PREDVIĐANJE STEČAJA PODUZEĆA

Jerat, Franka

Master's thesis / Diplomski rad

2018

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:124:601060

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET

DIPLOMSKI RAD

PREDVIĐANJE STEČAJA PODUZEĆA

Mentor:

Prof.dr.sc. Maja Pervan

Student:

Franka Jerat, 2161931

Split, rujan, 2018.

SADRŽAJ:

1. UVOD 4

1.1. Definicija problema 4

1.2. Cilj rada 5

1.3. Metode istraživanja 6

1.4. Struktura rada 7

2. STEČAJ I NJEGOVE KARAKTERISTIKE 8

2.1. Pojmovno definiranje stečaja i restrukturiranje 8

2.2. Uzroci stečaja 9

2.3. Likvidnost, solventnost i insolventnost 12

3. MODELI ZA PREDVIĐANJE STEČAJA 14

3.1. Modeli za predviđanje stečaja izvan Republike Hrvatske 14

3.1.1. William H. Beaver model 14

3.1.2. Edward I. Altmanov model 16

3.1.3. Edward B. Deakin model 19

3.1.4. Robert O. Edminster model 20

3.1.5. James Ohlson model 22

3.1.6. Mark E. Zmijewski model 24

3.1.7. Robert Shumway model 24

3.1.8. Peter Kralicek model 26

3.1.9. Gordon L.V.Springate model 27

3.2. Modeli za predviđanje stečaja u RH 28

3.2.1. Pervan, Pervan, Vukoja model 28

3.2.2. Pervan i Kuvek model 29

3.2.2. FP Rating 31

3.2.3. Ivičić i Cerovac model 32

3.2.4. Šarlija model 33

3.2.5. Zanzerović model 35

3.3. Statistička metodologija predviđanja stečaja 37

4. EMPIRIJSKI DIO RADA 40
4.1. Opis uzorka istraživanja 40
4.2. Opis varijabli 41
4.3. Rezultati istraživanja 44
5. ZAKLJUČAK 48
LITERATURA 49
POPIS TABLICA 52
POPIS GRAFIKONA 52
SAŽETAK 53
SUMMARY 53

1. UVOD

1.1. Definicija problema

Postoji nebrojeno puno metoda za predviđanje stečaja, počevši od Beaversa (1966) koji koristi univarijantnu metodu, pa sve do novijih metoda kao što su logistička regresija ili hibridni modeli, od kojih je najpoznatiji Altmanov multivarijabilni „Z-score“ (1968). Unatoč razvijanju novih modela, modeli koji su nastali sredinom 1990-ih godina i dalje zadržavaju poziciju najpopularnijih.

S obzirom na relativno veliku učestalost stečaja, koja ne štete samo poduzećima već predstavljaju prijetnju dobavljačima i ostalim sudionicima koji se oslanjaju na solventnost poduzeća za vlastiti uspjeh, pouzdani stečajni model iznimno je bitan u današnjem poslovnom okruženju (Hayes et al.,2010). To naglašava važnost pronalaženja i ažuriranja korisnih metoda i modela za predviđanja stečaja. Ukoliko se financijske poteškoće otkriju na vrijeme, imajući pripremljene načine kako se rješavaju određeni problemi, to će dovesti do rješenja za spašavanje poduzeća ili će u suprotnom dovesti do stečaja. Zbog ovih razloga iznimno je važno da se razviju modeli kako bi se dobili najtočniji rezultati predviđanja stečaja.

Osim poduzeća, banke i drugi investitori također koriste podatke o poslovanju kada traže i odlučuju o novim i isplativijim investicijama. Kako se metode predviđanja razvijaju, banke također imaju koristi jer dobivaju preciznije i detaljnije informacije o mogućem ulaganju. Vjerovnici također dobivaju korisno znanje iz ovih podataka pri razmatranju o poduzimanju investiranja.

Predviđanje neuspjeha ima utjecaja i na gospodarstvo. Primjerice, ako srednje veliko poduzeća propadne, osobito ako se to dogodi u manjem gradu, to će se odraziti na gospodarstvo zajednice. Pod time se smatra da će doći do otpuštanja zaposlenika što dovodi do rasta stope nezaposlenosti. Slijedom toga, prikupljat će se manje poreza te postoji mogućnost da će doći i do dodatnog zaduživanja.

Stečaj se najčešće predviđa korištenjem financijskih izvještaja poduzeća. Glavna ideja jest utvrditi (financijske) razlike između uspješnih poduzeća i onih koja su u stečaju.

U radu će se analizirati i usporediti rezultati putem logističke regresije na temelju podataka za uspješna poduzeća i ona koja su u stečaju u Republici Hrvatskoj. U istraživanju će biti uključena poduzeća iz prerađivačke industrije (područje C prema NKD-u, NN 58/2007).

U proteklih nekoliko godina, sve više pažnje se posvećuje razlozima zbog kojih poduzeća idu u stečaj. Društvo mora kontinuirano pratiti svoje rezultate i promjene u okruženju kako bi se mogle poduzeti potrebne mjere da ne dođe do stečajnog postupka .Smatra se da poduzeća koja idu u stečaj imaju direktora, tj. upravu koji nemaju dovoljno znanja i iskustva u vođenju poduzeća. Posljedice mogu biti sporo prilagođavanje na promjene koje se događaju okruženju, prejaka konkurencija, nemogućnost snižavanja cijene zbog visokih troškova proizvodnje,… Međutim, nije samo „ loša“ uprava glavni krivac za pokretanje stečaja. Postoje okolnosti na koje se ne može utjecati, a to su primjerice novi supstituti, političke odluke, nove tehnologije, opća recesija u industriji, efekti globalizacije i ostali teško predvidivi događaji. Prilikom stečaja, potrebno je voditi računa o imovini s kojom poduzeće raspolaže jer je ona bitna komponenta svakog tržišno utemeljenog gospodarskog sustava te je važan element za poboljšanje politike gospodarskog rasta i oporavka.

Iz gore navedenih razloga, treba se što više istraživati ovo područje ekonomije, ne samo kako bi pojedini investitori profitirali, već za poboljšanje i razvitak cjelokupnog gospodarstva.

1.2. Cilj rada

Postupak pokretanja stečaja uglavnom rezultira gašenjem poslovanja i rasprodajom imovine. Zbog prekasnog otvaranja stečaja može se dogoditi da vjerovnici ne mogu naplatiti svoja potraživanja. Problem je što posljedice snose i sami zaposlenici (npr. ostanak bez radnog mjesta, dohotka,…), kreditori, dobavljači, itd. Iz ovoga proizlazi da treba voditi računa o „financijskom zdravlju“ poduzeća kako ne bi negativno utjecalo na samo poslovanje već i na cjelokupno gospodarstvo.

Svrha korištenja modela predviđanja stečaja jest pravodobno sprječavanje ili minimiziranje potencijalnih gubitaka i nenaplativih potraživanja. Budući da je tema ovog diplomskog rada vezana uz problem stečaja poduzeća, rezultati istraživanja bi trebali pokazati razlog isključivanja nedovoljno učinkovitih poslovnih subjekata s tržišta i pružiti informacije vrednovanja poduzeća, tj. što treba predvidjeti u slučaju kada je promatrano poduzeće u

stečajnom postupku, a koje je nekoć bilo profitabilno te se zbog nekih razloga jednostavno nije uspjelo „ održati“ na tržištu.

U skladu sa definicijom problema, osnovna istraživačka hipoteza glasi:

H1: Temeljem financijskih podataka moguće je formirati efikasan model za predviđanje stečaja primjenom modela logističke regresije.

Hipoteza 1 će se prihvatiti ili odbaciti na temelju točnosti modela logističke regresije koja će se dobiti u rezultatima obrade statističkim metodama.

1.3. Metode istraživanja

Prilikom izrade diplomskog rada koristit će se sljedeće metode znanstvenog istraživanja:

- **Metoda deskripcije -** je postupak jednostavnog opisivanja procesa i predmeta te njihovih empirijskih potvrđivanja odnosa i veza, ali bez znanstvenog tumačenja i objašnjavanja.
- **Metoda sinteze –** je postupak spajanja jednostavnih misaonih tvorevina u složene i složenih u još složenije.
- **Metoda analize –** temelji se na raščlanjivanju složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove i elemente.
- **Metoda komparacije –** postupak kojim se proučavaju odnosi, sličnosti i razlike između dva predmeta ili pojave sa ciljem da se izvedu određeni zaključci
- **Metoda kompilacije** - iznošenje tuđih stavova i zaključaka iz domaće i strane literature
- **Induktivna metoda -** uključuje način zaključivanja iz općih postavki do konkretnih pojedinačnih zaključaka.
- **Deduktivna metoda –** uključuje zaključivanje o općim sudovima temeljem pojedinačnih ili posebnih činjenica.
- **Povijesna metoda -** postupak kojim se na temelju raznih dokumenata i dokaznog materijala može saznati sve što se u prošlosti dogodilo te kako i zašto se dogodilo.
- **Statistička metoda** - pomoću ove metode mogu se na prihvatljivo egzaktan način saznati opća određenost, pravilnosti i zakonitosti masovnih pojava

Empirijski dio diplomskog rada izradit će se u programu SPSS, a podaci za sve varijable prikupit će se iz Amadeus baze podataka.

1.4. Struktura rada

Diplomski rad će se sastojati od 5 osnovnih poglavlja, uključujući uvod i zaključak.

U prvom, uvodnom poglavlju, definirat će se problem i predmet istraživanja te svrha i ciljevi istraživanja. Nakon toga postavit će se istraživačka hipoteza koja će se testirati u empirijskom dijelu rada te će se ista, na osnovi dobivenih rezultata, prihvatiti ili odbaciti.

U drugom poglavlju će se objasniti sama terminologija stečaja. Isto tako, definirat će se stečajni razlozi te koji su uzroci nastanka stečaja u poduzećima.

Treće poglavlje prikazuje najznačajnije modele kao što su Altmanov, Kralicekov i Zmijewskite, također uključuje i modele iz Hrvatske.

Četvrto poglavlje je empirijski dio rada. Započet će se sa opisom prikupljenih podataka i obrazloženjem primijenjene metodologije. Istraživanjem će se testirati postavljena istraživačka hipoteza, te će se analizirati rezultati i donijeti zaključci na temelju kojih će istraživačka hipoteza biti prihvaćena ili odbačena.

Posljednji, peti dio rada je zaključak u kojem će se prezentirati najvažniji rezultati do kojih se došlo istraživanjem.

2. STEČAJ I NJEGOVE KARAKTERISTIKE

2.1. Pojmovno definiranje stečaja i restrukturiranje

Prema stečajnom zakonu (NN 25/12) stečaj (čl.2. Stečajnog zakona) se može definirati kao „postupak koji se provodi radi skupnoga namirenja vjerovnika stečajnog dužnika, unovčenjem njegove imovine i podjelom prikupljenih sredstava vjerovnicima“ (čl.2. Stečajnog zakona).

Stečajna masa (čl.67. Stečajnog zakona) je pojam kojim se obuhvaća „cjelokupna imovina dužnika u trenutku otvaranja stečajnog postupka i imovina koju dužnik stekne tijekom stečajnog postupka“ (čl.67. Stečajnog zakona). Svrha stečajne mase je „namirenje troškova stečajnog postupka i potraživanja vjerovnika stečajnog dužnika, odnosno potraživanja čije je namirenje osigurano određenim pravima na imovini dužnika“ (čl.67. Stečajnog zakona).

Stečajni vjerovnici (čl.70. Stečajnog zakona) su „osobni vjerovnici dužnika koji u vrijeme otvaranja stečajnog postupka imaju imovinsko pravno potraživanje prema dužniku“ (čl.70. Stečajnog zakona).

Razlozi ulaska u stečajni postupak (čl.4. Stečajnog zakona) mogu biti slijedeći:

- **Nesposobnost za plaćanje** – kada „dužnik ima evidentirane nepodmirene obveze kod banke koja za njega obavlja poslove platnog prometa u razdoblju duljem od 60 dana“ (čl.4. Stečajnog zakona),
- **Prezaduženost** – „dužnikova imovina ne pokriva postojeće obveze“ (čl.4. Stečajnog zakona).

Termini „stečaj“ i „zatvaranje poduzeća“ (zatvaranje u smislu prestanka rada, rasprodaje imovine i nestanka radnih mjesta) ne znače isto. U Hrvatskoj se podrazumijeva proglašenje stečaja „konačnim rješenjem“ i za njega više nema oporavka. Jedna od mogućnosti za poduzeće jest proces restrukturiranja i nastavka poslovanja nakon stečaja.

Restrukturiranje u stečaju je proces sveobuhvatne revizije i sanacije poslovanja stečajnog dužnika, a koja rezultira opstankom u više ili manje izmijenjenom obliku te ne mora značiti da će doći do otpuštanja svih radnika, prodaje imovine ili u konačnici zatvaranja samog poduzeća. Restrukturiranje je kompleksan proces, od donošenja odluke može li se i kako će se

uopće provesti, do osmišljavanja novog koncepta za ponovno oživljavanje s kojim bi dužnik trebao postati uspješan. Uz sam proces, treba se pobrinuti da se sve odrađuje po zakonima i propisima.

Restrukturiranje u stečaju ima učinkovitiji ishod od likvidacije, jer poduzeće a i društvo u cjelini, opstaju nakon restrukturiranja, nastavlja sa djelatnošću bez prezaduženosti, zadržavaju se radna mjesta, sačuvana je vrijednost imovine (u stečaju, imovina dužnika se rasprodaje ispod realne cijene), stvara se prihod za radnike i njihove obitelji, a plaćanjem poreza i drugih davanja omogućuje se funkcioniranje lokalne zajednice i države u cjelini (Dika, 1998).

2.2. Uzroci stečaja

„Uzroci stečaja mogu se podijeliti u dvije osnovne grupe, a to su interni i eksterni uzroci stečaja. Interni uzroci se odnose na budućeg stečajnog dužnika, koji su po njegovom nadležnošću, dužnik može na njih neposredno utjecati, te oni ovise o aktivnostima dužnika. Eksterni uzroci stečaja su oni na koje dužnik ne može neposredno utjecati, nisu u njegovoj nadležnosti i nalaze se izvan domene njegovog utjecaja.

Ooghe i Waeyaert (2004) opisuju „konceptualni model stečaja“ s pet osnovnih grupa stečajnih uzroka, od kojih prve dvije se mogu svrstati u eksterne uzroke stečaja, a ostale u interne uzroke.

1. Opće okruženje
2. Neposredno okruženje
3. Karakteristike menadžmenta
4. Korporativna politika
5. Karakteristike samog trgovačkog društva

Eksterni uzroci stečaja

Eksterni uzroci stečaja nalaze se izvan dohvata samog stečajnog dužnika, i stečajni dužnik ne može na njih direktno i/ili kratkoročno, a nalaze se u općem ili u indirektnom okruženju trgovačkog društva.

Opće okruženje trgovačkog društva čine svi ekonomski, tehnološki, politički, socijalni, prirodni , inozemni i drugi faktori koji određeno individualno poduzeće mogu odvesti u stečaj. Sve faktore je nemoguće nabrojati zbog npr. političke nestabilnosti, ratova, funkcioniranja financijskih tržišta, utjecaja globalizacije, tehnološke nerazvijenosti, izmjena zakona koja reguliraju područje djelovanja poduzeća i druge regulatorne promjene.

U neposrednom okruženju nalaze se subjekti koji imaju određen interes za poslovanje društva: klijenti, dobavljači, konkurencija, banke i ostali zajmodavci, dioničari, itd. Društvo ima više ili manje utjecaja sa ovim subjektima i može na njihove odluke utjecati do određene mjere.

U Hrvatskoj, kao i u drugim zemljama, može se također uočiti kako odgovorne osobe na čelu stečajnog dužnika pronalaze uzroke stečaja u društvu i okruženju općenito. Razlog zbog kojeg društvo percipira stečajeve u Hrvatskoj kao nepoštene je zaslužno jednim dijelom i zbog privatizacije društvenih poduzeća. Često je za opstanak i nastavak poslovanja poduzeća bilo puno važnije imati dobre kontakte s aktualnom političkom vlasti nego poslovanje koje je utemeljeno po propisima.

Hrvatsko poslovno okruženje je zahtjevno te traži dodatne napore kako bi poduzeće bilo uspješno i solventno, što je pogotovo izazov za mala i srednja poduzeća koja ne mogu beskrajno dugo odgađati svoja plaćanja i prebacivati ih na druge subjekte.

U eksterne uzroke stečaja koji su osobito specifični za Hrvatsku mogu se još ubrojiti i:

- Nepostojanje jasne i konzistentne strategije razvoja
- Porezna preopterećenja
- Nelikvidnost i lanac insolventnosti
- Komplicirana i korumpirana državna administracija što rezultira odlaskom stranih investitora i visokim oportunitetnim troškovima
- Ratovi i politička nestabilnost na području bivše države, koji se rezultirali nestabilnošću i nepovoljnom investicijskom klimom

Od izuzetne je važnosti imati stabilno poslovno okruženje jer utječe na poslovanje cjelokupnog društva.

Interni uzroci stečaja

Interni uzroci stečaja nalaze se unutar dohvata samog stečajnog dužnika, i stečajni dužnik može na njih direktno utjecati. Interni uzroci stečaja mogu se pronaći u:

- **Karakteristikama menadžmenta:** to su motivacija, kvalitete, vještine, kompetentnost, osobne karakteristike, itd**.**
- **Korporativnoj politici –** uspostavlja je menadžment, a uključuje strategije, investiranje, marketing, prodaju, operativno poslovanje, administraciju, financije, kadrovsku politiku, ...
- **Karakteristikama samog trgovačkog društva –** veličina, starost i djelatnost.

Kod analiziranja treba obratiti pozornost na veličinu poduzeća te na određene industrijske grane koje su sklonije stečajevima nego neke druge.

Uzroci stečajeva u Hrvatskoj

„Temeljem istraživanja (Sajter, 2009) uzroci stečaja mogu se grupirati u interne (oni koji su vezani uz samog stečajnog dužnika i njegovo poslovanje), eksterne (vezani uz ekonomsko – političko okruženje), te ostale uzroke (koji se nisu dali svrstati u dvije prethodne kategorije)“ .

Tablica 1. Interni uzroci stečajeva u Republici Hrvatskoj

INTERNI UZROCI STEČAJEVA	EKSTERNI UZROCI STEČAJEVA	OSTALI UZROCI STEČAJEVA
• loš menadžment	• neplaćanje obveza kao obrazac „normalnog ponašanja“	• povlašteni položaj banaka kao vjerovnika
• loše planiranje poslova, ugovaranje i vođenje poslova	• nedovoljno razvijeno tržište i primjena pravila tržišta, slabo djelovanje tržišnih mehanizama, gubitak tržišta nakon osamostaljenja	• povlašteni položaj pojedinih trgovaca
• nemogućnost naplate vlastitih tražbina što dovodi do otežanja cjelokupnog	• tehnološko zaostajanje	• uvozničko trgovački lobi

poslovanja		
• neiskorištenost kapaciteta i zaposlenika (višak radnika)	• posljedice ratnih događaja	• mogući krivci mogu biti i sami građani
• loši međuljudski odnosi u poduzeću	• nastojanje izigravanja propisa i vjerovnika, poslovanje protivno zakonskim propisima. Poduzeća se vode s ciljem da pojedinci pribave za sebe materijalnu korist a ne u korist poduzeća koje vode	
• slabo nagrađivanje – plaćanje radnika	• nepostojanje kaznene i materijalne odgovornosti vlasnika i poduzetnika	
	• loša pretvorba i privatizacija – ciljana pljačka društava	
	• poslovni partneri se ne ponašaju odgovorno i u interesu svojih poduzeća jer u protivnom ne bi radili s nekim tko im duguje po nekoliko godina	

Izvor: Izrada autora prema Sajter (2009).

2.3. Likvidnost, solventnost i insolventnost

Općenito u gospodarskoj teoriji i praksi nerijetko se poistovjećuju pojmovi likvidnost i solventnost. U širem smislu možemo govoriti o solventnosti kao sposobnosti plaćanja svih dugova, dok za likvidnost možemo reći da je sposobnost plaćanja odnosno pokrića kratkoročnih obveza, tj. tekućeg plaćanja. Često se za likvidnost kaže da je to kratkoročna solventnost pa upravo zbog toga i dolazi do zamjene pojmova likvidnost i solventnost, smatrajući da solventnost pokriva oba pojma (Belak, 1995). Ova dva termina su usko povezana.

Likvidnost je sposobnost poduzeća da u kratkom roku koji podrazumijeva vremensko razdoblje do jedne godine prihodima koje je ostvarilo podmiri svoje obveze. Menadžment poduzeća primarno je zainteresiran za likvidnost poduzeća, ali osim menadžmenta za likvidnost su također zainteresirani i svi vjerovnici. Iz razloga što o likvidnost ovisi sposobnosti urednog podmirivanja obveza. Ako se obveze ne podmiruju uredno postoji opasnost od nelikvidnosti, u čijem slučaju može doći do obustave plaćanja samih obveza, blokiranja žiro računa poduzeća, ovrhe, gubitka dobavljača i sličnih problema u poslovanju (Belak, 1995).

Solventnost je sposobnost poduzeća da u određenom trenutku podmiri novčanim sredstvima svoje dospjele novčane obveze. Solventnost je u stvari platežna sposobnost poduzeća (Grubišić, 2013).

„Stečajni postupak“ se često naziva kao „stečaj“ te je jasno kako stečaj nije trenutak u vremenu već proces. S druge strane „stečaj“ i „insolventnost“ nisu istoznačnice. Insolventnost se u Stečajnom zakonu definira kao dužnikova nesposobnost za plaćanje, i to ukoliko postoje nepodmirene obveze kod banke koja za dužnika obavlja poslove platnog prometa u razdoblju duljem od 60 dana (čl.4. Stečajnog zakona).

Postoje tri razloga za pokretanje stečaja, a to su: insolventnost, prijeteća insolventnost i prezaduženost (čl. 4 Stečajnog zakona). Proizlazi kako je stečaj širi pojam od insolventnosti jer ga obuhvaća jednako kao što obuhvaća i prezaduženost. Poduzeće može biti u stečaju jer je insolventno, drugo može biti u stečaju jer je prezaduženo, a treće može biti zbog velikih izgleda kako u budućnosti neće moći podmiriti svoje obveze.

Riječi insolventnost se opisuju negativni efekti poslovanja. Insolventnost može biti privremena, čime indicira manjak likvidnosti te može, ali i ne mora predstavljati stečajni razlog. Ne smije se dopustiti da na tržištu sudjeluju insolventni sudionici koji odugovlače plaćanje svojih obveza te se iz tog razloga stečajni postupak mora pokrenuti. Poduzeće može biti insolventno, ali ne mora biti i u stečaju što je čest slučaj u Hrvatskoj.

3. MODELI ZA PREDVIĐANJE STEČAJA

Posljedice stečaja se ne odnose samo na promatrano poduzeće koje se našlo u problemima nego na cjelokupno društvo. Upravo je to razlog zbog kojeg ovo područje ekonomije postaje sve značajnije. Današnje dinamično okruženje iziskuje da se predvide i razumiju razlozi zbog kojih dolazi do propasti.

Uspješno predviđanje stečaja značilo bi da poduzeća, financijske institucije i potencijalni investitori raspolažu potrebnim informacija i na taj način bi se dovelo do funkcioniranja tržišta u cjelini. Pomoću potrebnih informacija, svi sudionici bi lakše donosili odluke vezane za nastavak poslovanja te se ne bi ugrožavala radna mjesta, gospodarstvo,…

Pitanje koje se postavlja jest može li se predvidjeti stečaj poduzeća? Odgovor na ovo pitanje pokušat će razjasniti različiti znanstvenici, njihovi modeli i metode (logistička regresija, diskriminacijska analiza, neuronske mreže,…) koji će biti obrađeni u slijedećim poglavljima.

3.1. Modeli za predviđanje stečaja izvan Republike Hrvatske

3.1.1. William H. Beaver model

Beaver (1966) prvi predstavlja značajan model za predviđanje poslovnog neuspjeha. Pod poslovnim neuspjehom podrazumijeva nesposobnost poslovnog subjekta da podmiri dospjele financijske obveze. Uzorak se sastojao od 158 proizvodnih poslovnih subjekata iz 38 različitih industrija, a čijim se dionicama javno trgovalo. Taj uzorak je zatim podijeljen na dvije jednake grupe, dakle svaka grupa se sastojala od 79 poslovnih subjekata, od kojih je jedna grupa poduzeća koja su ušla u stečajni postupak u razdoblju od 1954. do 1964. godine., a druga grupa financijski zdrava poduzeća (Zenzerović i Peruško, 2006).

Prikupljeni su financijski izvještaji poslovnih subjekata za razdoblje od 5 godina prije pokretanja stečajnog postupka, te isto razdoblje za financijski zdrava poduzeća. Beaver je potom uparivao zdravo i nezdravo poduzeće prema vrsti industrije i veličini imovine. Izračunao je 30 financijskih pokazatelja koje je grupirao u 6 skupina.

Tablica 2. Popis testiranih varijabli

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

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

Kriterij odabira financijskih pokazatelja bio je učestalost njihova spominjanja u literaturi, relevantnost pokazatelja u predviđanju poslovnog neuspjeha u dotadašnjim istraživanjima, te pripadnost pokazatelja skupini temeljenoj na novčanom tijeku. Koristeći se univarijantnom analizom od navedenih 30 omjera dokazalo se da financijski neuspjeh najbolje predviđaju sljedeća 3 pokazatelja:

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

Njegovo istraživanje se smatra „poticajnim radom u predviđanju financijskog neuspjeha poduzeća putem financijskih pokazatelja te se smatra univarijantnom klasifikacijskom tehnikom za predviđanje vjerojatnosti neuspjeha.“ (Pena et al., 2009).

3.1.2. Edward I. Altmanov model

Altman (1968.) u svom istraživanju za formiranje modela za predviđanje stečaja koristi diskriminantnu analizu. Budući da je prvi provodio multivarijantnu analizu, svrha njegovog rada je bilo dokazivanje da će pokazatelji „ako su analizirani u multivarijantnom okviru imati veću statističku signifikantnost nego uobičajena tehnika sekvencijalne usporedbe financijskih pokazatelja“ (Altman, 1968.), što je u konačnici i uspio dokazati.

Ukupna točnost predviđanja Altmanova modela iznosi 95% za jednu godinu prije stečaja, 83% za dvije godine prije stečaja, 48% za tri godine prije stečaja, 29% za četiri godine prije stečaja, te 36% za pet godina prije stečaja.

Tablica 3. Točnost predviđanja Altmanovog Z-scorea

Godina prije bankrota	Postotak točne klasifikacije
1	95%
2	72%
3	48%
4	29%
5	36%

Prerađeno prema**:** Altman, E., I.: „Predicting financial distress of companies: revisiting the z-score and zeta® models“, 2000.

Uzorak poduzeća nad kojima je provedena analiza sastojao se od 66 proizvodnih poduzeća od kojih su 33 financijski zdrava, te 33 poduzeća koja su pokrenula stečajni postupak u razdoblju od 1946. do 1965. godine. Ta poduzeća su potom uparena prema vrsti industrije i veličini imovine kao kod Beavera.

Jednadžba Altmanovog Z - score modela može se prikazati sljedećom jednadžbom (Altman, 2000):

Z = 1.2 X1 + 1.4 X2 + 3.3 X3 + 0.6 X4 + 0,999 X5 (1)

Objašnjenje oznaka:

Z – vrijednost Altmanovog Z – score modela

X_1 – radni kapital (kratkoročna imovina – kratkoročne obveze) / ukupna imovina

X_2 – zadržani dobitak / ukupna imovina

X_3 – EBIT / ukupna imovina

X_4 – tržišna vrijednost glavnice / ukupni dug

X_5 – prihod od prodaje / ukupna imovina

Tablica 4. Referentni intervali Altmanovog Z – scorea

Referentni intervali	Zaključak o vjerojatnosti stečaja
Z > 2,65	Poduzeće posluje jako dobro i vjerojatnost stečaja je niska.
2,65 > Z > 1,81	Postoji mogućnost stečaja, ali on nije vjerojatan.
Z < 1,81	Vrlo vjerojatna mogućnost stečaja.

Izvor: Pervan, I., Filipović, D.: „FP-rating – model za predviđanje insolventnosti poslovnih partnera“, RRiF, 2010.

Altman je 1993. godine originalni model za predviđanje bankrota za privatna poduzeća s obzirom na to da se originalni model odnosio samo na listana poduzeća. Zamijenio je u varijabli X4 tržišnu vrijednost glavnice njenom knjigovodstvenom vrijednosti. Cijeli model je potom izmijenjen budući da su prilagođeni ponderi svih varijabli, pa konačna jednadžba glasi:

Z' = 0.717 X1 + 0.847 X2 + 3.107 X3 + 0.420 X4 + 0.998 X5 (2)

Objašnjenje oznaka:

Z' – vrijednost Altmanovog Z' – score modela

X_1 – radni kapital (kratkoročna imovina – kratkoročne obveze) / ukupna imovina

X_2 – zadržani dobitak / ukupna imovina

X_3 – EBIT / ukupna imovina

X_4 – knjigovodstvena glavnica / ukupni dug

X_5 – prihod od prodaje / ukupna imovina

Tablica 5. Referentni intervali Altmanovog Z'scorea

Referentni intervali	Zaključak o vjerojatnosti stečaja
Z' > 2,90	Poduzeće posluje jako dobro i vjerojatnost stečaja je niska.
2,90 > Z' > 1,21	Postoji mogućnost stečaja, ali on nije vjerojatan.
Z' < 1,21	Vrlo vjerojatna mogućnost stečaja.

Izvor: Pervan, I., Filipović, D.: „FP-rating – model za predviđanje insolventnosti poslovnih partnera“, RRiF, 2010.

Provedena je još jedna izmjena modela kako bi se namijenio predviđanju bankrota za neproizvodna poduzeća. Iz modela se isključuje varijabla X5, dok su ostale varijable jednake kao kod modela za privatna poduzeća, kao i vrijednosti intervala za predviđanje vjerojatnosti stečaja.

Z'' = 6.65 X1 + 3.26 X2 + 6.72 X3 + 1.05 X4 (3)

Tablica 6. Referentni intervali Altmanovog Z'' modela

Referentni intervali	Zaključak o vjerojatnosti stečaja
Z''>2,60	Poduzeće posluje jako dobro i vjerojatnost stečaja je niska.
2,60> Z''>1,10	Postoji mogućnost stečaja, ali on nije vjerojatan.
Z''<1,10	Vrlo vjerojatna mogućnost stečaja.

Izvor: Pervan, I., Filipović, D.: „FP-rating – model za predviđanje insolventnosti poslovnih partnera“, RRiF, 2010.

3.1.3. Edward B. Deakin model

Edward B. Deakin (1972) u svojoj studiji kombinira rezultate istraživanja Beavera i Altmana. Istraživanjem je obuhvatio uzorak od 64 poslovna subjekta koji su bili podijeljeni na dvije grupe. Prvu grupu činili su poslovni subjekti kod kojih je pokrenut stečajni postupak u razdoblju od 1964. do 1970. godine, dok su drugu grupu činili financijski zdravi poslovni subjekti.

Za razliku od Beavera Deakin poduzeća u stečaju smatra ona koja su bankrotirala, koja su insolventna ili su likvidirana s namjerom isplate obveza kreditorima-

Kao i u ranijim istraživanjima, postojala je podudarnost između dviju grupa u pogledu veličine aktive, razdoblja na koje su se odnosili financijski izvještaji te djelatnosti poslovnih subjekata. Za potrebe provedbe istraživanja odabrano je 14 pokazatelja koje je koristio Beaver. Prva analiza obuhvatila je upotrebu metodologije koju je koristio i Beaver, odnosno provođenje klasifikacijskog testa raščlambe. Nalazi su ukazali na tendenciju potvrđivanja zapažanja do kojih je došao isti autor. Druga metoda obuhvaćala je provođenje multivarijantne diskriminantne analize nad istih 14 pokazatelja.

Provođenjem ove metode statističke analize, Deakin je došao do spoznaje da eliminiranje varijabli s niskim ponderom u funkciji bitno utječe na povećanje pogrešnog klasificiranja poslovnih subjekata. Isto tako utvrdio je da se relativan značaj pokazatelja tijekom vremena mijenja iz čega je moguće zaključiti da sve varijable značajno utječu na diskriminacijsku sposobnost funkcije (Deakin, 1972). Tablicom 7. prikazani su financijski pokazatelji uključeni u model s pripadajućim ponderima.

Tablica 7. Financijski pokazatelji s pripadajućim ponderima po godinama prije pokretanja stečajnog postupka

Pokazatelji	Godina prije pokretanja stečajnog postupka				
	5	4	3	2	1
Novčani tok / Ukupne obveze	-0,250	0,094	0,104	-0,046	0,005
Neto dobit / Ukupna imovina	0,122	0,219	-0,585	0,378	0,083
Ukupne obveze / Ukupna imovina	0,220	-0,133	0,287	-0,225	-0,184

Kratkotrajna imovina / Ukupna imovina	0,406	-0,017	0,436	-0,410	-0,101
(Novac + utržive vrijednosnice) / Ukupna imovina	0,230	-0,062	-0,479	0,394	0,212
Radni kapital / Ukupna imovina	0,487	-0,054	0,106	0,102	-0,176
Novac / Ukupna imovina	0,621	-0,701	-0,205	-0,626	-0,900
Kratkotrajna imovina / Kratkoročne obveze	0,003	-0,001	-0,069	0,020	0,052
(Novac + utržive vrijednosnice) / Kratkoročne obveze	0,068	0,017	0,034	-0,065	-0,068
Novac / Kratkoročne obveze	0,077	0,165	0,151	0,111	0,096
Kratkotrajna imovina / Prihodi od prodaje	0,018	0,283	0,057	-0,060	-0,020
(Novac + utržive vrijednosnice) / Prihodi od prodaje	0,123	0,138	0,176	-0,014	-0,074
Radni kapital / Prihodi od prodaje	0,009	0,243	-0,159	0,132	0,069
Novac / Prihodi od prodaje	0,084	0,492	-0,055	-0,203	0,209

Izvor: Deakin, 1972., str. 175

3.1.4. Robert O. Edminster model

Robert Edminister (1972) odlučio je svoje istraživanje bazirati na malim poslovnim subjektima. Malim subjektima smatrao je ona poduzeća koja su u „Agenciji za mala poduzeća“ (Small Business Administration) podigla kredit ili kojima je agencija izdala garanciju. S obzirom na to da je bilo puno lakše doći do financijskih izvještaja i informacija velikih poduzeća, te onih čije su dionice bile javno dostupne, on je ipak među prvima pristupio takvom uzorku poduzeća. Uzorak se sastojao od 562 poslovna subjekta za razdoblje od 1958. – 1965. godine. Isto tako za razliku od prijašnjih istraživanja, kod Edminstera je

stečaj označavao nesposobnost poslovnog subjekta da podmiri dospjele rate kredita, odnosno nije bilo potrebno da stečajni postupak bude pokrenut.

U svom istraživanju za formiranje modela za predviđanje stečaja koristio diskriminantnu analizu, te je dobio „funkciju od sedam varijabli koja ispravno diskriminira u 93% slučajeva.“. Svoj model prikazao je slijedećom jednadžbom:

$Z = 0{,}951 - 0{,}423\ X1 - 0{,}293\ X2 - 0{,}482\ X3 + 0{,}2774\ X4 - 0{,}452\ X5 - 0{,}352\ X6 - 0{,}924\ X7$ (4)

Objašnjenje oznaka:

Z – vrijednost Edminsterovog pokazatelja (1 za uspješno i 0 za neuspješno poduzeće)

X_1 – godišnji novčani tok / kratkoročne obveze (X1 = 1 ako je omjer manji od 0,05, u suprotnom slučaju X1 = 0),

X_2 – glavnica / prihod od prodaje (X2 = 1 ako je omjer manji od 0,07, u suprotnom X2 = 0),

X_3 – (neto radni kapital / prihodi od prodaje) / (neto radni kapital djelatnosti / prihodi od prodaje djelatnosti) (X3 = 1 ako je omjer manji od -0,02, u suprotnom X3 = 0),

X_4 – (kratkoročne obveze / glavnica) / (kratkoročne obveze djelatnosti / glavnica djelatnosti) (X4 = 1 ako je omjer manji od 0,48, a u suprotnom X4 = 0),

X_5 – zalihe / prihodi od prodaje) / (zalihe uk. djelatnosti / prihodi od prodaje uk. djelatnosti) (X5 = 1 ako je omjer manji od 0,04, u suprotnom X5 = 0),

X_6 – omjer ubrzane likvidnosti / omjer ubrzane likvidnosti za djelatnost (X6 = 1 ako je omjer manji od 0,34, u suprotnom X6 = 0),

X_7 - omjer ubrzane likvidnosti / omjer ubrzane likvidnosti za djelatnost (X7 = 1 ako omjer pokazuje uzlazni trend, u suprotnom X7 = 0).

Edminster je također izradio i tablicu komparativnog prikaza varijabli korištenih od strane začetnika istraživanja predviđanja bankrota, Beavera i Altmana (Edminster, 1972).

Tablica 8. Komparativni prikaz varijabli korištenih u Beaverovom i Altmanovom istraživanju

Pokazatelj	Beaver	Altman
Neto radni kapital / Ukupna imovina		X
Obveze / Ukupna imovina	X	X
Obrataj imovine		X
Neto operativna marža		X
Dobit nakon poreza / Ukupna imovina	X	
Tržišna vrijednost kapitala / Knjigovodstvena vrijednost ukupnih obveza		X
Novčani tijek / Ukupne obveza	X	

Prilagođeno prema: Edminster, R.O.: „An empirical test of financial ratio analysis for small business failure prediction, Journal of financial and quantitative analysis, 1972.

3.1.5. James Ohlson model

Ohlson (1980) je u svom istraživanju prvi upotrijebio logističku regresiju. Istraživanje je provedeno nad 2163 poslovna subjekta od kojih su čak 2058 klasificirana kao financijski zdrava, a 105 poduzeća sa poslovnim poteškoćama. Financijski izvještaji navedenih poduzeća prikupljeni su za razdoblje od 1970. do 1976. godine, a odnosili su se na razdoblje od 3 godine prije pokretanja stečajnog postupka. Ohlson je uočio da četiri faktora statistički značajno utječu na vjerojatnost stečaja. To su veličina poduzeća, pokazatelj zaduženosti, pokazatelj uspješnosti poslovanja i pokazatelj tekuće likvidnosti.
U svom istraživanju odlučio je upotrijebiti metodu logističke regresije kako bi izbjegao neke od problema multivarijantne diskriminacijske analize, a razlozi su slijedeći:

- problemi kod korištenja višestruke diskriminantne analize,
- jednakost matrice varijanci i kovarijanci,
- normalna distribuiranost podataka,
- problemi sa „uparivanjem“ kod višestruke diskriminantne analize.

Ohlson razvija tri modela gdje model 1predviđa bankrot unutar jedne godine, model 2predviđa bankrot unutar dvije godine, s time da kompanija nije bankrotirala u idućoj godini i

model 3koji predviđa bankrot unutar jedne ili dvije godine. Ukupna točnost predviđanja prvog modela iznosi 96,12%, drugog modela 95,5%, te trećeg modela 92,84%.

Jednadžbe za sva tri razvijena modela i njihove oznake (Ohlson, 1980):

O-score (1) = -1.32 – 0.407 X1 + 6.03 X2 – 1.43 X3 + 0.08 X4 – 1.72 X5 – 2.71 X6 - 1.83 X7 + 0.285X8 – 0.52 X9 (5)

O-score (2) = 1.84 – 0.519 X1 + 4.76 X2 – 1.71 X3 - 0.3 X4 – 1.98 X5 – 2.74 X6 - 2.18 X7 – 0.780X8 + 0.42 X9 (6)

O-score (3) = 1.13 – 0.478 X1 + 5.29 X2 – 0.990 X3 + 0.07 X4 – 1.71 X5 – 4.62 X6 - 2.25 X7 – 0.521X8 + 0.21 X9 (7)

Objašnjenje oznaka:

X_1 – veličina poduzeća,

X_2 – ukupne obveze / ukupna imovina,

X_3 – radni kapital / ukupna imovina,

X_4 – tekuće obveze / tekuća imovina,

X_5 – vrijednost pokazatelja 1 ako ukupne obveze premašuju ukupnu imovinu, u suprotnom 0,

X_6 – neto dobit / ukupne obveze,

X_7 – novac od poslovanja / ukupne obveze,

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

X_9 – (NIt – NIt-1) / (│NIt│+ │ NIt-1 │), gdje je NIt dobit u posljednjem periodu.

Tablica 9. Referentne vrijednosti P (O-scorea)

Vrijednost P (O – scorea)	Ishod
>0,50	Neuspješno poduzeće
< 0,50	Uspješno poduzeće

Konstruirano prema: Kumar, R.G., Kumar, K.: „A comparison of bankruptcy models“, International Journal of Marketing, Financial Services & Management Research, Vol.1, No.4, 2012.

3.1.6. Mark E. Zmijewski model

Zmijewski (1984) u svom istraživanju u formiranju modela za predviđanje stečaja poslovnog subjekta ne koristi pristup jednakih poduzoraka poduzeća u stečaju i onih koji to nisu, nego „uzorak 81 poduzeća koji je u stečaj, uzorak od 1600 poduzeća koji nisu u stečaju i ukupan uzorak od 1681 poduzeća.“. Jednadžba modela koji je razvio Zmijevski je sljedeća (Zmijewski, 1984):

X = -4,3 - 4,5 X1 + 5,7 X2- 0,004 X3 (8)

Objašnjenje oznaka:

X - vrijednost Zmijevski modela,

X_1 - neto dobit / ukupna imovina,

X_2 - ukupne obveze / ukupna imovina,

X_3 - kratkoročna imovina / kratkoročne obveze.

Razradio je i dvije potencijalne pristranosti koje se mogu pojaviti kod izbora uzorka (Zmijewski, 1984):

- Pristranost temeljena na izboru uzorka – „istraživač prvo opaža zavisnu varijablu i onda izabire uzorak temeljen na tom znanju“ (Zmijewski, 1984),
- Pristranost izbora uzorka – „rezultira kada su samo opservacije sa potpunim podacima korištene za procjenu modela i nepotpune opservacije podataka se događaju nenasumično“ (Zmijewski, 1984).

3.1.7. Robert Shumway model

Shumway (2001)u svom istraživanju za predviđanje bankrota koristi hazard model, te je prilično kritičan prema tradicionalnim, statičkim modelima: „Statički modeli su neprimjenjivi zbog prirode podataka vezanih uz bankrot. Budući da se stečaj ne događa često, prognozeri koriste podatke koji se protežu kroz nekoliko godina unatrag da bi uradili procjene vlastitih modela. Karakteristike većine poduzeća se mijenjaju iz godine u godinu. Prognozeri koji koriste statičke modele uvode nepotrebnu pristranost pri odabiru u vlastita istraživanja.“ (Shumway, 2001)

Shumway je formirao slijedeće jednadžbe kao rezultat svog istraživanja (Shumway, 2001):

Samo tržišne varijable:

X = -12,027 – 0,503X1 – 2,072X2 + 9,834X3 (9)

Objašnjenje oznaka:

X - Vrijednost Shumwayovog modela

X_1 - Veličina poduzeća

X_2 - Povrat iz prethodnih razdoblja

X_3 - Varijabilnost povrata (Sigma)

Tržišne i računovodstvene varijable:

X = -13,303 – 1,982X1 + 3,593X2 - 0,467X3 - 1,809X4 + 5,791X5 (10)

Objašnjenje oznaka:

X – Vrijednost Shumwayovog modela

X_1 – Neto dobit / Ukupna imovina

X_2 – Ukupne obveze / Ukupna imovina

X_3 – Veličina poduzeća

X_4 – Povrat iz prethodnih razdoblja

X_5 - Varijabilnost povrata (Sigma)

Prednosti dinamičnih modela kojima pripada i Shumwayev model u svom istraživanju iznio je Sajter (2009):

- analiziraju i vremensku komponentu rizika ulaska društva u stečajni postupak,
- lakše je uočiti kada poduzeće propada,
- postoji mogućnost uvrštavanja makroekonomskih varijabli,
- pouzdaniji su.

3.1.8. Peter Kralicek model

Peter Kralicek (2007) je provodeći multivarijantnu analizu izveo model za predviđanje financijske nestabilnosti. Koristio je podatke njemačkih, švicarskih i austrijskih poslovnih subjekata te je model prilagođen europskom okruženju.
Formula za DF model glasi :

$$\boldsymbol{DF = 1{,}5X1 + 0{,}08X2 + 10X3 + 5X4 + 0{,}3X5 + 0{,}1X6} \quad \textbf{(11)}$$

Objašnjenje oznaka:

$X_1 - \frac{čisti\ novčani\ tok}{ukupne\ obveze}$

$X_2 - \frac{ukupna\ imovina}{ukupne\ obveze}$

$X_3 - \frac{dobit\ prije\ kamata\ i\ poreza\ (EBIT)}{ukupna\ imovina}$

$X_4 - \frac{dobit\ prije\ kamata\ i\ poreza\ (EBIT)}{ukupni\ prihodi}$

$X_5 - \frac{zalihe}{ukupni\ prihodi}$

$X_6 - \frac{poslovni\ prihodi}{ukupna\ imovina}$

Tablica 10.Prikaz vrijednosti pokazatelja i stupanj 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: prilagođeno od Koban (1978) u Zenzerović i Peruško (2006): Kratki osvrt za predviđanje stečaja, Ekonomska istraživanja, 19. str 132. -151.

Vrijednost diskriminantne funkcije (DF) Kralicekovog modela može poprimiti negativne ili pozitivne vrijednosti pri čemu negativne vrijednosti ukazuju na insolventnost prema predefiniranim stupnjevima insolventnosti dok pozitivne vrijednosti ukazuju na solventnost subjekta. Ocjene financijske stabilnosti prema vrijednosti DF pokazatelja prikazane su u tablici 10.

3.1.9. Gordon L.V.Springate model

Gordon. L.V Springate 1978. je po uzoru na Altmanov model razvio model za predviđanje poslovnog neuspjeha prilagođen kanadskim tržišnim uvjetima. Pri izradi modela korištena je multidiskrimintna analiza na uzorku od 40 poduzeća. Naknadno je odabrano 19 financijskih pokazatelja te su temelju njih određene četiri varijable pomoću koji se radi izračun za razlikovanje uspješnih poduzeća od onih kojima prijeti stečaj.

Springate model glasi:

Springate score = $1{,}03X_1 + 3{,}07X_2 + 0{,}66X_3 + 0{,}4X_4$ (12)

Objašnjenje oznaka:

X1 = $\frac{obrtni\ kapital}{ukupna\ imovina}$

X2= $\frac{dobit\ prije\ kamata\ i\ poreza}{ukupna\ imovina}$

X3 = $\frac{dobit\ prije\ poreza}{kratkoročne\ obveze}$

X4 = $\frac{prihodi\ od\ prodaje}{ukupna\ imovina}$

Ako je vrijednost manja od 0,862 to znači da postoji velika mogućnost financijskog neuspjeha tj. stečaja poduzeća.

3.2. Modeli za predviđanje stečaja u RH

3.2.1. Pervan, Pervan, Vukoja model

Cilj studije Pervan I., Pervan M., Vukoja (2011) bio je odrediti model za predviđanje bankrota poduzeća koristeći samo javno dostupne informacije. Uzorak se sastojao od 156 poduzeća koja su spadala u sektor proizvodnje i trgovine. Prikupljeni su podaci za poduzeća koja su ušla u stečaj za razdoblje od siječnja do lipnja 2010. godine, te su prikazana zajedno sa zdravim poduzećima.

Na temelju financijskih izvještaja izračunato je 15 financijskih pokazatelja prema učestalosti njihova spominjanja u literaturi predviđanja stečaja poduzeća. Da bi se izbjegao problem multikolinearnosti izračunali su Pearsonov koeficijent korelacija i faktor inflacije varijance čime je određeno konačnih 6 financijskih pokazatelja.

Tablica11. Opis financijskih pokazatelja korištenih u modelu

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

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

U radu je korištena diskriminacijska analiza i logistička regresija. Rezultat modela korištenjem diskriminacijske analize jest da uspješno klasificira 80,8% zdravih tvrtki, te 79,5% tvrtki u stečaju, dok je model korištenjem logističke regresije uspješno klasificirao 80,8% zdravih poduzeća i 85,9% poduzeća u stečaju.

Korištenje diskriminacijske analize pokazalo se problematičnim s obzirom da dvije glavne statističke pretpostavke nisu ispunjene, a to su jednakost matrice varijanci i kovarijanci i normalna distribucija. Na kraju je donesen zaključak da javno dostupni financijski izvještaji i izračunati financijski pokazatelji imaju informacijsku vrijednost s obzirom na to da se mogu efikasno koristiti u predviđanju stečaja poduzeća.[1]

3.2.2. Pervan i Kuvek model

Pervan i Kuvek su po prvi puta na uzorku hrvatskih poduzeća uz financijske varijable koristili i nefinancijske varijable. Kvaliteta financijskih izvještaja, kreditni bonitet vlasnika i kvaliteta uprave su uvrštene u model kao nefinancijske varijable koje imaju značajan utjecaj u predviđanju poslovne neuspješnosti. Istraživanje je vršeno na uzorku od 825 trgovačkih društava od kojih je 698 predstavljalo uspješna poduzeća dok je 127 imalo poteškoće u poslovanju ili im je prijetio stečaj (Pervan, Kuvek 2013).

Autori su odlučili koristiti logističku regresiju zbog određenih prednosti u odnosu na multi diskriminantnu analizu (koja zahtjeva striktne pretpostavke poput jednakosti matrica varijanci i kovarijanci za obje skupine poduzeća).

Kako bi se dokazala informacijska vrijednost i utjecaj nefinancijskih varijabli prvo je izračunat model samo sa financijskim vrijednostima, te je naknadno uspoređen sa drugim modelom koji je sadržavao financijske i nefinancijske varijable.

U prvom modelu korištene su sljedeće financijske varijable:

$$X_1 = \left(\frac{D}{A}\right) = \frac{\text{dug (debt)}}{\text{ukupna imovina (assets)}}$$

$$X_2 = \left(\frac{E}{FA}\right) = \frac{\text{vlastiti kapital (equity)}}{\text{stalna imovina (fixed assets)}}$$

$$X_3 = \left(\frac{CFO}{A}\right) = \frac{\text{operativni novčani tok (operating cash flow)}}{\text{ukupna imovina (assets)}}$$

[1] U svom kasnijem radu Pervan, Pervan, Raković (2018) su dodatno povećali točnost modela formirajući zasebne skupine poduzeća sukladno njihovoj veličini.

$$X_4 = \left(\frac{NI}{A}\right) = \frac{\text{neto dobit (net income)}}{\text{ukupna imovina (assets)}}$$

Model sa financijskim varijablama je rezultirao sa 88.4% (617 od 698) točnošću klasifikacije kod zdravih trgovačkih društava dok je za predviđanje neuspješnih trgovačkih društava točnost bila 52% (66 od 127). U drugom modelu su uz prethodno navedene financijske varijable dodane sljedeće nefinancijske varijable:

X5 = ACCQ tj. kvaliteta financijskih izvještaja; eng.quality of accounting information
X6 = MANQ) tj. kvaliteta uprave; eng. management quality
X7 = OFIN tj. kreditni bonitet vlasnika; eng. owners personal credit performance

U tablici 12. prikazan je pregled financijskih i nefinancijskih varijabli u Pervan Kuvek modelu.

Tablica 12. Prikaz varijabli u Pervan Kuvek modelu

Variable	B	S.E.	Wald	df	Sig.
D/A	0.023	0.007	11.875	1	0.0010
E/FA	-0.040	0.018	4.791	1	0.0290
NI/A	-0.129	0.041	9.617	1	0.0020
CFO/A	-0.085	0.032	6.857	1	0.0090
ACCQ	1.083	0.250	18.747	1	0.0001
QFIN	-1.930	0.316	37.263	1	0.0001
MANQ	-1.132	0.361	9.833	1	0.0020
Constant	-3.270	0.254	166.043	1	0.0001

Izvor: Pervan, I. i Kuvek, T. (2013.) The relative importance of fi nancial ratios and nonfi nancial variables in predicting of insolvency, Croatian Operational Research Review, Vol. 4, str. 194.

U drugom modelu s nefinancijskim varijablama točnost predviđanja tj. klasifikacije uspješnih poduzeća iznosila je 92.4% dok je za poduzeća sa poteškoćama iznosila 64.6%. Rezultati istraživanja su pokazali kako je točnost klasifikacije (odnosno predviđanje poslovnog neuspjeha) veće kod modela koji kombinira financijske i nefinancijske varijable u odnosu na model koji sadrži samo financijske varijable.

3.2.2. FP Rating

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

U konačnoj obradi uzorak se sveo na mala i srednje velika trgovačka društva, od kojih su 447 imala sve podatke potrebne za izračun financijskih pokazatelja dok su velika trgovačka društva eliminirana iz analize jer se pokazalo da su greške modela u tom slučaju previsoke. Od ukupno 447 trgovačkih društava 53 su bila insolventna dok su 394 društva bila solventna. Korištena je statistička metoda diskriminantne analize kojom su utvrđene najutjecajnije varijable na klasifikaciju poduzeća u solventne i insolventne.

Jednadžba modela glasi: (Pervan, Filipović, 2010)

$$\textbf{FP RATING®} = -1{,}0937 + 2{,}0956X_1 - 0{,}005X_2 + 0{,}6220X_3 - 0{,}000005X_4 + 0{,}1116X_5 \quad \textbf{(13)}$$

Objašnjenje oznaka:

$$X_1 = \frac{\text{ukupan kapital}}{\text{ukupna imovina}}$$

$$X_2 = \frac{\text{ukupne dugoročne obveze} + \text{ukupne kratkoročne obveze}}{\frac{\text{neto dobitak}}{\text{gubitak tekuće godine}} + \frac{\text{zadržani dobitak}}{\text{preneseni gubitak}} + \text{amortizacija}}$$

$$X3 = \frac{\text{ukupni prihod}}{\text{ukupna imovina}}$$

$$X4 = \frac{365}{\text{koeficijent obrtaja kratkoročnih potraživanja}}$$

$$X5 = \frac{\text{EBITDA} - \Delta\text{obrtni kapital}}{\text{ukupan prihod}}$$

Tako je putem FP RATING® modela u kategoriju solventnih klijenata klasificirano 327, dok je stvarni broj solventnih klijenata iznosio 394, što znači da točnost modela u predviđanju

solventnih klijenata iznosi 83%. Nadalje model je u kategoriju insolventnih klijenata svrstao njih 37, dok je stvarni broj iznosio 53, što mu daje točnost klasifikacije od 69,8%.

3.2.3. Ivičić i Cerovac model

Ivičić i Cerovac (2009) objavljuju rad sa ciljem modeliranje kreditnog rizika nefinancijskih poslovnih subjekata procjenjivanjem vjerojatnosti migracija rejtinga i prognoziranjem vjerojatnosti neurednog podmirivanja kreditnih obveza u razdoblju od jedne godine na temelju financijskih izvještaja poduzeća.

Uzorak se sastojao od 7.719 poduzeća tijekom 2007. i 2008. godine tvoreći neujednačenu skupinu koja se sastoji od 12.462 promatranja binarne ovisne varijable, odnosno poduzeća za koja su postojali podaci o tome jesu li tijekom određene godine podmirivala obveze ili ne. Koristili su 84 potencijalno relevantna financijska pokazatelja koja su odabrana prema kriteriju uspješnosti predviđanja neurednog podmirenja obveza u prijašnjim istraživanjima.
Financijski pokazatelji su grupirani u pokazatelje likvidnosti, solventnosti, aktivnosti, ekonomičnosti, profitabilnosti i pokazatelje ulaganja. Konačni model za predviđanje vjerojatnosti neurednog podmirivanja obveza tijekom sljedeće godine dobiven je korištenjem multivarijantne logističke regresije na temelju veličine poduzeća (mjerene ukupnom prodajom), ekonomske aktivnosti (građevina i nekretnine prema ostalim sektorima) i pet financijskih pokazatelja:

1. Pokazatelja likvidnosti (mjerenoga kao gotovina prema ukupnoj imovini)
2. Pokazatelja vlastitog financiranja (dionički kapital prema ukupnoj imovini)
3. Pokazatelja aktivnosti (promet potraživanja od kupaca u danima)
4. Dva pokazatelja profitabilnosti (zarada prije oporezivanja i kamata prema ukupnim obvezama te prodaja i amortizacija prema ukupnoj imovini)

Konačni model glasi (Ivičić, Cerovac, 2009):

$$\mathbf{F}[\boldsymbol{Xi}, \boldsymbol{\beta}] = 1/1+ e^{-(-0,17-0,28\ Di,t - 0,63w_1_10i,t\ -0,63w_1_10i,t - 1,96w_2_2i,t + 0,09w_3_4i,t - 0,1w_5_16i,t - 0,37w_5_22i,t - 0,01w_7_5i,t} \quad \textbf{(14)}$$

Kao najvažniji pokazatelji rizika neurednog podmirivanja obveza navode se sljedeći:

- omjer dioničkog kapitala prema ukupnoj imovini
- omjer zarade prije kamata i oporezivanja prema ukupnim obvezama

Veća likvidnost, profitabilnost i prodaja, kao i poslovanje u sektoru građevine i nekretnina, smanjuju vjerojatnost neurednog podmirivanja kreditnih obveza poduzeća u sljedećoj godini. Model je točno klasificirao 74,4% poduzeća koja uredno podmiruju obveze i 71,2% poduzeća koja ih ne podmiruju uredno.

3.2.4. Šarlija model

Šarlija (2009) objavljuju rad sa ciljem kreiranja modela za predviđanje kratkoročne nelikvidnosti poduzeća u Hrvatskoj. Nelikvidno poduzeće definirano je kao ono poduzeće čiji je žiro-račun u blokadi kontinuirano tri mjeseca i više. Uzorak se sastojao od 75.145 trgovačkih društva u Hrvatskoj koja su predala financijske izvještaje u FINA-i 2006. godine. Ovim uzorkom nisu obuhvaćene banke, štedionice i društva za osiguranje. Prikupljeni su podaci iz bilance i računa dobiti i gubitka te podaci o broju dana blokada u toj i idućoj godini. Uzorak je podijeljen na dvije skupine, a od toga je prvu skupinu predstavljala skupina za razvoj modela i drugu kao uzorak za testiranje modela (omjer skupina je 80:20). Dobiveni model definiran je na temelju uzorka za razvoj modela dok su daljina testiranja provođena na uzorku za testiranje modela.

Za potrebe istraživanje korišteno je 29 financijskih pokazatelja, ali se konačni model sastojao od 16 varijabli. Uz financijske pokazatelje koji su predstavljali nezavisne varijable u model su uvrštene i dvije kategoričke varijable (djelatnost i županija).
Primjenom metode logističke regresije na uzorku skupine za razvijanje modela dobiveni su rezultati koji ukazuju na to da su za predviđanje nelikvidnosti poduzeća bitni financijski koeficijenti iz svih pet grupa, dakle likvidnosti, zaduženosti, aktivnosti, ekonomičnosti i profitabilnosti. Rezultati istraživanja također pokazuju da postoje razlike u likvidnosti poduzeća u Hrvatskoj s obzirom na djelatnost i županiju.

Tablica 13. Značajni prediktori nelikvidnosti u Hrvatskoj prema modelu Šarlija et al.

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

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

Ukupna točnost modela iznosi 68,16% za likvidna poduzeća, te 74,22% za nelikvidna poduzeća. Navodi se da su najrizičnija poduzeća, odnosno ona kod kojih postoji relativno visoka vjerojatnost da postanu nelikvidna u Međimurskoj, Osječko-baranjskoj, Požeško-slavonskoj i Varaždinskoj županiji, a najmanje rizična su ona u Zadarskoj, Šibensko-kninskoj i Zagrebačkoj županiji te Gradu Zagrebu. Što se tiče djelatnosti najmanja vjerojatnost da

postanu nelikvidna poduzeća u idućem razdoblju su ona koja se bave financijskim posredovanjem i javnom upravom, dok je najveća vjerojatnost kod djelatnosti prerađivačke industrije i hotela.

3.2.5. Zanzerović model

Zenzerović (2009) u radu prezentira model za predviđanje poslovne neuspješnosti koji je izveden korištenjem višestruke diskriminantne analize. Poduzeća su podijeljena u financijski stabilna i nestabilna poduzeća. Uzorak se sastojao od 55 financijski stabilnih i jednak broj nestabilnih poduzeća koja su klasificirana prema veličini i djelatnosti. Financijski nestabilna poduzeća su ona koja su ušla u stečajni postupak ili koja su u svojim financijskim izvještajima objavila gubitak iznad visine kapitala. Informacije potrebne za izračun 50 financijskih pokazatelja su prikupljene iz dva glavna izvora; javno dostupnih financijskih izvješća trgovačkih društva čije dionice kotiraju nahrvatskoj burzi i Fina-e. (Zanzerović, Peruško 2009) Pod 50 izračunatih pokazatelja spadaju pokazatelji likvidnosti, solventnosti, aktivnosti, profitabilnosti, pokazatelji koji stavljaju u odnos različite skupine prihoda i rashoda, te pokazatelji temeljeni na izvještaju o novčanom tijeku.

Jednadžba za izračun Zenzerević modela glasi:

CGE1 = -2,207 – 0,026 FS + 0,733 N/I + 1,905 RK/I – 1,086 Z – 0,626 SF – 0,008 FZ + 2,812 A + 2,989 EUP – 0,047 ROA – 0,548 RTIF – 0,124 TL + 0,433 EP (15)

Objašnjenje oznaka:

$$FS = \frac{dugotrajna\ imovina}{dugoročne\ obveze + kapital}$$

$$N/I = \frac{novac\ i\ novčani\ ekvivalenti}{kratkoročna\ imovina}$$

$$RK/I = \frac{radni\ kapital}{ukupna\ imovina}$$

$$Z = \frac{ukupne\ obveze}{ukupna\ imovina}$$

SF = $\frac{vlastita\ imovina}{ukupna\ imovina}$

FZ = $\frac{ukupne\ obveze}{zadržani\ dobitak+deprecijacija}$

A = $\frac{zadržani\ dobitak}{ukupna\ imovina}$

EUP = $\frac{ukupni\ prihodi}{ukupni\ rashodi}$

FS = $\frac{dugotrajna\ imovina}{dugoročne\ obveze+kapital}$

ROA – povrat na imovinu

RTIF = $\frac{neto\ dobit+kamate}{ukupne\ obveze}$

TL – pokazatelj likvidnosti

EP = $\frac{poslovni\ prihodi}{poslovni\ rashodi}$

Rezultati modela prikazuju kako je 93,5% originalnih jedinica točno klasificirano, dok je analizom presjeka 89,8% jedinica točno klasificirano. Zenzerović potom razvija drugi i treći CGE model. Drugi se razlikuje u tome što je iz modela izbačeno 6 financijskih pokazatelja. Varijable FS, ROA i RTIF su izbačene zbog negativnih predznaka koji nisu u skladu s postulatima financijske teorije, dok su varijable N/I, TL i EP izbačene zbog toga što su bile manje značajne. Jednadžba drugog modela glasi:

CGE2 = - 1,802 + 1,478 RK/I – 0,995 Z – 0,647 SF – 0,008 FZ + 3,048 A + 2,808 EUP (16)

Rezultat drugog modela pokazuje kako je 95,4% originalnih jedinica točno klasificirano, dok je analizom presjeka 93,5% jedinica točno klasificirano što ukazuje na to da se rezultat poboljšao provođenjem navedenih promjena.

Treći model se razlikuje od drugoga po tome što su iz drugog modela izostavljene dvije jedinice uzorka koje su imale najveću standardnu grešku, dok su varijable ostale jednake kao kod drugog modela. Jednadžba trećeg modela glasi:

CGE3 = -1,74 + 1,517 RK/I – 1,079 Z – 0,601 SF – 0,008 FZ + 3,151 A + 2,771 EUP (17)

Rezultat trećeg modela pokazuje kako je točno klasificirano 95,3% jedinica u oba slučaja što ukazuje da navedene promjene dodatno povećavaju preciznost modela.

3.3. Statistička metodologija predviđanja stečaja

Statistička metodologija predviđanja bankrota u velikom broju slučajeva oslanja se na „četiri široke kategorije metoda“ (Yazdanfar, Nillson, 2008):

- Višestruke diskriminantne modele (MDA – Multiple Discriminant Analysis),
- Modele logističke regresije (Logit),
- Regresijski probit model (Probit),
- Neuronske mreže (NN – Neural Network).

Logistička regresija (Logit) je „višestruka regresija sa kategoričnom zavisnom varijablom i sa nezavisnim varijablama koje su kontinuirane i kategoričke“ (Field, 2009.). „U logističkoj regresiji zavisna varijabla je Y indikator varijabla koja može poprimiti samo vrijednosti 0 i 1“ (Aczel-Sounderpandian, 2008). „Jednadžba logističke regresije ima mnoge sličnosti s jednadžbom linearne i višestruke regresije, a u najjednostavnijem obliku sa samo jednom prediktor varijablom X vjerojatnost ostvarivanja Y se prikazuje jednadžbom“ (Field, 2009):

$$P(Y) = \frac{1}{1+e^{-(b_0+b_1 b_{1i})}} \quad (18)$$

Objašnjenje oznaka:

P(Y) – Vjerojatnost ostvarivanja Y,

E – Baza prirodnog algoritma,

b_0 – Sjecište Y osi (konstanta),

b_1 – Nagib (ponder ili koeficijent prediktor varijable),

X – Vrijednost prediktor varijable.

Kada se ova jednadžba „proširi sa više prediktora“ (Field, 2009.) izgleda ovako:

$$P(Y) = \frac{1}{1+e^{-(b_0+b_1b_{1i})+b_2x_{2i}+\cdots+b_nx_{ni}}} \quad (19)$$

Dvije su vrste logističke regresije(Field, 2009):

- Binarna logistička regresija,
- Multinominalna logistička regresija.

Diskriminantna analiza (DA) je „multivarijatna tehnika kojom se pokušava generirati jednadžba kojom se procjenjuje vrijednost zavisne varijable temeljem vrijednosti nezavisnih varijabli“ (Aczel-Sounderpandian, 2008.). „Diskriminantnom analizom poduzeća se klasificiraju u dvije grupe (bankrotirana ili nebankrotirana) na temelju karakteristika svakog poduzeća (pokazatelja/faktora), a koeficijenti se kalkuliraju iz svakog pokazatelja na temelju opservacija uzorka“ (Bellovary et al., 2007.). „Klasifikacija poslovnih subjekata provodi se usporedbom vrijednosti modela pojedinog poslovnog subjekta s kritičnim vrijednostima“ (Zenzerović, Peruško, 2006).

Jednadžba modela diskriminantne analize formira se po slijedećem obrascu (Zenzerović, Peruško, 2006):

$$\mathbf{Z_i = b_0+b_1x_1+b_2x_2+\ldots+b_nx_n} \quad \mathbf{(20)}$$

Objašnjenja oznaka:

$\mathbf{Z_i}$ - vrijednost diskriminantnog modela,

$\mathbf{x_1 – x_n}$ - vrijednost nezavisne varijable signifikantne za predviđanje stečaja,

$\mathbf{b_1 - b_n}$ – ponderi nezavisnih varijabli

Neuronske mreže (NN) su „mreže jednostavnih analitičkih jedinica koje nazivamo „čvorištima“ koja međusobno djeluju koristeći ponderirane veze“ (Raghupathi et al., 1991). Funkcioniraju tako da „traže obrasce u bazama podataka, nauče obrasce i razviju sposobnost ispravne klasifikacije novih obrazaca ili predviđanja“ (Al Osaimy, 1998.). „Znanje se u neuronskim mrežama pohranjuje u skup pondera u međupoveznicama između čvorova neuronskih mreža“ (Raghupathi et al., 1991). „Neuronske mreže, kao oblik nelinearne optimizacije, koji koriste različite pondere i funkcije s ciljem pretvaranja ulaznih podataka u korisne informacije, svoju primjenu pronalaze i u predviđanju stečaja“ (Zenzerović, Peruško

2006). „Istraživanja su pokazala da su modeli temeljeni na neuronskim mrežama uspješnija od statističkih modela poput MDA, Logit analize i Probit analize“ (Yildiz, Akkoc, 2010).

4. EMPIRIJSKI DIO RADA

4.1. Opis uzorka istraživanja

Istraživanje je usmjereno na određivanje modela za predviđanje stečaja u Republici Hrvatskoj. Za potrebe analize modela prikupljeni su podaci iz „Amadeus“ baze podataka, koja raspolaže financijskim podacima javnih i privatnih poduzeća europskih zemalja. Korištene su financijske informacije iz Republike Hrvatske za period 2014. i 2015. godine koje pripadaju prerađivačkoj industriji (područje C prema NKD-u, NN 58/2007).

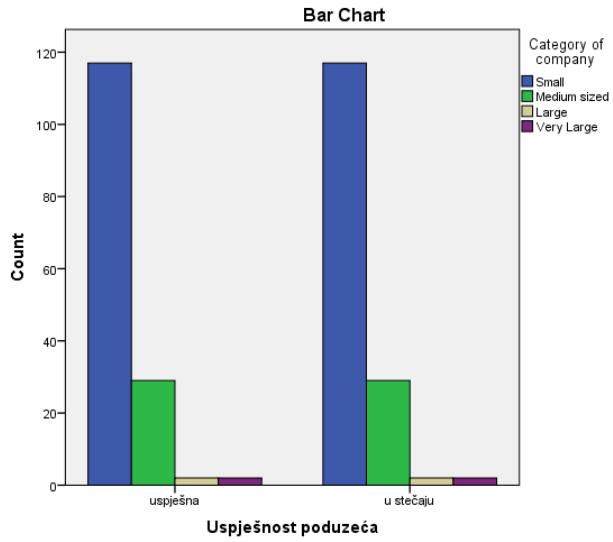
U obradi podataka i formiranju modela primjenjen je softverski paket SPSS - „Statistical package for social sciences“. Korištena statistička metoda je logistička regresija koja se primjenjuje u situacijama u kojima je zavisna varijabla kategorijalna (1-poduzeća u stečaju, 0-uspješna poduzeća), dok su nezavisne varijable (financijski pokazatelji) kontinuirane i kategorijalne.

Logistička regresija za ocjenu parametara nezavisnih varijabli koristi sljedeću formulu (Hair, Black, Babin, Anderson, 2010):

logit (p) = b0 + b1X1+ b2X2+ … + bnXn; gdje je logit (p) =ln (p/(1-p)) (21)

Logistička regresija ima određene prednosti nad ostalim analizama jer ne zahtijeva obveznu normalnost nezavisnih varijabli, linearnost odnosa nezavisne i zavisnih varijabli, te homogenost varijanci i kovarijanci.

Grafikon 1. Broj poduzeća prema veličini



Odabrani uzorak sastojao se od 300 poduzeća od kojih je 150 bilo „u stečaju“. Sukladno standardnoj metodologiji poduzećima „u stečaju“ je upareno 150 uspješnih poduzeća. Pritom se pri uparivanju vodilo računa da su uspješna poduzeća po veličini i imovini slična poduzećima u stečaju. Od ukupnog broja poduzeća, 117 je malih, 29 srednjih, 2 velika i 2 vrlo velika poduzeća što se vidi na grafikonu 1.

4.2. Opis varijabli

Iako logistička regresija ima brojne prednosti, osjetljiva je na problem multikolinearnosti, tj. postojanje snažne veze između nezavisnih varijabli. U cilju testiranja potencijalnog problema multikolinearnosti korištena je matrica Pearsonovih koeficijenata, te je utvrđeno postojanje visokog stupnja korelacije između dva para nezavisnih varijabli (Profitna marža i EBIT; te Likvidnosti i Tekućeg pokazatelja). U cilju otklanjanja uočenog problema multikolinearnosti, prethodno navedene varijable su naizmjenice bile uvođene u model.

Tablica 14. Rezultati analize korelacije nezavisnih varijabli

		LN- Broj zaposlenih Year -1	Profitna marža % Year - 1	ROA Year - 1	EBITDA Marža % Year - 1	EBIT Marža % Year - 1	ROE Year - 1	Tekući pokazatelj Year - 1	Likvidnost Year - 1	Solventnost Year - 1
LN-Broj zaposlenih Year -1	Pearson Correlation	1	-,040	,007	-,052	-,062	-,099	,071	,053	,116
	Sig. (2-tailed)		,529	,903	,415	,318	,137	,236	,375	,057
	N	284	255	281	247	264	227	283	282	268
Profitna marža % Year - 1	Pearson Correlation	-,040	1	,528**	,780**	,937**	,389**	,216**	,225**	,470**
	Sig. (2-tailed)	,529		,000	,000	,000	,000	,000	,000	,000
	N	255	265	264	243	264	230	263	263	259
ROA Year - 1	Pearson Correlation	,007	,528**	1	,446**	,492**	,634**	,235**	,241**	,538**

	Sig. (2-tailed)	,903	,000		,000	,000	,000	,000	,000	,000
	N	281	264	296	254	273	236	293	292	282
EBITDA Marža Year - 1	Pearson Correlation	-,052	,780**	,446**	1	,864**	,281**	,169**	,170**	,335**
	Sig. (2-tailed)	,415	,000	,000		,000	,000	,007	,007	,000
	N	247	243	254	256	252	210	254	254	245
EBIT Marža Year - 1	Pearson Correlation	-,062	,937**	,492**	,864**	1	,322**	,209**	,209**	,464**
	Sig. (2-tailed)	,318	,000	,000	,000		,000	,001	,001	,000
	N	264	264	273	252	274	230	272	272	265
ROE Year - 1	Pearson Correlation	-,099	,389**	,634**	,281**	,322**	1	-,018	-,003	-,041
	Sig. (2-tailed)	,137	,000	,000	,000	,000		,788	,964	,531
	N	227	230	236	210	230	236	233	232	236
Tekući pokazatelj Year - 1	Pearson Correlation	,071	,216**	,235**	,169**	,209**	-,018	1	,933**	,495**
	Sig. (2-tailed)	,236	,000	,000	,007	,001	,788		,000	,000
	N	283	263	293	254	272	233	297	296	280
Likvidnost Year - 1	Pearson Correlation	,053	,225**	,241**	,170**	,209**	-,003	,933**	1	,469**
	Sig. (2-tailed)	,375	,000	,000	,007	,001	,964	,000		,000
	N	282	263	292	254	272	232	296	296	279
Solventnost Year - 1	Pearson Correlation	,116	,470**	,538**	,335**	,464**	-,041	,495**	,469**	1
	Sig. (2-tailed)	,057	,000	,000	,000	,000	,531	,000	,000	
	N	268	259	282	245	265	236	280	279	283

Izvor: Izračun autora

Koeficijenti linearne korelacije za pokazatelje koji su u modelu pokazuju da ne postoji statistički značajna povezanost između logaritma broja zaposlenih u prethodnoj godini s jedne strane i ROA, odnosno solventnosti u prethodnoj godini jer su empirijske razine signifikantnosti veće od 5%, a povezanost između ROA u prethodnoj godini i solventnosti u prethodnoj godini je statistički značajna, srednje jaka i pozitivna (p ≈0) što je manje od 5% (r=0,538). Dodatna analiza problema multikolinearnosti provedena je uporabom faktora inflacije varijance - VIF. Za te potrebe se oblikuje pomoćni regresijski model u koji su uključene nezavisne varijable, u kojem se jedna varijabla postavlja kao zavisna, a ostale kao nezavisne. Svi izračunati VIF-ovi su bili manji od 5 (raspon od 1,044 do 1,448) što pokazuje da problem multikolineranosti nije prisutan među preostalim nezavisnim varijablama.

Tablica 15. Analiza faktora inflacije varijanace

Model	TOL	VIF
LN- Broj zaposlenih	0,958	1,044
ROA	0,701	1,427
Solventnost	0,691	1,448

Izvor: Izračun autora

Na temelju dostupnih financijskih informacija iz uzorka odabrani su sljedeći financijski pokazatelji kao konačne varijable: ln broj zaposlenika, solventnost i ROA.
U sljedećoj tablici su izračunate aritmetičke sredine te je proveden t- test za nezavisne uzorke.

Tablica 16. Usporedba aritmetičkih sredina nezavisnih varijabli

Varijabla	Skupina	Broj opservacija	Aritmetička sredina	Standardna devijacija	Standardna greška
LN –BROJ ZAPOSLENIH	Stečaj	135	1,57725	1,32664	0,11418
	Uspješni	149	2,01730	1,10728	0,09071
SOLVENTNOST	Stečaj	146	-7,08444	24,55073	2,03183
	Uspješni	150	15,07556	15,47277	1,26335
ROA	Stečaj	133	8,68577	41,61164	3,60819
	Uspješni	150	66,94625	20,15656	1,64578

Izvor: Izračun autora

Rezultati iz tablice 16 potvrđuju da se prosječna vrijednost financijskih pokazatelja kod poduzeća u stečaju znatno lošija u usporedbi s uspješnim poduzećima. Primjerice, ROA u prosjeku kod uspješnih poduzeća iznosi 66, 94%, dok kod poduzeća u stečaju ROA iznosi samo 8,68%.

Tablica 17. T-test razlike aritmetičkih sredina nezavisnih varijabli

Varijabla	Sig.	T-vrijednost	Stupnjevi slobode	Razlika aritmetičke sredine
LN- BROJ ZAPOSLENIKA	0,020	-3,044	283	-0,44005
SOLVENTNOST	0,006	-9,316	294	-22,16000
ROA	0,000	15,250	281	-58,26049

Izvor: Izračun autora

Rezultati t-testa su pokazali da varijance ROA između poduzeća koja su u stečaju i onih koja su uspješna nisu jednake ($p = 0,006 < 0,05$) i da postoji statistički značajna razlika u ROA između dvije grupe jer je empirijska razina signifikantnosti manja od 0,05 ($p \approx 0$). Uspješna poduzeća u osnovnom skupu imaju statistički značajno veći ROA u odnosu na poduzeća u stečaju. Isto vrijedi i za preostala dva pokazatelja.

4.3. Rezultati istraživanja

Kod ocjene parametara koristila se logistička regresija uz primjenu metode „enter“, što je rezultiralo da su sve tri nezavisne varijable imale signifikantnost manju od 5%. Pokazatelji koji su ušli u model: ln broja zaposlenika, solventnost i ROA.

Svi procijenjeni parametri uz nezavisne varijable (tablica 19) su negativnog predznaka, što znači da se povećavanjem broja zaposlenih, ROA i solventnosti smanjuju izgledi stečaja poduzeća.

Tablica 18. Deskriptivna statistika

Varijabla	Min.	Max.	Aritmetička sredina		Standardna devijacija
	Vrijednost	Vrijednost	Vrijednost	Standardna greška	Vrijednost
LN- BROJ ZAPOSLENIKA	0,00000	6,55819	1,80811	0,07323	1,23410
SOLVENTNOST	296	165,372	-97,778	67,594	4,14529
ROA	283	189,693	-89,722	99,971	39,56588

Izvor: Izračun autora

Tablica 19. Varijable u finalnom modelu

Varijabla	Parametar (B)	Standardna greška	Wald	df	Signifikantnost	Exp (B)
LN- BROJ ZAPOSLENIKA	-0,032	0,166	3,746	1	0,053	0,726
SOLVENTNOST	-0,067	0,009	52,332	1	0,000	0,935
ROA	-0,074	0,019	14,940	1	0,000	0,929
Konstanta	3,863	0,606	40,589	1	0,000	47,603

Izvor: Izračun autora

Parametar uz prirodni logaritam broja zaposlenih je granično značajan ($p=0,053 < 0,1$) i iznosi -0,032, odnosno $e^{-0,032} = 0,929$ što znači porast prirodnog logaritma broja zaposlenih za jednu jedinicu (broj zaposlenih se poveća približno 2,7 puta) te smanjuje omjer šansi za otvaranje stečaja za 27,4% (100%-72,6%) uz c.p.

Parametar uz solventnost je statistički značajan ($p \approx 0$) i iznosi -0,067, odnosno $e^{-0,067} = 0,935$ što znači da porast solventnosti za 1 jedinicu smanjuje omjer šansi za otvaranje stečaja za 6,5% (100%-93,5%) uz c.p.

Parametar uz ROA je statistički značajan ($p \approx 0$) i iznosi -0,074, odnosno $e^{-0,074} = 0,929$ što znači da porast ROA za 1 p.p. smanjuje omjer šansi za otvaranje stečaja za 7,1% (100%-92,9%) uz c.p.

Tablica 20. Sažetak modela

-2LL	Cox & Snell R^2	Nagelkerke R^2
164,679[a]	0,530	0,711

a.Proces je okončan u 7.koraku jer su promjene ocjena parametara manje od 0,001

Izvor: Izračun autora

U tablici 20 prikazan je sažetak kvalitete ocijenjenog modela, te su prezentirani „pseudo“ koeficijenti determinacije (Cox & Snell R^2 i Nagelkerke R^2). Navedeni koeficijenti determinacije u literaturi se nazivaju „pseudo“ jer imitiraju „izvorni“ koeficijent determinacije-R^2 koji se koristi kod klasične regresije, a koji se bazira na sumi odstupanja. Specifičnost „pseudo“ koeficijenata determinacije ogleda se u tome što se oni izračunavaju na bazi –2LL vrijednosti (-2*logaritam vjerodostojnosti), te je poželjna što niža –2LL vrijednost. Cox & Snell R^2 je malo problematičan za interpretaciju jer nema gornji maksimum od 1,0 (odnosno 100%).

U ocijenjenom modelu za predviđanje stečaja, Cox & Snell R^2 pokazuje da se 53% varijacije zavisne varijable stečaja u prerađivačkoj industriji može objasniti uporabom tri financijska pokazatelja iz finalnog modela. Nagelkerke R^2 je malo jednostavniji za interpretaciju jer se njegova vrijednost uvijek kreće u rasponu od 0 do 1 (odnosno od 0% do 100%). Izračunata vrijednost Nagelkerke R^2 od 71,1% ukazuje na postojanje umjereno jake veze između predviđanja stečaja prerađivačke industrija i financijskih pokazatelja korištenih u finalnom modelu.

Kvaliteta finalnog modela se pored spomenutih „pseudo“ koeficijenata determinacije može prosuđivati i temeljem H-L testa (Hosmer i Lemeshow test). H-L test dijeli opservacije u 10 grupa, te uspoređuje broj opservacija u svakoj od stvarnih grupa s brojem opservacija u svakoj od grupa prema predviđanju ocijenjenog modela logističke regresije. Kod ovog testa poželjna je nesignifikantna vrijednost (p>5%), što znači da nema značajnih razlika između stvarne grupe i grupe koju predviđa ocijenjeni model. U tablici 21 provedeni H-L test je rezultirao signifikantnošću od 66 % što je u skladu s traženim teorijskim postavkama.

Tablica 21. Hosmer i Lemeshow test

Hi-kvadrat	Stupnjevi slobode	Signifikantnost
5,885	8	0,660

Izvor: Izračun autora

Detaljniji uvid u točnost predviđanja ocijenjenog modela prikazan je u tablici 22 u kojoj je prezentirana ukupna točnost predviđanja za sva poduzeća iz uzorka, te zasebna točnost predviđanja za poduzeća u stečaju i za uspješna poduzeća.

Tablica 22. Točnost predviđanja modela

		Predviđena grupa		
		Uspješna poduzeća	**Poduzeća u stečaju**	**Točnost predviđanja grupe %**
Izvorna grupa	Uspješna poduzeća	133	16	89,3
	Poduzeća u stečaju	21	97	82,2
Ukupna točnost predviđanja				**86,1**

Izvor: Izračun autora

Točnost predviđanja modela kao cjeline iznosi 86,1%, dok je točnost predviđanja u segmentu uspješnih poduzeća (89,3%) viša u odnosu na točnost predviđanja poduzeća u stečaju (82,2%). Preciznije rečeno, model je od ukupno 118 poduzeća u stečaju točno klasificirao 97 poduzeća (82,2%), dok je pogrešno klasificirao 21 poduzeće (17,8%). U poduzorku uspješnih poduzeća model je od ukupno 149 poduzeća točno klasificirao 133 poduzeća (89,3%), dok je pogrešno klasificirao 16 poduzeća (13,6%). Može se zaključiti da je ocijenjeni model rezultirao zadovoljavajućom razinom prognostičke točnosti.

5. ZAKLJUČAK

Zbog velikog broja poduzeća koja su imala poteškoće, što zbog financijske krize i recesije ili samo lošeg upravljanja samim poduzećem, veliki broj znanstvenika, ali i samih sudionika na tržištu se zainteresirao za ovu temu. Rezultati modela mogu poslužiti kao smjernice u što boljem provođenju restrukturiranja, ocjeni financijskog rejtinga, pomoć u poslovnom odlučivanju, odluke o kreditiranju poduzeća, itd.

Predviđanje stečaja započelo je još 60-ih godina prošlog stoljeća, no i dalje dominira Altmanov model iz 1968. Situacija u Hrvatskoj nije dala mnogo znanstvenih radova na tu temu. Razlog tome je što je u Hrvatskoj tek 2008. godine započeta obveza javne objave financijskih izvještaja poduzeća stoga je bilo teško doći do relevantnih financijskih podataka.

Cilj ovog rada je bilo primjenom logističke regresije formulirati model za predviđanje stečaja poduzeća. Model u konačnici sadržavao tri pokazatelja (ln-broj zaposlenih, solventnost i ROA). Svi pokazatelji su imali negativne predznake, što kod logističke regresije znači da se povećanjem njihove vrijednosti smanjuje omjer šansi za otvaranje stečaja. Izračunati „pseudo“ koeficijenti determinacije (Cox & Snell R^2 i Nagelkerke R^2), kao i Hosmer i Lemeshow test ukazuju na visoku kvalitetu ocijenjenog modela.

Točnost predviđanja oblikovanog modela u poduzorku uspješnih poduzeća iznosi vrlo visokih 89,3%, dok je u poduzorku poduzeća u stečaju točnost predviđanja malo niža i iznosi 82,2%. Ukupna točnost predviđanja modela iznosi 86,1%, te se može kazati da model može poslužiti za kvalitetno predviđanje poslovnog neuspjeha prerađivačkih poduzeća u Hrvatskoj.

LITERATURA

1. Al Osaimy, M.H. (1998): A Neural Networks System for Predicting Islamic Banks Performance, JKAU: Econ. & Adm., str. 33-46.
2. Alkhatib, K., Al Bzour, A.E. (2011): Predicting Corporate Bankruptcy of Jordanian Listed Companies: Using Altman and Kida Models, International Journal of Business and Management, str. 208-215.
3. Altman E., Hotchkiss E. (2006): Corporate Financial Distress and Bankruptcy, Wiley Finance, str.13.
4. Altman, E.I. (1968): Financial ratios, discriminant analysis and prediction of corporate bankruptcy, The Journal of Finance, str. 589-609.
5. Beaver, W. (1967): Financial Ratios as Predictor of Failure, Empirical Researching Accounting, Empirical Studies, Journal of Accounting Research, br.4, str. 71-111.
6. Belak, V. (1995.): Menadžersko računovodstvo, RRiF, Zagreb, str. 71.
7. Chowdhury, A., Barua, S. (2009): Rationalities of z-category shares in Dhaka Stock Exchange: are they in financial distress risk?, str. 45-58.
8. Cirmizi E., Klapper L. and Uttamchandani M. (2011): The Challenges of Bankruptcy Reform, The World Bank Research Observer, br.2., str. 185-203.
9. Deakin, E. B., (1972): A Discriminant Analysis of Predictors of Business Failure, Journal of Acounting Research, Spring, str. 167-179.
10. Dika, M. (1996): Insolvencijsko pravo, Pravni fakultet u Zagrebu, Zagreb, str.13.
11. Edminster, R.O. (1972): An empirical test of financial ratio analysis for small business failure prediction, Journal of financial and quantitative analysis,
12. Fan, W., White, M.J., (2003): Personal bankruptcy and the level of entrepreneurial activity, Journal of Law and Economics, str.543-567.
13. Field, A. (2009): Discovering Statistics using SPSS, Sage Publications Inc.,
14. Frisby, S. (2007): A preliminary analysis of pre-packaged administrations, Report to the Association of Business Recovery Professionals
15. Funchal, B., Clovis, M. (2009): Firms capital structure and the bankruptcy law design, Journal of Financial Economic Policy, str.264-275.
16. Gerantonis, N., Vergos, K. and Christopoulos, A.G. (2009): Can Altman Z-score Models Predict Business Failures in Greece?, Research Journal of International Studies, str. 21-28.

17. Gine, X., Love, I. (2010): Do Reorganisation Costs Matter for Efficiency? Evidence from a Bankruptcy Reform in Colombia
18. Grubišić, D. (2013.): Poslovna ekonomija, Ekonomski fakultet u Splitu, Split, str. 114.
19. Hair, J., F., Black, W., C., Babin, B. J., Anderson, R. E. (2010.): *Multivariate Data Analysis*, Pearson Prentice Hall, Harlow, str. 323.
20. Hayes, S., Hodge, K., Hughes, L. (2010): A Study of the Efficacy of Altman's Z To Predict Bankruptcy of Specialty Retail Firms Doing Business in Contemporary Times – Economics and Busuness Journal: Inquiries and Perspectives, br. 3, str. 122-134.
21. Ivičić, L., Cerovac S. (2009): Procjena kreditnog rizika poduzeća u Hrvatskoj, Financijska teorija i praksa, Vol.33 br. 4., str 397.
22. Kraakman, R., Armour, J., Davies, P., Hansmann, H., Hertig, G., Hopt, K., Kanda, H., Pargendler, M., Ringe, W.G., Rock, E. (2009): The Anatomy of Corporate Law, A Comparative and Functional Approach
23. Mathur, A. (2009): A Spatial Model of the Impact of Bankruptcy Law on Entrepreneurship, Spatial Economic Analysis
24. Mizan, A.N., Hossain M.M. (2014): Financial Soundness of Cemetn Industry of Bangladesh: An Empirical Investigation Using Z-score American Journal of Trade and Policy, str.16-22.
25. Ohlson, R. (1980): Financial Ratios and the Probabilistic Predicition of Bankruptcy, Journal of Accounting Reaserch, Spring, Vol. 18., No. 1., str. 110.
26. Ooghe, H., Waeyaert, N. (2004): Oorzaken van faling: Literatuuroverzicht en conceptueel verklaringsmodel, Economisch en Social Tijdschrift, University of Antwerp, Faculty of Applied Economics, str. 367-393.
27. Pena, T., Serafin, M., Abudu, B. (2009): Bankruptcy Prediction: A Comparison of Some Statistical and Machine Learning Techniques, Banco de Mexico, str. 257-275.
28. Pervan, I. i Kuvek, T. (2013.): The relative importance of financial ratios and non financial variables in predicting of insolvency, Croatian Operational Research Review, Br. 13, Sv. 4, str. 187-197.
29. Pervan, I., Filipović D. (2010): FP rating – model za predviđanje (in) solventnosti poslovnih partnera, RRiF br.7, str. 94.
30. Pervan, I., Pervan, M., Vukoja, B. (2011): Prediction of company bankruptcy using statistical techniques – Case of Croatia, Croatian Operational Research Review (CRORR), Vol.2, str. 158-167.

31. Pervan, I., Pervan, M., Raković, G., (2018): Firm failure prediction: prediction accuracy improvements based on firm size groupings, 18th International Joint Conference: Central and Eastern Europe in the Changing Business Environment.
32. Polemis, D. and Gounopoulos, D. (2012): Prediction of Distress and Identification of Potential Mand As Targets in UK. Managerial Finance, Vol. 38, str. 1085-1104.
33. Raghupathi, W. et al. (1991): A Neural Network application for Bankruptcy Prediction", The University of Texas at Arlington.
34. Rodano, G., Serrano-Velarde, N., Tarantino, E. (2012): Bankruptcy Law and the Cost of Banking Finance, Oxford University Centre for Business Taxation
35. Sajter, D. (2009): Pregled određenih metoda i istraživanja poslovnih poteškoća uz predviđanje stečaja, Ekonomska misao i praksa, br. 2, str. 429-452.
36. Shumway, T. (2001): Forecasting Bankruptcy More Accurately: A Simple Hazard Model, Journal of Business
37. Šarlija, N., Penavin, S., Harc, M. (2009): Pregledni rad: Predviđanje nelikvidnosti poduzeća u Hrvatskoj, Zbornik Ekonomskog fakulteta u Zagrebu, br.2, str. 21-36.
38. Uttamchandani, M., Menezes, A. (2010): The Freedom to Fail: Why Small Business Insolvencies are Critical for Emerging Market, International Corporate Rescue
39. Van Praag, M., Versloot, H.P. (2008): The Economic Benefits and Costs of Entrepreneurship: A Review of the Research, Foundations and Trends in Entrepreurship, Vol.4, No.2, str. 65-154.
40. Yazdanfar, D., Nilsson, M. (2008): The bankruptcy determinants of Swedish SMEs, Institute for Small Business & Entrepreneurship
41. Yildiz, B., Akkoc, S. (2010): Bankruptcy Prediction Using Neuro Fuzzy: An Application in Turkish Banks, NYSEA Proceedings
42. Zenzerović R., Peruško T. (2009): Business financial problems prediction - Croatian experience, Economic Research-Ekonomska Istraživanja, Vol. 22, Issue 4. str. 1-15.
43. Zenzerović R., Peruško, T. (2006): Kratki osvrt na modele za predviđanje stečaja, Ekonomska istraživanja, str. 132 - 151.
44. Zmijewski, M.E. (1984): Methodological Issues Related to the Estimation of Financial Distress Prediction Models, Journal of Accounting Research, str. 59-82.

POPIS TABLICA

Tablica 1. Interni uzroci stečajeva u Republici Hrvatskoj 11
Tablica 2. Popis testiranih varijabli 15
Tablica 3. Točnost predviđanja Altmanovog Z-scorea 16
Tablica 4. Referentni intervali Altmanovog Z – scorea 17
Tablica 5. Referentni intervali Altmanovog Z'scorea 18
Tablica 6. Referentni intervali Altmanovog Z'' modela 18
Tablica 7. Financijski pokazatelji s pripadajućim ponderima po godinama prije pokretanja stečajnog postupka 19
Tablica 8. Komparativni prikaz varijabli korištenih u Beaverovom i Altmanovom istraživanju 22
Tablica 9. Referentne vrijednosti P (O-scorea) 23
Tablica 10.Prikaz vrijednosti pokazatelja i stupanj financijske stabilnosti 26
Tablica11. Opis financijskih pokazatelja korištenih u modelu 28
Tablica 12. Prikaz varijabli u Pervan Kuvek modelu 30
Tablica 13. Značajni prediktori nelikvidnosti u Hrvatskoj prema modelu Šarlija et al. 34
Tablica 14. Rezultati analize korelacije nezavisnih varijabli 41
Tablica 15. Analiza faktora inflacije varijanace 43
Tablica 16. Usporedba aritmetičkih sredina nezavisnih varijabli 43
Tablica 17. T-test razlike aritmetičkih sredina nezavisnih varijabli 44
Tablica 18. Deskriptivna statistika 45
Tablica 19. Varijable u finalnom modelu 45
Tablica 20. Sažetak modela 46
Tablica 21. Hosmer i Lemeshow test 47
Tablica 22. Točnost predviđanja modela 47

POPIS GRAFIKONA

Grafikon1. Broj poduzeća po veličini……..40

SAŽETAK

Modeli za predviđanje stečaja česta su tema istraživanja i znanstvenih radova u svijetu i u Hrvatskoj. Njihova uspješnost je od velikog značaja za praksu posebno u trenucima financijske krize i dinamičnog tržišnog okruženja. Modeli za predviđanje stečaja razlikuju se po mnogim karakteristikama kao što su broj varijabli, vrsta varijabli, itd. Najvažnija karakteristika modela jest točnost kojom model klasificira poduzeća koja su u stečaju i ona koja su uspješna.

U ovom radu, cilj je bio putem logističke regresije predvidjeti mogućnost stečaja i to korištenjem računovodstvenih podataka za 2014. i 2015. godinu. Podaci su preuzeti iz baze podataka „Amadeus“. Uzorak se sastojao od 300 poduzeća. Primjena logističke regresije rezultirala je modelom koji je sa 82,2% sveukupne točnosti predviđao poslovni neuspjeh poduzeća.

Ključne riječi: stečaj, predviđanje, Hrvatska

SUMMARY

Models for predicting bankruptcy have significant role in research and scientific papers over the world. Their correctness has huge importance for practice especially in time of financial crisis and turbulent dynamic environment. Models for bankruptcy prediction differ in many ways, such as number of variables, category variables, etc. The most important feature of the model is accuracy by which the model classifies the companies that are in bankruptcy and the ones that are successful.

In this paper, the main purpose of logistic regression was to predict the possibility of company’s bankruptcy by using accounting data for 2014 and 2015. The data was downloaded from the „Amadeus“ data base. The sample accounted 300 companies.

The application of a logistic regression resulted with the model whose correctness for predicting a business failure was define at 82,2%.

Key words: Bankruptcy, Prediction, Croatia