USPJEŠNOST ALTMANOVA Z SCORE-A KAO POKAZATELJA ZA PREDVIĐANJE BANKROTA MEĐU ODABRANIM IZLISTANIM PODUZEĆIMA U REPUBLICI HRVATSKOJ

Grdović, Krševan

Master's thesis / Diplomski rad

2021

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:124:165685

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

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

DIPLOMSKI RAD

USPJEŠNOST ALTMANOVA Z SCORE-A KAO POKAZATELJA ZA PREDVIĐANJE BANKROTA MEĐU ODABRANIM IZLISTANIM PODUZEĆIMA U REPUBLICI HRVATSKOJ

Mentorica:

Prof. dr. sc. Branka Ramljak

Student:

Krševan Grdović, 2190982

Split, rujan, 2021.

TABLICA SADRŽAJA:

1. UVOD 1

1.1. Problem istraživanja 1

1.2. Predmet istraživanja 3

1.3. Istraživačke hipoteze 4

1.4. Ciljevi istraživanja 5

1.5. Metode istraživanja 6

1.6. Doprinosi istraživanja 7

1.7. Struktura diplomskog rada 8

2. BANKROT, PROBLEM LIKVIDNOSTI, INSOLVENTNOST 9

2.2. Računovodstveno značenje bankrota 15

2.2.1. Prvi scenarij – zdravo poduzeće 15

2.2.2. Drugi scenarij – nepravilan omjer duga i glavnice 16

2.2.3. Treći scenarij – poduzeće u stečaju 16

3. ALTMANOV Z SCORE 20

3.1. Povijest Altmanova Z score modela 20

3.2. Definiranje Altmanova Z score modela 21

3.2.1. Rezultati 22

3.2.2. Preciznost rezultata predviđanja 22

3.3. Drugi modeli za predviđanje bankrota 25

3.3.1. Williama H. Beawer 25

3.3.2. Roberta O. Edmistera 26

3.3.3. Peter Kralicek 28

3.3.4. BEX Indeks 29

3.3.5. FP RATING 31

4. EMPIRIJSKO ISTRAŽIVANJE PODUZEĆA PO INDUSTRIJAMA 32

4.3. Definiranje uzorka 32

4.2. Izračun Altmanova Z-score-a za ukupno gospodarstvo 36

4.2.1. Metodologija rada 36

4.2.2. Rezultati izračunavanja Altmanova Z-score-a 38

4.2.3. Zaključak testiranja pokazatelja za cjelokupno gospodarstvo 41

4.3. Izračun Altmanova Z score-a po industrijama 42

4.3.1. Industrija Brodogradnje 42

4.3.2. Prerađivačka industrija 43

4.3.3. Energetski sektor 44
4.3.4. Industrije hotelijerstva 45
4.3.5. Građevinska industrija 46
4.3.6. Zaključak testiranja pokazatelja po industrijama 47
5. ZAKLJUČAK 48
SAŽETAK 49
SUMMARY 50
POPIS LITERATURE 51
POPIS TABLICA 54
POPIS SLIKA 55

1. UVOD

1.1. Problem istraživanja

Puno je opcija i načina na koji se može uložiti i u što se može uložiti. Kao mladi ekonomisti koji pristupaju tržištu rada, svakodnevno imamo dvojbe, hoćemo li uložiti, kada ćemo početi ulagati, u što ulagati? Jedna od opcija ulaganje je u postojeća ili rastuća poduzeća, što ima jako velik broj oblika ulaganja. Međutim, prema svakom od tih oblika ulaganja imali bismo puno manje averzije ili bismo imali puno veću motivaciju da uložimo kada bismo imali vjerodostojne mjere za predviđanje ili barem smanjenje rizika.

Druga perspektiva koja predstavlja problem istraživanja jest situacija u kojoj poduzeće ne posjeduje sredstva za podmirivanje svakodnevnih obveza, tzv. problem likvidnosti. „Razlozi mogu biti manjak tekućih, likvidnih sredstava, nedovoljno dobro upravljanje radnim kapitalom, slab obrtaj kratkotrajne imovine, neadekvatna struktura i politike poduzeća, problemi industrijske grane i sl.“, (Časopis Mirakul, 2020). Gradacijom dolazimo do situacije u kojoj se pojavljuje prezaduženost poduzeća. Naime situacija u kojoj poduzeće u bilanci ima veće obveze od imovine isto to poduzeće čini insolventnim, što znači da ono nije u mogućnosti platiti sve svoje obveze ni kada bi se one plaćale ukupnom imovinom, što je naravno zadnja slamka spasa, jer velik dio te imovine nije likvidan i potrebno je jako puno vremena vjerovnicima da se od imovine naplate. Predviđanjem takve situacije dovoljno vremena unaprijed omogućava vodstvu poduzeća priliku za restrukturiranjem i poduzimanjem preventivnih djelovanja.

Kada bi barem postojala nekakva čarobna formula koja bi predvidjela probleme s likvidnošću i prezaduženošću, te ponudila investitorima tehniku smanjenja rizika portfelja.

Prvi model ('čarobna formula') u kojemu počinje primjena multivarijatnog pristupa za izračunavanje rizičnosti poslovanja poduzeća bio je Altmanov Z-score model (Altman E. I., 1968). Model je to koji predviđa stečaj unutar slijedeće dvije godine.

Altmanov Z score predstavlja sintetički pokazatelj što znači da je formula ponderirani zbroj više pojedinačnih pokazatelja koji se sintetiziraju u cjelinu u svrhu svojevrsne ocjene poslovanja poduzeća.

Originalni Altmanov Z-score model (1968.) stvoren za potrebe američkog tržišta prvotno je bio namijenjen poslovnim subjektima koji kotiraju na burzi, te se nalaze unutar sektora proizvodnje. Kasnijim revidiranjem originalnog modela konstruiran je Z'-score model (1983) namijenjen poslovnim subjektima koji ne kotiraju na burzi, te Z"-score model (1983.) koji je namijenjen analizi poslovnih subjekata izvan sektora proizvodnje. **S obzirom da je navedeni model pozitivno prihvaćen od strane akademske zajednice, a i privatnog sektora cilj ovog istraživanja je testirati uspješnost Altmanovog Z"-score modela na poduzećima u RH koja kotiraju na burzi.** Model koji je nazvao "Z-score", predviđao je stečaj ukoliko se dobiveni rezultat za analizirani poslovni subjekt nalazio ispod granične vrijednosti koja ukazuje na stečaj. Ovaj model imao je visoku sposobnost predviđanja stečaja (Altman 2003). Analizirani uzorak godinu dana prije proglašenja istog imao je 95%- tnu točnost. Međutim, sposobnost ispravnog predviđanja znatno se smanjila s vremenskim pomakom, tako je iznosila 72% dvije godine prije proglašenja stečaja, 48%, 29% i 36% točnosti predviđanja za tri, četiri i pet godina prije stečaja.

S obzirom da je model inicijalno napravljen da bi koristio poduzećima koja su izlistana na burzi, uzeti će se po nekoliko kompanija iz nekoliko industrija koje možemo naći na ZSE (Zagreb Stock Exchange), a bitno je to da će svaka industrija imati barem jedno poduzeće koje je u stečaju čime će se testirati Altmanova mjera za predviđanje stečaja (bankrota). Rezultati ovog istraživanja koriste širokom spektru sudionika financijskog tržišta od menadžmenta kojemu će olakšati planiranje poslovanja, preko dioničara koji će imati signale za kupnju i prodaju udjela sve do zaposlenika koji mogu dobiti kakav takav uvid u financije okruženja u kojem provodi trećinu dana.

1.2. Predmet istraživanja

Prethodnim poglavljem razrađen je problem koji je sveprisutan kod donošenja odluka prilikom investiranja. Stoga možemo reći da naš predmet istraživanja proizlazi iz problema istraživanja. Ako ovim istraživanjem dobijemo pozitivne rezultate, možemo reći kako su naše istraživanje i pretpostavka potvrđeni. Altmanov Z score multivarijatna je formula za mjerenje financijskog 'zdravlja'. Prihvaćena je od strane svih sudionika financijske industrije, analitičara, investitora, konzultanata, bankara, revizora i ostalih, budući da nudi izvrsnu mjeru za procjenu financijske stabilnosti subjekta. Eksplicitno mjeri subjektovu likvidnost, profitabilnost, solventnost i produktivnost, sve aspekte korporativnih performansi. Dovodi do jednoznačnog zaključka i pouzdana je (Eidleman, 2007). Ovim istraživanjem pokušat će se dokazati da Altmanovom formulom možemo predvidjeti s visokom pouzdanošću, godinu dana prije, te nešto nižom pouzdanošću dvije godine prije bankrota. Bankrot je prema stečajnom zakonu (NN 71/15) drugim imenom insolventnost, tj. situacija u kojoj se nalazi poduzeće koje nije u mogućnosti trajno podmiriti svoje obveze, obustavlja plaćanja te ima obveze više od ukupne imovine. Istraživanje će se segmentirati prema industrijama da bismo imali usporedive i nepristrane rezultate, te će se nastojati za svaku industriju u uzorku koristiti jedno poduzeće koje ima status 'u stečaju'.

1.3. Istraživačke hipoteze

Kako bi se prezentirana problematika istražila što kvalitetnije te ukazalo na bitne značajke primjene prezentiranih modela i alata prakse ključno je testirati iste kroz istraživačke hipoteze

H1..Altmanov Z score uspješan je pokazatelj u predviđanju stečaja u RH

Ovu tezu testirat će se u sklopu empirijskog dijela rada, te će se na temelju dobivenih rezultata donijeti zaključak.t

H2…Altmanov Z score jednako je primjenjiv na sve industrije

Ovu tezu također testiramo kroz empirijski dio, međutim potrebno je segmentirati podatke obrade prema industrijama i dobivene rezultate analize usporediti. Svaka od industrija koje će biti u uzorku ima različite cikluse, metode vrednovanja zaliha, vrijeme potrebno za proizvodnju, financiranje itd., što uvelike utječe na interpretaciju rezultata Altmanova Z score-a i motiv je za testiranje hipoteze.

Do zaključaka doći će se nakon obrade financijskih izvještaja odabranih poduzeća i literature koju koristimo kao izvore za pisanje rada.

1.4. Ciljevi istraživanja

Glavni istraživački ciljevi jesu prikazati i analizirati računovodstveno i zakonodavno značenje bankrota poduzeća te analizirati uspješnost Altmanova Z scorea u predviđanju poslovnog neuspjeha (bankrota), dakle želimo odgovoriti na istraživačka pitanja.

Dodatno, ovim radom nastojimo potvrditi da tržište ima svoja pravila i da se ne ponaša nasumično, te da je uz pomoć pravih alata u glavnini slučajeva moguće utjecati na ishod što daje doprinos ukupnoj financijskoj zajednici

1.5. Metode istraživanja

U radu će se koristiti sljedeće metode koje je opisao Zelenika (1992):

- Metoda analize je postupak znanstvenog istraživanja i objašnjenja stvarnosti putem raščlanjivanja složenih misaonih tvorevina (pojmova, sudova i zaključaka) na njihove jednostavnije sastavne dijelove i elemente. Metoda sinteze je postupak znanstvenog istraživanja i objašnjavanja stvarnosti putem spajanja, sastavljanja jednostavnih misaonih tvorevina u složene i složenijih u još složenije, povezujući izdvojene elemente, pojave, procese i odnose u jedinstvenu cjelinu.
- Induktivna metoda je sistematska i dosljedna primjena induktivnog načina zaključivanja u kojem se na temelju pojedinačnih ili posebnih činjenica dolazi do zaključka o općem sudu. Deduktivna metoda je sustavna i dosljedna primjena deduktivnog načina zaključivanja u kojem se iz općih stavova izvode posebni, pojedinačni, iz općih postavki dolazi se do konkretnih pojedinačnih zaključaka, iz jedne ili više tvrdnji izvodi se neka nova tvrdnja koja proizlazi iz prethodnih tvrdnji.
- Metoda dokazivanja je misaono-sadržajni postupak kojim se utvrđuje istinitost pojedinih spoznaja, stavova ili teorija.
- Metoda deskripcije je postupak jednostavnog opisivanja ili ocrtavanja činjenica, procesa i predmeta u prirodi i društvu te njihovih empirijskih potvrđivanja odnosa i veza, ali bez znanstvenog tumačenja i objašnjavanja.
- Metoda kompilacije je metoda kojom se preuzimaju tuđi rezultati istraživačkih, znanstvenih i empirijskih radova.
- Metoda klasifikacije je metoda kojom se vrši sistemska i potpuna podjela općeg pojma na posebne.
- Metoda komparacije predstavlja postupak uspoređivanja istih ili sličnih činjenica, pojava, predmeta i utvrđivanja njihovih sličnosti i razlika.

1.6. Doprinosi istraživanja

Ovim istraživanjem nastoji se istražiti, objasniti i empirijski utvrditi primjenjivost mjera za predviđanje bankrota. Redovito kontroliranje i kvantificiranje rizika može pravovremeno pružiti upraviteljima poduzeća znakove i signale za promjene i restrukturiranje kako bi se poduzeće održalo zdravim i spasilo od poslovnog neuspjeha.

Rezultati istraživanja pokazati će kolika je uspješnost Altmanova Z score u predviđanju poslovnog neuspjeha, te će se nakon obrade podataka donijeti zaključak koje industrije imaju bolje šanse u predviđanju bankrota korištenjem Altamanova Z score-a.

1.7. Struktura diplomskog rada

Ovaj diplomski rad sastojati će se od 7 cjelina, uključujući uvod i zaključak.

U uvodnom dijelu rada definirati će se problem i ciljevi istraživanja, te će biti navedene metode koje će se koristiti u svrhu kvalitetnog provođenja istraživanja, kao i sama struktura rada.

Drugi dio rada obuhvaća definiranje bankrota iz više perspektiva, zakonodavno i računovodstveno, istražiti će se razloge zbog kojih dolazi do bankrota, postoje li neki signali koji to nagoviještaju te koje su posljedice istog.

Treći dio rada detaljno objašnjava Altmanov Z score od samog začetka, njegov razvoj sve do finalne verzije modela, te njegovu primjenu danas, s čime završavamo deskriptivni dio rada.

Četvrti dio rada, empirijske je prirode. U ovom dijelu analizirati će se podatci. Financijski izvještaji koje nalazimo na stranici *Zagreb Stock Exchange* posložiti će nam za izračune Altmanova Z scora za sva poduzeća iz uzorka, na temelju čega donosimo finalni zaključak.

U petom dijelu povezujemo empirijski i deskriptivni dio rada u jedno, te donosimo zaključak.

2. BANKROT, PROBLEM LIKVIDNOSTI, INSOLVENTNOST

Bankrot iliti stečaj u poslovnom okruženju nezavidna je pozicija u kojoj se može pronaći svako društvo ili pojedinac, fizička ili pravna osoba. U slijedećih nekoliko stranica pokušati ćemo razjasniti što je to stečaj kako do njega dolazi i što on predstavlja pred zakonom.

2.1. Zakonodavni okviri poslovnog bankrota

Pojedini autori smatraju da porijeklo riječi bankrot dolazi od latinskih riječi bancus (sto) i ruptus (razbijen), dok drugi, od talijanske fraze Banco rotto (banko roto = trula klupa) ili od francuskih banque i route koje znače trag/otisak na stolu, a koje su se u praksi još u rimsko doba povezivale sa novčanom propast

U domaćoj literaturi umjesto bankrota, upotrebljavaju se termini stečaj i likvidacija. Bankrot je pravno regulirana situacija kada jedno poduzeće nije u stanju isplatiti svoje dospjele obaveze prema vjerovnicima. Tada sud pokreće predstečajni ili stečajni postupak, čiji je **cilj** namirenje vjerovnika, ali u novije vrijeme i reorganizaciju poduzeća dužnika (Prema poslovnoj studiji Duvnjak, V., 2010)

Osnovni cilj bankrota je zaštita ugovora, odnosno zaštita privatne imovine vjerovnika. U ekonomskom smislu, prijetnja bankrotom je disciplinsko sredstvo koje potiče menadžment na što bolje vođenje poduzeća.

Ciljevi predstečajnoga i stečajnoga postupka

Članak 2.

(1) Predstečajni postupak provodi se radi uređivanja pravnoga položaja dužnika i njegova odnosa prema vjerovnicima i održavanja njegove djelatnosti.

(2) Stečajni postupak provodi se radi skupnoga namirenja vjerovnika stečajnoga dužnika, unovčenjem njegove imovine i podjelom prikupljenih sredstava vjerovnicima. Poštenim dužnicima pojedincima omogućit će se oslobođenje od preostalih obveza prema odredbama glave IX. ovoga Zakona. (Stečajni zakon, NN 71/15, 104/17)

Radi razumijevanja teme, pojasniti ćemo nad kime se može provesti predstečajni i stečajni postupak:

Predstečajni i stečajni dužnik (isječak)

Članak 3.

Predstečajni i stečajni postupak **mogu se** provesti nad **pravnom osobom i nad imovinom dužnika pojedinca**, ako zakonom nije drukčije određeno. Dužnikom pojedincem u smislu ovoga Zakona smatra se fizička osoba obveznik poreza na dohodak od samostalne djelatnosti prema odredbama Zakona o porezu na dohodak i fizička osoba obveznik poreza na dobit prema odredbama Zakona o porezu na dobit.

(2) Predstečajni i stečajni postupak **ne mogu se** provesti nad:

− Republikom Hrvatskom i fondovima koji se financiraju iz proračuna Republike Hrvatske

− Hrvatskim zavodom za zdravstveno osiguranje

− Hrvatskim zavodom za mirovinsko osiguranje i

− jedinicama lokalne i područne (regionalne) samouprave. (Stečajni zakon, NN 71/15, 104/17)

Pravno gledajući, razlozi zbog kojih dolazi do ovakvih procesa mogu biti različiti, stečajni zakon ih navodi kako slijedi:

Predstečajni razlog

Članak 4. (NN 104/17)

(1) Predstečajni postupak može se otvoriti ako sud utvrdi postojanje prijeteće nesposobnosti za plaćanje. Prijeteća nesposobnost za plaćanje postoji ako predlagatelj učini vjerojatnim da dužnik svoje postojeće obveze neće moći ispuniti po dospijeću.

(2) Smatrat će se da postoji prijeteća nesposobnost za plaćanje ako u trenutku podnošenja prijedloga nisu nastale okolnosti zbog kojih se smatra da je dužnik postao trajnije nesposoban za plaćanje i ako:

− dužnik u Očevidniku redoslijeda osnova za plaćanje koji vodi Financijska agencija ima jednu ili više evidentiranih neizvršenih osnova za plaćanje koje je trebalo, na temelju valjanih osnova za plaćanje, bez daljnjeg pristanka dužnika naplatiti s bilo kojeg od njegovih računa ili

− duže od 30 dana kasni s isplatom plaće koja radniku pripada prema ugovoru o radu, pravilniku o radu, kolektivnom ugovoru ili posebnom propisu odnosno prema drugom aktu kojim se uređuju obveze poslodavca prema radniku ili

− u roku od 30 dana ne uplati doprinose i poreze prema plaći iz podstavka 2. ovoga stavka, računajući od dana kada je radniku bio dužan isplatiti plaću.

(3) Postojanje okolnosti iz stavka 2. podstavka 1. ovoga članka dokazuje se potvrdom Financijske agencije. Financijska agencija dužna je na zahtjev dužnika ili vjerovnika bez odgode izdati takvu potvrdu. U protivnom Financijska agencija odgovara za štetu koju bi podnositelj zahtjeva zbog toga mogao pretrpjeti.

(4) Postojanje okolnosti iz stavka 2. podstavaka 2. i 3. ovoga članka dokazuje se obračunom neisplaćene plaće koji je sastavljen u skladu s propisima. Uz obračun podnositelj prijedloga dužan je dostaviti potvrdu Ministarstva financija – Porezne uprave kojom se potvrđuje da je dostavljeni obračun o neisplati plaće sastavljen u skladu s propisima. (Stečajni zakon, NN 71/15, 104/17)

Stečajni razlozi

Članak 5. (NN 104/17)

(1) Stečajni postupak može se otvoriti ako sud utvrdi postojanje stečajnoga razloga.

(2) Stečajni razlozi su **nesposobnost za plaćanje i prezaduženost**.

(3) Dužnik može predložiti otvaranje stečajnoga postupka i ako učini vjerojatnim da svoje već postojeće obveze neće moći ispuniti po dospijeću (prijeteća nesposobnost za plaćanje).

(4) Na prijeteću nesposobnost za plaćanje kao stečajni razlog na odgovarajući način primjenjuju se odredbe članka 4. ovoga Zakona. (Stečajni zakon, NN 71/15, 104/17)

S obzirom da zakon kao osnovne razloge za otvaranje stečaja navodi nesposobnost za plaćanje i prezaduženost, u nastavnu su dodatno pojašnjeni prethodni termini.

Nesposobnost za plaćanje

Članak 6.

(1) Nesposobnost za plaćanje postoji ako dužnik ne može trajnije ispunjavati svoje dospjele novčane obveze. Okolnost da je dužnik namirio ili da može namiriti u cijelosti ili djelomično tražbine nekih vjerovnika ne znači da je sposoban za plaćanje.

(2) Smatrat će se da je dužnik nesposoban za plaćanje:

− ako u Očevidniku redoslijeda osnova za plaćanje koji vodi Financijska agencija ima jednu ili više evidentiranih neizvršenih osnova za plaćanje u razdoblju dužem od 60 dana koje je trebalo,

na temelju valjanih osnova za plaćanje, bez daljnjeg pristanka dužnika naplatiti s bilo kojeg od njegovih računa

− ako nije isplatio tri uzastopne plaće koje radniku pripadaju prema ugovoru o radu, pravilniku o radu, kolektivnom ugovoru ili posebnom propisu odnosno prema drugom aktu kojim se uređuju obveze poslodavca prema radniku.

(3) Odredba stavka 2. ovoga članka neće se primijeniti ako dužnik tijekom prethodnoga postupka namiri sve tražbine koje je na temelju valjanih osnova za plaćanje trebalo naplatiti sa svih njegovih računa ili ako dođe do pristupanja dugu. Namirenje tražbina dužnik može dokazivati samo javnom ili javno ovjerovljenom ispravom ili potvrdom Financijske agencije.

(4) Postojanje okolnosti iz stavka 2. podstavka 1. ovoga članka dokazuje se potvrdom Financijske agencije. Financijska agencija dužna je na zahtjev dužnika ili vjerovnika bez odgode izdati takvu potvrdu. U protivnom Financijska agencija odgovara za štetu koju bi podnositelj zahtjeva zbog toga mogao pretrpjeti.

(5) Postojanje okolnosti iz stavka 2. podstavka 2. ovoga članka dokazuje se obračunom neisplaćene plaće koji je sastavljen u skladu s propisima. Uz obračun podnositelj prijedloga dužan je dostaviti potvrdu Ministarstva financija − Porezne uprave kojom se potvrđuje da je dostavljeni obračun o neisplati plaće sastavljen u skladu s propisima. (Stečajni zakon, NN 71/15, 104/17)

Prezaduženost

Članak 7.

(1) Prezaduženost postoji ako je imovina dužnika pravne osobe manja od postojećih obveza.

(2) Odredba stavka 1. ovoga članka neće se primijeniti:

− ako se prema okolnostima slučaja (razvojnom programu, raspoloživim izvorima sredstava, vrsti imovine, pribavljenim osiguranjima i slično) osnovano može pretpostaviti da će dužnik pravna osoba nastavljanjem poslovanja uredno ispunjavati svoje obveze po dospijeću

− ako za obveze društva osoba solidarno odgovara član društva fizička osoba nad čijom imovinom nije pokrenut ili otvoren stečajni postupak. (Stečajni zakon, NN 71/15, 104/17)

Opstanak poduzeća je ozbiljno ugrožen u uvjetima kad je stečajna vrijednost poduzeća manja od ukupne vrijednosti dugovanja. Ukoliko se opadanje performansi poduzeća nastavi, dovest će do bankrota. Bankrot predstavlja rješavanje ili reorganizaciju pod zaštitom zakona. Mnogi su razlozi za bankrot poduzeća:

Primarni uzroci bankrota preduzeća	u %
Visoki troškovi poslovanja	40,5
Industrijska grana i konkurencija	22,3
Niski profiti	11,6
Katastrofa	6,3
Zanemarivanje ključnih faktora uspjeha	3,9
Strah od promjena	3,8
Dugovi	3,6
Nedovoljan kapital	3,2
Mala prodaja	2,2
Nenaplaćena potraživanja	0,8

Slika 1: Primarni uzroci bankrota

Izvor: poslovna studija Duvnjak, V. (2010)

Sumarno, predstečajna nagodba i stečaj (bankrot, likvidacija) postupci su do kojih dolazi radi uređivanja pravnoga položaja dužnika i njegova odnosa prema vjerovnicima i održavanja njegove djelatnosti u slučaju predstečajne nagodbe, te radi skupnoga namirenja vjerovnika stečajnoga dužnika, unovčenjem njegove imovine i podjelom prikupljenih sredstava vjerovnicima u slučaju stečaja. Prethodni postupci mogu se provesti nad svakom pravnom i fizičkom osobom, a ne mogu se provesti nad Republikom Hrvatskom i fondovima koji se financiraju iz proračuna Republike Hrvatske, HZZO-om, HZMO-om, te jedinicama lokalne i područne uprave. Kao osnovni stečajni razlozi navode se nesposobnost za plaćanje i prezaduženost prema vjerovnicima, a unutar samih kompanija, visoki troškovi i kombinacija lošeg managementa i konkurencije.

Ako ćemo gledati budućnost možemo reći da je bitno imati dobar stečajni zakon jer on može omogućiti inicijative za investitore u boljoj selekciji i efikasnijem monitoringu, čime se osigurava efikasnije upravljanje imovinom poduzeća. Cilj postupka bankrota je likvidacija ekonomski neefikasnih poduzeća i reorganizacija poduzeća tokom krize (poslovna studija Duvnjak, V., 2010).

2.2. Računovodstveno značenje bankrota

U prethodnom poglavlju objasnjen je bankrot na pravnoj osnovi. U ovom poglavlju pojasniti će se značenje bankrota s računovodstvene osnove, kako do njega dolazi gledajući stavke iz bilance i računa dobiti i gubitka.

Bilanca kao jedan od temeljnih ako ne i najvažniji financijski izvještaj u osnovi se djeli na Aktivu i Pasivu, a Pasiva se dalje dijeli na Kapital i Obveze. Bitno je to imati na umu jer će se u nastavku shematski prikazati nekoliko scenarija temeljenih upravo na ovoj podjeli.

Prvi scenarij biti će shema bilance poduzeća koje ima zdrav odnos glavnice i duga

Drugi scenarij biti će shema bilance poduzeća koje je van referentnih granica

Treći scenarij biti će shema poduzeća u stečaju.

2.2.1. Prvi scenarij – zdravo poduzeće

Prema Belak, V. (1995) gornja granica stupnja zaduženosti treba iznositi 50%, odnosno udjel obveza u ukupnoj imovini trebao bi biti maksimalno 50%. To se može shematski prikazati na slijedeći način, Slikom 2:

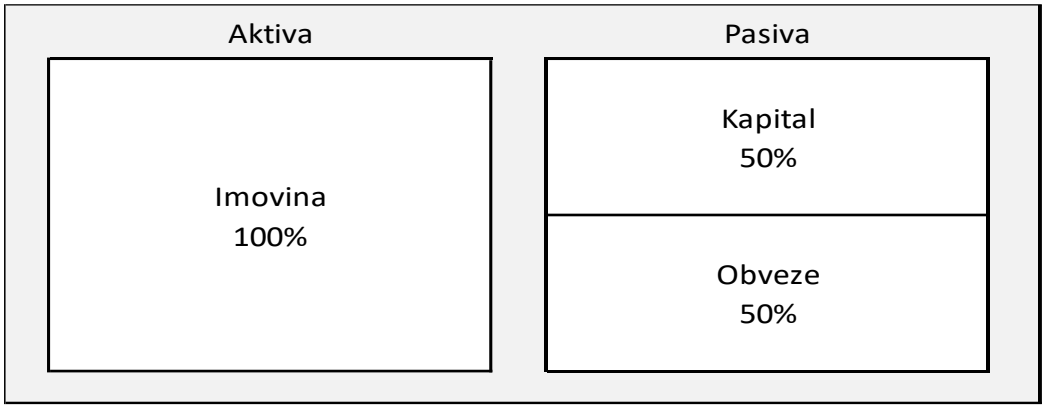

Slika 2: Shema bilance zdravog poduzeća

Izrada autora prema skripti za vježbe 'Menadžersko računovodstvo' (2016)

Ovakav prikaz bilance konzervativan je prikaz jer malo koje poduzeće ima omjer 50:50
U stvarnosti, realniji prikaz biti će prikaz u nastavku:

2.2.2. Drugi scenarij – nepravilan omjer duga i glavnice

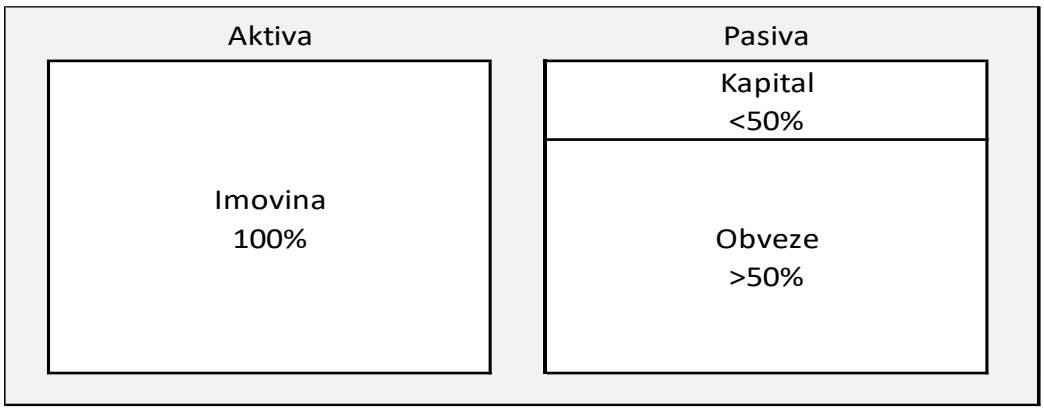

Slika 3: Shema bilance lošeg poduzeća

Izrada autora prema skripti za vježbe 'Menadžersko računovodstvo' (2016.)

Dok struka nalaže da je za poduzeće idealan omjer duga i glavnice 1:1, u stvarnosti ćemo vrlo vjerojatnije naići na oblik pasive iz prethodne sheme, gdje se tolerira sve do omjera 2:1 u korist duga, što je prikazano Slikom 3.

2.2.3. Treći scenarij – poduzeće u stečaju

Poduzeće koje se prezaduži i dovede do situacije gdje mu cijelu pasivu čine obveze, odlazi u stečaj. Slijedeći shematski prikaz, Slika 4, preslikava takvu situaciju:

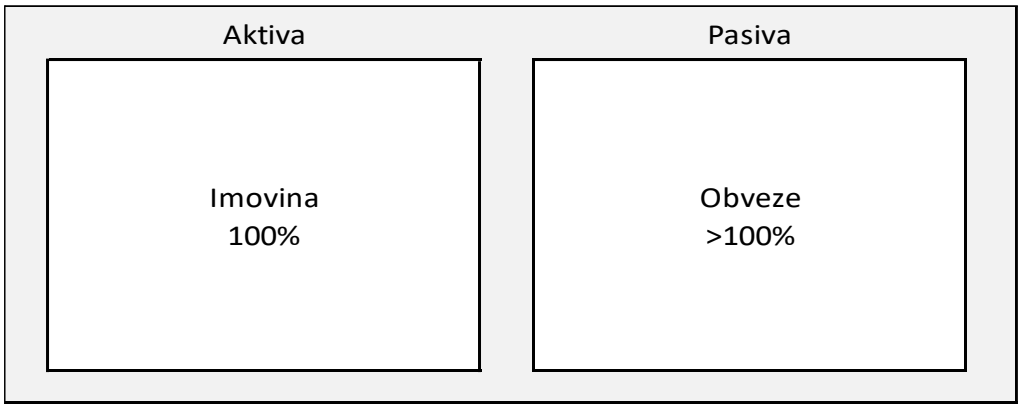

Slika 4: Shema bilance poduzeća u stečaju

Izrada autora prema skripti za vježbe 'Menadžersko računovodstvo' (2016.)

Za ovakvo poduzeće kažemo da je insolventno, odnosno da nema dovoljne imovine u vlasništvu da pokrije sve obveze u odrađenom trenutku.

Za bolje razumijevanje teme na stvarnom primjeru prikazati ćemo kretanje glavnih stavki bilance kod dva tipa poduzeća, prvi je zdravo poduzeće, drugi je poduzeće u stečaju. Za zdravo poduzeće odabrali smo najveću članicu *C.I.O.S. grupacije, CE-ZA-R d.o.o.*, centar za reciklažu. S druge strane u filtar *Fininfo* stranice stavili smo *društva u stečaju* i kao reprezentativno za ovu temu, odabrali smo društvo *Hangar 18 d.o.o.* Društvo se bavi prodajom informatičke i gaming opreme, a 2019. godine nakon bezuspješne predstečajne nagodbe otišlo u stečaj.

Slika 5 prikazuje bilancu društva CE-ZA-R d.o.o., dok ćemo Slikom 6 pokušati približiti kako izgleda bilanca društva *Hangar 18 d.o.o.* u stečaju.

FININFO

	2018.	2019.	2020.
Dugotrajna imovina	82.718.039	284.744.275	274.621.762
Nematerijalna imovina	0	49.734	24.911
Materijalna imovina	45.570.389	258.630.697	261.277.108
Zemljišta	1.499.592	86.910.857	87.052.297
Građevinski objekti	13.660.136	84.813.126	74.382.522
Postrojenja i oprema	21.870.024	45.846.253	54.407.993
Ostala materijalna imovina	8.540.637	41.060.461	45.434.296
Financijska imovina	36.124.898	25.147.196	12.345.439
Dani zajmovi, depoziti i sl. (dugotrajni)	36.124.898	25.147.196	12.345.439
Potraživanja	141.544	402.941	353.225
Odgođena porezna imovina	881.208	513.707	621.079
Kratkotrajna imovina	396.895.733	239.861.570	440.990.368
Zalihe	69.197.268	48.076.487	96.100.395
Sirovine i materijal	30.406.899	15.261.320	22.825.346
Proizvodnja u tijeku	303.991	388.270	359.310
Gotovi proizvodi i trgovačka roba	19.491.330	24.019.474	65.738.457
Ostale zalihe	18.995.048	8.407.423	7.177.282
Potraživanja	93.728.069	66.017.765	182.461.831
Potraživanja od kupaca	74.026.766	39.362.744	52.344.167
Ostala potraživanja	19.701.303	26.655.021	130.117.664
Financijska imovina	226.486.329	121.573.672	158.771.570
Dani zajmovi, depoziti i sl. (kratkotrajni)	225.234.552	116.303.502	150.390.384
Ostala kratkotrajna financijska imovina	1.251.777	5.270.170	8.381.186
Novac	7.484.067	4.193.646	3.656.572
Plaćeni troškovi budućeg razdoblja i obračunati prihodi	1.132.964	2.190.506	11.319.184
Ukupno aktiva	**480.746.736**	**526.796.351**	**726.931.314**
Kapital i rezerve	**201.918.126**	**201.020.175**	**332.868.143**
Temeljni kapital	84.324.000	84.344.000	84.344.000
Kapitalne rezerve	23.439.400	23.439.400	23.439.400
Rezerve iz dobiti, revalorizacijske rezerve i rezerve fer vrijednosti	192	192	192
Zadržana dobit/preneseni gubici	31.010.253	20.255.329	91.826.349
Dobit/gubitak poslovne godine	63.144.281	72.981.254	133.258.202
Rezerviranja	12.486.135	7.831.734	11.163.660
Dugoročne obveze	**97.028.208**	**110.492.582**	**127.870.357**
Kamatonosne (financijske) obveze (dugoročne)	97.028.208	110.492.582	127.870.357
Kratkoročne obveze	**164.054.899**	**201.496.204**	**242.490.046**
Kamatonosne (financijske) obveze (kratkoročne)	47.954.581	81.885.576	75.547.126
Obveze prema dobavljačima (kratkoročne)	60.660.155	51.151.350	59.567.211
Obveze prema zaposlenicima	2.446.932	2.396.279	2.778.056
Ostale kratkoročne obveze	52.993.231	66.062.999	104.597.653
Odgođeno plaćanje troškova i prihod budućeg razdoblja	5.259.368	5.955.656	12.539.108
Ukupno pasiva	**480.746.736**	**526.796.351**	**726.931.314**

Slika 5: Bilanca društva CE-ZA-R d.o.o.

Izvor: Fininfo

Ukupna Aktiva (2020) - 726.931.314 **(100%)**

Ukupni Kapital rezerve i rezerviranja (2020) – 344.031.803 **(47,33%)**

Ukupne Obveze i odgođena plaćanja (2020) – 382.899.511 **(52,67%)**

Nalaz kalkulacije je slijedeći: **Društvo ima gotovo školski primjer omjera duga i glavnice**

FININFO

	2018.	2019.	2020.
Dugotrajna imovina	31.249.556	43.696.211	13.293.521
Nematerijalna imovina	14.728.427	17.903.159	9.207.613
Materijalna imovina	8.096.109	16.432.317	3.915.908
Zemljišta	674.360	674.360	674.360
Građevinski objekti	6.488.931	8.292.425	2.010.196
Postrojenja i oprema	469.688	7.465.532	1.231.352
Ostala materijalna imovina	463.130	0	0
Financijska imovina	8.425.020	9.360.735	170.000
Udjeli, dionice i ostali vrijednosni papiri (dugotrajni)	8.425.020	9.190.735	0
Dani zajmovi, depoziti i sl. (dugotrajni)	0	170.000	170.000
Kratkotrajna imovina	102.959.240	100.185.753	35.878.240
Zalihe	63.358.406	52.685.491	21.004.123
Sirovine i materijal	2.619.275	2.664.533	0
Proizvodnja u tijeku	5.640.038	49.214	0
Gotovi proizvodi i trgovačka roba	30.719.263	49.971.744	17.586.211
Ostale zalihe	24.379.830	0	3.417.912
Potraživanja	28.623.702	42.093.242	10.599.428
Potraživanja od kupaca	25.250.761	21.988.804	9.363.337
Ostala potraživanja	3.372.941	20.104.438	1.236.091
Financijska imovina	947.434	1.244.638	3.090.698
Dani zajmovi, depoziti i sl. (kratkotrajni)	947.434	1.244.638	3.090.698
Novac	10.029.698	4.162.382	1.183.991
Plaćeni troškovi budućeg razdoblja i obračunati prihodi	0	11.277	0
Ukupno aktiva	**134.208.796**	**143.893.241**	**49.171.761**
Kapital i rezerve	**25.354.162**	**-79.388.832**	**-175.439.023**
Temeljni kapital	11.981.000	11.981.000	11.981.000
Zadržana dobit/preneseni gubici	7.632.712	13.373.163	-92.209.797
Dobit/gubitak poslovne godine	5.740.450	-104.742.995	-95.210.226
Dugoročne obveze	**25.023.031**	**18.942.045**	**198.926.107**
Kamatonosne (financijske) obveze (dugoročne)	25.023.031	18.942.045	198.926.107
Kratkoročne obveze	**83.829.914**	**204.286.818**	**25.684.677**
Kamatonosne (financijske) obveze (kratkoročne)	67.429.546	179.813.300	172.351
Obveze prema dobavljačima (kratkoročne)	14.403.501	18.725.453	20.294.579
Obveze prema zaposlenicima	485.737	338.190	31.261
Ostale kratkoročne obveze	1.511.130	5.409.875	5.186.486
Odgođeno plaćanje troškova i prihod budućeg razdoblja	1.689	53.210	0
Ukupno pasiva	**134.208.796**	**143.893.241**	**49.171.761**

Slika 6: Bilanca društva Hangar 18 d.o.o.

Izvor: Fininfo

Ukupna Aktiva (2019) – 49.171.761 **(100%)**

Ukupni Kapital i rezerve (2019) – -79.388.832 **(-55,17%)**

Ukupne Obveze (2019) – 223.282.073 **(155,17%)**

Nalaz kalkulacije je slijedeći: **Društvo ima dug veći od imovine, društvo je insolventno.**

Odabrali smo 2019. godinu jer je to godina u kojoj je promijenjen status društva iz *'aktivno'* u *'u stečaju'*.

3. ALTMANOV Z SCORE

3.1. Povijest Altmanova Z score modela

Davne 1967. godine, profesor sa sveučilišta Stern, Edward Altman, razvio je model kasnije nazvan Altmanov Z-score. Model je objavljen godinu dana kasnije, u rujnu 1968. godine, (simbolično, u čast Altmanu ovaj će rad biti predan u rujnu, bez obzira što je gotov ranije) u časopisu *The Journal of Finance*, u članku *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy* na svega 20-ak stranica ispisana je povijest. U tom članku predstavio je Altmanov Z-score za predviđanje bankrota. Altmanov Z-score se još uvijek koristi za predviđanje vjerojatnosti da će tvrtka otići u stečaj/bankrot u roku od dvije godine. Prvi je koji je upotrijebio multivarijatnu analizu financijskih pokazatelja, jer se dotad nije koristila statistička analiza na taj način.

Početni model osmišljen je za izlistane proizvodne kompanije s imovinom većom od 1 milijun dolara

Originalni model = 1.2A + 1.4B + 3.3C + 0.6D + 1.0E **(1)**

Nakon toga, 1983., razvija dodatna dva tipa Altmanova Z-score-a A i B

A model je razvijen kako bi bio primjenjiv i na proizvodna poduzeća koja ne kotiraju na burzi. Razlikovao se od originalnog modela po faktoru X_4, gdje se više nije nalazila tržišna vrijednost glavnice već knjigovodstvena, te također po ponderima svakog faktora.

A model Z = 0,717 X_1 + 0,847 X_2 + 3,107 X_3 + 0,42 X_4 + 0,998 X_5 **(2)**

No i taj model nije bio dovoljno dobar jer je uključivao samo proizvodna poduzeća. Tada na scenu stupa B model Altmanova Z-score-a. B model izbacio je iz računice faktor X_5 jer su postojala velika odstupanja po određenim industrijama.

B model Z = 6,56 X_1 + 3,26 X_2 + 6,72 X_3 + 1,05 X_4 **(3)**

3.2. Definiranje Altmanova Z score modela

Slikom 7 prikazane su komponente svakog faktora iz originalnog modela Altmanova Z-score-a

Naziv pokazatelja	Brojnik	Nazivnik
X_1	Radni kapital	Aktiva
X_2	Zadržana dobit	Aktiva
X_3	EBIT	Aktiva
X_4	Tržišna vrijednost glavnice	Obveze
X_5	Prihodi	Obveze

Slika 7: Pokazatelji iz Altmanova Z-score-a

Izvor: Isječak iz časopisa Serdarušić.com

Radni kapital/ukupna imovina (X_1) mjera je likvidne imovine u odnosu na veličinu poduzeća. Razlika između kratkoročne imovine i kratkoročnih obveza predstavlja obrtni kapital. Tekuća imovina poduzeća uključuje gotovinu u blagajni, potraživanja i zalihe. Altmanovo istraživanje smatra taj omjer korisniji od ostalih pokazatelja likvidnosti, poput trenutnog omjera ili brzog omjera likvidnosti. (Altman, 2000; Chuvakhin & Germania, 2003)

Zadržana dobit/ukupna imovina (X2) predstavlja mjeru odražavanja kumulativne profitabilnosti koja u obzir uzima starost tvrtke, kao i zaradu.

Zarada prije kamata i poreza/ukupne imovine (X3), ovaj omjer procjenjuje raspoloživu novčanu ponudu za raspodjele vjerovnicima, vladi i dioničarima. Altman (2000) klasificira omjer kao superiorna mjera profitabilnosti koja je bolja od novčanog toka.

Altman (2000, 2002) definira tržišnu vrijednost kapitala ili tržišnu kapitalizaciju, kao **zbroj povlaštenih i običnih dionica ili omjer tržišne vrijednosti kapitala** i knjigovodstvene vrijednosti ukupnog dugovanja **(X4)**. Altman vjeruje da je ovaj omjer učinkovitiji prediktor financijskih poteškoća od neto vrijednosti/ukupnog duga (knjigovodstvene vrijednosti).

Sljedeći omjer, **prihodi/ukupna imovina (X5)** označava standardnu mjeru prihoda koja nažalost varira od jedne industrije do druge. Ipak, omjer je pokazatelj učinkovitog korištenja

imovine poduzeća za ostvarivanje prodaje (Chuvakhin & Gertmenian, 2003.). Altman (2000) je to definirao kao *'mjera sposobnosti menadžmenta u rješavanju konkurentskih uvjeta*' .

3.2.1. Rezultati

Nakon izračunavanja Altamnova Z-scorea potrebno je svrstati rezultat u jedan od razreda. Naime Altaman je postavio referentne granice za poduzeća koja imaju optimalan koeficijent i vrlo je mala vjerojatnost da će bankrotirati, nadalje, za poduzeća koja će vrlo vjerojatno bankrotirati, te na kraju između ta dva pola postoji siva zona, u kojoj ishod nije jasan.

Tablica 1 prikazuje shematski prikaz referentnih granica iz modela:

Tablica 1: Referentne vrijednosti modela

Bankrot	Siva zona	Zdravo poslovanje
∞	1,81	2,675 ∞

Izrada autora prema podatcima iz Altman E. I. (1968)

Ako se rezultat Altmanova Z-score-a nalazi u rasponu od 0 do 1,81, situacija nije povoljna i poduzeće ima predispozicije da u naredne dvije godine bankrotira, ako se rezultat nađe između 1,81 i 2,675 poduzeće se nalazi na drhtavom tlu i rezultat nije izvjestan. Konačno, ako je rezultat iznad 2,675 poduzeće je stabilno i bankrot nije izvjestan.

3.2.2. Preciznost rezultata predviđanja

Profesor Altman je istraživanje provodio na temelju starih financijskih izvještaja kako bi pokušao uspostaviti pravilo. Tako je za poduzeća koja su davnih dana bankrotirala, Altmanov Z-score izračunavao na temelju izvještaja iz godine prije proglašenja bankrota, a nakon toga i dvije godine prije proglašenja bankrota. Kao što je i za pretpostaviti, što smo dalje od

promatranog događaja, to je manja vjerojatnost predviđanja. U nastavku je statistika provedenog istraživanja koje je proveo i objavio profesor Altman (1968.)

U istraživanju provedenom s financijskim izvještajima **iz godine prethodne bankrotu**, rezultati su izgledali kako slijedi:

Tablica 2 : Veličina uzorka

	Ukupan broj
Grupa 1 (Bankrot)	33
Grupa 2	33
SUM	66

Izrada autora prema Altman E. I. (1968)

Tablica 3: Rezultati s financijskim izvještajima iz godine prije stečaja

	Broj točnih predviđanja	Postotak točnih predviđanja	Postotak pogreške	n
Type 1	31	94%	6%	33
Type 2	32	97%	3%	33
Total	63	95%	5%	66

Izrada autora prema Altman E. I. (1968.)

Prethodne Tablice 2 i 3 prikazuju za početak, da je u istraživanju sudjelovalo 66 poduzeća, od čega su 33 poduzeća bankrotirala, a 33 nisu. Iz grupe bankrotiranih (Grupa 1) poduzeća, postotak predviđanja iznosi visokih 94%, dok je greška 6%. Druga grupa (Grupa 2) poduzeća koja nisu bankrotirala, isti taj scenarij predviđen je s još većom preciznošću, 97% točnih predviđanja i samo 3% iliti jedno pogrešno predviđanje.

Ukupni rezultat govori da je preciznost predviđanja bankrota Altamnovim Z-score-om korištenjem financijskih izvještaja iz godine prije deklariranja bankrota visokih **95%**.

S financijskim izvještajima, **dvije godine prije bankrota**, nešto je drugačija situacija:

Tablica 4: Veličina uzorka

Ukupan broj	
Grupa 1 (Bankrot)	32
Grupa 2	33
SUM	65

Izrada autora prema Altman E. I. (1968)

Tablica 5: Rezultati s financijskim izvještajima dvije godine prije stečaja

	Broj točnih predviđanja	Postotak točnih predviđanja	Postotak pogreške	n
Type 1	23	72%	28%	32
Type 2	31	94%	6%	33
Total	63	83%	17%	65

Izrada autora prema Altman E. I. (1968)

Dvije godine prije deklariranja bankrota postotak predviđanja je nešto manji ali opet zadovoljavajući. Od ukupno 32 promatrana poduzeća koja su bankrotirala, predviđanje je 72% pozitivno, dakle 23 od 32 poduzeća predviđen je bankrot korištenjem Altmanova Z-score-a. U drugoj grupi, od poduzeća koja nisu bankrotirala postotak predviđanja je 94%, što je jako slično rezultatima istraživanja korištenjem financijskih izvještaja jednu godinu prije bankrota bankrotiranih poduzeća. Postotak predviđanja je 94%.

Ukupni nalazi istraživanja jesu, postotak pozitivnog predviđanja bankrota, korištenjem financijskih izvještaja 2 godine prije deklariranja bankrota jest 83%.

3.3. Drugi modeli za predviđanje bankrota

Prema Zenzerović (2006.) Rastući broj statističkih i matematičkih metoda i atraktivnost problematike predviđanja stečaja naveo je veliki broj znanstvenika da istražuju navedeno područje što je rezultiralo razvojem niza modela. Među njima su se, kao najviše citirani i/ili u praksi najviše korišteni, istaknuli modeli, nastali kao rezultat istraživanja, sljedećih autora:

- Williama H. Beawera,

- Roberta O. Edmistera,

- Petera Kraliceka.

- BEX Indeks

- Pervan i FIlipović

U nastavku će se pobliže istražiti modeli navedenih autora pridržavajući se kronologije objave rezultata istraživanja u relevantnoj literaturi.

3.3.1. Williama H. Beawer

Istraživao je poslovni neuspjeh subjekta, a pod poslovni neuspjeh, smatrao je: 'nesposobnost poslovnog subjekta da podmiri dospjele financijske obveze' (Beawer, 1966). Istraživanje je provedeno na uzorku od 158 proizvodnih poduzeća čijim se dionicama javno trgovalo, te je bio podijeljen na dvije jednake grupe. Prva grupa sastojala se od 79 poduzeća koja su ušla u stečaj u razdoblju od 1954. do 1964. godine, dok je druga grupa obuhvaćala isti broj zdravih poduzeća. Za obije grupe prikupili su se izvještaj za razdoblje od 5 godina prije stečaja za prvu grupu, te za neko petogodišnje razdoblje za drugu grupu. Navedene korporacije poslovale su u 38 različitih djelatnosti, njihova imovina varirala je od 600 tisuća do 45 milijuna dolara, navodi Zenzerović (2006.)

Za potrebe analize Beawer je izabrao 30 pokazatelja. Istraživanje je pokazalo da svega 3 pokazatelja pokazuju najbolje rezultate:

- Tijek novca/ukupna imovina – 90% točnosti
- Čisti prihodi/ukupni dugovi – 87% točnosti
- Tijek novca/ukupni dugovi – 85% točnosti

3.3.2. Roberta O. Edmistera

Robert O. Edmister svoje je istraživanje proveo nad mikro i malim poslovnim subjektima, prvenstveno iz razloga što su se do tada sva istraživanja odnosila na velika i srednja poduzeća. Razlog tomu bila je dostupnost financijskim izvješćima i podatcima. Istraživanje je obuhvatilo 19 u literaturi najčešće spominjanih financijskih pokazatelja prikladnih za predviđanje stečaja te su oni izračunati za 562 mala poslovna subjekta. Pod stečajem se podrazumijevala nesposobnost poslovnih subjekata da podmiruju dospjele rate kredita. Promatrani financijski izvještaji odnosili su se na razdoblje od 1958. do 1965. godine, a korištena je dobro poznata multivarijantna diskriminantna analiza (MVA). U odnosu na ranije studije, Edmister u istraživanje uvodi sljedeće nove metode: korištenje trogodišnjeg prosjeka pokazatelja, korištenje trogodišnjeg trenda kretanja pokazatelja te odnos pokazatelja poslovnog subjekta s prosječnim pokazateljem djelatnosti. Kao glavno obilježje Edmisterovog modela jesu dummy varijable koje ovise o vrijednosti izračunatih pokazatelja navodi Zenzerović (2006.). Model za predviđanje stečaja prikazan je jednadžbom u nastavku:

$$\mathbf{Z = 0,951 - 0,423X_1 - 0,293X_2 - 0,482X_3 + 0,277X_4 - 0,452X_5 - 0,352X_6 - 0,924X_7} \quad \mathbf{(4)}$$

Z – vrijednost diskriminantne funkcije,

$\mathbf{X_1}$ – 1 ukoliko je čisti novčani tok / kratkoročne obveze manji od 0,05, a 0 u ostalim slučajevima,

$\mathbf{X_2}$ – 1 ukoliko je glavnica / prihodi od prodaje manji od 0,07, a 0 u ostalim slučajevima,

$\mathbf{X_3}$ – 1, ukoliko je (radni kapital / prihodi od prodaje) / (radni kapital ukupne djelatnosti / prihodi od prodaje ukupne djelatnosti) manji od – 0,02, a 0 u ostalim slučajevima,

$\mathbf{X_4}$ – 1, ukoliko je (kratkoročne obveze / glavnica) / (kratkoročne obveze ukupne djelatnosti / glavnica ukupne djelatnosti) manji od 0,48, a 0 u ostalim slučajevima,

$\mathbf{X_5}$ – 1, ukoliko (zalihe / prihodi od prodaje) / (zalihe ukupne djelatnosti / prihodi od prodaje ukupne djelatnosti) ima rastući trend8 i manji je od 0,04, a 0 u ostalim slučajevima,

$\mathbf{X_6}$ – 1, ukoliko pokazatelj ubrzane likvidnosti / pokazatelj ubrzane likvidnosti ukupne djelatnosti ima padajući trend i manji je od 0,34, a 0 u ostalim slučajevima i

$\mathbf{X_7}$ – 1, ukoliko pokazatelj ubrzane likvidnosti / pokazatelj ubrzane likvidnosti ukupne djelatnosti ima rastući trend, a u ostalim slučajevima – 0 (Edmister, 1972).

Tablica 6: Točnost predviđanja stečaja Edmisterovog z-pokazatelja

Edmisterov Z-pokazatelj	Postotak točnosti razvrstavanja	
	Pokrenut stečaj	Financijski zdravi subjekti
0-0469	80	100
0,470 - 0,519	85	95
0,520 - 0,529	90	95
0,530-	100	86

Izrada autora prema Zenzerović (2006.)

Svoje istraživanje Edmister je objasnio tablicom broj 6 na slijedeći način.

Poduzeća sa Z-score-om **manjim od 0,469** su klasificirana kao poduzeća koja su u stečaju, što u ovom slučaju znači da u posljednjih 90 dana nisu izvršila uplatu glavnice ili kamata.

Poduzeća sa Z-score-om **iznad 0,53** su klasificirana kao financijski zdravi subjekti

Poduzeća koja sa Z-score-om **između 0,469 i 0,53** nalaze se u takozvanoj *sivoj zoni* i takva poduzeća su zahtijevala dodatne analize.

Za dodatno razumijevanje tablice, valja objasniti što označavaju pojedini postotci po razredima. Tako 80% u razredu, 0-0,469, za poduzeća u stupcu 'Pokrenut stečaj', označava da od svih promatranih poduzeća nad kojima je pokrenut stečajni postupak, model je predvidio nastupanje stečaja u 80% slučajeva. Pogreška je 20%

Dok je, u stupcu 'Financijski zdrava poduzeća', u retku 0,530-, model predvidio ne-nastupanje stečaja u 86% slučajeva. Pogreška je 14%

3.3.3. Peter Kralicek

Peter Kralicek jedan je od poznatijih znanstvenika koji je provodeći multivarijantnu diskriminantnu analizu izveo model za predviđanje stečaja, a da ne dolazi iz Amerike. Koristeći se podacima iz financijskih izvještaja za poduzeća s njemačkog govornog područja (Njemačka, Austrija i Švicarska),

Kralicek je izveo sljedeći model, formulu broj 5:

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

gdje je:

DF – Vrijednost diskriminantne funkcije,

X_1 – Čisti novčani tok / Ukupne obveze,

X_2 – Ukupna imovina / Ukupne obveze,

X_3 – Dobit prije kamata i poreza / Ukupna imovina,

X_4 – Dobit prije kamata i poreza / Ukupni prihodi,

X_5 – Zalihe / Ukupni prihodi i

X_6 – Poslovni prihodi / Ukupna imovina

Kralicekov DF pokazatelj može poprimiti pozitivne i negativne rezultate, pozitivni rezultati ukazuju na solventnost poduzeća, dok negativni rezultati označavaju da poduzeće nije u mogućnosti imovinom podmiriti svoje obveze tj. da je insolventno.

Kritične vrijednosti DF pokazatelja prikazane su Tablicom 7 u nastavku:

Tablica 7: Referentne vrijednosti Kralicekovog modela

Vrijednost DF pokazatelja	Financijska stabilnost
>3.0	IZVRSNA
>2.2	DOBRA
>1.5	VRLO DOBRA
>1.0	OSREDNJA
>0.3	LOŠA
≤0.3	POČETAK INSOLVENTNOSTI
≤0.0	UMJERENA INSOLVENTNOST
≤-1.0	IZRAZITA INSOLVENTNOST

Izrada autora prema podatcima Zenzerović (2006.)

Modeli financijskih neuspjeha jako su poznata tema i među domaćim znanstvenicima. Tako su profesor Vinko Belak i profesorica Željana Aljinović Barać izradili indeks poslovne izvrsnosti kakav do tada nije korišten u svijetu:

3.3.4. BEX Indeks

BEX indeks sintetički i analitički prikazuje sadašnju, a djelomično i buduću poslovnu izvrsnost svakog poduzeća. Model je izrađen za procjenu poslovne izvrsnosti poduzeća na hrvatskom tržištu. BEX model je testiran i na uzorku poduzeća koja ne kotiraju na tržištu kapitala, te pokazuje i mjeri poslovnu izvrsnost poduzeća u dvije dimenzije, i to:

1. trenutačna poslovna izvrsnost

2. očekivana poslovna izvrsnost

Od sebi sličnih indeksa u svijetu, BEX se razlikuje po tome što je prilagođen hrvatskom tržištu i hrvatskom računovodstvu. BEX je testiran empirijski na temelju stvarnih statističkih podataka tvrtki na tržištu kapitala u Hrvatskoj. Belak ističe još jednu prednost BEX-a. Ovaj indeks, naime, mjeri pokazatelje u posebne četiri kategorije: profitabilnost, stvaranje vrijednosti, likvidnost, snagu financiranja, a onda ih na kraju zbraja.

BEX model sastoji se od četiri pokazatelja s određenim ponderima utjecaja, što u konačnici tvori sljedeći izraz, Formulu 6:

$$\mathbf{BEX = 0{,}388}ex1 \mathbf{+ 0{,}579}ex2 \mathbf{+ 0{,}153}ex3 \mathbf{+ 0{,}316}ex4 \quad \mathbf{(6)}$$

Gdje bi značilo:

$ex1$ = profitabilnost

$ex2$= stvaranje vrijednosti

$ex3$= likvidnost

$ex4$= financijska snaga (Belak, i Aljinović Barać, 2008)

Izračun BEX modela:

Tablica 8: Komponente za izračun BEX modela

ex_1=EBIT/ukupna aktiva	Granična mjera je 17%, što veći %, to bolje
ex_2 = neto poslovna dobit/vlastiti kapital*cijena	Ako je ex_2 veći od 1 tvrtka stvara vrijednost, ako je manji od jedan, tvrtka jede svoju supstancu. Cijena kapitala se aproksimira kamatnom stopom na štednju.
ex_3 = radni kapital/ukupna aktiva	Granična mjera likvidnosti 25%. (>25% je dobro, < od 25% je loše)
ex_4 = 5(dobit+d+a)/ukupne obveze	Standardna mjera pokrića obveza novcem je 20%, pokazatelj, što je veći od 1 to je bolje. Maksimalna vrijednost postavljena na 10.

Izvor: Izrada autorice prema podacima iz: Belak, V. i Aljinović Barać, Ž. (2008)

Rezultati izračuna modela, očitavaju se na način:

-BEX INDEX veći od 1 - dobre tvrtke

-BEX INDEX između 0 i 1 - potrebna su unaprjeđenja

-BEX INDEX manji od 0 (negativan) - ugrožena egzistencija (Belak, V. i Aljinović Barać, Ž. 2008)

3.3.5. FP RATING

Drugi model koji je rezultat znanstvenika s Ekonomskog Fakulteta u Splitu, model je profesora Ivice Pervana i Dalibora Filipovića iz 2010. godine. Razvijen je s ciljem procjene insolventnosti odnosno blokade poduzetnika. Kao kod Edmisterovog modela i ovdje se misli na nemogućnost plaćanja glavnice ili kamate kredita u periodu duljem od 90 dana.

Uzorak ovog istraživanja bila su društva koja su imala kreditno zaduženje u banci X d.d. koja posluje u RH. 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. Konačni uzorak bio je 447 poduzeća od kojih su 53 bila insolventna i 394 solventna. Granica između te dvije skupine bila je 90 dana neplaćanja dospjelih obveza prema kreditu. (Pervan i Filipović, 2010)

FP RATING = -1,0937 + 2,0956 X_1 – 0,005 X_2 + 0,6220 X_3 – 0,000005 X_4 + 0,1116 X_5 (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

Rezultati istraživanja bili su kako slijedi:

Od ukupnog broja promatranih solventnih poduzeća koji je 394, u model je ušlo (što znači da je model predvidio buduće kretanje) njih 327. Što daje točnost od 83% za predviđanje solventnih poduzeća.

S druge strane, od 53 insolventna poduzeća u model je ušlo njih 37, iz čega proizlazi da je točnost 69,8% za predviđanje insolventnosti.

4. EMPIRIJSKO ISTRAŽIVANJE PODUZEĆA PO INDUSTRIJAMA

4.3. Definiranje uzorka

Kako bismo pravilno proveli istraživanje najprije ćemo razraditi, tko će biti subjekti u istraživanju, koja je populacija u pitanju i koliko jedinki ulazi u uzorak.

Obvezali smo se provesti istraživanje nad poduzećima pravnog oblika **dioničko društvo**, što uvelike sužava istraživanje jer hrvatsko tržište je više okrenuto tradicionalnim načinima financiranja, dok su neka tržišta poput američkog, više okrenuta tržištu i financiranju putem emisije vrijednosnih papira.

Također je bitno to da smo istraživanje proveli nad dvije grupe poduzeća, prema njihovoj aktivnosti na tržištu. Tako imamo grupu od 28 poduzeća koja su trenutno **aktivna** bez ikakvih opterećenja poput stečaja i predstečajne nagodbe. Druga grupa poduzeća su ona poduzeća koja su **u stečaju**. Njih smo odabrali 24.

Poduzeća koja su **u stečaju** filtrirali smo na način da smo na stranici '*fininfo'*, u pretragu uključili samo poduzeća koja su u stečaju i koja su dionička društva. *Fininfo* je baza podataka koja sadrži podatke svih poduzeća od stvaranja Republike. To je prikazano slikom 8:

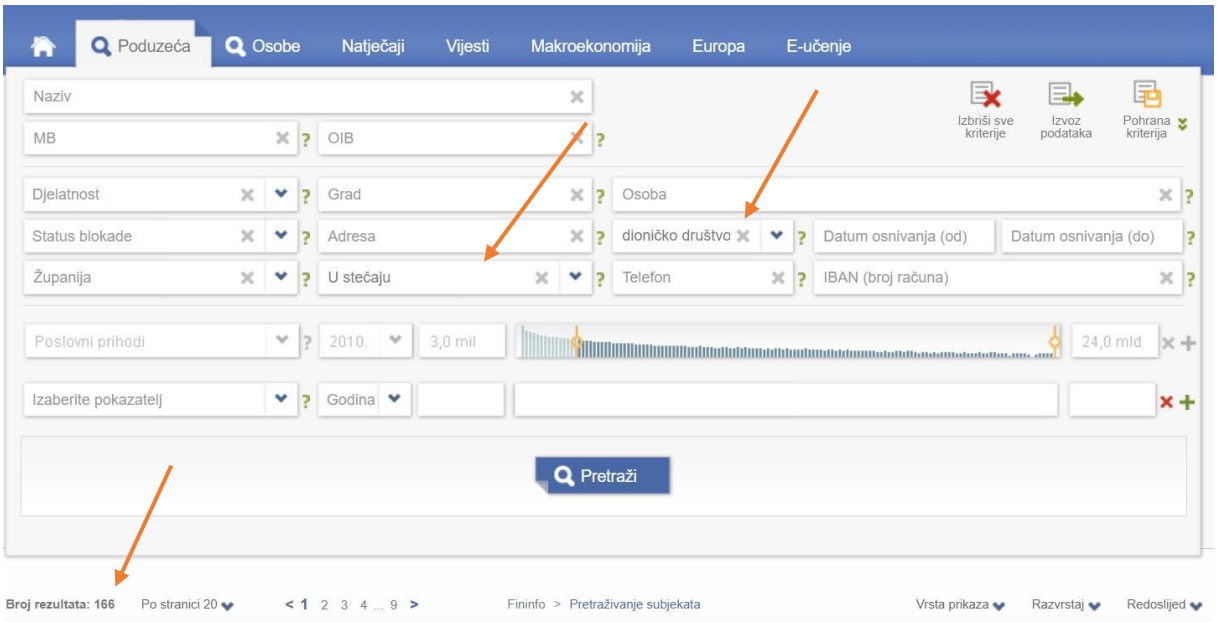

Slika 8: Fininfo filter za poduzeća u stečaju

Izvor: Fininfo

Rezultat pretrage je prikazan Slikom 8. 166 poduzeća kao što navodi strelica u lijevom donjem kutu. Gorenje dvije strelice prikazuju filtriranje prema statusu *'u stečaju'* i *'dioničko društvo'*. Pregledom svih 166 društava, samo njih 24 je ušlo u uzorak. Eliminirali smo sva ona poduzeća koja nemaju objavljene financijske izvještaje, te koja su proglasila stečaj prije 2018 (uz nekoliko iznimki) jer stranica 'Fininfo' sadrži financijske izvještaj do 2016. godine, a s obzirom da mi testiramo predviđanje stečaja prema financijskim izvještajima od dvije godine prije proglašenja stečaja, moramo paziti na to da uzmemo samo ona poduzeća u stečaju od 2018. godine na ovamo.

Dakle, u uzorak su ušla sva poduzeća koja su u ovom trenutku i s ovim mogućnostima, dostupna. 24 od 166 poduzeća daje 14,45% populacije u uzorku.

Poduzeća koja su **aktivna** filtrirali smo sličnom metodologijom. Još uvijek je u filteru kao pravni oblik stajalo *'dioničko društvo'*, dok je u statusu aktivnosti bilo *'aktivan'*. S obzirom da je izvorni Altmanov Z-score model uključivao samo ona poduzeća koja imaju više od 1 milijun dolara prihoda, tako smo i mi napravili. Takav filter nam je pronašao 410 poduzeća, što čini našu populaciju. Naš uzorak od 28 poduzeća odabrali smo na način da smo iz svake od promatranih industrija (hoteljerstvo, građevinarstvo, proizvodnja, energetika i brodogradnja) odabrali određen broj poduzeća prema ukupnom broju poduzeća unutar gospodarstva, tako će proizvodna grana imati najveći broj predstavnika u uzorku, dok će brodogradnja imati najmanji

broj predstavnika. Također, populaciju smo poredali po poslovnom prihodu, od višeg prema nižem, i za uzorak smo uzeli poduzeća s najvećim prihodom. Razlog tomu je činjenica da je hrvatsko gospodarstvo maleno i vjerojatnost da će poduzeće s malenim prihodima imati nereprezentativne financijske izvještaje, ili da se ti izvještaji neće ponašati u skladu s ekonomskim načelima jer su jednostavno premaleni iznosi je velika.

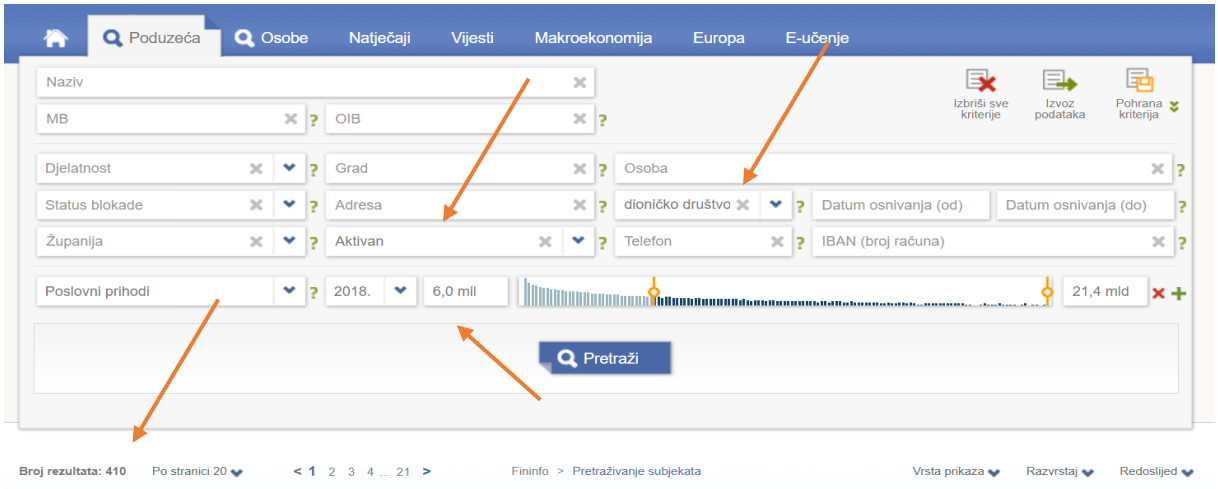

Slika 9: Fininfo filter za zdrava poduzeća

Izvor: Fininfo

Sve prethodno navedene filtere i veličinu populacije možete vidjeti crvenom strelicom označene na Slici 9 iznad teksta.

U Slici 10, ispod teksta možemo vidjeti imenom sva poduzeća u uzorku, te također njihov status aktivnosti, industriju i u slučaju da su *'u stečaju'*, godina u kojoj je proglašen stečaj:

RBR	Naziv poduzeća	Status	Godina stećaja	Industrija
1	ULJANIK, d. d.	Stečaj	2019	Brodogradnja
2	MORE BRODOVI d.d.	Stečaj	2020	Brodogradnja
3	BRODOSPLIT d.d.	Zdrava	-	Brodogradnja
4	BRODOGRADILIŠTE VIKTC	Zdrava	-	Brodogradnja
5	3. MAJ BRODOGRADILIŠTE	Zdrava	-	Brodogradnja
6	RADEŽ d.d.	Zdrava	-	Brodogradnja
7	PULJANKA d. d.	Stečaj	2018	drugo
8	CONING d.d.	Stečaj	2018	drugo
9	GEOFIZIKA d.d.	Stečaj	2018	drugo
10	RAAFOURTY d.d.	Stečaj	2019	drugo
11	DIVECOM d.d.	Stečaj	2020	drugo
12	KOMPAS ZAGREB d.d.	Stečaj	2018	drugo
13	ADRIATIQ ISLANDS GROUI	Stečaj	2021	drugo
14	VIADUKT d.d.	Stečaj	2017	Građevina
15	KONSTRUKTOR-INŽENJER	Stečaj	2017	Građevina
16	VODOGRADNJA OSIJEK d.d	Stečaj	2019	Građevina
17	GRAĐEVNO d.d.	Stečaj	2017	Građevina
18	VIG- d.d.	Stečaj	2019	Građevina
19	ZAGORJE d.d.	Stečaj	2018	Građevina
20	ELEKTROMETAL d.d.	Stečaj	2017	Građevina
21	Dalekovod, d.d.	Zdrava	-	Građevina
22	Osijek Koteks d.d.	Zdrava	-	Građevina
23	Vodoprivreda Zagreb d.d.	Zdrava	-	Građevina
24	LAVČEVIĆ d.d.	Zdrava	-	Građevina
25	HIDROELEKTRA MEHANIZ	Stečaj	2019	Građevina
26	MAISTRA d. d.	Zdrava	-	Hoteli
27	Valamar Riviera d.d.	Zdrava	-	Hoteli
28	PLAVA LAGUNA d. d.	Zdrava	-	Hoteli
29	Arena Hospitality Group d.d.	Zdrava	-	Hoteli
30	SUNCE HOTELI d.d.	Zdrava	-	Hoteli
31	TURISTHOTEL d.d.	Zdrava	-	Hoteli
32	ULJANIK Brodogradilište, d. (	Stečaj	2019	Prerađivačka
33	ULJANIK TESU, d. d.	Stečaj	2019	Prerađivačka
34	ULJANIK Strojogradnja Diese	Stečaj	2019	Prerađivačka
35	OPEKA d.d.	Stečaj	2019	Prerađivačka
36	RIZ-ODAŠILJAČI d.d.	Stečaj	2019	Prerađivačka
37	ZRINSKI d.d.	Stečaj	2019	Prerađivačka
38	INA, d.d.	Zdrava	-	Prerađivačka
39	VINDIJA d.d. Varaždin	Zdrava	-	Prerađivačka
40	PODRAVKA d.d.	Zdrava	-	Prerađivačka
41	PETROKEMIJA, d.d.	Zdrava	-	Prerađivačka
42	DUKAT d.d.	Zdrava	-	Prerađivačka
43	ERICSSON NIKOLA TESLA	Zdrava	-	Prerađivačka
44	P P K d.d.	Zdrava	-	Prerađivačka
45	KRAŠ d.d.	Zdrava	-	Prerađivačka
46	AD PLASTIK d.d.	Zdrava	-	Prerađivačka
47	CEMEX Hrvatska d.d.	Zdrava	-	Prerađivačka
48	BRODOSPLIT d.d.	Zdrava	-	Prerađivačka
49	FRANCK d.d.	Zdrava	-	Prerađivačka
50	Siemens d.d.	Zdrava	-	Prerađivačka
51	Končar d.d.	Zdrava	-	Prerađivačka
52	MEISO d.d.	Stečaj	2019	Prerađivačka

Slika 10: Popis poduzeća iz uzorka

4. Izrada autora prema podatcima s Fininfo; https://www.fininfo.hr/

4.2. Izračun Altmanova Z-score-a za ukupno gospodarstvo

4.2.1. Metodologija rada

Da bismo odgovorili na prvu hipotezu koja glasi *'Altmanov Z-score uspješan je pokazatelj za predviđanje stečaja u RH'*, bilo je potrebno provesti određeno istraživanje i kalkulacije koje ćemo detaljno obraditi u nastavku.

Altmanov Z-score model je koji kao što znamo sadrži pet ponderiranih faktora. Svaki od tih faktora potrebno je samostalno izračunati da bismo došli do rješenje. Tako je preslikan taj model u programu Excel na slijedeći način:

Tablica 9: Stavke za izračun modela

RBR	Stavka	Iznos	Izvor
1.	Imovina		Bilanca
2.	Obveze		Bilanca
3.	Zadržana dobit		Bilanca
4.	Kratkotrajna imovin		Bilanca
5.	Kratkotrajne obveze		Bilanca
6.	EBIT		RDG
7.	Cijena dionice		ZSE
8.	Br dionica		ZSE
9.	Prihod od prodaje		RDG
10.	Radni kapital		(RBR) 4.-5.
11.	Trz vrj kap		(RBR) 7.x 8.

Izrada autora

Tablica 9 u koju bismo upisali sve podatke koji se koriste unutar originalne Altmanove formule. I onda bi se dotični podatci preslikali u model (tablica 10) u nastavku i dali nam rješenje, Z-score:

Tablica 10: Excel model za izračun Altmanova Z-score-a

Z-score	#DIV/0!	X1+X2+X3+X4+X5
X1	#DIV/0!	10./1.
X2	#DIV/0!	3./1.
X3	#DIV/0!	6./1.
X4	#DIV/0!	11./2.
X5	#DIV/0!	9./1.

Izrada autora

Na primjer, Zadržanu dobit, iščitali smo iz Bilance pojedinog društva, i taj podatak nalazi se u retku broj tri Tablice 9, dok se imovina nalazi u prvom retku iste tablice. To nas dovodi do slijedeće Tablice 10, gdje vidimo kako su se koristili pojedini podatci, tako za izračun faktora X2, koristimo upravo prethodne podatke. Podatak o zadržanoj dobiti iz trećeg retka, Tablice 9, podijelimo s iznosom imovine, koja se nalazi u prvom retku iste Tablice 9.

Kada smo izračunali svaki pojedini faktor, redak Z-score u Tablici 10 te sve faktore zbraja i daje nam konačan rezultat.

Za razumijevanje metodologije, u nastavku ćemo pobliže objasniti pojedine podatke koje koristili i na koji način smo do njih došli.

- Imovina, obveze, zadržana dobit, kratkotrajna imovina, kratkotrajne obveze – jednostavnim kopiranjem iz Bilance
- EBIT i Prihodi od prodaje – jednostavnim kopiranjem iz Računa dobiti i gubitka
- Radni kapital – razlika kratkotrajne imovine i kratkotrajnih obveza
- Tržišna vrijednost glavnice – umnožak cijene dionice i broja dionica.

Da bismo pronašli iznos **tržišne vrijednosti glavnice**, morali smo na stranicama *'Zagreb Stock Exchange'*, filtrirati cijene za razdoblje (npr. 1.1.2018. – 31.12.2018.), takav filtar bi nam dao sve cijene unutar promatranog razdoblja, za svaki dan trgovanja. To smo morali to izvesti u Excel, gdje smo izračunali prosječnu cijenu za promatranu godinu. Ponavljamo, kod poduzeća koja su u stečaju to je bila godine, dvije financijske godine prije stečaja, dok kod zdravih poduzeća, godina iz koje smo uzimali podatke bila je 2018. za sva promatrana zdrava poduzeća.

Slika 11: Isječak pretraživanja cijene dionice

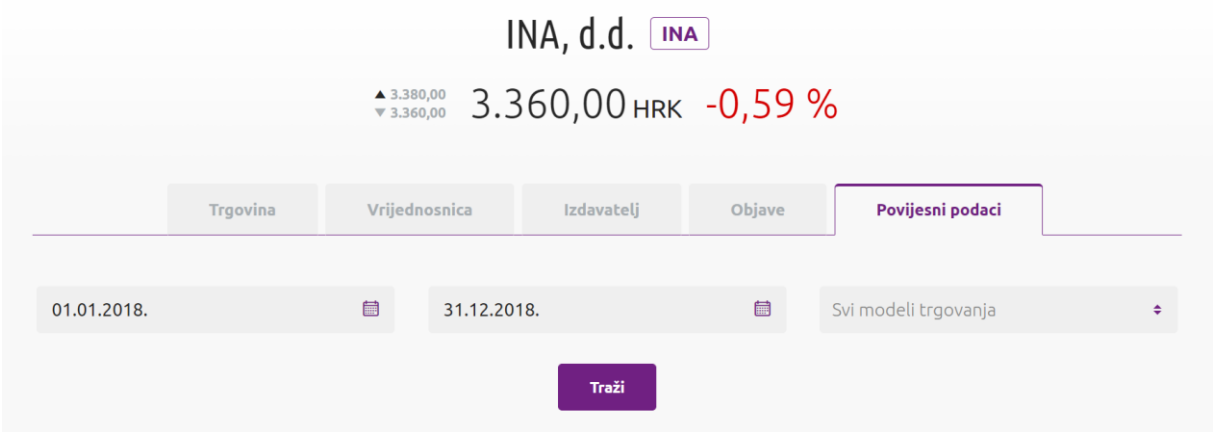

Izvor: ZSE; https://zse.hr/

Na Slici 11 vidimo primjer, na koji smo način pretraživali cijenu dionice za pojedino razdoblje. Rezultati se ne nalaze na promatranoj slici jer je pre dug popis.

4.2.2. Rezultati izračunavanja Altmanova Z-score-a

Nakon što smo se upoznali s obavljenim procedurama rada u prethodnom poglavlju, u ovom ćemo poglavlju iznijeti rezultate istraživanja nad uzorkom ukupnog gospodarstva.

U tablici 11 nalazi se popis svih poduzeća iz uzorka. Za svako od tih poduzeća smo izračunali Altmanov Z-score.

S obzirom da znamo ishod koji poduzeće očekuje, jer uzimamo stare financijske izvještaje, možemo reći je li Altmanov Z-score uspješno predvidio budući status poduzeća, dvije godine unaprijed.

U slijedećoj Tablici 11 možemo ponovno vidjeti popis svih poduzeća iz uzorka, no imamo i dodatna 3 stupca, od kojih je posljednji najrelevantnije. U njemu se nalazi odgovor, je li Altmanov Z-score predvidio buduće ponašanje poduzeća. Uz odgovor *'da'* koji označava točno predviđanje i *'ne'* koji označava potpuno pogrešno predviđanje, postoji još mogućnost da rezultat upada u kategoriju *'sivo'*, što označava da je budućnost neizvjesna i da bismo došli do odgovora, potrebno je provesti dodatna dubinska istraživanja kojima se nećemo baviti u ovom radu, već ćemo sva poduzeća koja su u sivoj zoni (Altmanov Z-score između 1,81 i 2,675) smatrati pogrešnim predviđanjem.

Tablica 11: Rezultati izračuna Altmanova Z-score-a

RBR	Naziv poduzeća	Status	Godina stećaja	Industrija	Altman	Razred	Predviđeno
1	ULJANIK, d. d.	Stečaj	2019	Brodogradnja	-0,95	1	da
2	MORE BRODOVI d.d.	Stečaj	2020	Brodogradnja	0,28	1	da
3	BRODOSPLIT d.d.	Zdrava	-	Brodogradnja	0,74	1	ne
4	BRODOGRADILIŠTE VIKTC	Zdrava	-	Brodogradnja	1,20	1	ne
5	3. MAJ BRODOGRADILIŠTE	Zdrava	-	Brodogradnja	-9,66	1	ne
6	RADEŽ d.d.	Zdrava	-	Brodogradnja	1,24	1	ne
7	PULJANKA d. d.	Stečaj	2018	drugo	-0,83	1	da
8	CONING d.d.	Stečaj	2018	drugo	-1,14	1	da
9	GEOFIZIKA d.d.	Stečaj	2018	drugo	-1,87	1	da
10	RAAFOURTY d.d.	Stečaj	2019	drugo	2,32	2	sivo
11	DIVECOM d.d.	Stečaj	2020	drugo	0,36	1	da
12	KOMPAS ZAGREB d.d.	Stečaj	2018	drugo	2,77	3	ne
13	ADRIATIQ ISLANDS GROUI	Stečaj	2021	drugo	1,69	1	da
14	VIADUKT d.d.	Stečaj	2017	Građevina	0,85	1	da
15	KONSTRUKTOR-INŽENJER	Stečaj	2017	Građevina	-1,20	1	da
16	VODOGRADNJA OSIJEK d.d	Stečaj	2019	Građevina	-1,12	1	da
17	GRAĐEVNO d.d.	Stečaj	2017	Građevina	-0,28	1	da
18	VIG- d.d.	Stečaj	2019	Građevina	-3,80	1	da
19	ZAGORJE d.d.	Stečaj	2018	Građevina	-0,36	1	da
20	ELEKTROMETAL d.d.	Stečaj	2017	Građevina	-3,42	1	da
21	Dalekovod, d.d.	Zdrava	-	Građevina	0,72	1	ne
22	Osijek Koteks d.d.	Zdrava	-	Građevina	0,89	1	ne
23	Vodoprivreda Zagreb d.d.	Zdrava	-	Građevina	14,63	3	da
24	LAVČEVIĆ d.d.	Zdrava	-	Građevina	1,72	1	ne
25	HIDROELEKTRA MEHANIZ	Stečaj	2019	Građevina	-2,04	1	da
26	MAISTRA d. d.	Zdrava	-	Hoteli	1,79	1	ne
27	Valamar Riviera d.d.	Zdrava	-	Hoteli	1,90	1	ne
28	PLAVA LAGUNA d. d.	Zdrava	-	Hoteli	3,43	3	da
29	Arena Hospitality Group d.d.	Zdrava	-	Hoteli	2,69	3	da
30	SUNCE HOTELI d.d.	Zdrava	-	Hoteli	22,20	3	da
31	TURISTHOTEL d.d.	Zdrava	-	Hoteli	4,55	3	da
32	ULJANIK Brodogradilište, d. d	Stečaj	2019	Prerađivačka	-7,03	1	da
33	ULJANIK TESU, d. d.	Stečaj	2019	Prerađivačka	0,64	1	da
34	ULJANIK Strojogradnja Diese	Stečaj	2019	Prerađivačka	-2,58	1	da
35	OPEKA d.d.	Stečaj	2019	Prerađivačka	-0,52	1	da
36	RIZ-ODAŠILJAČI d.d.	Stečaj	2019	Prerađivačka	1,09	1	da
37	ZRINSKI d.d.	Stečaj	2019	Prerađivačka	0,93	1	da
38	INA, d.d.	Zdrava	-	Prerađivačka	5,27	3	da
39	VINDIJA d.d. Varaždin	Zdrava	-	Prerađivačka	1,72	1	ne
40	PODRAVKA d.d.	Zdrava	-	Prerađivačka	2,79	3	da
41	PETROKEMIJA, d.d.	Zdrava	-	Prerađivačka	1,07	1	ne
42	DUKAT d.d.	Zdrava	-	Prerađivačka	5,11	3	da
43	ERICSSON NIKOLA TESLA	Zdrava	-	Prerađivačka	6,68	3	da
44	P P K d.d.	Zdrava	-	Prerađivačka	6,10	3	da
45	KRAŠ d.d.	Zdrava	-	Prerađivačka	2,15	2	sivo
46	AD PLASTIK d.d.	Zdrava	-	Prerađivačka	1,61	1	ne
47	CEMEX Hrvatska d.d.	Zdrava	-	Prerađivačka	2,11	2	sivo
48	BRODOSPLIT d.d.	Zdrava	-	Prerađivačka	0,74	1	ne
49	FRANCK d.d.	Zdrava	-	Prerađivačka	0,87	1	ne
50	Siemens d.d.	Zdrava	-	Prerađivačka	5,43	3	da
51	Končar d.d.	Zdrava	-	Prerađivačka	23,53	3	da
52	MEISO d.d.	Stečaj	2019	Prerađivačka	-1,17	1	da

Izrada autora prema podatcima s Fininfo; https://www.fininfo.hr/

Kako bismo mogli donijeti zaključke, rezultate istraživanja ćemo prikazati na još jedan način.

Slijedeća Tablica 12 prikaz je poput onog koji je iznio Altman u svom radu *'The Journal of Finance,* u članku *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy'*. Rezultat će biti podijeljen po grupama, poduzeća koja su bankrotirala *'Stečaj'* i poduzeća koja nisu bankrotirala *'Zdrava'*.

Tablica 12: Rezultati izračuna Altmanova Z-score-a u postotcima

Count of Predviđeno	Predviđeno						
Status	da	%	ne	%	sivo	%	Grand Total
Stečaj	22	92%	1	4%	1	4%	24
Zdrava	12	43%	14	50%	2	7%	28
Grand Total	34	65%	15	29%	3	6%	52

Izrada autora prema podatcima s Fininfo; https://www.fininfo.hr/

Prethodna Tablica, broj 12, sumarni je prikaz čitavog istraživanja.

Od 24 ispitivana poduzeća koja su u stečaju, originalni model Altmanovog Z-score-a, uz korištenje financijskih izvještaja od dvije godine prije stečaja, predvidio je stečaj za 22 poduzeća, što čini uspješnost predviđanja od 92%. U usporedbi s Altmanovim rezultatima, korištenjem izvještaja od dvije godine prije bankrota, predviđanje poduzeća u stečaju imalo je uspješnost od 72% iliti, 23 od 32 ispitivana poduzeća.

Stoga možemo reći kako je Altmanov Z-score pouzdan pokazatelj u predviđanju bankrota u Republici Hrvatskoj nad izlistanim poduzećima.

S druge strane, od 28 poduzeća koja nisu u bankrotu, koristeći financijske izvještaje od dvije godine prije promatrane *'zdrave'* 2020. godine, dakle koristeći izvještaje iz 2018. godine, Altmanov Z-score, uspješno je predvidio da neće doći do stečaja za tek 12 poduzeća, što daje uspješnost od 43%.

U usporedbi s Altmanovim istraživanjem gdje je predviđanje da neće doći do stečaja na razini od 94%, možemo reći kako temeljem našeg istraživanja, Altmanov Z-score nije dobar pokazatelj za predviđanje budućeg stanja kod poduzeća koja su zdrava.

Sveukupno, razina pouzdanosti Altmanova Z-score-a nad dioničkim društvima u Republici Hrvatskoj iznosi 65%.

4.2.3. Zaključak testiranja pokazatelja za cjelokupno gospodarstvo

Možemo reći da korištenjem Altmanova Z-score-a , u slučaju da predvidi stečaj, vrlo je izvjesno da će se on i dogoditi, točnije 92% je vjerojatnost. S druge strane, u slučaju da Altmanov Z-score predvidi da se u naredne dvije godine neće dogoditi stečaj, nije pouzdan.

Odgovor na H1 hipotezu koja glasi:

'H_1..Altmanov Z score uspješan je pokazatelj u predviđanju stečaja u RH'

Altmanov Z-score uspješan je pokazatelj kada je predviđanje da će nastupiti stečaj, a bezuspješan je pokazatelj u predviđanju budućnosti u kojoj ishod nije stečaj.

Hipoteza H_1 se prihvaća jer veću važnost pridajemo istinitom predviđanju stečaja nego lažnom predviđanju bankrota.

4.3. Izračun Altmanova Z score-a po industrijama

4.3.1. Industrija Brodogradnje

Da bismo pokušali pobliže objasniti pouzdanost modela, segmentirati ćemo poduzeća po industrijama.

Industrija brodogradnje specifična je industrija koja zahtjeva jako velika kapitalna ulaganja da bi isporučila svega nekoliko proizvoda godišnje, stoga su i njihovi podatci u bilanci i računu dobiti i gubitka specifični.

U nastavku ćemo vidjeti kakva je bila uspješnost predviđanja modela, Tablicom 13

Tablica 13: Rezultati u industriji brodogradnje

Count of Predviđeno			Predviđeno		
Industrija	Status	Naziv poduzeća	da	ne	Grand Total
Brodogradnja	Stečaj	MORE BRODOVI d.d.	1		1
		ULJANIK, d. d.	1		1
	Stečaj Total		2		2
	Zdrava	3. MAJ BRODOGRADILIŠTE d. d.		1	1
		BRODOGRADILIŠTE VIKTOR LENA		1	1
		BRODOSPLIT d.d.		1	1
		RADEŽ d.d.		1	1
	Zdrava Total			4	4
Brodogradnja Total			2	4	6

Izrada autora prema podatcima s Fininfo; https://www.fininfo.hr/

Prethodna Tablica 13, detaljno prikazuje rezultat predviđanja modela. Od ukupno 52 poduzeća koja smo obradili u prethodnoj cjelini, 6 poduzeća je iz industrije brodogradnje. Od tih 6 poduzeća u stečaju su 2 a zdrava su 4 poduzeća.

Altmanov Z-score, predvidio je stečaj za sva poduzeća iz industrije brodogradnje, te je točno predvidio za 2, ona koja stvarno jesu u stečaju.

Razlog zašto kod zdravih poduzeća, model predviđa bankrot a on se nije dogodio jest, visoki udio negativnog radnog kapitala u ukupnoj imovini, veliki preneseni gubitci i mala tržišna vrijednost u odnosu na imovinu, a to su ujedno faktori koji imaju najveće pondere.

Industrija brodogradnje u hrvatskoj općenito ima loše konotacije, ali nije bez razloga, već dulje vrijeme žive od državnih i EU subvenicija bez kojih ne bi mogli opstati, i jako puno koštaju porezne obveznike, samo da bi se održali na životu jer su karakteristična i stara industrija.

Zaključno, model predviđanja stečaja nije uspješan u industriji brodogradnje za zdrava poduzeća, a uspješan je za poduzeća u stečaju. Možda to samo znači da je karakteristika ove industrije da imaju loše financijske pokazatelje.

4.3.2. Prerađivačka industrija

Pod prerađivačkom industrijom smatramo poduzeća koja obradom i doradom sirovih ili poluproizvoda stvara novi proizvod koji je namijenjen krajnjem proizvođaču, a ne drugim industrijama. Prerađivačka industrija je industrija koju obilježavaju viša izdvajanja za ljudski kapital.

Od ukupnog uzorka koji broji 52 poduzeća, 21 poduzeće dolazi iz prerađivačke industrije. Od dvadeset i jednog poduzeća, sedam ih je sa statusom *'u stečaju'*, a četrnaest ih je *'zdravo'*.

Slijedeća Tablica 14 prikazuje ishode izračuna Altmanova Z-score-a:

Tablica 14: Rezultati u prerađivačkoj industriji

Count of Predviđeno			Predviđeno			
Industrija	Status	Naziv poduzeća	da	ne	sivo	Grand Total
Prerađivačka	Stečaj	MEISO d.d.	1			1
		OPEKA d.d.	1			1
		RIZ-ODAŠILJAČI d.d.	1			1
		ULJANIK Brodogradilište, d. d.	1			1
		ULJANIK Strojogradnja Diesel d.d.	1			1
		ULJANIK TESU, d. d.	1			1
		ZRINSKI d.d.	1			1
	Stečaj Total		7			7
	Zdrava	AD PLASTIK d.d.		1		1
		BRODOSPLIT d.d.		1		1
		CEMEX Hrvatska d.d.			1	1
		DUKAT d.d.	1			1
		ERICSSON NIKOLA TESLA d.d.	1			1
		FRANCK d.d.		1		1
		INA, d.d.	1			1
		Končar d.d.	1			1
		KRAŠ d.d.			1	1
		P P K d.d.	1			1
		PETROKEMIJA, d.d.		1		1
		PODRAVKA d.d.	1			1
		Siemens d.d.	1			1
		VINDIJA d.d. Varaždin		1		1
	Zdrava Total		7	5	2	14
Prerađivačka Total			14	5	2	21

Izrada autora prema podatcima s Fininfo; https://www.fininfo.hr/

Model Altmanova Z-score-a za poduzeća iz prerađivačke industrije koja su u stečaju, predvidio je točan ishod u 100% slučajeva. Dok je za zdrava poduzeća, ishod da neće doći do stečaja u naredne dvije godine, predvidio na razini od 50%.

Tako, kao i za ukupno gospodarstvo, možemo zaključiti da je Altmanov Z-score, pouzdan pokazatelj kada predvidi bankrot, međutim, kada mu je predviđanje prosperitet, nije pouzdan pokazatelje.

4.3.3. Energetski sektor

Energetski sektor grana je u kojoj nismo pronašli niti jedno poduzeće koje je objavilo stečaj u bazi podataka *'Fininfo'* , a da pritom ima obilježja koja su nam potrebna za istraživanje.

Kako je to bio slučaj s poduzećima u stečaju, poduzeća koja su zdrava, a iz energetskog su sektora i imaju pravni oblik 'dioničko društvo', odlučili smo uvrstiti u prerađivačku industriju koja je testirana u prethodnom poglavlju.

Zapravo samo je jedno poduzeće koje ulazi u okvire istraživanja energetskog sektora, a to je INA d.d.

4.3.4. Industrije hotelijerstva

U industriji hoteljerstva brojimo ukupno 6 poduzeća i sva promatrana poduzeća dolaze iz segmenta *'zdrava'* poduzeća.

Tablica 15 u nastavku prikazuje rezultate modela Altmanova Z-score-a za industriju hotelijerstva:

Tablica 15: Rezultati u industriji hotelijerstva

Count of Predviđeno			Predviđeno		
Industrija	Status	Naziv poduzeća	da	ne	Grand Total
Hoteli	Zdrava	Arena Hospitality Group d.d.	1		1
		MAISTRA d. d.		1	1
		PLAVA LAGUNA d. d.	1		1
		SUNCE HOTELI d.d.	1		1
		TURISTHOTEL d.d.	1		1
		Valamar Riviera d.d.		1	1
	Zdrava Total		4	2	6
Hoteli Total			4	2	6

Izrada autora prema podatcima s Fininfo; https://www.fininfo.hr/

Sve promatrane kompanije imaju promatrajući podatke korištene u izračunu imaju nešto zajedničko, a to je visoka tržišna vrijednost glavnice. Visokom tržišnom vrijednošću glavnice.

Od 6 promatranih poduzeća, model je za 4 točno predvidio ishod, dok je za 2 predvidio pogrešno. Što mu daje 67% točnost, ali moramo pripaziti da je to predviđanje da u slijedeće dvije godine neće doći do stečaja.

Za predviđanje stečaja, nemamo uzorak za promatranje i kalkulaciju, stoga ne možemo komentirati. Postoji 13 poduzeća koja su iz industrije hotelijerstva i u stečaju su, međutim ona ili nemaju dovoljan prihod ili nismo uspjeli pribaviti financijske izvještaje.

4.3.5. Građevinska industrija

Industrija građevine jako je volatilna industrija, s obzirom na to da se često veliki udio ukupnog novca na raspolaganju ulaže u jedan veliki projekt, koji ako propadne, za sobom vuče cijelo poduzeće.

Istraživanje industrije građevine proveli smo nad 12 poduzeća od čega je 8 proglasilo stečaj u prethodnom razdoblju, a 4 su zdrava poduzeća.

Slijedeća Tablica 16 pokazuje rezultate istraživanja:

Tablica 16: Rezultati u građevinarskoj industriji

Count of Predviđeno			Predviđeno		
Industrija	Status	Naziv poduzeća	da	ne	Grand Total
Građevina	Stečaj	ELEKTROMETAL d.d.	1		1
		GRAĐEVNO d.d.	1		1
		HIDROELEKTRA MEHANIZACIJA d.d.	1		1
		KONSTRUKTOR-INŽENJERING d.d.	1		1
		VIADUKT d.d.	1		1
		VIG- d.d.	1		1
		VODOGRADNJA OSIJEK d.d.	1		1
		ZAGORJE d.d.	1		1
	Stečaj Total		8		8
	Zdrava	Dalekovod, d.d.		1	1
		LAVČEVIĆ d.d.		1	1
		Osijek Koteks d.d.		1	1
		Vodoprivreda Zagreb d.d.	1		1
	Zdrava Total		1	3	4
Građevina Total			9	3	12

Izrada autora prema podatcima s Fininfo; https://www.fininfo.hr/

Rezultati istraživanja grupe poduzeća koja su proglasila stečaj jesu stopostotni, dakle, model je svim poduzećima, na temelju financijskih izvještaja od dvije godine prije stečaja, predvidio isti.

S druge strane, zdrava poduzeća se ne mogu pohvaliti takvim rezultatima. Naima, od 4 poduzeća koja su u grupi testiranih poduzeća *'zdrava'*, model je imao učinak 25%, tj. predvidio je točan ishod samo za jedno od 4 promatrana poduzeća. Što ga čini nepouzdanim.

Sumarno, model u industriji ima sveukupnu snagu za predviđanje stečaja od 75%. Takav rezultat se prihvaća kao uspješan.

4.3.6. Zaključak testiranja pokazatelja po industrijama

Prethodna poglavlja obradili smo kako bismo odgovorili na hipotezu H_2:

'H_2…Altmanov Z score jednako je primjenjiv na sve industrije'

U nastavku ćemo sumirati zaključke iz svake industrije koju smo obradili da bismo donijeli zaključak i odgovor na hipotezu.

Industrija brodogradnje ima jako specifične izvještaje i ili je Altmanov Z-score neprilagođen tom sektoru ili su stvarno sva poduzeća na pragu stečaja.

Prerađivačka industrija pokazuje visoku korelaciju sa slikom ukupnog gospodarstva. Naime, model jasno i precizno predviđa stečaj za sva poduzeća u industriji, međutim tek za 50% slučajeva točno predviđa da se stečaj neće dogoditi u naredne dvije godine.

Energetska industrija nije imala dovoljno poduzeća za uzorak.

Industrija hotela u uzorku je imala samo zdrava poduzeća, gdje je model imao 67% uspjeha, što stvarno možemo smatrati uspjehom.

Industrija graditeljstva bilježi visoku stopu predvidivosti nastupa stečaja modelom Z-score, čak 100% za poduzeća u stečaju, no samo 25% za zdrava poduzeća. Sve zajedno rezultat je 75% uspješnosti predviđanja.

Odgovor na hipotezu glasi:

Altmanov Z-score nije jednako primjenjiv na sve industrije, stoga odbacujemo H_2 hipotezu.

5. ZAKLJUČAK

Tema ovog istraživanja bila je istražiti primjenjivost Altmanova Z-score-a nad dioničkim društvima u Hrvatskoj te paralelno uspješnost predviđanja po sektorima. Za istraživanje smo odabrali 5 sektora, a to su: brodogradnja, prerađivačka industrija, energetika, hotelijerstvo i građevinarstvo. Altmanov Z-score, model je za predviđanje stečaja.

Stečaj se provodi radi skupnoga namirenja vjerovnika stečajnoga dužnika, unovčenjem njegove imovine i podjelom prikupljenih sredstava vjerovnicima. Može se provesti nad pravnim i fizičkim osobama, a ne može nad Državom hrvatskom, fondovima, HZZO-om, HZMO-om, te jedinicama lokalne uprave i samouprave. U računovodstvenom smislu, ako poduzeću udio obveza u pasivi nadilazi 75%, ono ima preduvjete za stečaj, dok je u teoriji zdrav odnos kapitala i obveza unutar pasive 1:1.

Altmanov Z-score, model je osmišljen od strane profesora sa sveučilišta Stern, Edwarda Altmana, davne 1968. godine, kada je i objavljen u časopisu *The Journal of Finance*, u članku *Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy.* Od tada, osmišljeno je još jako puno modela za predviđanje poslovnog neuspjeha, među koji su se istaknuli Williama H. Beawera, Roberta O. Edmistera, Petera Kraliceka, BEX Indeks, Pervan i Filipović.

Altmanov Z-score pokazao se dobar pokazatelj na ukupnom gospodarstvu za predviđanje bankrota, no ne tako dobar u predviđanju stabilnosti poduzeća. Među 5 promatranih industrija, jako je malo sličnosti u rezultatima, stoga smo i zaključili kako Altmanov Z-score nije jednako primjenjiv na sve industrije.

SAŽETAK

Ovim radom napravili smo pravni i računovodstveni pregled i značaj stečaja, povijesni pregled i razvoj Altmanova Z-score-a, istražili smo i druge modele za predviđanje poslovnog neuspjeha, te smo finalno istražili jeli model primjenjiv na Hrvatskom tržištu.

Prvi dio opisao je metode, ciljeve doprinose rada te hipoteze koje su predmet istraživanja

U teorijskom dijelu rada, s obzirom da je Altmanov Z-score, model za predviđanje stečaja, obrađen je stečaj. Objašnjeno je što stečaj znači prema hrvatskom zakonu, a što je stečaj u ekonomskoj teoriji, te je finalno na pravom primjeru pokazano kako izgleda bilanca zdravog društva, te društva u stečaju

Drugi dio deskriptivnog dijela rada bio je upoznati se s modelom koji će biti korišten u empirijsko dijelu. Objašnjeno je što je Altmanov Z-score, koje su još verzije bile kroz povijest, kakav je bio rezultat Altmanovog istraživanja, te razrede u koje Altman svrstava svoje rezultate.

U empirijskom dijelu definirala se što populacija i uzorak. Nakon čega je napravljen izračun Altmanova Z-score-a i donesen zaključak na razini gospodarstva, a slijedno tomu i za pojedine industrije. Na temelju istraživanja, dolazi se do zaključka je Altmanov Z-score dobar pokazatelj u predviđanju bankrota, no ne i u predviđanju stabilnosti. Također zaključeno je da model nije jednako uspješan među različitim industrijama.

KLJUČNE RIJEČI: Altmanov Z-score, stečaj, uzorak, model

SUMMARY

With this paper, we made a legal and accounting review and significance of bankruptcy, historical review and development of Altman's Z-score, we investigated other models for predicting business failure, and we finally investigated whether the model is applicable in the Croatian market.

The first part described the methods, objectives, contribution of the work and the hypotheses that are the subject of research

In the theoretical part of the paper, since Altman's Z-score is a model for predicting bankruptcy, bankruptcy is explaned. It is explained what bankruptcy means according to Croatian law, and what bankruptcy is in economic theory, and finally the real example shows what the balance sheet of a healthy society and a bankrupt company looks like.

The second part of the descriptive part of the paper was to get acquainted with the model that will be used in the empirical part. It is explained what Altman's Z-score is, what other versions have been throughout history, what was the result of Altman's research, and the classes into which Altman classifies his results.

In the empirical part, the population and the sample were defined. After that, the calculation of Altman's Z-score was made and a conclusion was made at the level of the Croatian economy, and consequently for individual industries. Based on the research, it is concluded that Altman's Z-score is a good indicator in predicting bankruptcy, but not in predicting stability. It was also concluded that the model is not equally successful among different industries.

KEY WORDS: Altman Z-score, bankruptcy, sample

POPIS LITERATURE

Knjige:

1. Altman,E.I., Financial Ratios, Disriminant Analysis and the Prediction of Corporate Bankruptcy, Journal of Finance 23, 1968, str.189-209.
2. Altman, E. (2003). Financial Ratios, Discriminant Analysis, and Prediction of Corporate Bankruptcy, Journal of Finance, 23(4), 589- 610.
3. Altman E., Hotchkiss E. (2006): Corporate Financial Distress and Bankruptcy, Wiley Finance.
4. Beaver,W. (1966) Financial ratios as predictors of failure, Empirical Research in Accounting, Selected Studies, Supplement to Journal of Accounting Research
5. Belak, V. (1995): Menadžersko računovodstvo, RRiF, Zagreb
6. Belak, V. i Aljinović Barać, Ž. (2008) Tajne tržišta kapitala : BEX indeks, analiza financijskih izvještaja, pokazatelji efikasnosti ulaganja i modeli odlučivanja. Zagreb: Belak excellens
7. Edminster, R. O. (1972), "An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction", Journal of Financial and Quantitative Analysis, March, pp. 1477-1493.
8. Eidleman, E.B. (2007) A discriminant analysis of predictors of business failure. Journal of Accounting Research, Spring, Institute of Professional Accounting, Chicago
9. Pervan, I., Filipović, D. (2010): „FP rating – Model za predviđanje (in)solventnosti poslovnih partnera, Računovodstvo, Revizija i Financije, br.7, str. 92 - 96
10. Sheppard, J. P., Strategy and bankruptcy: an exploration into organizational death-includes appendices, Journal of Management, Vol.. 20. No. 4, 1994. str. 829
11. Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog rada, IV. izdanje, Ekonomski fakultet u Rijeci, Rijeka.
12. Žager K., Mamić Sačer I., Sever Mališ S., Ježovita A., Žager L. (2017): Analiza financijskih izvještaja, 3. izdanje, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb .

Članci:

1. Bogdan S., Bareša S., Hađina V. (2019): Testiranje primjenjivosti Altmanovog Z-score modela za predviđanje stečaja u Republici Hrvatskoj, Notitia časopis za ekonomske, poslovne i društvene teme.
2. Duvnjak, V. (2010): Bankrot Poduzeća, Poslovne studije; raspoloživo na: https://poslovnestudije.com/arhiva/radovi2009/valentinaduvnjak.pdf
3. Hills, M. (2013): Global Journal Of Commerce & Management Perspective, The Analytical Implication Of Altman's Z Score Analysis Of Bse Listed Small Cap Companies, TKM Institute; raspoloživo na: the-analytical-implication-f-altmans-z-score-analysis-of-bse-listed-small-cap-companies.pdf (longdom.org).
4. Ministarstvo pravosuđa Republike Hrvatske (2015): Vodič kroz stečajni postupak, [Internet] raspoloživo na: Vodič kroz stečajni postupak (mingo.hr).
5. Pervan I., Pervan M., Vukoja B. (2011): Prediction of company bankruptcy using statistical techniques – Case of croatia; [Internet]; raspoloživo na: CRORR_2_17.pdf .
6. Pervan I. (2017): Predviđanje stečaja – SME proizvodna poduzeća u Hrvatskoj, Zbornik radova Veleučilišta u Šibeniku.
7. Zenzerović, R. i Peruško, T. (2006): Kratki osvrt na modele za predviđanje stečaja, Economic research - Ekonomska istraživanja, 19 (2), str. 132 - 151.

Internet:

1. Chuvakhin & Gertmenian (2003); Predictin Bankruptcy in the WorldCom Age; raspoloživo na: http://csinvesting.org/wp-content/uploads/2015/04/Predicting-Bankruptcy-for-Worldcom-Final.pdf
2. Časopis Miraku (2017)l; Kako bolest nelikvidnosti liječiti kontrolingom, [Internet], raspoloživo na: https://www.mirakul.hr/blog/bolest-nelikvidnosti-lijeciti-kontrolingom/
3. EkonomskiLab (2019): Slučaj Agrokor: pad crnog jastreba mogao se lako predvidjeti; [Internet]; raspoloživo na: Slučaj Agrokor: pad crnog jastreba mogao se lako predvidjeti – Arhivanalitika.
4. Fininfo (2021); financijski izvještaji, [Internet], raspoloživo na: https://www.fininfo.hr/.

5. Serdarusic.com (2021): Možemo li predvidjeti bankrot? Evo kakva je učinkovitost dvaju popularnih pokazatelja; [Internet]; raspoloživo na: Predviđanje bankrota: kako nam u tome mogu pomoći pokazatelji? (serdarusic.com).
6. ZSE (2021): Periodična izvješća trgovanja: Godišnja [Internet]; raspoloživo na: Vrijednosni papiri (zse.hr).

Pravilnik/Zakon:

1. Narodne novine (2017): Stečajni zakon, Narodne novine d.d. Zagreb, broj NN 71/15, 104/17.

POPIS TABLICA

Tablica 1: Referentne vrijednosti modela.....22
Tablica 2 : Veličina uzorka 23
Tablica 3: Rezultati s financijskim izvještajima iz godine prije stečaja 23
Tablica 4: Veličina uzorka 24
Tablica 5: Rezultati s financijskim izvještajima dvije godine prije stečaja.....24
Tablica 6: Točnost predviđanja stečaja Edmisterovog z-pokazatelja 27
Tablica 7: Referentne vrijednosti Kralicekovog modela.....29
Tablica 8: Komponente za izračun BEX modela 30
Tablica 9: Stavke za izračun modela 36
Tablica 10: Excel model za izračun Altmanova Z-score-a.....36
Tablica 11: Rezultati izračuna Altmanova Z-score-a.....39
Tablica 12: Rezultati izračuna Altmanova Z-score-a u postotcima.....40
Tablica 13: Rezultati u industriji brodogradnje 42
Tablica 14: Rezultati u prerađivačkoj industriji.....43
Tablica 15: Rezultati u industriji hotelijerstva.....45
Tablica 16: Rezultati u građevinarskoj industriji 46

POPIS SLIKA

Slika 1: Primarni uzroci bankrota 13
Slika 2: Shema bilance zdravog poduzeća 15
Slika 3: Shema bilance lošeg poduzeća 16
Slika 4: Shema bilance poduzeća u stečaju 16
Slika 5: Bilanca društva CE-ZA-R d.o.o. 18
Slika 6: Bilanca društva Hangar 18 d.o.o. 19
Slika 7: Pokazatelji iz Altmanova Z-score-a 21
Slika 8: Fininfo filter za poduzeća u stečaju 33
Slika 9: Fininfo filter za zdrava poduzeća 34
Slika 10: Popis poduzeća iz uzorka 35
Slika 11: Isječak pretraživanja cijene dionice 37

PRILOG – podloge izračuna Altmanova Z-score-a

Poduzeća u stečaju	X1	X2	X3	X4	X5	Z-score
ADRIATIQ ISLANDS GROUP (	-0,011	-0,011	0,018	2,729	0,027	1,695
CONING d.d.	-0,468	-0,369	-0,036	0,030	0,038	-1,139
DIVECOM d.d.	-0,029	-0,002	-0,032	0,000	0,498	0,356
ELEKTROMETAL d.d.	-1,523	-1,129	-0,112	0,000	0,358	-3,421
GEOFIZIKA d.d.	-0,414	-0,889	-0,049	0,000	0,033	-1,871
GRAĐEVNO d.d.	-0,087	-0,400	-0,032	0,000	0,490	-0,281
HIDROELEKTRA MEHANIZA	-1,480	-2,370	0,658	0,000	0,884	-2,038
KOMPAS ZAGREB d.d.	-0,420	-0,860	0,040	0,000	4,349	2,775
KONSTRUKTOR-INŽENJERIN	-0,161	-0,627	-0,041	0,000	0,009	-1,198
MEISO d.d.	-0,990	-0,861	-0,004	0,000	1,232	-1,174
More brodovi	-0,441	0,000	0,005	0,022	0,775	0,276
OPEKA d.d.	-0,469	-0,418	-0,005	0,803	0,164	-0,518
PULJANKA d. d.	-0,310	-0,385	0,007	0,024	0,046	-0,827
RAAFOURTY d.d.	0,039	-0,111	0,114	2,686	0,443	2,323
RIZ-ODAŠILJAČI d.d.	0,326	0,005	-0,027	0,472	0,495	1,087
Uljanik	-0,157	0,000	-0,429	0,032	0,631	-0,952
Uljanik brodogradilište	-2,310	-2,085	-0,576	0,224	0,425	-7,032
ULJANIK Strojogradnja Diesel d	-0,772	-1,348	-0,131	0,573	0,319	-2,582
Uljanik TESU	-0,157	-0,054	0,109	0,427	0,294	0,643
VIADUKT d.d.	-0,285	-0,001	0,049	0,187	0,918	0,849
VIG- d.d.	-1,051	-3,254	0,072	0,000	1,780	-3,798
VODOGRADNJA OSIJEK d.d.	-0,217	-0,963	-0,117	0,133	0,793	-1,121
ZAGORJE d.d.	-0,492	0,000	0,017	0,232	0,031	-0,365
ZRINSKI d.d.	-0,030	-0,033	0,014	0,705	0,542	0,929

Zdrava poduzeća	X1	X2	X3	X4	X5	Z-score
3. MAJ BRODOGRADILIŠTE	-1,430	-1,192	-2,026	0,048	0,385	-9,655
AD PLASTIK d.d.	0,000	0,010	0,021	1,366	0,710	1,613
Arena Hospitality Group d.d.	0,236	0,025	0,036	3,430	0,196	2,690
BRODOGRADILIŠTE VIKTOI	-0,075	0,000	-0,050	1,249	0,703	1,196
BRODOSPLIT d.d.	-0,226	0,133	0,015	0,628	0,397	0,738
BRODOSPLIT d.d.	-0,226	0,133	0,015	0,628	0,397	0,738
CEMEX Hrvatska d.d.	-0,005	0,126	-0,003	2,248	0,603	2,113
Dalekovod, d.d.	0,087	-0,183	-0,054	0,004	1,053	0,725
DUKAT d.d.	0,137	0,644	0,026	4,797	1,085	5,113
ERICSSON NIKOLA TESLA d	0,496	0,030	0,143	6,393	1,735	6,682
FRANCK d.d.	-0,083	-0,052	0,040	0,435	0,653	0,873
INA, d.d.	-0,004	0,029	0,065	6,664	1,026	5,273
Končar d.d.	0,185	0,003	0,044	38,440	0,098	23,534
KRAŠ d.d.	0,215	0,007	0,048	1,535	0,800	2,148
LAVČEVIĆ d.d.	0,330	0,019	-0,001	0,574	0,954	1,719
MAISTRA d. d.	-0,241	0,062	0,065	2,373	0,355	1,791
Osijek Koteks d.d.	0,355	-0,907	0,215	0,004	1,022	0,890
P P K d.d.	0,395	0,172	0,102	1,504	4,146	6,102
PETROKEMIJA, d.d.	0,122	0,000	-0,276	0,985	1,244	1,071
PLAVA LAGUNA d. d.	-0,013	0,085	0,082	4,480	0,371	3,432
PODRAVKA d.d.	0,149	0,001	0,037	3,070	0,649	2,793
Siemens d.d.	0,458	0,000	0,129	4,247	1,909	5,434
SUNCE HOTELI d.d.	0,028	0,000	-0,026	37,011	0,047	22,203
TURISTHOTEL d.d.	0,236	0,195	0,105	5,386	0,416	4,549
Valamar Riviera d.d.	-0,029	0,093	0,055	2,104	0,358	1,897
VINDIJA d.d. Varaždin	-0,159	0,205	0,028	0,018	1,522	1,721
Vodoprivreda Zagreb d.d.	0,216	0,359	-0,067	22,069	0,847	14,628