Pouzdanost Altmanovog i Kralicekovog pokazatelja

Tonković, Danijel

Undergraduate thesis / Završni rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **The Polytechnic of Rijeka / Veleučilište u Rijeci**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:125:768985

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Polytechnic of Rijeka Digital Repository - DR PolyRi

zir.nsk.hr

Image not found or type unknown

VELEUČILIŠTE U RIJECI

Danijel Tonković

POUZDANOST ALTMANOVOG I KRALICEKOVOG POKAZATELJA

(završni rad)

Rijeka, 2020.

VELEUČILIŠTE U RIJECI

Poslovni odjel

Stručni studij Poduzetništvo

POUZDANOST ALTMANOVOG I KRALICEKOVOG POKAZATELJA

(završni rad)

Mentor: mr. sc. Denis Buterin

Student: Danijel Tonković

MBS: 2423000072/16

Rijeka, rujan 2020.

VELEUČILIŠTE U RIJECI

Poslovni odjel

Rijeka, 01.4.2020.

ZADATAK
za završni rad

Pristupniku Danijelu Tonkoviću **MBS: 2423000072/16**

Studentu stručnog studija Poduzetništvo izdaje se zadatak završni rad – tema završnog rada pod nazivom:

Pouzdanost Altmanovog i Kralicekovog pokazatelja

Sadržaj zadatka:

Dati sustavan teorijski pregled relevantnih značajki analize boniteta temeljem financijskih pokazatelja. Posebnu pozornost posvetiti pokazateljima fianncijskih nestabilnosti te analizirati njihove najznačajnije teorijske odrednice. Temeljem javno dostupnih financijskih izvješća odabranih poduzeća provesti postupak ex post analize Altmanovog i Kralicekovog pokazatelja radi testiranja njihove pouzdanosti. Rezultate istraživanja sustavno prikazati u zaključku.

Rad obraditi sukladno odredbama Pravilnika o završnom radu Veleučilišta u Rijeci.

Zadano:01.4.2020. **Predati do: 15.9.2020.**

Mentor:

Dr.sc.Denis Buterin

Pročelnica odjela:

Mr.sc. Anita Stilin

Zadatak primio dana: 1.4.2020.

Danijel Tonković

- mentoru
- pristupniku

Izjava

Izjavljujem da sam završni rad pod naslovom **POUZDANOST ALTMANOVOG I KRALICEKOVOG POKAZATELJA** izradio samostalno pod nadzorom i uz stručnu pomoć mentora **mr.sc. Denisa Buterina**.

Danijel Tonković

Danijel Tonković

(potpis studenta)

Sažetak

Predmet istraživanja završnog rada je pouzdanost Altmanovog i Kralicekovog modela predviđanja stečaja. To su modeli pomoću kojih se utvrđuje financijska stabilnost poduzeća. Danas poduzeća vrlo pažljivo moraju birati poslovne partnere jer im je u interesu da su oni financijski stabilni i da im ne prijeti stečaj, u protivnom će i stabilnost njihovog poslovanja biti dovedena u rizik. Analizirana je pouzdanost Altmanovog i Kralicekovog modela za predviđanje stečaja na temelju financijskih izvještaja od Varteksa d.d., Solane Pag d.d. i Valalte d.o.o. u razdoblju od 2013.-2015. Rezultati izračunavanja su analizirani te je utvrđena preciznost odabranih modela te procijenjeno jesu li oni pouzdani i može li ih se koristiti u poslovanju.

Ključne riječi: financijska stabilnost, stečaj, Altmanova metoda i Kralicekova metoda

Sadržaj

1. UVOD 1

1.1 Problem, predmet i objekt istraživanja 1

1.2 Svrha i cilj istraživanja 1

1.3 Znanstvene metode 1

1.4 Struktura završnog rada 2

2. POKAZATELJI U ANALIZI BONITETA 2

2.1 Pokazatelji likvidnosti 4

2.2 Pokazatelji zaduženosti 5

2.3 Ostali pokazatelji 7

2.3.1 Pokazatelji aktivnosti 7

2.3.2 Pokazatelji ekonomičnosti 9

2.3.3 Pokazatelji profitabilnosti 10

3. TEORIJSKE OSNOVE PREDVIĐANJA FINANCIJSKIH NESTABILNOSTI 12

3.1 Altmanov model predviđanja stečaja 13

3.2 Kralicekov model predviđanja stečaja 17

3.3 Ostali modeli 18

3.3.1 Beawerov model predviđanja stečaja 18

3.3.2 Ohlsonov model predviđanja stečaja 20

3.3.3 Edmisterov model predviđanja stečaja 21

3.3.4 Mark E. Zmijewski model predviđanja stečaja 23

4. ANALIZA FINANCIJSKE NESTABILNOSTI PROMATRANIH PODUZEĆA 24

4.1 Altmanov model predviđanja stečaja na promatranim poduzećima 24

4.2 Kralicekov model predviđanja stečaja na promatranim poduzećima 26

4.3 Interpretacija rezultata analize 28

5. ZAKLJUČAK 30
LITERATURA 31
POPIS TABLICA I SLIKA 33

1. UVOD

1.1 Problem, predmet i objekt istraživanja

Predmet istraživanja završnog rada je Altmanov i Kralicekov pokazatelj. Edward I. Altman i Peter Kralicek su jedni od brojnih znanstvenika koji su razvili model za predviđanja stečaja. Navedeni modeli svoje zaključke crpe iz financijskih izvještaja poduzeća. Oni su važni za poduzeća jer pomoću njih procjenjuju koja je vjerojatnost stečaja njihovih poslovnih partnera. Stečaj jednog poslovnog partnera može imati ozbiljne posljedice za određenu tvrtku pa je u cilju pronalazak poslovnih partnera koji imaju malu vjerojatnost stečaja.

Problem istraživanja ovog završnog rada je pouzdanost Altmanovog i Kraicekovog pokazatelja, odnosno koliko su se oni do sada pokazali ispravnima i koliki značaj bi im se trebao pripisivati u analizi određenog poduzeća, i njegovog stečaja.

Objekt istraživanja ovog završnog rada su poduzeća pomoću čijih financijskih izvještaja ćemo izračunati Altmanove i Kralicekove pokazatelje; Valalta d.o.o., Solana Pag d.d. i Varteks d.d.

1.2 Svrha i cilj istraživanja

Svrha istraživanja je dobiti uvod u modele Altmanovog i Kralicekovog pokazatelja rizika stečaja s teorijskog i praktičnog aspekta. Cilj rada je detaljno objasniti navedene modele te na primjeru tvrtki pokazati kako se vrše izračuni i do kakvih zaključaka dolazimo.

1.3 Znanstvene metode

Završni rad predstavlja rezultat sustavnog proučavanja i analiziranja dostupne literature i financijskih izvještaja poduzeća Valalta d.o.o., Solana Pag d.d. i Varteks d.d. Pri tome su korištene i odgovarajuće znanstvene metode: induktivna metoda, metoda analize, metoda dokazivanja, statistička metoda i matematička metoda.

1.4 Struktura završnog rada

U prvom dijelu **Uvodu** objašnjen je problem, predmet i objekt istraživanja, svrha i cilj istraživanja, znanstvene metode koje se koriste u završnom radu te struktura završnog rada.

U drugom dijelu naslova **Pokazatelji u analizi boniteta** navedeni su pokazatelji koji se koriste u analizi boniteta te je opisano kako se izračunavaju i čemu služe.

U trećem dijelu naslova **Teorijske osnove predviđanja financijskih nestabilnosti** opisani su Altmanov i Kralicekov model izračunavanja. Objašnjeno je kako se računaju i interpretiraju dobiveni rezultati.

U četvrtom dijelu naslova **Analiza financijske nestabilnosti promatranih poduzeća** primijenjeni su Altmanov i Kralicekov model u izračunavanju rizika od stečaja, te je izveden zaključak iz dobivenih rezultata.

U posljednjem dijelu naslova **Zaključak** sažeto su formulirani najvažniji rezultati korištenih modela koji su detaljno razrađeni u samom radu.

Iza zaključka predočena je literatura koja se koristila u izradi završnog rada, te popis tablica i grafikona.

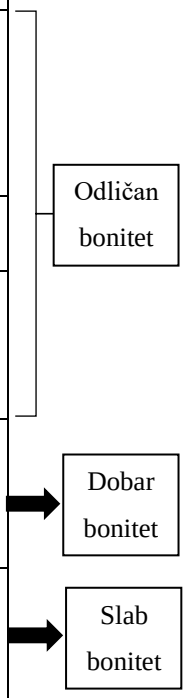
2. POKAZATELJI U ANALIZI BONITETA

Bonitet je skup svojstava kojima se prosuđuje kvaliteta poslovanja poduzeća (vrijednost, poslovna i kreditna sposobnost). Ocjena boniteta ponajprije se temelji na kriterijima sigurnosti i uspješnosti poslovanja poduzeća, a njihovo se ostvarivanje prosuđuje na temelju financijskog izvještaja. Kompleksna ocjena boniteta zahtijeva i informacije o položaju poduzeća na tržištu, o životnom ciklusu proizvoda te informacije vezane za buduće poslovanje poduzeća. (Hrvatska enciklopedija, mrežno izdanje)

Bonitetne ocjene su neophodan ekonomski instrument koji se primjenjuje u suvremenom poslovnom svijetu i koriste se kao valjana provjera cjelokupnog poslovanja jednog poslovnog subjekta. Omogućuju brže i jednostavnije donošenje poslovnih odluka pri izboru poslovnog partnera, analize konkurencije i procjene rizika. Predstavljaju podršku u postupku financijske analize pojedinačnog poslovnog društva. (Company wall, 2020.)

Tablica 1. Bonitetne ocjene

Bonitetna ocjena	Opis tvrtke
AAA	Izuzetno visoka sposobnost izvršavanja financijskih obveza, minimalan kreditni rizik. Besprijekorna solventnost i poslovna učinkovitost. Potvrda stabilnosti tvrtke i kvalitete poslovanja, te označena kao pouzdan i idealan poslovni partner.
AA+	Pouzdana i stabilna. Suradnja s tvrtkom ne predstavlja rizik, jer ona zadovoljava sve visoke kriterije uspješnog poslovanja.
A	Nikakvi znakovi rizičnog poslovanja u budućnosti. Nešto slabija ocjena je dodijeljena zbog poslovanja u prošlosti, ili kada je riječ o mladoj tvrtki, ipak ona je sada pouzdan poslovni partner.
BBB	Sposobnost izvršavanja financijskih obveza, prisutan rizik promjene poslovne klime i ekonomskih uvjeta, kao i znatan kreditni rizik. Tvrtka posluje zadovoljavajuće, ali ponekad ima teškoća s likvidnošću.
CCC	Loša sposobnost izvršenja financijskih obveza, veoma visok kreditni rizik. Poduzeće posluje rizično i u budućnosti neće opstati. Vjerojatnost blokade, stečaja ili likvidacije je gotovo neizvjesna u naredne dvije godine.



Izvor: izrada autora

Da bi poduzeće bilo bonitetno, odnosno uspješno, treba zadovoljiti određene pokazatelje koji se mjere iz financijskih izvještaja. To su pokazatelji likvidnosti, pokazatelji zaduženosti te ostali pokazatelji.

2.1 Pokazatelji likvidnosti

Pokazateljima likvidnosti mjeri se sposobnost društva kako podmiruje dospjele kratkoročne obveze. Pokazatelji likvidnosti izračunavaju se na temelju podataka iz bilance. Pokazuju ima li na raspolaganju dovoljno gotovog novca i sredstava, koja se brzo mogu pretvoriti u novčani oblik kako bi se podmirila dugovanja prema njihovom dospijeću. (Mijoč, Martinović i Mahaček, 2010.)

Tablica 2. Pokazatelji likvidnosti

Opis	Način izračunavanja	Standardna veličina
koeficijent tekuće likvidnosti	kratkotrajna imovina/ kratkotrajne obveze	2 i veći
koeficijent trenutne likvidnosti	novac/ kratkoročne obveze	1
koeficijent ubrzane likvidnosti	kratkotrajna imovina- zalihe /kratkoročne obveze	1 i veći
koeficijent financijske stabilnosti	dugotrajna imovina/ (kapital + dugoročne obveze)	manji od 1

Izvor: izrada autora

Koeficijentom tekuće likvidnosti nastoji se ukazati na mogućnost održavanja solventnosti. Standardna veličina ovog pokazatelja je 2, što znači da bi tekuća imovina trebala biti barem dvostruko veća od tekućih obveza kako bi ih društvo bilo sposobno podmiriti dospjele (tekuće). Ako je pokazatelj veći, smatra se kako je veća sposobnost društva da podmiruje svoje račune. Veličina pokazatelja likvidnosti, u znatnoj mjeri, ovisi o vrsti poslovanja te o specifičnostima stavki potraživanja i dugovanja. (Mijoč, Martinović i Mahaček, 2010.)

Koeficijent trenutne likvidnosti predstavlja odnos najlikvidnije imovine, novca i kratkoročnih obveza. Ako je izračunati pokazatelj 1, znači kako su raspoloživa novčana sredstva dostatna za podmirenje kratkoročnih obveza.

Koeficijent ubrzane likvidnosti pokazuje može li društvo podmiriti svoja dugovanja, odnosno kratkoročne obveze iz gotovine kojom raspolaže ili brzo unovčivih izvora. Iz tekuće imovine isključene su zalihe kao najnelikvidniji dio obrtnih sredstava. Navedeni pokazatelj bi trebao biti jedan i veći. Takvo stajalište proizlazi iz uvjerenja da zalihe i fiksnu imovinu treba financirati dugoročno, a nematerijalne oblike tekuće imovine moguće je financirati kratkoročno. (Mijoč, Martinović i Mahaček, 2010.)

Koeficijent financijske stabilnosti mora biti manji od jedan jer se tada povećava likvidnost i financijska stabilnost društva. Tada se manji dio glavnice i dugoročnih obaveza koristi za financiranje dugotrajne imovine, a sve veći dio se koristi za financiranje kratkoročne imovine. (Mijoč, Martinović i Mahaček, 2010.)

Među mogućim načinima za povećanje omjera likvidnosti može se spomenuti smanjivanje zaliha, pretvaranje dijela dugotrajne imovine u kratkotrajnu, plaćanje nekih dugova te povećavanje tekuće imovine putem kredita ili drugih posudbi novca sa dospijećem dužim od jedne godine. (Mijoč, Martinović i Mahaček, 2010.)

Ako su svi koeficijenti poduzeća jednaki preporučenoj veličini znači da je to poduzeće likvidno, odnosno spremno je u bilo kojem trenutku podmiriti svoje obaveze. Također, to znači da ispunjava jedan od uvjeta za bonitetno, odnosno uspješno poduzeće.

2.2 Pokazatelji zaduženosti

Pokazatelji zaduženosti odgovaraju na pitanja koliko se poduzeće financira iz vlastitih, a koliko iz tuđih izvora financiranja. Iako je gotovo nemoguće financirati se samo iz vlastitih izvora, svako poduzeće bi trebalo težiti financiranju iz vlastitih izvora u što većem postotku.

U sljedećoj tablici navedeni su pokazatelji zaduženosti:

Tablica 3. Pokazatelji zaduženosti

Opis	Način izračunavanja	Standardna veličina
Koeficijent zaduženosti	Ukupne obveze/ukupna imovina	Manje od 0,50
Koeficijent vlastitog financiranja	Kapital i rezerve/ ukupna imovina	Više od 0,50
Koeficijent financiranja	Ukupne obveze/ kapital i rezerve	Do 1,00
Stupanj pokrića I	Glavnica/ dugotrajna imovina	-
Stupanj pokrića II	Glavnica+ dugoročne obveze /dugotrajna imovina	-

Izvor: izrada autora

Koeficijent zaduženosti je najčešći pokazatelj kojim se mjeri zaduženost poduzeća. To je odnos između ukupnih obveza i ukupne imovine. Prihvatljiv je do 50%, što znači da financiranje poduzeća iz vlastitih izvora mora biti barem 50%. Sve manje od toga znači da je poduzeće previše zaduženo.

Rizik zaduženosti može biti i neiskazan, ali ipak prisutan: jedan od načina njegovog ogledanja je izrazita lakoća dobivanja kredita na tržištu što može nagovještavati dolazak gospodarske i financijske krize pa je u takvim uvjetima potreban veliki oprez (Buterin et al, 2018). Posljedice bilančnih neravnoteža kao učinak prezaduženosti bile su vrlo izražene u vrijeme Velike recesije (Buterin i Buterin, 2014). Naime, tad je bio upitan ne samo opstanak zaduženih poduzeća nego i mogućnost preživljavanja jakih financijskih institucija, poput mirovinskih fondova ili banaka (Olgić Draženović et al, 2018). Nadalje, zaduživanje u inozemnoj valuti podložno je tečajnom riziku što se posebno dobro moglo uočiti godine 2010. kad je zbog kvantitativnog popuštanja gotovo došlo do pariteta američke i europske valute (Buterin et al, 2015).

Koeficijent vlastitog financiranja pokazuje koliko je dio ukupne imovine financiran vlastitim izvorima sredstava. Udjel vlastitog financiranja mora biti barem 50%. Što se poduzeće više financira iz vlastitih izvora u odnosu na tuđe izvore, to je položaj tog društva bolji.

Koeficijent financiranja pokazuje koliko jedinica tuđeg kapitala po jedinici vlastitog kapitala društvo koristi za financiranje poslovanja. Ako se poduzeće zadužuje iznad iznosa vlastite glavnice znači da nije stabilno i da se previše zadužilo. (Mijoč, Martinović i Mahaček, 2010.)

Stopa pokrića I i II mogu se ubrojiti u pokazatelje likvidnosti i u pokazatelje zaduženosti. Temelje se na podatcima iz bilance. Kod stope pokrića I promatra se pokriće dugotrajne imovine glavnicom dok stopa pokrića II promatra pokriće dugotrajne imovine glavnicom uvećanom za dugoročne obveze. Povećanje ovih koeficijenata ukazuje na smanjenje zaduženosti uz, istovremeno, povećanje likvidnosti. (Mijoč, Martinović i Mahaček, 2010.)

Ako su sve vrijednosti pokazatelja zaduženosti jednake ili u standardnom rangu, znači da se poduzeće dovoljno zadužuje iz vlastitih izvora, odnosno da nije previše zaduženo. Samim time ispunjava se još jedan od uvjeta uspješnog poslovanja poduzeća.

2.3 Ostali pokazatelji

Pod ostalim pokazateljima treba spomenuti pokazatelje aktivnosti, pokazatelje ekonomičnosti i pokazatelje profitabilnosti.

2.3.1 Pokazatelji aktivnosti

Pokazatelji aktivnosti prikazuju koliko efikasno se koriste resursi poduzeća. Isto tako, prikazuju koliko brzo imovina cirkulira u poslovnom procesu. Pokazatelji aktivnosti nazivaju se i koeficijent obrtaja.

Tablica 4. Pokazatelji aktivnosti

Opis	Način izračunavanja	Standardna veličina
Koeficijent obrtaja ukupne imovine	Ukupni prihod/ ukupna imovina	4
Koeficijent obrtaja kratkotrajne imovine	Ukupni prihod/ kratkotrajna imovina	8
Koeficijent obrtaja potraživanja	Prihodi od prodaje/ potraživanja	28
Trajanje naplate potraživanja	365/ koeficijent obrtaja potraživanja	14

Izvor: izrada autora

Koeficijent obrtaja ukupne imovine računa se kao odnos između ukupnih prihoda i ukupne imovine. Ovaj koeficijent prikazuje koliko jedna novčana jedinica aktiva stvara novčanih jedinica prihoda. Standardna veličina ovog koeficijenta je 4. Ako se koeficijent obrta ukupne imovine povećava u odnosu na prethodno promatrano razdoblje znači da prosječno trajanje cirkulacije sredstava u poslovnom procesu se smanjilo te je prisutna pozitivna tendencija u poslovanju. (Mijoč, Martinović i Mahaček, 2010.)

Koeficijent obrtaja kratkotrajne imovine odnos je ukupnih prihoda i kratkotrajne imovine. Standardna veličina ovog koeficijenta je 8. Povećanje koeficijenta u odnosu na prethodno promatrano razdoblje ukazuje na pozitivnu tendenciju u poslovanju, što znači da poduzeće stvara više novčanih jedinica prihoda po novčanoj jedinici kratkotrajne imovine.

Koeficijent obrtaja potraživanja računa se kao odnos između prihoda od prodaje i potraživanja. Standardna veličina je 28, a povećanjem koeficijenta smanjuje se trajanje naplate potraživanja.

Koeficijent trajanja naplate potraživanja odnos je 365 (broj dana u godini) sa koeficijentom obrtaja potraživanja. Dobiveni rezultat koeficijenta je broj dana potreban za naplatu potraživanja, što znači da bi ovaj koeficijent trebao biti što manji. Ako se koeficijent smanjuje u odnosu na prethodno promatrano razdoblje znači da poduzeće posluje sa pozitivnom tendencijom. (Mijoč, Martinović i Mahaček, 2010.)

2.3.2 Pokazatelji ekonomičnosti

Pokazatelji ekonomičnosti pokazuju koliko se jedinica prihoda ostvari po jedinici rashoda. Podaci za izračunavanje ovog pokazatelja dobivaju se iz Računa dobiti i gubitka. Vrijednost pokazatelja ekonomičnosti treba biti veći od 1, ako je suprotno znači da poduzeće posluje u gubitku. (Mijoč, Martinović i Mahaček, 2010.)

Tablica 5. Pokazatelji ekonomičnosti

Opis	Način izračunavanja	Standardna veličina
Ekonomičnost ukupnog poslovanja	Ukupni prihodi/ ukupni rashodi	1
Ekonomičnost poslovanja	Prihodi od prodaje/ rashodi prodaje	1
Ekonomičnost financiranja	Financijski prihodi/ financijski rashodi	1
Ekonomičnost izvanrednih aktivnosti	Izvanredni prihodi/ izvanredni rashodi	1

Izvor: izrada autora

Ekonomičnost ukupnog poslovanja odnos je između ukupnih prihoda i ukupnih rashoda. Ovaj koeficijent prikazuje koliko jedinica prihoda ostvarujemo po jedinici rashoda. Da bi poduzeće bilo stabilno, ovaj koeficijent mora biti iznad standardne veličine koja iznosi 1.

Ekonomičnost poslovanja odnos je između prihoda od prodaje i rashoda prodaje. Ako su prihodi od prodaje veći od rashoda od prodaje znači da je koeficijent iznad standardne veličine i da poduzeće pozitivno posluje. (Mijoč, Martinović i Mahaček, 2010.)

Ekonomičnost financiranja je odnos financijskih prihoda i financijskih rashoda. Ako je dobiveni rezultat manji od standardne vrijednosti ekonomičnost financiranja je negativna, odnosno ne ostvaruje se dovoljno financijskih prihoda za pokriće nastalih financijskih rashoda.

Ekonomičnost izvanrednih aktivnosti odnos je između izvanrednih prihoda i izvanrednih rashoda. Izvanredni prihodi moraju biti veći od izvanrednih rashoda da bi ekonomičnost izvanrednih aktivnosti bila pozitivna i da bi poduzeće pozitivno poslovalo. (Mijoč, Martinović i Mahaček, 2010.)

2.3.3 Pokazatelji profitabilnosti

Krajnji cilj svakog poduzeća je ostvarivanje profita. Pokazatelji profitabilnosti daju odgovor na pitanje je li poduzeće profitabilno i ako je, koliko? Efikasnost korištenja resursa društva i povrat uloženog kapitala utvrđuje se na temelju pokazatelja profitabilnosti.

Tablica 6. Pokazatelji profitabilnosti

Opis	**Način izračunavanja**
Neto marža profita	Neto dobit+ kamate/ ukupni prihod
Bruto marža profita	Dobit prije poreza+ kamate/ ukupni prihod
Rentabilnost vlastitog kapitala	Neto dobit/ vlastiti kapital
Neto rentabilnost imovine	Neto dobit+ kamate/ ukupna imovina

Izvor: izrada autora

Neto marža profita odnos je neto dobiti i kamate sa ukupnim prihodom. Ako se neto marža povećava u odnosu na prethodno promatrano razdoblje znači da poduzeće bilježi pozitivno kretanje.

Bruto marža profita odnos je dobiti prije poreza uvećan za kamate sa ukupnim prihodima. „Bruto profitna marža pokazuje uspješnost poduzeća, odnosno sposobnost managementa da upravlja prodajnim cijenama, troškovima i obujmom poslovne aktivnosti.“ (Mijoč, Martinović i Mahaček, 2010.). Ukoliko se ovaj pokazatelj povećava znači da je došlo do povećanja rentabilnosti i da poduzeće bilježi pozitivno kretanje.

Rentabilnost vlastitog kapitala odnos je između neto dobiti i vlastitog kapitala. Ako poduzeće zabilježi smanjenje ovog pokazatelja u odnosu na prethodno razdoblje znači da mu se smanjila rentabilnost vlastitog kapitala. (Mijoč, Martinović i Mahaček, 2010.)

Neto rentabilnost imovine rezultat je odnosa između neto dobiti uvećane za kamatu sa ukupnom imovinom. Poduzeće treba težiti što većem pokazatelju neto rentabilnosti imovine, jer što je pokazatelj veći to poduzeće profitabilnije posluje. (Mijoč, Martinović i Mahaček, 2010.)

Pokazatelji rentabilnosti se izračunavaju korištenjem informacija iz bilance i računa dobiti i gubitka, a prilikom definiranja rentabilnost imovine razlikuju se neto i bruto rentabilnost. Kao i kod prethodno navedene marže profita, razlika je u obuhvatu poreza u brojniku pokazatelja. Stopa prinosa na ukupnu imovinu ili rentabilnost ukupne imovine prikazuje odnos između financijskog rezultata prije oporezivanja (bruto dobiti) uvećanog za iznos kamata, te ukupne imovine. Potrebno je napomenuti da se ovaj pokazatelj prikazuje i kao odnos između realizirane neto dobiti uvećane za kamate te ukupne imovine. Ukoliko organizacija ostvaruje stopu prinosa na ukupnu imovinu koja je manja od prosječnog troška korištenih sredstava, tada dolazi do smanjivanja vrijednosti. Stopa prinosa na ukupnu imovinu se povezuje s uspjehom rukovodstva u procesu upravljanja ukupnom imovinom organizacije, a kao i kod drugih pokazatelja, objektivizira se usporedbom s organizacijama iz slične ili iste djelatnosti (Barbić i sur., 2008).

3. TEORIJSKE OSNOVE PREDVIĐANJA FINANCIJSKIH NESTABILNOSTI

Tržišni način privređivanja karakterizira postojanje niza poslovnih rizika s kojima su suočeni poduzetnici pri obavljanju gospodarske djelatnosti. Rizik od gubitka tržišta prodaje i nabave, valutni rizik, rizik promjene kamatnih stopa, rizik gubitka djelatnika i mnoštvo drugih poslovnih rizika sastavni su dio života poslovnih subjekata pri čemu se mnogi od njih nisu u stanju nositi s njima te su prinuđeni napustiti tržišnu utakmicu.

Čest je slučaj da poduzeća ulažu u nešto o čemu nemaju dovoljno saznanja, ali očekuju velike povrate. Tako se, na primjer, proizvodi ili usluge temeljene na znanju smatraju dobrom investicijskom prilikom koju zbog porasta cijene vrlo često prihvaćaju upravo oni investitori koji o samom proizvodu i njegovom funkcioniranju vrlo malo znaju, a to kasnije može dovesti do brojnih neželjenih posljedica, poput gubitka likvidnosti, solventnosti, pa čak i stečaja (Boras et al, 2002).

Prestanak poslovanja jednog poslovnog subjekta često za sobom povlači niz multiplikativnih učinaka, budući da je imao razvijenu mrežu poslovnih odnosa s mnoštvom drugih poslovnih subjekata koji su zainteresirani za njegovo poslovanje (stakeholdersi). Stoga je u interesu svakog poslovnog subjekta procjenjivati vjerojatnost stečaja poslovnih partnera u cilju odgovarajućeg upravljanja poslovnim rizicima. U tom smislu na raspolaganju im stoji niz različitih alata među kojima značajno mjesto zauzimaju financijski pokazatelji. Predviđanju stečaja u početku se pristupalo razmatranjem pojedinačnih financijskih pokazatelja i njihovom usporedbom s određenim referentnim vrijednostima temeljem čega su izvođeni određeni zaključci. Implementacijom statističkih i matematičkih metoda u svrhu predviđanja stečaja otišlo se korak dalje te su razvijeni modeli za predviđanje stečaja kod kojih su središnje mjesto također zauzimali financijski pokazatelji, a bitan napredak učinjen je u smislu određivanja važnosti pojedinog pokazatelja te preciznosti korištenog modela. (Zenzerović, Peruško, 2006.)

Vjerojatnost stečaja na početku se mjerila znanstvenom tehnikom, a kasnije su korištene kvantitativne metode predviđanja stečaja kao što su diskriminantna analiza, modeli linearnih vrijednosti, stablo odlučivanja, neuronske mreže i sl. 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. Najpoznatiji i najčešće korišteni su modeli sljedećih autora:

- Petera Kraliceka,
- Edwarda I. Altmana,
- Edwarda B. Deakina,
- Jamesa A. Ohlsona,
- Roberta O. Edmistera,
- Christine V. Zavgren i
- Williama H. Beawera.

3.1 Altmanov model predviđanja stečaja

Zasigurno najznačajniji doprinos razvoju modela za predviđanje stečaja dao je Edward I. Altman. Godine 1968. objavio je rezultate prvog multivarijantnog istraživanja odnosa između financijskih pokazatelja i vjerojatnosti stečaja. Za razliku od Beawerovog jednovarijantnog modela, koji je istaknuo važnost pojedinih pokazatelja za predviđanje stečaja, Altman je smatrao da "upotreba samo jednog pokazatelja za predviđanje stečaja može dovesti do krive interpretacije, ukoliko je isti "uštiman" ili izjednačen se nekim drugim pokazateljima koji pokazuju drugačije vjerojatnost stečaja" (Tearney, Vitezić, 1996.).

Empirijsko istraživanje provedeno je na uzorku od 66 proizvodnih poslovnih subjekata čijim se vrijednosnim papirima javno trgovalo. Uzorak je bio podijeljen na dvije jednake grupe. Prva grupa obuhvaćala je proizvodne poslovne subjekte koji su pokrenuli stečajni postupak u razdoblju od 1946. do 1965. godine. Veličina aktive ove grupe poslovnih subjekata varirala je od 700 tisuća do 25,9 milijuna dolara s prosjekom od 6,4 milijuna. Druga grupa obuhvaćala je financijski stabilne poslovne subjekte iz iste djelatnosti i približno iste veličine aktive. Prikupljeni financijski izvještaji za poslovne subjekte iz obiju grupa odnosili su se na isto izvještajno razdoblje. Na temelju prikupljenih financijskih informacija izračunata su 22 financijska pokazatelja te su provedbom metode statističke analize pod nazivom multivarijantna diskriminantna analiza utvrđeni ponderi za svakog od njih. S obzirom da važnost među pokazateljima varira, izdvojeno je pet pokazatelja koji najbolje diskriminiraju financijski zdrave od poslovnih subjekata suočenih s pokretanjem stečajnog postupka.

Razvijeni način za predviđanje stečaja poznat je i kao Z-score, a prikazan je sljedećom jednadžbom:

$$\mathrm{Z} = 0.012X_1 + 0{,}014X_2 + 0{,}033X_3 + 0{,}006X_4 + 0{,}999X_5$$

gdje je:

Z- vrijednost diskriminantne funkcije

X_1- radni kapital/ ukupna imovina

X_2- zadržana dobit/ ukupna imovina

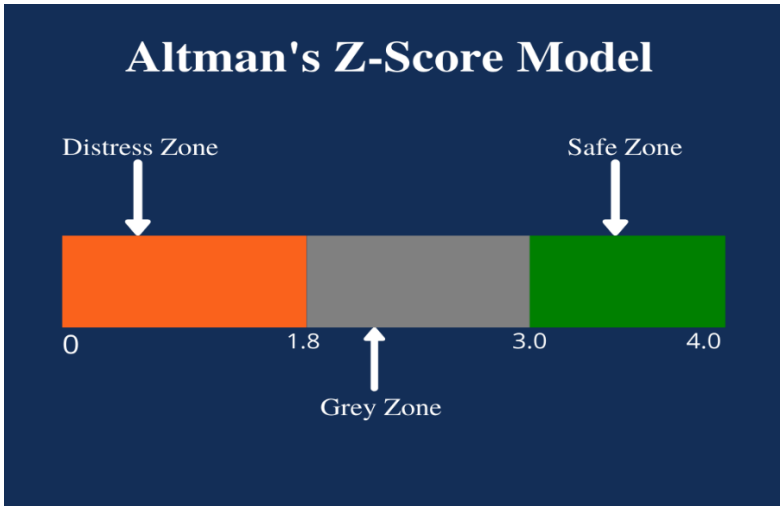
X_3- dobit prije poreza i kamata/ ukupna imovina

X_4- tržišna vrijednost glavnice/ ukupne obveze (knjigovodstvena vrijednost)

X_5- prihodi od prodaje/ ukupna imovina

Daljnjom statističkom analizom izvedenog modela Altman je utvrdio kritične vrijednosti diskriminantne funkcije koje su prikazane Slikom 1.

Slika 1. Kritične vrijednosti Z-score



Izvor: Corporate finance institute

Prema modelu, vrijednost Z-score poslovnog subjekta manja od 1,8 ukazuje na nevolje i veliku mogućnost stečaja. Vrijednost unutar intervala od 1.8- 3.0 predstavljaju tzv. sivu zonu. U njoj se najčešće nalaze poduzeća koja imaju ugroženu financijsku stabilnost, ali sa mogućnosti ozdravljenja. Vrijednosti Z- scorea poslovnog subjekta iznad 2.99 ukazuju na financijski stabilan poslovni subjekt.

Nakon izvođenja diskriminantne funkcije Altman je pristupio testiranju njezine točnosti na uzorku poslovnih subjekata i utvrdio je da preciznost opada kako se produžuje vremenski horizont predviđanja. Preciznost funkcije, odnosno modela prikazana je Tablicom 7.

Tablica 7. Točnost predviđanja stečaja Z- score

Godine prije postupanja stečajnog postupka	Postotak točnosti razvrstavanja
1	95
2	72
3	48
4	29
5	36

Izvor: izrada autora prema Altman, 1968.

Prema navedenim podacima može se zaključiti da je Z- score imao vrlo visoku točnost razvrstavanja neposredno prije stečaja, odnosno godinu dana prije. Postotak točnosti je iznosio 95%. Relativno visoka točnost je bila i 2 godine prije postupanja stečajnog postupka- 72%. Ipak, sa većim vremenskim razmakom Z score nije toliko pouzdan, i postotak točnosti iznosi manje od 50%.

Budući da je navedeni model za predviđanje stečaja izveden korištenjem podataka proizvodnih poslovnih subjekata čije su vrijednosnice izlistane na burzi, Altman je u kasnijim istraživanjima izvršio dvije korekcije. Prva se odnosila na prilagodbu modela za predviđanje stečaja onim poslovnim subjektima čije vrijednosnice nisu izlistane na burzi, odnosno koji su u vlasništvu manjeg broja osoba. Sukladno tome, u brojniku varijable X_4 došlo je do zamjene tržišne vrijednosti glavnice njezinom knjigovodstvenom vrijednošću, a prilagođeni su i ponderi. (Zenzerović, Peruško, 2006.)

Novi model izgleda ovako:

$$Z' = 0.717X_1 + 0{,}847X_2 + 3{,}107X_3 + 0{,}420X_4 + 0{,}998X_5$$

Prilikom tumačenja korigiranog modela potrebno je napomenuti da je došlo do promjena kritičnih vrijednosti koji više ne iznose 2,99, i 1,81, već 2,90 i 1,23.

Druga izmjena rezultat je nastojanja da se model prilagodi predviđanju stečaja neproizvodnih poslovnih subjekata. Iz modela je tako isključena varijabla X_5 jer se ona bitno razlikuje između različitih djelatnosti. Izmjenom modela došlo je do izmjene kritičnih vrijednosti koje sada iznose 2,60 i 1,10. (Zenzerović, Peruško, 2006.)

Novi model izgleda ovako:

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

3.2 Kralicekov model predviđanja stečaja

Peter Kralicek među poznatijim je neameričkim istraživačima koji je provodeći multivarijantnu diskriminantnu analizu izveo model za predviđanje stečaja. Koristeći se podacima iz financijskih izvještaja njemačkih, švicarskih i austrijskih poslovnih subjekata. (Zenzerović, Peruško, 2006.).

Kralicek je izveo sljedeći model:

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

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

X_6- poslovni prihodi/ ukupna imovina

Ukupni prihodi predstavljaju zbroj poslovnih, financijskih i ostalih prihoda uvećanih za prihode od usklađivanja vrijednosti ostale imovine.

Kralicekov model može poprimiti pozitivne i negativne vrijednosti. Negativna vrijednost ukazuje na insolventnost poduzeća, a pozitivna na solventnost. Kritične vrijednosti DF pokazatelja prikazane su u Tablici 8.

Tablica 8. Kritične vrijednosti DF pokazatelja s pripadajućom ocjenom financijske stabilnosti

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: izrada autora prema Koban, 1978.

3.3 Ostali modeli

Među znanstvenicima čiji modeli se često koriste za predviđanje stečaja treba još spomenuti William H. Beawera, James A.Ohlsona, Robert O. Edmistera i Mark E. Zmijewskog. Modeli navedenih autora biti će objašnjeni u nastavku rada.

3.3.1 Beawerov model predviđanja stečaja

Beawer je 1966. krenuo istraživati može li se stečaj predvidjeti na temelju financijskih pokazatelja, te je u svojemu radu donesao jasnu preporuku za buduća istraživanja ove teme.

Korisnost financijskih pokazatelja William H. Beaver testirao je na primjeru predviđanja financijskog neuspjeha poslovnog subjekta gdje je pod neuspjehom podrazumijevao nesposobnost poslovnog subjekta da podmiri dospjele financijske obveze. Beawer je proveo empirijsko istraživanje na uzorku od 158 proizvodnih korporacija čijim se dionicama javno trgovalo. Uzorak je podijeljen na dvije jednake grupe. Prva grupa sastojala se od 79 korporacija koje su ušle u stečaj u razdoblju od 1954. do 1964. godine, dok je druga grupa obuhvaćala isti broj financijski zdravih korporacija. Za obje kategorije prikupljeni su financijski izvještaji, i to za razdoblje od pet godina prije pokretanja stečajnog postupka za prvu grupu, te za isto petogodišnje razdoblje za drugu grupu. Navedene korporacije poslovale su u 38 različitih djelatnosti, njihova aktiva varirala je od 600 tisuća do 45 milijuna dolara.

Za potrebe analize Beawer je izabrao 30 pokazatelja grupiranih u šest skupina. Odabir pokazatelja izvršen je na temelju sljedećih kriterija: 1. učestalo spominjanje pokazatelja u literaturi; 2. dobri rezultati pokazatelja pri predviđanju stečaja u prijašnjim istraživanjima ili 3. pripadnost skupini pokazatelja na temelju novčanog toka. Odabrani pokazatelji ispunjavali su jedan od navedenih kriterija. Na svakom pokazatelju proveden je klasifikacijski test raščlambe te je iz svake od šest skupina pokazatelja izabran onaj koji je imao najmanju pogrešku klasifikacije poslovnih subjekata na financijski zdrave i one u poteškoćama tijekom petogodišnjeg razdoblja promatranja. (Zenzerović, Peruško, 2006.).

Tablica 9. prikazuje izabrane pokazatelje i pripadajuće pogreške klasifikacije svakog od njih. Pokazatelji su navedeni redom počevši od najpreciznijih prema manje preciznima.

Tablica 9. Pogrešno klasificiranje poslovnih subjekata za 6 najtočnijih pokazatelja u %

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
6	(Kratkotrajna imovina- zalihe- kratkoročne obveze)/ (operativni troškovi- amortizacija- umanjenja imovine)	23	38	43	38	37

Izvor: izrada autora prema Beawer, 1966.

3.3.2 Ohlsonov model predviđanja stečaja

James A. Ohlson objavio je 1980. godine rezultate istraživanja koje je proveo na 2163 proizvodna poslovna subjekta u razdoblju od 1970. do 1976. godine. Uzorak je bio podijeljen na dva dijela, ali je za razliku od njih prvi dio obuhvaćao 105 poslovnih subjekata nad kojima je pokrenut stečajni postupak, dok je drugi sadržavao podatke 2058 financijski zdrava poslovna subjekta. Istraživanjem su prikupljeni financijski izvještaji poslovnih subjekata za razdoblje od tri godine prije pokretanja stečajnog postupka. Na temelju istraživanja izračunati su sljedeći pokazatelji:

1. Veličina mjerena logaritmom odnosa ukupne imovine i indeksa bruto nacionalnog proizvoda
2. Pokazatelj zaduženosti kao odnos ukupnih obveza i ukupne imovine
3. Udio radnog kapitala u ukupnoj imovini
4. Odnos kratkoročnih obveza i kratkotrajne imovine
5. Dummy varijabla 1-1, ukoliko su ukupne obveze veće od ukupne imovine i 0 ako je obrnut slučaj
6. Udio neto dobiti u ukupnoj imovini
7. Odnos novčanog toka od poslovnih aktivnosti i ukupnih obveza
8. Dummy varijabla 2-1, ukoliko je neto dobit negativna kroz posljednje dvije godine i 0 u ostalim slučajevima
9. $\frac{NI_t - NI_{t-1}}{|NI_t| + |NI_{t-1}|}$ gdje je NI_t neto dobit u posljednjem razdoblju promatranja (Zenzerović, Peruško, 2006.).

Nakon izračuna pokazatelja provedena je logit statistička analiza koja je rezultirala izvedbom triju modela za predviđanje stečaja. Model 1 predviđa stečaj unutar prve godine, Model 2 unutar druge godine, pod uvjetom da nije pokrenut stečaj u prvoj godini, dok je Model 3 izveden za predviđanje stečaja unutar razdoblja od dvije godine. Tablicom 10. prikazana su tri modela za predviđanje stečaja s pripadajućim ponderima.

Tablica 10. Ohlsonovi modeli za predviđanje stečaja

Model	**Redni broj pokazatelja**									
	1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**Konstanta**
Model 1										
Ponderi	-0,407	6,03	-1,43	0,0757	-2,37	-1,83	0,285	-1,72	-0,521	-1,32
Model 2										
Ponderi	-0,519	4,76	-1,71	-0,297	-2,74	-2,18	-0,78	-1,98	0,4218	1,84
Model 3										
Ponderi	-0,478	5,29	-0,99	0,062	-4,62	-2,25	-0,521	-1,91	0,212	1,13

Izvor: izrada autora prema Ohlson, 1980.

Preciznost ovih modela je veoma visoka i može se reći da je pouzdana. Naime, Model 1 predviđa stečaj točno u 96,12% slučajeva, Model 2 u 95,55% te Model 3 sa 92,84%.

3.3.3 Edmisterov model predviđanja stečaja

Edmister se koncentrirao na predviđanje stečaja velikih i srednjih poduzeća. Razlog tome bila je nedostupnost informacija i financijskih izvještaja malih poduzeća. Pod stečajem se podrazumijevala nesposobnost poslovnih subjekata da podmiruju dospjele rate kredita, te se nije zahtijevalo da nad njima bude formalno pokrenut stečajni postupak. Promatrani financijski izvještaji odnosili su se na vremenski interval od 1958.-1965. godine. (Zenzerović, Peruško, 2006.).

U odnosu na ranije studije, Edmister u istraživanje uvodi sljedeće novosti: korištenje trogodišnjeg prosjeka pokazatelja, korištenje trogodišnjeg trenda kretanja pokazatelja te odnos pokazatelja poslovnog subjekta s prosječnim pokazateljem djelatnosti. Obilježje su Edmisterovog modela dummy varijable koje ovise o vrijednosti izračunatih pokazatelja.

Edmisterov model za predviđanje stečaja prikazan je sljedećom jednadžbom:

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

gdje je:

Z- vrijednost diskriminantne funkcije

X_1- 1 ukoliko je čisti novčani tok / kratkoročne obveze manji od 0,05, a 0 u ostalim slučajevima

X_2- 1 ukoliko je glavnica / prihodi od prodaje manji od 0,07, a 0 u ostalim slučajevima

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

X_4- 1, ukoliko je (kratkoročne obveze / glavnica) / (kratkoročne obveze ukupne djelatnosti / glavnica ukupne djelatnosti) manji od 0,48, a 0 u ostalim slučajevima

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

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

X_7- 1, ukoliko pokazatelj ubrzane likvidnosti / pokazatelj ubrzane likvidnosti ukupne djelatnosti ima rastući trend, a 0 u ostalim slučajevima (Zenzerović, Peruško, 2006.).

Preciznost predviđanja stečaja Edmisterovog modela prikazana je Tablicom 11.

Tablica 11. Točnost predviđanja stečaja Edmisterovog z- pokazatelja

Edmisterov z- pokazatelj	**Postotak točnosti razvrstavanja**	
	Pokrenut stečaj	**Financijski zdravi poslovni subjekti**
-0,469	80	100
0,470-0,519	85	95
0,520-0,529	90	95
0,530-	100	86

Izvor: izrada autora prema Edmister, 1972.

Prema podacima iz tablice vidi se da je najmanji postotak točnosti 80% za pokrenute stečaje, a 86% za financijski zdrave poslovne subjekte, a svi ostali postotci točnosti predviđanja su veći, stoga se može zaključiti da ovaj model ima visoki postotak predviđanja stečaja i vrlo je pouzdan.

3.3.4 Mark E. Zmijewski model predviđanja stečaja

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):

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

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:

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

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

4. ANALIZA FINANCIJSKE NESTABILNOSTI PROMATRANIH PODUZEĆA

Poduzeća koja su promatrana i na temelju čijih financijskih izvještaja će se vršiti izračun Altmanovog i Kralicekovog modela predviđanja stečaja su Solana Pag d.d., Valalta d.o.o. i Varteks d.d.

Solana Pag je jedan od najuspješnijih poslovnih subjekata u Republici Hrvatskoj. Bavi se proizvodnjom više vrsta soli i 2015. je bila dobitnik nagrade Zlatna bilanca za za najuspješnijeg poduzetnika u 2015. godini u djelatnosti Rudarstvo i vađenje.

Valalta d.o.o. je naturistički kamp u Istri koji nudi 4 km plaže te smještaj na parcelama i u bungalovima. Naturistički kamp Valalta u Rovinju osvojio je prestižno priznanje kojeg dodjeljuje nizozemski autoklub ANWB i to za najbolji kamp Europe za 2014. godine - The Best Naturist Campsite 2014.

Varteks d.d. je hrvatska modna i tekstilna kompanija u segmentu proizvodnje i prodaje odjeće, osnovana 1918. godine. 2018. je uspješno provedena dokapitalizacija Varteksa, koja je omogućila stabilizaciju poslovanja i revitaliziranje branda. Varteks je započeo s ponovnim otvaranjem dućana, nakon višegodišnjeg intenzivnog smanjivanja prodajne mreže.

4.1 Altmanov model predviđanja stečaja na promatranim poduzećima

Prilikom računanja Altmanovog modela koristit će se osnovna formula, te njezine dvije korekcije koje su razrađene u 3.1 točki rada. Dobiveni rezultati Altmanovog modela predviđanja stečaja prikazani su u Tablicama 12., 13. i 14.

Tablica 12. Altmanov Z-score na promatranim poduzećima

Poduzeće	Godina	Z-score	Zona	Točno/netočno
Solana Pag	2013.	0,67	stečaj	netočno
	2014.	0,66	stečaj	netočno
	2015.	0,86	stečaj	netočno
Valalta	2013.	0,81	stečaj	netočno
	2014.	0,82	stečaj	netočno
	2015.	0,76	stečaj	netočno
Varteks	2013.	0,26	stečaj	točno
	2014.	0,35	stečaj	netočno
	2015.	0,36	stečaj	netočno
	prosjek			**11%**

Izvor: izrada autora prema financijskim izvještajima

Tablica 12. prikazuje postotak točnosti Altmanovog Z-scorea. Postotak točnosti predviđanja stečaja iznosi samo 11% te se može zaključiti da ovaj model nije vjerodostojan. Svako promatrano razdoblje se našlo u zoni stečaja, iako od njih 9 je zapravo samo Varteks d.d. 2013. doživio predstečajnu nagodbu.

Tablica 13. Altmanov Z' score na promatranim poduzećima

Poduzeće	Godina	Z'-score	Zona	Točno/netočno
Solana Pag	2013.	1,67	siva zona	netočno
	2014.	3,45	stabilno	točno
	2015.	3,75	stabilno	točno
Valalta	2013.	2,92	stabilno	točno
	2014.	3,51	stabilno	točno
	2015.	3,90	stabilno	točno
Varteks	2013.	0,99	stečaj	točno
	2014.	0,61	stečaj	netočno
	2015.	0,68	stečaj	netočno
	prosjek			**67%**

Izvor: izrada autora prema financijskim izvještajima

Na temelju tablice 13. može se zaključiti da je došlo do povećanja postotka točnosti u odnosu na Altmanov model izračuna bez napravljenih korekcija. Postotak točnosti je narastao sa 11% na 67%. Ipak, ni toliki postotak ne zadovoljava preciznošću te se i dalje može reći da je Altmanov Z'-score prilično nepouzdan.

Tablica 14. Altmanov Z'' score na promatranim poduzećima

Poduzeće	Godina	Z'' -score	Zona	Točno/netočno
Solana Pag	2013.	4,37	stabilno	točno
	2014.	9,99	stabilno	točno
	2015.	9,74	stabilno	točno
Valalta	2013.	7,07	stabilno	točno
	2014.	8,48	stabilno	točno
	2015.	9,46	stabilno	točno
Varteks	2013.	2,44	siva zona	netočno
	2014.	1,62	siva zona	točno
	2015.	1,82	siva zona	točno
	prosjek			**89%**

Na temelju Tablice 14. vidi se da Altmanov Z'' score čija jednadžba sadrži završne korekcije je ujedno i najprecizniji. Postotak točnosti izračuna iznosi visokih 89%. Klasificirana kao netočno je samo 2013. godina poduzeća Varteks koja je procijenjena kao siva zona, a 2013. se Varteks našao u predstečajnoj nagodbi te se to klasificira kao stečaj. Ovaj model točno klasificira 2014. i 2015. godinu poduzeća Varteks koje su sivoj zoni. Upravo bi se tako mogla opisati financijska situacija Varteksa te dvije godine- ugrožena financijsku stabilnost, ali sa mogućnošću ozdravljenja. Pošto je postotak točnosti izračuna 89% može se reći da je ovaj model predviđanja stečaja dovoljno pouzdan.

4.2 Kralicekov model predviđanja stečaja na promatranim poduzećima

Pomoću Kralicekovog modela predviđanja stečaja biti će izračunati i interpretirani podaci sljedećih poduzeća: Solana Pag, Valalta i Varteks. Rezultati istraživanja su prikazani u Tablici 15.

Tablica 15. Kralicekov DF pokazatelj na promatranim poduzećima

Poduzeće	Godina	DF	Zona	Točno/netočno
Solana Pag	2013.	1,9	dobra	točno
	2014.	2,72	vrlo dobra	točno
	2015.	3,75	izvrsna	točno
Valalta	2013.	3,66	izvrsna	točno
	2014.	4,63	izvrsna	točno
	2015.	6,17	izvrsna	točno
Varteks	2013.	2,48	vrlo dobra	netočno
	2014.	-1,87	izrazita insolventnost	točno
	2015.	-0,79	umjerena insolventnost	točno
	prosjek			**89%**

Izvor: izrada autora na temelju financijskih izvještaja

Na temelju podataka iz Tablice 15. može se uvidjeti da je preciznost Kralicekovog modela predviđanja stečaja visokih 89%. Jedino promatrano razdoblje koje je procijenjeno kao netočno je poduezće Varteks u 2013. godini.

Po Kralicekovom modelu 2013. godina je klasificirana u vrlo dobroj zoni solventnosti, iako se te godine Varteks našao na rubu stečaja. Ipak, treba uzeti u obzir da financijsko izvješće iz 2013. godine donosi zaključak za prijašnju godinu, pa je vjerojatno to razlog netočne procjene. Već na 2014. godini se može vidjeti da je ovaj model prepoznao financijsku krizu u kojoj se našao Varteks te ga je ocijenila kao poduzeće sa izrazitom insolventnosti.

4.3 Interpretacija rezultata analize

Na temelju analize Altmanovog i Kralicekovog modela predviđanja stečaja može se donijeti zaključak o preciznosti i pouzdanosti ovih modela u svakodnevnom korištenju.

Izvorni Altmanov Z- score pokazao se kao najnepouzdaniji jer postotak točnosti predviđanja stečaja svega 11%. Samim time, može se zaključiti da je ovaj model izrazito nepouzdan te da bi ga se trebalo izbjegavati u korištenju poduzeća za izračunavanje predviđanja stečaja. Korekcije koje je Altman napravio pokazale su se točne jer je njihovom implementacijom postotak točnosti porastao sa 11% na 67%. Ipak, i dalje nedovoljno da bi se poduzeća mogla osloniti na takvu analizu te da bi se moglo reći za nju da je pouzdana. Završnom korekcijom Altmanove jednadžbe postotak točnosti predviđanja stečaja narastao je na respektabilnih 89%. Za krajnji model može se reći da je pouzdan, pa ga samim time poduzeća mogu sa velikom sigurnošću koristiti u svojim izračunima predviđanja stečaja.

Analiziranjem Kralicekovog modela zaključuje se da je postotak točnosti 89%, isto kao finalni Altmanov model. Također, i za ovaj model se može reći da je dovoljno pouzdan za izračunavanje financijske stabilnosti određenog poduzeća te se može koristiti u izračunavanju predviđanja stečaja.

2015. godine oba modela su opisali poduzeća Solana Pag kao stabilno i solventno, i gledajući današnji položaj tog poduzeća izračuni su se pokazali točni. Na temelju financijskih izvještaja iz 2015., poduzeće Valalta je također opisano kao stabilno i solventno, a takvu stabilnost održavaju i danas da tržištu, pa se može zaključiti da su i ovo poduzeće oba modela točno procijenili. 2015. poduzeće Varteks je po Altmanovoj metodi spadao u „sivu zonu“, odnosno poduzeće kojem je ugrožena financijsku stabilnost, ali sa mogućnošću ozdravljenja, a Kralicekova metoda ga je svrstala u umjereno insolventno poduzeće.

Oba modela su ispravno opisala tadašnju financijsku situaciju Varteksa, dok je danas Varteks financijski stabilno poduzeće i ispunio je mogućnost ozdravljenja.

Na kraju se može zaključiti da su oba modela vjerodostojna te se mogu koristiti u predviđanju stečaja. Manja prednost bi se dala Kralicekovom modelu jer ima raznovrsnije parametre te se dobiveni rezultati mogu detaljnije opisati. Dok Altmanov model nudi 3 ishoda: stečaj, siva zona i stabilno poduzeće, Kralicekov model nudi 8 razina financijske stabilnosti poduzeća pa je samim time i detaljnije opisano.

5. ZAKLJUČAK

Predmet istraživanja ovog završnog rada je procjenjivanje pouzdanosti Altmanovog i Kralicekovog modela za predviđanje stečaja. Završni rad je kombinacija teorijskih i praktičnih dijelova koji govore o važnosti analize i upravljanja financijama koje nam koriste za donošenje boljih strateških odluka u poduzeću i procjenu financijske stabilnosti budućeg poslovnog partnera.

U radu je provedena analiza financijske stabilnosti poduzeća Valalta d.o.o., Solana Pag d.d. i Varteks d.d. uz pomoć Altmanove i Kralicekove metode predviđanja stečaja. Na temelju razdoblja od 2013.-2015. godine prikazani su rezultati metoda, te se te rezultate usporedilo sa današnjim stanjem promatranih poduzeća i ocijenjena je vjerodostojnost i pouzdanost modela za predviđanje stečaja. Analiza financijske stabilnosti izračunata je pomoću podataka iz financijskih izvještaja promatranih poduzeća: računa dobiti i gubitka, bilance.

Na temelju istraživanja poduzeća Valalta d.o.o., Solana Pag d.d. i Varteks d.d. konstatirano je da su poduzeća Valalta d.o.o. i Solana Pag d.d. kroz cijelo razdoblje bile financijski stabilne i nije im prijetio stečaj, dok su se kod poduzeća Varteks d.d. uvidjeli tragovi financijske nestabilnosti te je to poduzeće opisano kao nesolventno poduzeće sa mogućnošću stečaja.

Analiziranjem Altmanovog i Kralicekovog modela može se zaključiti da su oba modela pouzdana te se pomoću njih može računati financijska stabilnost poduzeća i predvidjeti stečaj. Postotak točnosti predviđanja stečaja i financijske stabilnosti je visokih 89% za oba modela predviđanja stečaja.

LITERATURA

Knjige:

1. Altman, E. I., (1968), Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy, The Journal of Finance, 23, New York
2. Barbić, J., Čolaković, E., Parać, B., Vujić, V. (2008). Korporativno upravljanje – osnove dobre prakse vođenja društva kapitala. Zagreb: Hum-Croma
3. Beawer, W. H., (1966), Financial Ratios as a Predictors of Failure, Empirical Research in Accounting: Selected Studies, Supplement to Journal of Accounting Research,
4. Edminster, R. O., (1972), An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction, Journal of Financial and Quantitative Analysis, Cambridge University Press
5. Koban, R., (1978), Betriebswirtschaft für die Praxis, ÖWV
6. Ohlson, J.A., (1980), Financial Ratios and the Probabilistic Prediction of Bankruptcy, Journal of Service Science and Management
7. Tearney, M., Journal of Accounting Research Vitezić, N., (1996), "Cash Flow model u predviđanju financijskog neuspjeha poduzeća", Računovodstvo, poslovne financije i revizija u suvremenim gospodarskim uvjetima, Zbornik radova s 31. simpozija Hrvatske zajednice računovođa i financijskih djelatnika, Zagreb, 169 - 184.

Članci:

1. Boras, I., Buterin, V., Buterin, D. (2002), Znanje u funkciji dinamičkog razvoja gospodarstva (s osvrtom na stanje u Primorsko-goranskoj županiji), Zbornik radova sa znanstvenog skupa Znanje – temeljni ekonomski resurs, Rijeka, 2002., Ekonomski fakultet Rijeka
2. Buterin, V., Buterin, D. (2014), Hrvatska i bilančna recesija, Zbornik radova Međimurskog veleučilišta u Čakovcu, 5, 1, 29-38

3. Buterin, V., Lukežić, E., Buterin, D. (2018), Should Croatia develop its mortgage market? 7th International Scientific Symposium "Economy of Eastern Croatia - Vision and Growth", Osijek : Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet Osijek,
4. Buterin, V., Plenča, J., Buterin, D. (2015), Analiza mogućnosti pariteta eura i dolara, Praktični menadžment, 6, 1, 22-29
5. Mijoč I., Martinović J. i Mahaček D. (2010), Analiza financijskih izvještaja, Financije i porezi : časopis za poduzeća i banke, obrtnike, proračune i proračunske korisnike, neprofitne i ostale organizacije.
6. Olgić Draženović, B., Buterin, V. Buterin, D. (2018), Strukturne reforme zemalja CEE-a u tranzicijskom razdoblju – pouke i zaključci, Zbornik Veleučilišta u Rijeci, 6, 1, 127-142
7. Šodan, S. (2016), Financijska analiza poslovanja, Sveučilište u Splitu, Ekonomski fakultet, ak. godina 2015/2016, predavanja br.4.
8. Zenzerović R., Peruško T. (2006), Kratki osvrt na modele za predviđanje stečaja, Economic Research, Vol. 19, No. 2, str. 132. - 151.

Internet:

Company wall business, 2020., https://www.companywall.hr/bonitetna-ocjena, (22.4.2020.)

Corporate finance institute, https://corporatefinanceinstitute.com/resources/knowledge/credit/altmans-z-score-model/, (23.4.2020.)

Hrvatska enciklopedija, mrežno izdanje, http://www.enciklopedija.hr/Natuknica.aspx?ID=8677 (22.4.2020.)

Ostali izvori:

1. Bilanca poduzeća Solana Pag d.d. za razdoblje od 2013.-2015. godine., „Poslovna Hrvatska“,
2. Bilanca poduzeća Valalta d.o.o. za razdoblje od 2013.-2015. godine., „Poslovna Hrvatska“,
3. Bilanca poduzeća Varteks d.d. za razdoblje od 2013.-2015. godine., „Poslovna Hrvatska“,
4. Račun dobiti i gubitka poduzeća Solana Pag d.d. za razdoblje od 2013.-2015. godine. “Poslovna Hrvatska“.
5. Račun dobiti i gubitka poduzeća Valalta d.o.o. za razdoblje od 2013.-2015. godine., “Poslovna Hrvatska“
6. Račun dobiti i gubitka poduzeća Varteks d.d. za razdoblje od 2013.-2015. godine., “Poslovna Hrvatska“,

POPIS TABLICA I SLIKA

Slika 1. Kritične vrijednosti Z-score, https://corporatefinanceinstitute.com/resources/knowledge/credit/altmans-z-score-model/, (23.4.2020.)

Tablica 1. Bonitetne ocjene

Tablica 2. Pokazatelji likvidnosti

Tablica 3. Pokazatelji zaduženosti

Tablica 4. Pokazatelji aktivnosti

Tablica 5. Pokazatelji ekonomičnosti

Tablica 6. Pokazatelji profitabilnosti

Tablica 7. Točnost predviđanja stečaja Z- score

Tablica 8. Kritične vrijednosti DF pokazatelja s pripadajućom ocjenom financijske stabilnosti

Tablica 9. Pogrešno klasificiranje poslovnih subjekata za 6 najtočnijih pokazatelja u %

Tablica 10. Ohlsonovi modeli za predviđanje stečaja

Tablica 11. Točnost predviđanja stečaja Edmisterovog z- pokazatelja

Tablica 12. Altmanov Z-score na promatranim poduzećima

Tablica 13. Altmanov Z' score na promatranim poduzećima

Tablica 14. Altmanov Z'' score na promatranim poduzećima

Tablica 15. Kralicekov DF pokazatelj na promatranim poduzećima