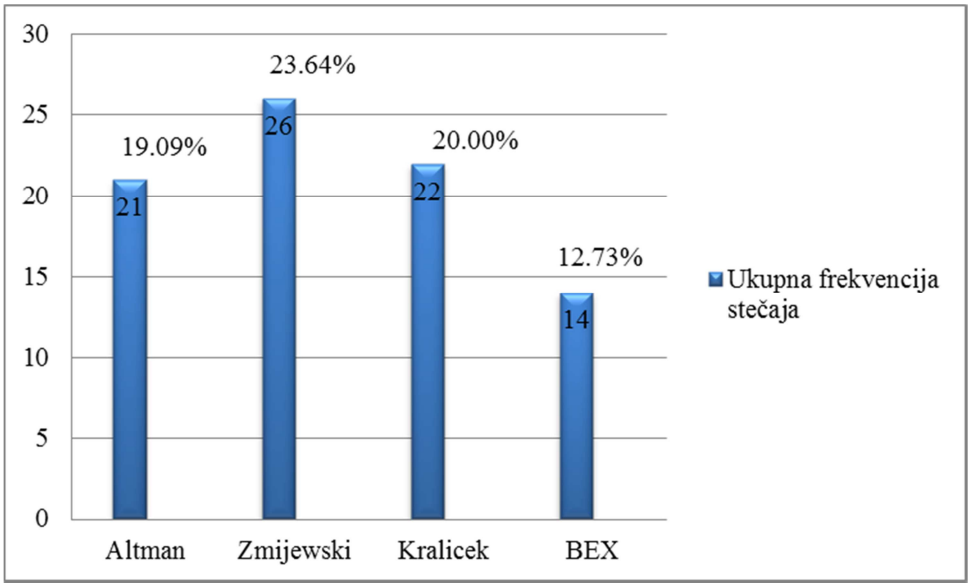
	ALTMANOV MODEL ili Z-score model					ZMIJEWSKI MODEL					KRALICEK MODEL					BEX INDEKS				
Uzorak hrvatskih poduzeća	2011	2012	2013	2014	2015	2011	2012	2013	2014	2015	2011	2012	2013	2014	2015	2011	2012	2013	2014	2015
AMADEUS M.A.J., D.O.O.	Ne	Ne	Ne	Ne	Da	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Da	Da	Da	Ne	Da	Da
FENJER D.O.O.	Ne	Da	Ne	Da	Da	Ne	Ne	Ne	Ne	Da	Ne	Da	Ne	Da	Ne	Ne	Da	Ne	Ne	Da
INOX BRAMAR D.O.O.	Da	Da	Da	Da	Da	Ne	Ne	Ne	Ne	Ne	Da	Da	Da	Da	Da	Da	Da	Da	Da	Da
INOX CENTAR SESVETE D.O.O.	Da	Da	Da	Da	Da	Da	Ne	Da	Da	Da	Ne	Ne	Ne	Da	Da	Da	Da	Da	Da	Da
INSTRUMENTARIA, D.D.	Da	Da	Da	Da	Da	Ne	Ne	Ne	Ne	Da	Ne	Ne	Ne	Ne	Da	Ne	Ne	Da	Ne	Da
INTERUGOS D.O.O.	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Da	Da
JADRAN D.D.	Da	Da	Da	Da	Da	Ne	Ne	Ne	Ne	Ne	Da	Da	Da	Da	Da	Da	Da	Da	Da	Da
KAMELEON D.O.O.	Ne	Ne	Ne	Da	Da	Da	Da	Da	Da	Da	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Da	Ne
KUMAL S D.O.O.	Da	Da	Da	Da	Da	Ne	Da	Da	Da	Da	Ne	Da	Da	Da	Da	Da	Da	Da	Da	Da
METAL REŠETAR D.O.O.	Ne	Da	Da	Da	Da	Da	Da	Da	Da	Da	Ne	Ne	Ne	Da	Ne	Ne	Ne	Da	Da	Da
NAVALIA D.O.O.	Ne	Da	Da	Da	Da	Ne	Ne	Ne	Ne	Da	Ne	Da	Da	Ne	Da	Ne	Da	Da	Da	Da
OPRUGA D.D.	Da	Da	Da	Da	Da	Ne	Ne	Ne	Ne	Ne	Da	Ne	Da	Da	Da	Da	Ne	Da	Da	Da
PHOENIX CAPITIS D.O.O.	Da	Da	Da	Da	Da	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Da	Ne	Ne	Ne	Ne	Da	Ne
PROIZVODNJA JAVOR D.O.O.	Da	Da	Ne	Ne	Ne	Da	Da	Da	Da	Ne	Da	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Da
TEHNO FILTER D.O.O.	Da	Da	Da	Da	Ne	Da	Da	Da	Da	Ne	Ne	Ne	Ne	Da	Ne	Ne	Ne	Ne	Ne	Ne
ULJANIK TESU, D. D.	Da	Da	Da	Da	Da	Da	Da	Da	Da	Da	Da	Da	Ne	Da	Da	Da	Ne	Ne	Ne	Ne
UNO-MARKETING - D.O.O.	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Da	Ne	Ne	Ne	Ne	Da	Ne	Ne	Ne	Ne	Da	Ne
V & V D.O.O.	Ne	Ne	Da	Da	Da	Da	Ne	Da	Da	Da	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Ne	Ne
VITEK D.O.O.	Ne	Ne	Ne	Da	Da	Da	Da	Da	Da	Da	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Ne	Ne
ZIT D.O.O.	Da	Da	Da	Da	Da	Ne	Da	Ne	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Da	Da	Ne	Da
ZM-ELEMES D.O.O.	Ne	Da	Da	Da	Da	Ne	Da	Da	Da	Da	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Da	Ne
ZRINSKI AG D.O.O.	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Ne	Da	Da	Ne	Ne	Ne	Da	Da

Da - model predviđa financijsku nestabilnost; Ne - model predviđa nastavak financijske stabilnosti

Slika 8. Sinteza rezultata testiranja odabranih modela za predviđanje financijskih nestabilnosti na uzorku hrvatskih poduzeća

Izvor: izrada Autora

Dalje u radu se analizira kontrolna skupina zdravih poduzeća unutar promatranog perioda te sinteza rezultata dobivenih definiranim modelima za predviđanje financijske nestabilnosti. Ukupna frekvencija predviđene financijske nestabilnosti po pojedinom modelu za 22 financijski stabilna poduzeća je dana u tablici 9.



Slika 9. Ukupna frekvencija predviđene financijske nestabilnosti u periodu 2011-2015 za 22 financijski stabilna poduzeća

Izvor: izrada Autora

Dobiveni rezultati se kreću od 14 do 26 predviđene buduće financijske nestabilnosti što iznosi u prosjeku 19%. To znači da modeli predviđaju stabilnu financijsku situaciju za čak 81% kontrolnih poduzeća. Postoje male razlike između stranih analiziranih modela tako da se može tvrditi da su sva tri strana modela relativno dobro procijenila financijski stabilna poduzeća. Najbolju procjenu financijski uspješnih poduzeća je dao BEX indeks s visokim postotkom od prosječno 87,27% točnih klasifikacija odnosno ukupna frekvencija točnog klasificiranja iznosi 96 točno klasificiranih poduzeća od ukupno 110 poduzeća za cijeli promatrani period.

Dobiveni rezultati korespondiraju sa početnim pretpostavkama ovog rada međutim potrebno je istaknuti i činjenicu da nisu poznati podaci za 2016. godinu te daljnje kretanje financijske (ne)stabilnosti za promatrana društva kao i činjenicu da ne postoje podatci o tome li je koje društvo imalo u tijeku promatranog perioda manje ili veće financijske probleme te iznašlo načina da iste minimizira i otkloni u većoj ili manjoj mjeri te na taj način anulira početne pretpostavke za nastup stečaja.

5. ZAKLJUČAK

U ovom radu su obrađeni različiti modeli za predviđanje financijske nestabilnosti poduzeća, njihov teorijski dio kao i testiranje odabranih modela. Izabrani su modeli renomiranih autora kako slijedi: Altmanova prva modifikacija Z'-score, Zmijewski model, Kralicek DF model i hrvatski BEX indeks i FP rating model. Iz Amadeus baze je dana 18. studenog 2016. godine odabran uzorak od 44 hrvatska poduzeća proizvodne djelatnosti te su namjernim uzorkom odabrana 22 zdrava, financijski stabilna poduzeća i 22 financijski nestabilna poduzeća koja su započela stečajni postupak tijekom 2015. godine i to u periodu od siječnja do studenog. Zdrava poduzeća su uzeta kao kontrolna skupina kako bi se testirala uspješnost pojedinog modela.

Za velik broj poduzeća prognoziran je mogući stečaj prije nego što je zaista i nastupio kod svih odabranih modela. Najveću točnost klasifikacije između odabranih modela imala je Atlmanova prva modifikacija Z'-score modela dok su BEX indeks, Zmijewski model i Kralicek polučili slične rezultate s tim da je od ova tri modela najuspješniji bio BEX indeks, zatim Kralicekov DF model. Svaki od modela je predvidio stečaj u zadnjoj promatranoj godini poslovanja sa pouzdanosti od minimalno 50% do maksimalno ostvarenih 91%. Hrvatski model FP Rating nije bilo moguće usporediti sa stranim modelima predviđanja financijske nestabilnosti jer u dostupnoj literaturi nema referentne vrijednosti koja bi se koristila kao kriterij razvrstavanja poduzeća na financijski stabilna i nestabilna.

Altmanova prva modifikacija se na izabranom uzorku izdvojila kao iznimno uspješna u predviđanju stečaja hrvatskih proizvodnih poduzeća na temelju dobivenih rezultata te se u potpunosti može primijeniti u redovnom donošenju odluka kako bi se na vrijeme spriječili odnosno minimizirali financijski pokazatelji koji mogu voditi budućoj financijskoj nestabilnosti poduzeća. Neke će se vrijednosti moći u potpunosti izbjeći dok će se druge moći minimizirati, a sve u cilju što uspješnijeg poslovanja poduzeća.

LITERATURA:

1. Altman, E. I. (1968): Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bancruptcy, The Journal of Finance, 23 (4), pp. 589 - 609
2. Altman, E. I., Hotchkiss, E. (2006): Corporate Financial Distress and Bancruptcy, 3. izd., John Wiley and Sons, Hoboken, New Jersey
3. Beaver, W. H. (1966): Financial Ratios as Predictors of Failure, Empirical Research in Accounting: Selected Studies, Supplement to Journal of Accounting Research, pp. 71 – 111
4. Belak, V. i Aljinović Barać, Ž. (2007): Business excellence (Bex) indeks – za procjenu poslovne izvrsnosti tvrtki na tržištu kapitala u Republici Hrvatskoj, Računovodstvo, revizija i financije, br. 10., str. 15. – 25.
5. Belak, V. i Aljinović Barać, Ž: (2008): Tajne tržišta kapitala, Belak Excellens, Zagreb.
6. Belak, V., Božina, A., Brkanić, V., Cirkveni, T., Dremel, N., Guzić, Š., Habek, M., Horvat Jurjec, K., Jurić, Đ., Markota, Lj., Mrša, J., Proklin, M., Trcović, Z., Turković-Jarža, L. i Vuk, J. (2014): Računovodstvo poduzetnika s primjerima knjiženja, 10. izd., RRIF Plus, Zagreb
7. Bureau von Dijk (2017): Amadeus – User guide raspoloživo na: https://help.bvdinfo.com/mergedProjects/64_es/Home.htm, [pristupljeno 19.6.2017.]
8. Cirkveni Filipović, T. (2017): Izvještaj o promjenama kapitala, Računovodstvo, Revizija i Financije, br.2., str. 129. – 138.
9. Deloitte (2009): Međunarodni financijski standard 1 – Prezentacija financijskih izvještaja, raspoloživo na: https://www.iasplus.com/en/standards/ias/ias1, [pristupljeno 22.3.2017.]
10. Fina (2016): Godišnji financijski izvještaji , raspoloživo na : http://www.fina.hr/Default.aspx?sec=915, [pristupljeno 22.3.2017.]
11. Helfert, E.A. (2010): Financial analysis: Tools and techniques, A Guide for Managers, McGraw-Hill, New York

12. Keglević Kozjak, S., Šestanj-Perić, T., Bešvir, B. (2014): Assessment of bankruptcy prediction models' – Applicability in Croatia in An Enterprise Odyssey International Conference Proceedings; University of Zagreb, Faculty of Economics and Business, Zagreb str. 543-561.
13. Narodne novine (2009): Odluka o objavljivanju međunarodnih standarda financijskog izvještavanja, Narodne novine d.d., Zagreb, broj 136
14. Narodne novine (2016): Zakon o izmjenama i dopunama Zakona o računovodstvu, Narodne novine d.d., Zagreb, broj 120
15. Narodne novine (2015): Uredba o izmjenama i dopunama Zakona o računovodstvu, Narodne novine d.d., Zagreb, br. 134
16. Narodne novine (2015): Zakon o računovodstvu, Narodne novine d.d., Zagreb, broj 78
17. Narodne novine (2015): Odluka o objavljivanju hrvatskih standarda financijskog izvještavanja, Narodne novine d.d., Zagreb, broj 86
18. Narodne novine (2016): Pravilnik o strukturi i sadržaju godišnjih financijskih izvještaja, narodne novine d.d., Zagreb, broj 95
19. Pervan, I., Filipović, D. (2010): „FP rating – Model za predviđanje (in)solventnosti poslovnih partnera, Računovodstvo, Revizija i Financije, br.7, str. 92 - 96.
20. Verčić Tkalac, A., Sinčić Ćorić, D., Pološki Vokić, N. (2011): Priručnik za metodologiju istraživačkog rada u društvenim istraživanjima, M.E.P., Zagreb
21. Vidučić, Lj. (2012): Financijski menadžment, 8.izdanje, RRIF Plus, Zagreb
22. Vuk, J. (2013): IX. Izvještaj o novčanom tijeku, Računovodstvo, Revizija i Financije, br.1., str. 193. – 198.
23. Šodan, S. (2016): Financijska analiza poslovanja, Sveučilište u Splitu, Ekonomski fakultet, ak. godina 2015/2016, predavanja br.4.
24. Šodan, S. (2016): Financijska analiza poslovanja, Sveučilište u Splitu, Ekonomski fakultet, ak. godina 2015/2016, predavanja br.10.
25. Zenzerović, R. i Peruško, T. (2006): Kratki osvrt na modele za predviđanje stečaja, Economic research - Ekonomska istraživanja, 19 (2), str. 132 - 151.

26. Zmijewski, M.E. (1984): Methodological issues related to the estimation of financial distress prediction models, Journal of Accounting Research, Vol. 22, pp. 59 – 86

27. Žager, K., Mamić Sačer I., Sever, S. i Žager, L. (2008): Analiza financijskih izvještaja, 2. izd., Masmedia d.o.o., Zagreb

POPIS TABLICA:

Tablica 1. Razvrstavanje poduzetnika sukladno Zakonu o računovodstvu..... 8

Tablica 2. Financijski izvještaji sukladno MRS 1 (u primjeni od 1.1.2010.)..... 9

Tablica 3. Financijski izvještaji sukladno HSFI 1 (u primjeni od 1.1.2016.) 10

Tablica 4. Bilanca u RH prema GFI-POD (u primjeni od 1.1.2016.) 11

Tablica 5. Račun dobiti i gubitka u RH prema GFI-POD (u primjeni od 1.1.2016.)..... 12

Tablica 6. Izvještaj o promjenama kapitala u RH prema GFI-POD (u primjeni od 1.1.2016.)14

Tablica 7. Novčani tijekovi od poslovnih aktivnosti..... 16

Tablica 8. Novčani tijekovi od investicijskih aktivnosti 17

Tablica 9. Novčani tijekovi od financijskih aktivnosti..... 18

Tablica 10. Pogrešno klasificiranje poslovnih subjekata u šest najtočnijih pokazatelja u postotku 21

Tablica 11. Točnost predviđanja stečaja Z-score 24

Tablica 12. Kritične vrijednosti DF pokazatelja 26

Tablica 13. Kritične vrijednosti BEX indeksa 27

Tablica 14. Usporedba formata unutar Amadeus baze podataka sa hrvatskim formatom za bilancu 31

Tablica 15. Usporedba formata unutar Amadeus baze podataka sa hrvatskim formatom za račun dobiti i gubitka..... 32

Tablica 16. Postotak točnosti razvrstavanja Altmanovog modela na uzorku od 22 financijski nestabilna poduzeća..... 35

Tablica 17. Postotak točnosti razvrstavanja Altmanovog modela na uzorku od 22 financijski stabilna poduzeća 35

Tablica 18. Postotak točnosti razvrstavanja Zmijewski modela na uzorku od 22 financijski nestabilna poduzeća..... 37

Tablica 19. Postotak točnosti razvrstavanja Zmijewski modela na uzorku od 22 financijski stabilna poduzeća 38

Tablica 20. Postotak točnosti razvrstavanja Kralicek modela na uzorku od 22 financijski nestabilna poduzeća 40

Tablica 21. Postotak točnosti razvrstavanja Kralicek modela na uzorku od 22 financijski stabilna poduzeća 41

Tablica 22. Postotak točnosti razvrstavanja BEX indeksa na uzorku od 22 financijski nestabilna poduzeća 43

Tablica 23. Postotak točnosti razvrstavanja BEX indeksa na uzorku od 22 financijski stabilna poduzeća 44

Tablica 24. Postotak točnosti razvrstavanja Pervan i Filipović modela na uzorku od 22 financijski nestabilna poduzeća 46

POPIS SLIKA:

Slika 1. Beaverov sustav pokazatelja 22

Slika 2. Rezultati Altmanovog Z'-score modela..... 33

Slika 3. Rezultati Zmijewskog modela 37

Slika 4. Rezultati Kralicek DF modela..... 39

Slika 5. Rezultati BEX indeksa 42

Slika 6. Rezultati FP RATING®..... 45

Slika 7. Ukupna frekvencija predviđene financijske nestabilnosti u periodu 2011-2015 za 22 poduzeća koja su pokrenula stečaj 2015. godine 48

Slika 8. Sinteza rezultata testiranja odabranih modela za predviđanje financijskih nestabilnosti na uzorku hrvatskih poduzeća 49

Slika 9. Ukupna frekvencija predviđene financijske nestabilnosti u periodu 2011-2015 za 22 financijski stabilna poduzeća 50

SAŽETAK

Ključne riječi: Hrvatska, stečaj, predviđanje

Uvijek aktualna tema financijske nestabilnosti: stečaja, insolventnosti koja se obrađuje u raznim znanstvenim djelima navela je i ovog autora da pokuša iznaći optimalni model za predviđanje financijske nestabilnosti na poduzećima u Republici Hrvatskoj. Dan je pregled najistaknutijih modela prema godinama njihova razvoja te su dana i ograničenja pojedinih modela. Rezultati su dobiveni korištenjem povijesnih financijskih informacija poduzeća iz proizvodnog sektora Republike Hrvatske koji su dobiveni selekcijom iz Amadeus baze – europske baze podataka. U ovom radu su analizirana 22 poduzeća koja su tijekom 2015. godine započela stečajni postupak te su kao kontrolna skupina uzeta još 22 zdrava poduzeća iz iste skupine proizvodnih društava. Na temelju dobivenih rezultata može se zaključiti da svi analizirani modeli više ili manje uspješno predviđaju financijsku nestabilnost i to nekoliko godina prije samog stečaja. Uspoređujući rezultate i frekvenciju točnog predviđanja najbolji rezultat u predviđanju financijske nestabilnosti odnosno stečaja polučila je Altmanova prva modifikacija modela iz 1993. godine koja je napravljena za poduzeća čije dionice ne kotiraju na burzi. Altmanova prva modifikacija predviđa financijsku nestabilnost s točnošću od 91% za prve dvije godine prije početka stečaja dok je ukupni broj točno klasificiranih poduzeća za cijeli promatrani period ukupno 80 od 110 mogućih (5 godina pomnoženo sa 22 promatrana poduzeća) što predstavlja točnost od 73%. Ostali testirani modeli imaju manju uspješnost prognoze, ali isto predviđaju financijsku nestabilnost s manjom točnošću od prvog modela u godinama prije nastupa samog stečaja. Točnost predviđanja BEX indeksa, Kralicek i Zmijewski modela je redom 52, 50 i 49 točno klasificiranih poduzeća što predstavlja prosjek od 45% - 47%.

Koristeći Altmanovu prvu modifikaciju modela hrvatski menadžeri i dioničari mogu dobiti rano upozorenje o mogućoj financijskoj nestabilnosti i pravovremeno poduzeti akcije kako bi se otklonio ili minimizirao uzrok sa što većim uspjehom.

SUMMARY

Key words: Croatia, bankruptcy, prediction

Permanent actual theme of financial distress: bankruptcy, insolvency proceedings, which is a main object in different scientific papers and researches, encouraged this author to try to find an optimal model for bankruptcy prediction on the entities in Republic of Croatia. Review of the eminent bankruptcy prediction models is given along with critical observation for some models. Results are calculated using historical finance information of selected companies from manufacturing sector in Republic of Croatia extracted from Amadeus data base – European data base. In this work 22 companies that started insolvency proceeding in 2015 are analysed along with another 22 stabile manufacturing companies as control sample. Based on obtained results it is concluded that all models can predict insolvency proceeding with more or less success in several years before the insolvency proceeding actually accrue. By comparing the outcome and frequency of accurate prediction the best result in predicting bankruptcy is given by Revised Altman model modified in 1993 for manufacturing non-listed companies. This model predicts with accuracy of 91% in first two years before insolvency proceeding took place and the total frequency for whole period of 5 years before insolvency proceedings is also the highest, total of 80 accurate predictions of 110 (5 years multiply by 22 companies) which represents 73%. Other two models have lower accuracy but still are capable to predict financial distress in years before it took place. The accuracy of BEX indeks, Kralicek DF and Zmijewski model is total accurate prediction of 52, 50 and 49 companies which represents 45% - 47%.

Using Revised Altman model Croatian managers and shareholders can have an early warning of possible finance distress and take actions so that appropriate turnaround activities can be implemented much more successfully.