

Branko Novak*
Ivica Crnković**

UDK 336.712 (497.5)
JEL Classification E51, G30
Izvorni znanstveni rad

KLASIFIKACIJA DUŽNIKA BANKE PREMA RAZINI POSLOVNIH PROBLEMA NA OSNOVI PODATAKA IZ OSNOVNIH FINACIJSKIH IZVJEŠĆA

Rad predstavlja rezultate istraživanja klasifikacije poslovnih problema trgovačkih društava dužnika banke. Istraživanje je provedeno na polaznom uzorku veličine 168 jedinica – dužnika banke, a korišteno je 15 omjera dobijenih iz osnovnih financijskih izvješća. U radu su primijenjeni višestruka diskriminacijska analiza, logit model i metoda višedimenzionalnih skala za razvrstavanje trgovačkih društava prema urednosti izmirenja obveza prema banci. Budući da diskriminacijskom analizom i logit modelom nije bilo moguće uspješno razlikovati dobra i srednja društva, polazni je uzorak sužen na 141 jedinicu, pa su ga činila trgovačka društva grupirana na dobra i loša. Svi kreirani modeli pokazali su visok stupanj pouzdanosti predviđanja poslovnih problema društava u poslovnim odnosima s bankom, što je potvrđeno i na kontrolnom uzorku. Istraživanje je također pokazalo da se i metodom višedimenzionalnih skala može uspješno koristiti pri grupiranju društava prema razini poslovnih problema uz korištenje odgovarajućih financijskih omjera.

Ključne riječi: poslovni problemi, dužnici banke, diskriminacijska analiza, logit model, metoda višedimenzionalnih skala.

* B. Novak, dr. sc., redoviti profesor na Ekonomskom fakultetu u Osijeku. E-mail: profesornovak@hotmail.com

** I. Crnković, mr. sc., Slavenska banka d.d., Osijek. E-mail: ivica.crnkovic@slbo.hr
Prvobitna verzija članka primljena je 19. 5. 2005., a definitivna 11. 1. 2007.

Uvodno razmatranje

Prva istraživanja predviđanja poslovnih problema tvrtki (Altman 1968.¹ i Altman, Haldeman i Narayanan 1977.²) koristila su se višestrukom linearnom diskriminacijskom analizom pri definiranju modela za tu svrhu, a nakon toga se u istraživanju poslovnih problema tvrtki uvodi logistička regresija - logit model (Ohlson 1980.³, Aziz, Emanuel i Lawson 1988.⁴). Brojni kasniji radovi drugih autora koristili su se sličnim pristupom. Rezultati tih prvih istraživanja, koji su se osnivali na računovodstvenim podacima, općenito su prihvaćeni kao korisni. Poslovni se problem u tim istraživanjima definira kao stečaj. Kasnija istraživanja (Postom i Harmon 1994.⁵) pokazala su da u tim modelima postoji tendencija da se neuspjeh precjenjuje, odnosno da se prognozira veći broj tvrtki koje će propasti, premda one u stvarnosti i ne propadnu. Budući da se pri korištenju višestruke diskriminacijske analize i logit modela mora neku jedinicu uzorka unaprijed klasificirati kao uspješnu ili neuspješnu, a u većini slučajeva kao neuspješne uzimaju se tvrtke koje su u stečaju, pa je prema tome ta činjenica poznata, u predviđanju mogućih stečajeva javlja se određeni stupanj pristranosti, pa se neke tvrtke klasificiraju kao neuspješne (svrstavaju ih u grupu tvrtki u stečaju) iako se to poslije ne mora ni dogoditi. Istraživanje (Zmijewski 1984.⁶) je pokazalo da i dizajn uzorka na kojem se zasniva model može rezultirati pristranom procjenom koeficijenata, pa zato dolazi do netočnih predviđanja. Naime, uzorci koji su korišteni u brojnim istraživanjima sadržali su jednaki broj tvrtki u stečaju i tvrtki bez poslovnih problema. Budući da su stečajevi rjeđi događaji, Zmijewski je pokazao da će, ako se ne sačini model na osnovi cijele populacije, dobijena predviđanja precjenjivati proporciju tvrtki u stečaju. Rješenje je toga problema koristiti se uzorkom koji je što bliži cijeloj populaciji.

Poslovne je probleme moguće shvaćati i definirati na različite načine. U literaturi se prema Altmanu⁷ obično susreću četiri pojma: neuspješnost, insolvent-

¹ Altman, E.: "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy", *Journal of Finance* 4, 589-609, 1968.

² Altman, E., R. Haldeman and P.Narayanan: "Zeta Analysis – a New Model to Identify Bankruptcy Risk of Corporations", *Journal of Banking and Finance* 1, 29-54, 1977.

³ Ohlson, J.: "Financial Ratios and the Probabilistic Prediction of Bankruptcy", *Journal of Accounting Research* 18, 109-131, 1980.

⁴ Aziz, A., D. Emanuel and G. Lawson: "Bankruptcy Prediction – an Investigation of Cash Flow Based Model", *Journal of Management Studies* 25, 419-437, 1988.

⁵ Postom, Kay M. and Harmon, W. Ken: "A Test of Financial Ratios as Predictors of Turnaround Versus Failure Among Financially Distressed Firms", *Journal of Applied Business Research*, Winter 94, Vol. 10 Issue 1, p41, 16p.

⁶ Zmijewski, M.E., "Methodological Issues Related to the Estimation of Financial Distress Prediction Models". *Journal of Accounting Research* 22 (Supplement): 59-82, 1984.

⁷ Altman I. Edward: *Corporate Financial Distress and Bankruptcy –A Complete Guide to Predicting & Avoiding Distress and Profiting from Bankruptcy*, second edition. New York, John Wiley & Sons, Inc., 1993.

nost, ogluha i stečaj trgovačkog društva. Premda se tim pojmovima ponekad koriste u istome smislu, oni su ipak bitno različiti u formalnoj upotrebi. Neuspješnost, prema ekonomskim kriterijima, znači da je ostvarena stopa prinosa na investirani kapital, s rezerviranjima za rizike, značajno i trajno niža od prevladavajuće stope prinosa na slične investicije. Te ekonomske situacije ne daju podatak o postojanju opasnosti od diskontinuiteta određenoga subjekta. Insolventnost je pojam koji oslikava poslovanje tvrtke i općenito se njime koriste više u tehničkom smislu. Tehnička insolventnost postoji kada tvrtka ne može pomiriti svoje tekuće obveze, što pokazuje nedostatak likvidnosti. Pritom se kod opisa tehničke insolventnosti kao primarnim kriterijem koristi neto novčanim tijekom u odnosu na tekuće obveze. Insolventnost u smislu stečaja opisuje kroničnu, a ne privremenu situaciju. Tvrtka se nalazi u takvoj situaciji kada njezine ukupne obveze prelaze fer vrijednost njezine ukupne imovine. Zato je realna neto vrijednost tvrtke negativna. Slijedeći pojam koji je vezan uz tvrtku u poteškoćama jest ogluha. Ogluha može biti tehnička i/ili pravna i uvijek uključuje vezu između tvrtke dužnika i neke grupe vjerovnika. Tehnička se ogluha događa kada dužnik narušava uvjete sporazuma s vjerovnikom, što može biti osnova za pravnu akciju. Na primjer, narušavanja ugovorne odredbe o visini tekućega omjera ili razine zaduženosti osnova je za tehničku ogluhu. Kada tvrtka propusti pravovremeno plaćanje obveza, obično plaćanje kamata, tada je u pitanju formalna ogluha. Konačno, pojam tvrtke u poteškoćama vezan je uz stečaj. Jedan tip stečaja obilježen je negativnom neto vrijednošću tvrtke. Drugi je formalno objavljivanje stečaja u odgovarajućem sudu, uz mogućnost da se pristupi likvidaciji ili da se pokuša ostvariti program reorganizacije tvrtke.

U ovome radu provedeno je istraživanje korisnosti financijskih pokazatelja koji se zasnivaju na osnovnim financijskim izvješćima dužnika banke za procjenu poslovnih problema tih dužnika. Ti se problemi s pozicije banke ogledaju u sposobnosti, ili u nesposobnosti dužnika da obveze prema banci podmiruju po dospijeću. Kod nekih dužnika to može biti samo tehnička insolventnost, a kod drugih se može raditi o ogluhi i o insolventnosti u smislu stečaja. Polazna je hipoteza istraživanja da u dostupnim financijskim iskazima o poslovanju dužnika banke postoji informacijski sadržaj koji omogućuje razlikovati dužnike koji nemaju od onih koje imaju određene poslovne probleme. Priroda tih problema nije bila predmetom ovoga istraživanja. Ako bi primijenjenom metodologijom na osnovi reprezentativnog uzorka bili dobijeni modeli koji mogu pravilno svrstati značajnu proporciju dužnika u pripadajuće grupe, tada bi takvi modeli imali i određenu prognostičku snagu. Dobijeni bi modeli svoju prognostičku sposobnost morali dokazati i na kontrolnom uzorku dužnika banke koji nisu uzeti u analizu pri definiranju modela. Takvi bi modeli mogli biti polazna osnova za dalju izradu internih modela za ocjenu kreditnog rizika klijenata banke.

Metodologija istraživanja

U provedenom su istraživanju primijenjeni višestruka diskriminacijska analiza i logit model za određivanje financijskih omjera dobijenih iz financijskih izvješća komitenata banke, a koji najbolje mogu klasificirati dužnike prema njihovom bonitetu. Obadvije metode podrazumijevaju prethodno svrstavanje nekih objekata u dvije ili u više grupa. Višestrukom diskriminacijskom analizom koristi se kako bi se utvrdilo koje varijable najbolje diskriminiraju neke pojave koje pripadaju dvjema grupama ili većem broju grupa.

Pretpostavke modela višestruke diskriminacijske analize jesu:

- Podaci za varijable predstavljaju uzorak iz višestruke normalne distribucije. Ako ova pretpostavka nije zadovoljena to ipak ne mora obezvrjediti rezultate istraživanja, odnosno rezultirajući testovi signifikantnosti ipak mogu biti pouzdani.
- Matrice varijanci/kovarijanci varijabli homogene su za grupe. Ako su odstupanja od ove pretpostavke manjeg opsega ona ne moraju značajno utjecati na dobijene rezultate.
- Ne postoji korelacija između srednjih vrijednosti i varijanci za grupe. To se obično događa kada postoje ekstremne vrijednosti koje značajno odstupaju od srednje vrijednosti, a istovremeno povećavaju varijancu.
- Varijable kojima se koristi za diskriminaciju nisu potpuno redundantne.

Funkcija diskriminacije predstavljena je slijedećim izrazom:

Grupa = $a + b_1 * x_1 + b_2 * x_2 + \dots + b_m * x_m$, gdje su

a - konstanta

b₁, b₂, ..., b_m - koeficijenti diskriminacije

x₁, x₂, ..., x_m - varijable diskriminacije.

Broj funkcija diskriminacije manji je za jedan od broja grupa. Na osnovi diskriminacijske analize dobivaju se i funkcije klasifikacije kojih ima onoliko koliko i grupa u koje se vrši klasifikacija. Njih se ne smije brkati s funkcijama diskriminacije, a služe za razvrstavanje svakoga objekta klasifikacije u odgovarajuću grupu. Svaka funkcija klasifikacije omogućuje izračun klasifikacijskih vrijednosti svakoga objekta klasifikacije za svaku grupu, prema izrazu:

$S_i = c_i + w_{i1} * x_1 + w_{i2} * x_2 + \dots + w_{im} * x_m$, gdje su

S_i - vrijednost klasifikacije

c_i - konstanta

w_{ij} - vrijednosti pondera za j-tu varijablu u izračunu vrijednosti klasifikacije za i-tu grupu

x_j - vrijednost j-te varijable promatranog objekta.

Izračunom S_1, S_2, \dots, S_i za i grupa za pojedini slučaj svaki se slučaj klasificira u onu grupu za koju je klasifikacijska vrijednost najveća.

Logit model je praktičan za klasifikacije kada je zavisna varijabla po svojoj prirodi binarnog karaktera, odnosno postoje samo dvije moguće vrijednosti – tvrtka nema poslovnih problema (0) ili ih ima (1). U logit modelu prognozirane vrijednosti zavisne varijable nikada neće biti manje ili jednake 0, ili veće ili jednake od 1, bez obzira kakva je vrijednost nezavisnih varijabli. To se postiže korištenjem slijedećeg izraza:

$$y = e^{(b_0 + b_1 * x_1 + \dots + b_n * x_n)} / \{1 + e^{(b_0 + b_1 * x_1 + \dots + b_n * x_n)}\}$$

Lako je uočiti da bez obzira na vrijednosti regresijskih koeficijenata ili vrijednost x ovaj model uvijek daje prognozirane vrijednosti u rasponu 0 do 1, pa se te vrijednosti mogu smatrati vjerojatnostima. Logit analiza dijeli istu matematičku osnovu s diskriminacijskom analizom, ali ima nešto niže zahtjeve na podatke jer ne zahtijeva višestruku normalnu distribuciju, no logit analiza također je osjetljiva na promatranja koja imaju veliko odstupanje.

Metoda višedimenzionalnih skala (MDS) korištena je, zajedno s iskustvenom klasifikacijom, za osnovno grupiranje trgovačkih društava prema stupnju poslovnih problema u odnosu s bankom. MDS metodom rijetko se koristi u ovakvim istraživanjima,⁸ pa se ovim radom ponovo nastojalo verificirati njezino značenje i korisnost. MDS u analizi poslovnih problema tvrtki zaobilazi neke u uvodu navedene nedostatke diskriminacijske analize i logit modela, a obuhvaća niz tehnika zasnovanih na grafičkom prikazivanju. Konačan rezultat MDS analize jest statistička karta. Kod karata općenito vrijedi da ako je udaljenost između dviju točaka na karti mala, one se na karti nalaze blizu jedna drugoj, a ako je udaljenost velika one su na karti razdvojene. Na taj način vizualni pregled karte omogućuje da se odrede udaljenosti, odnosno različitosti. MDS ide u suprotnome smjeru. Ona stvara kartu iz tablice udaljenosti. Kada je udaljenost bilo koje dvije točke mala, MDS ih smješta blizu na karti, kada je udaljenost između nekog para točaka velika, one se na karti jako razdvajaju. Na taj način vizualan pregled karte može dati uvid u informacije koje su sadržane u matrici udaljenosti. MDS također stvara skale kao dio procesa lociranja točaka u prostoru. Prednost MDS je to što karte mogu biti konstruirane iz informacija o bliskosti ili udaljenosti između bilo kojih dviju točaka. Ova je tehnika robusna za brojne različite vrste podataka. Posebno zanimljiva karakteristika MDS karti jest robusnost na veoma udaljena promatranja. Ako

⁸ O tome vidjeti u Novak, B.: "Predviđanje poslovnih teškoća banaka u Republici Hrvatskoj na osnovi javno dostupnih financijskih pokazatelja", Ekonomski pregled 11-12, Zagreb 2003., str. 904-924.

je udaljenost između neke točke i ostalih točaka veoma velika, ta će točka samo biti smještena daleko od ostalih. Približne veze između ostalih točaka time uopće neće biti uvjetovane. MDS nije egzaktan postupak, već je to način "preuređenja" nekih objekata na efikasan način da bi se odredila konfiguracija koja najbolje aproksimira promatrane udaljenosti. Ova metoda zapravo pomiče neke objekte u prostoru koji je definiran zadanim brojem dimenzija i provjerava koliko je dobro udaljenost između objekata reproducirana novom konfiguracijom. Pritom se koristi algoritmom minimizacije funkcije koji vrednuje različite konfiguracije sa ciljem da se maksimizira podudarnost, odnosno minimizira nepodudarnost.

Postoji više načina na koje se mogu kreirati mjere različitosti ili sličnosti između objekata analize. Za podatke se ne postavljaju posebni zahtjevi, osim što u njima mora biti sadržana neka poruka. To se može smatrati prednošću kod financijskih pokazatelja, naravno, ako je u njima sadržana kakva poruka. Ovim istraživanjem testirana je i hipoteza da u financijskim izvješćima dužnika banke, dakle, u javno dostupnim informacijama, postoji poruka koja omogućuje da se dužnici svrstaju u dvije osnovne grupe – s poslovnim problemima i bez poslovnih problema. Ako je hipoteza točna, MDS analiza dat će karte na kojima su dvije grupe dužnika jasno razdvojene.

Informacijska osnova istraživanja

Polazni uzorak na kojem je provedeno istraživanje sastoji se od 168 trgovačkih društava, dužnika banke⁹. Podaci u uzorku potječu iz dvaju osnovnih financijskih izvješća (bilanca, račun dobiti i gubitka), a odnose se na godinu 2002., odnosno na stanja na dan 31.12.2002. Tablica 1. daje prikaz uzorka s obzirom na djelatnost kojom se trgovačka društva bave.

⁹ Slavonska banka d.d. Osijek

Tablica 1.

STRUKTURA UZORKA PREMA DJELATNOSTI
TRGOVAČKIH DRUŠTAVA

	Broj društava	u %
Građevinarstvo	28	16,67%
Trgovina	53	31,55%
Uslužne djelatnosti	13	7,74%
Proizvodnja	44	26,19%
Poljoprivreda, lov i šumarstvo	19	11,31%
Transportne djelatnosti	8	4,76%
Vađenje ruda i kamena	3	1,79%
UKUPNO	168	100,00%

Dakle vidi se da društva pripadaju različitim djelatnostima, a činjenica je da različite djelatnosti imaju svoje specifičnosti koje se odražavaju u financijskim pokazateljima. No statistička analiza koja bi obuhvatila društva samo jedne djelatnosti, što bi svakako bilo poželjno, bila bi zasnovana na malim uzorcima sa svim statističkim problemima koji iz toga proizlaze. Zato je istraživanje obavljeno korištenjem većeg uzorka iz različitih djelatnosti, pa se pri tumačenju konačnih rezultata istraživanja to mora imati na umu.

Tablica 2. daje pregled trgovačkih društava u uzorku prema iskustvu banke u poslovanju s njima. Broj jedinica uzorka svake skupine određen je prema stanju u portfelju banke na dan 31.12.2002. godine. Time je u kreiranju uzorka poštovana preporuka Zmijewskog da se model kreira na osnovi strukture cijele populacije. U grupu «dobra» svrstana su ona društva s kojima banka nikada nije imala problema u poslovanju, «srednja» su društva ona s kojima je banka imala manje probleme u poslovanju, kao što su, npr., nepodmirene obveze, pa je za neka formirala manje iznose rezervacija, a «loša» su društva ona s kojima je banka imala probleme u naplati potraživanja, pa je za njih morala formirati rezervacije.

Tablica 2.

**STRUKTURA UZORKA PREMA ISKUSTVU U POSLOVANJU
S DRUŠTVIMA U UZORKU**

		u %
LOŠA DRUŠTVA	35	21%
SREDNJA DRUŠTVA	27	16%
DOBRA DRUŠTVA	106	63%
UKUPNO	168	100%

Prikaz uzorka na osnovi odnosa ukupne obveze / ukupna imovina (tablica 3., tablica 4.) pokazuje društva prema financijskom pokazatelju ukupne zaduženosti. Pokazateljima zaduženosti prikazuje se kako se financira imovina, odnosno u kojem se omjeru imovina financira iz vlastitih izvora, a u kojem se omjeru financira iz tuđih izvora. Smisao prikaza uz pomoć ovoga financijskoga pokazatelja jest pokazati visinu obveza u odnosu na ukupnu imovinu u iskustvenim skupinama u uzorku (tablica 3). Vrijednosti u tablici 4. računane su kao vrijednost ukupne aktive i ukupnih obveza jedinica u uzorku po skupinama.

Tablica 3.

**UKUPNE OBVEZE I UKUPNA IMOVNA DRUŠTAVA
U UZORKU (U 000 KN)**

Stvarne vrijednosti				
	Razina ukupnog uzorka	Dobra društva	Srednja društva	Loša društva
Ukupne obveze	6.591.513	2.650.086	1.312.111	2.629.316
Ukupna imovina	11.987.128	4.851.937	2.591.100	4.544.091

Tablica 4.

**ODNOS UKUPNE OBVEZE / UKUPNA IMOVINA DRUŠTAVA
U UZORKU (U%)**

	Razina ukupnog uzorka	Dobra društva	Srednja društva	Loša društva
Ukupne obveze	55%	55%	51%	58%
Ukupna imovina	100%	100%	100%	100%

Uz pomoć ovoga pokazatelja može se zamijetiti da postoje razlike, iako ne velike, između iskustvenih skupina, pa se time potvrđuje opći stav vezan uz taj pokazatelj prema kojem “loša” društva u uzorku uvijek imaju veće obveze, odnosno veću zaduženost u odnosu na ukupnu imovinu od “dobrih” društava.

Pregled odnosa kratkotrajna imovina / kratkoročne obveze jest prikaz uzorka prema financijskom pokazatelju opće likvidnosti. Pokazatelji likvidnosti pokazuju kako se financira kratkotrajna imovina, odnosno kojim se dijelom financira iz kratkoročnih izvora, a kojim djelom iz dugoročnih izvora. Generalno gledano kod “dobrih” društava dio kratkotrajne imovine financira se iz dugoročnih izvora, a to znači da je kratkotrajna imovina kod “dobrih” društava veća od kratkoročnih obveza. Tablica 5. prikazuje bilančne pozicije za društva iz uzorka, i to tako da je kratkotrajna imovina uvijek prikazana sa vrijednošću 100%, a kratkoročne su obveze prikazane u postotku u odnosu na kratkotrajnu imovinu.

Tablica 5.

ODNOS KRATKOTRAJNE IMOVINE / KRATKOROČNIH OBEVEZA
TVRTKI U UZORKU (U%)

	Razina ukupnog uzorka	Dobra društva	Srednja društva	Loša društva
Kratkotrajna imovina	100%	100%	100%	100%
Kratkoročne obveze	81%	67%	79%	109%

Rezultati istraživanja

U istraživanju se pošlo od polaznog uzorka, 168 društava u kojem su sva društva klasificirana u tri grupe. U analizi je korišteno 15 financijskih omjera koji su prikazani u tablici 6. sa pridruženim oznakama. U izračunu parametar višestruke diskriminacijske analize i logit medela korištena je računalna aplikacija Statistica 6.0¹⁰.

¹⁰ Računalni program Statistica 6.0 tvrtke Statsoft Inc.

Tablica 6.

POPIS FINANCIJSKIH OMJERA KORIŠTENIH U ISTRAŽIVANJU
S PRIPADAJUĆIM OZNAKAMA ZA SVAKI OMJER

FINANCIJSKI OMJER	OZNAKA
RADNI KAPITAL/ UKUPNA IMOVINA	X1
ZADRŽANA DOBIT /UKUPNA IMOVINA	X2
EBIT/UKUPNA IMOVINA	X3
KNJIGOVODSTVENA VRIJED. GLAVNICE/ UKUPNE OBVEZE	X4
PRIHOD OD PRODAJE/ UKUPNA IMOVINA	X5
KRATKOTRAJNA IMOVINA/KRATKOROČNE OBVEZE	X6
(NOVAC + POTRAŽIVANJA)/KRATKOROČNE OBVEZE	X7
NOVAC/KRATKOROČNE OBVEZE	X8
DUGOTRAJNA IMOVINA/(KAPITAL + DUGOROČNE OBVEZE)	X9
KAPITAL/UKUPNA IMOVINA	X10
UKUPNI PRIHODI/UKUPNI RASHODI	X11
PRIHODI OSNOVNE DJELATNOSTI/RASHODI OSNOVNE DJELATNOSTI	X12
NETO DOBIT/VLASTITI KAPITAL	X13
(NETO DOBIT + RASHODI OD KAMATA)/UKUPNA IMOVINA	X14
UKUPNE OBVEZE/ UKUPNI PRIHODI	X15

Primjenom višestruke diskriminacijske analize i logit modela na ovakav uzorak dobijene su procjene koje nisu mogle sustavno razlikovati “dobra” od “srednjih” društava. “Srednja” društva uvijek su klasificirana kao “dobra”, ali su dobijeni modeli sustavno razlikovali “dobra” i “loša” društva. Postavlja se pitanje zašto se to događa? Razloge možemo potražiti u činjenici da banke ne klasificiraju društva u grupu “srednjih” po bonitetu samo na osnovi kašnjenja u plaćanju, već također i na osnovi kvalitete primljenih osiguranja za kredit, a postoje i mogućnosti da banke kalkuliraju s formiranim rezervacijama, jer one izravno utječu na prikazanu dobit banke. Moguće je da su neka društva u grupi “srednjih”, iako ne moraju biti tamo, a moguća je i obrnuta situacija. To što banka neko društvo označuje kao “srednje” ne znači bezuvjetno da ono ima probleme u svome poslovanju (što bi se odrazilo na financijska izvješća poduzeća). Uglavnom se može zaključiti da metode primijenjene u ovome radu, koje se kao ulaznim podacima koriste financijskim pokazateljima, ne daju grupiranje koje izdvaja “srednja” društva od “dobrih”, ali je bitno da uspješno razdvajaju “srednja” od “loših”, pa ako uzmemo u obzir da banke moraju prepoznati “loša” društva ova je činjenica značajna. Dakle problematiku “srednjih” društava možemo svesti na problem odvajanja “srednjih” od “dobrih” društava.

Zato je početni uzorak sužen na društva klasificirana kao dobra i loša, a dalja je analiza i procjena parametara modela napravljena na ovome uzorku. Tako kreiran osnovni uzorak ima 141 poduzeće. Struktura tako kreiranoga uzorka prikazana je u tablici 7.

Tablica 7.

STRUKTURA UZORKA OD 141 DRUŠTVA

	Broj društava	u %
LOŠA DRUŠTVA	35	25%
DOBRA DRUŠTVA	106	75%
UKUPNO	141	100%

Osnovne karakteristike uzorka kao najvažnijih pozicija financijskih izvješća prikazane su u tablici 8.

Tablica 8.

OSNOVNI POKAZATELJI UZORKA OD 141 DRUŠTVA U 000 KN

	Dobra društva	% u odnosu na imovinu	Loša društva	% u odnosu na imovinu
Ukupne obveze	2.650.086	55	2.629.316	58
Ukupna imovina	4.851.937	100	4.544.091	100
Ukupni prihodi	6.093.028	126	1.923.375	42

U daljem istraživanju primijenjene su dvije metode klasifikacije uzorka dužnika banke, i to iskustvena i klasifikacija na osnovu metode višedimenzionalnih skala i korišteni su uzorci veličine 141 i 90 društava. Uzorkom veličine 90 društava moralo se koristiti zato što MDS metoda u računalnoj aplikaciji Statistica 6.0 ne omogućuje uzorak veći od 90 jedinica, a svi su izračuni (višestruka diskriminacijska analiza i logit model) dobijeni korištenjem upravo te računalne aplikacije.

Višestruka diskriminacijska analiza uzorka od 141 društva

Osnovna pretpostavka primjene metode višestruke diskriminacijske analize na financijske omjere jest da će ova metoda izabrati omjere koji na najbolji način diskriminiraju društva koja pripadaju dvjema grupama u koje su podijeljena iskustvenim grupiranjem. Višestrukom diskriminacijskom analizom uz korištenje backward stepwise metode iz modela je eliminirano 12 omjera kao nesignifikantnih, odnosno izbačene su one varijable koje značajno ne pridonose diskriminacijskoj snazi modela, a kreirani model koji najbolje diskriminira skupine unutar uzorka zasnovan je na 3 financijska pokazatelja navedena u tablici 9. Rezultati su dobiveni uz korištenje vrijednosti $F=5$ za uključivanje i $F=4$ za isključivanje varijable.

Tablica 9.

VARIJABLE MODELA SA 141 DRUŠTVOM

Sveukupni Wilks' Lambda: ,50574 approx. F (3,137)=44,629 p<0,0000						
	Wilks' Lambda	Parcijalni Lambda	F-za izlaz (1,137)	p-razina	Tolerancija (1-R)²	1-toler. (R²)
X1	0,564786	0,895461	15,99389	0,000103	0,976498	0,023502
X2	0,596164	0,848331	24,49365	0,000002	0,970183	0,029817
X13	0,654046	0,773255	40,17320	0,000000	0,993144	0,006856

Uočljivo je da su najbolji diskriminatori u modelu pokazatelji likvidnosti (X1) i profitabilnosti (X2 i X13). Također je važno naglasiti da su pokazatelji X1 i X2 sastavni dio Altmanovog "Z" modela. Najveću diskriminacijsku snagu (na osnovi Wilks lambda koeficijentata) u modelu ima varijabla X13, a najslabiju diskriminacijsku snagu ima varijabla X1. Modelom dobijene funkcije klasifikacije prikazane su u tablici 10.

Tablica 10.

FUNKCIJE KLASIFIKACIJE MODELA SA 141 DRUŠTVOM

	D*	L*
	P=,75177	p=,24823
X1	2,848976	-1,88966
X2	3,954169	-6,28356
X13	2,637404	-2,42412
Konstanta	-0,938641	-2,06031

* "D" – dobra društva; "L" – loša društva

Primjena navedenih klasifikacijskih funkcija na podatke iz uzorka daje klasifikaciju prikazanu u tablici 11. Klasifikacija svakoga društva obavlja se tako da se u gornje funkcije uvrste vrijednosti varijabli, a društvo se svrstava u onu grupu funkcija koje daje veći broj.

Tablica 11.

MATRICA KLASIFIKACIJE MODELOM SA 141 DRUŠTVOM

	% dobro klasificiranih	D p=,75177	L p=,24823
D	100,00	106	0
L	57,14	15	20
Ukupno	89,36	121	20

Primjena funkcija klasifikacije na podatke iz uzorka rezultira sa 89,36% društava klasificiranih u skladu s očekivanom klasifikacijom, ili u apsolutnom broju 126 točno klasificiranih društava i 15 netočno klasificiranih društava. Uočavamo da su sva društva koja su iskustvenom klasifikacijom ocijenjena kao “dobra” točno klasificirana, odnosno sva društva klasificirana različito od očekivane klasifikacije iz grupe su “loših” društava. U tablici 12 prikazane su vjerojatnosti po kojima su društva netočno klasificirana.

Pregledom vjerojatnosti iz tablice 12. vidi se da je samo 4 društva klasificirano u grupu “dobrih” društava s vjerojatnošću većom od 80%, a sa druge je strane 5 društava klasificirano u grupu “dobrih” društava s vjerojatnošću manjom od 60%. Kvalitativnom analizom društva koja su klasificirana na osnovi modela drugačije od bančine klasifikacije utvrđeno je da su najčešći razlozi različite klasifikacije sljedeći:

- društvo je u prošlosti poslovalo s dobiti i zadržavalo je tu dobit, a sada je u problemima, no pozicija zadržane dobiti još postoji i utječe na financijske pokazatelje i u konačnici na netočnu klasifikaciju kreiranim modelom;
- kod nekih se društava pojavljuje problem trenutne vrijednosti diskriminacijskih pokazatelja (npr. povišenih zaliha nakon sjetve ili reprograma obveza);
- kod nekih društava postoji osnovana sumnja da neke pozicije financijskih izvješća nisu korektne (zalihe, amortizacija, potraživanja);
- kod manjeg dijela društava razlozi netočne klasifikacije nisu prepoznatljivi.

Činjenica da je veći dio društava netočno klasificiran na osnovi nerealnih pozicija iz financijskih izvješća govori u prilog kvaliteti te klasifikacijske metode i upućuje na dalja istraživanja u sferi ulaznih podataka za njezinu primjenu.

Tablica 12.

VJEROJATNOSTI KLASIFIKACIJE U JEDNU OD GRUPA
MODELOM SA 141 DRUŠTVOM

Šifra društva ¹¹	Klasifikacija banke	D p=,75177	L p=,24823
12L	L	70%	30%
31L	L	67%	33%
33L	L	74%	26%
37L	L	75%	25%
38L	L	78%	22%
43L	L	88%	12%
44L	L	59%	41%
5L	L	60%	40%
72L	L	59%	41%
79L	L	82%	18%
83L	L	59%	41%
85L	L	56%	44%
86L	L	81%	19%
87L	L	84%	16%
90L	L	51%	49%

Višestruka diskriminacijska analiza uzorka od 90 društava

U istraživanju je korištena i metoda višedimenzionalnih skala (MDS) za polaznu klasifikaciju društava na “dobra” i “loša”. U prijašnjim se istraživanjima¹² taj pristup pokazao korisnim, pa je ovim istraživanjem ponovno testiran. Tako suženi uzorak zatim je analiziran metodom višestruke diskriminacijske analize na osnovi iskustvene klasifikacije, a zatim istom metodom na osnovi grupiranja dobijenog MDS metodom.

¹¹ Sva “dobra” društva šifrirana su brojem, a “loša” društva brojem i slovom L.

¹² Novak B. ibidem.

Struktura suženog uzorka prikazana je u tablici 13. Uzorak je kreiran tako da su proporcionalno smanjene podskupine “dobrih” i “loših” društva prvobitnog uzorka od 141 društva, i to na takav način da podskupine čine 64% skupina osnovnog uzorka od 141 društva. Društva koja su izbačena iz prvobitnog uzorka od 141 društva određena su slučajnim odabirom.

Tablica 13.

STRUKTURA UZORKA OD 90 DRUŠTAVA

	Broj društva	u %
LOŠA DRUŠTVA	22	25%
DOBRA DRUŠTVA	68	75%
UKUPNO	90	100%

U tablici 14. prikazane su osnovne karakteristike skupina u uzorku gledano kroz prizmu najvažnijih pozicija financijskih izvješća.

Tablica 14.

OSNOVNI POKAZATELJI UZORKA OD 90 DRUŠTAVA U 000 KN

	Dobra društva	% u odnosu na imovinu	Loša društva	% u odnosu na imovinu
Ukupne obveze	2.134.238	52	2.066.042	56
Ukupna imovina	4.109.085	100	3.672.823	100
Ukupni prihodi	5.308.354	129	1.340.128	36

Višestrukom diskriminacijskom analizom uz korištenje backward stepwise metode iz modela je eliminirano 12 omjera kao nesignifikantnih, a kreirani je model zasnovan na 3 financijska omjera navedena u tablici 15. Rezultati su dobijeni uz korištenje vrijednosti $F=5$ za uključivanje i $F=4$ za isključivanje varijable.

Tablica 15.

VARIJABLE MODELA NA OSNOVI UZORKA 90 DRUŠTAVA
I ISKUSTVENE KLASIFIKACIJE

Sveukupni Wilks' Lambda: ,40135 approx. F (3,86)=42,759 p< ,0000						
	Wilks' Lambda	Parcijalni Lambda	F-za izlaz (1,86)	p-razina	tolerancija (1-R)²	1-toler. (R²)
X1	0,480540	0,835209	16,96823	0,000087	0,977071	0,022929
X2	0,472626	0,849194	15,27246	0,000185	0,977753	0,022247
X13	0,519100	0,773168	25,23065	0,000003	0,992753	0,007247

Ponovno se kao najbolji diskriminatori pojavljuju sva tri pokazatelja, koji su i najbolji diskriminatori u modelu kreiranom na osnovi uzorka 141 poduzeće. To su pokazatelji likvidnosti (X1) i profitabilnosti (X2 i X13). Funkcije klasifikacije koje služe za posteriori razdvajanje društava u dvije skupine prikazane su u tablici 16.

Tablica 16.

FUNKCIJE KLASIFIKACIJE UZORKA SA 90 DRUŠTAVA
I ISKUSTVENE KLASIFIKACIJE

	D	L
	p=,75556	p=,24444
X1	3,18178	-3,20891
X2	4,08915	-6,93445
X13	3,21357	-3,06580
Konstanta	-1,15830	-2,53978

* "D" – dobra društva; "L" – loša društva

Primjena navedenih klasifikacijskih funkcija na podatke društva iz uzorka 90 društava klasificira društva s točnošću prikazanom u tablici 17.

Tablica 17.

MATRICA KLASIFIKACIJE MODELOM SA 90 DRUŠTAVA
 I ISKUSTVENOM KLASIFIKACIJOM

	% dobro klasificiranih	D p=,75556	L p=,24444
D	100,00	68	0
L	72,72	6	16
Ukupno	93,33	74	16

Primjena klasifikacijskih funkcija na podatke klasificira 93,33% društva u skladu s očekivanom klasifikacijom. Kao i kod modela kreiranoga na uzorku od 141 društva, sva su društva koja su iskustvenom klasifikacijom ocijenjena kao dobra točno klasificirana, a sva netočno klasificirana društva dolaze iz grupe loših društva. Tablica 18. predstavlja vjerojatnosti klasifikacije u jednu od skupina za netočno klasificirana društva.

Tablica 18.

VJEROJATNOSTI KLASIFIKACIJE U JEDNU OD SKUPINA
 NA UZORKU OD 90 DRUŠTAVA

	Klasifikacija	D	L
	banke	p = 0,76	p = 0,24
*12L	L	75%	25%
*44L	L	60%	40%
*85L	L	53%	47%
*5L	L	57%	43%
*72L	L	62%	38%
*79L	L	87%	13%

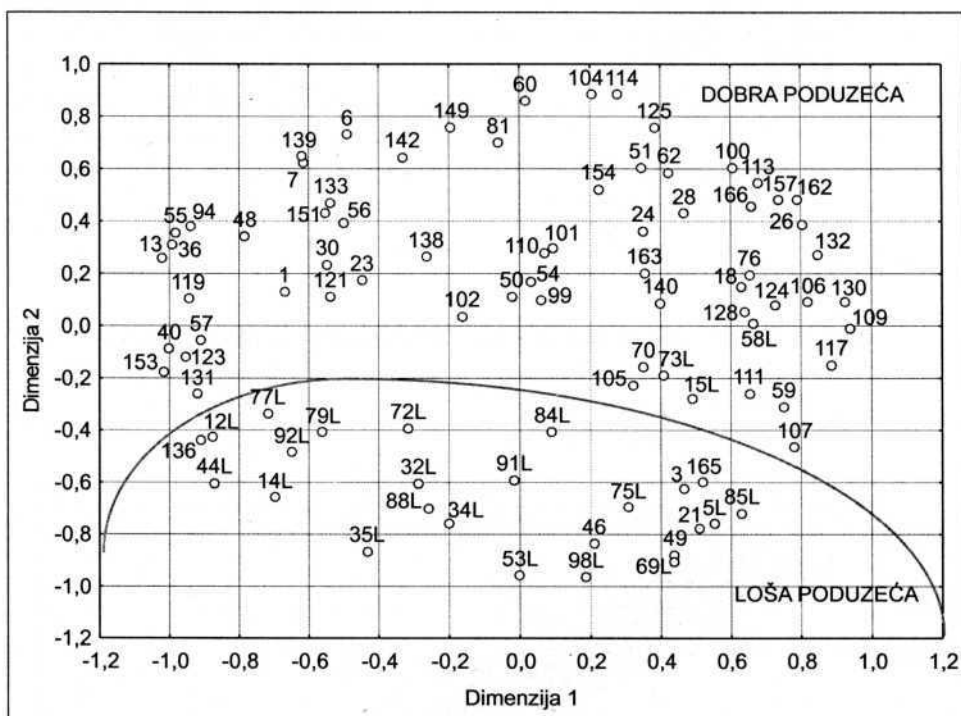
Društva navedena u prethodnoj tablici nisu isto tako točno klasificirana ni u modelu dobijenom na osnovi uzorka 141 društva.

Analiza uzorka od 90 društava metodom višedimenzionalnih skala (MDS)

Polazna je pretpostavka da MDS metoda primijenjena na financijskim pokazateljima uzorka 90 društava može uspješno grupirati društva u višedimenzionalnom prostoru, tako da će odvojiti “dobra” od “loših” društava. Takvo bi odvajanje pokazalo da metoda višedimenzionalnih skala ima sposobnost klasificiranja, ako korišteni financijski pokazatelji imaju potreban informacijski sadržaj koji omogućuje takvu klasifikaciju. Budući da je svaki od 15 omjera formiran od vrijednosti različitoga reda veličina, omjeri za pojedino društvo standardizirani su oduzimanjem srednje vrijednosti danog omjera za cijeli uzorak od vrijednosti omjera društva, a zatim dijeljenjem sa standardnom devijacijom danoga omjera za cijeli uzorak. Na taj se način postižu međusobno usporedive veličine koje predstavljaju udaljenosti danoga omjera od srednje vrijednosti omjera izražene u standardnim devijacijama. Taj je postupak ekvivalentan promjeni originalnih omjera koji opisuju neko društvo u niz višestrukih poredaka. Nakon standardizacije načinjena je matrica korelacija između društava (matrica 90x90), pri čemu su društva varijable, a standardizirani su omjeri vrijednosti varijable. Tako dobijena matrica predstavlja međusobne sličnosti društava u uzorku i osnova je za MDS analizu. Podaci su analizirani uz korištenje 5 dimenzija, ali se u nastavku daje samo dvodimenzionalna karta zbog činjenice da se tako prikazane karte lakše tumače. Pregledom dobijenih karata uočljivo je da dvodimenzionalna karta koja sadrži dimenzije 1 i 2 (slika 1.) daje grupiranje društva usporedivo s klasifikacijom koje je sačinila banka. Iz karte se jasno vidi grupiranje “loših” društva u donjem dijelu karte, a “dobrih” društva u gornjem dijelu karte. Karta pokazuje da su neka društva prvo-bitno klasificirana kao dobra na karti u grupi “loših” i obratno.

Slika 1.

DVODIMENZIONALNA KARTA UZORKA OD 90 DRUŠTVA
DOBIJENA MDS METODOM



Preciznost MDS metode mjeri se koeficijentom alijenacije (0,059154) i stress koeficijentom (0,0572864) i Shepardovim dijagramom. Shepardov dijagram prikazan na slici 2. pokazatelj je kvalitete reproduciranih udaljenosti. Taj dijagram prikazuje odnos između reproduciranih udaljenosti za pet dimenzija u odnosu na stvarne ulazne podatke. Tako dobijena klasifikacija društva osnova je nove višestruke diskriminacijske analize i logit analize, a struktura ovoga uzorka prikazana je u tablici 19., pri čemu je:

- šest društava koja su iskustvenom klasifikacijom označena kao dobra klasificirano u skupinu loših društva
- tri društva koja su iskustvenom klasifikacijom označena kao loša klasificirana su u skupinu dobrih društva


Tablica 19.

UZORAK NAKON MDS KLASIFIKACIJE

	Broj društva	u %
LOŠA DRUŠTVA	25	28%
DOBRA DRUŠTVA	65	72%
UKUPNO	90	100%

Slika 2.

SHEPARDOV DIJAGRAM ZA UZORAK OD 90 DRUŠTAVA



Višestruka diskriminacijska analiza uzorka od 90 društava nakon klasifikacije MDS metodom

Na uzorku od 90 društava uz drugačiju a priori klasifikaciju društava učinjena je ponovo višestruka diskriminacijska analiza. A priori klasifikacija društava u ovome modelu rezultat je podjele društava sukladno s rezultatima MDS analize uzorka od 90 društava. Analizom tako klasificiranog uzorka metodom višestruke diskriminacijske analize uz korištenje backward stepwise metode dobijen je model iz kojeg je eliminirano devet financijskih pokazatelja, a šest financijskih pokazatelja koji čine model navedeno je u tablici 20. Rezultati su dobijeni uz korištenje vrijednosti $F=5$ za uključivanje i $F=4$ za isključivanje varijable.

Tablica 20.

VARIJABLE MODELA NA OSNOVI UZORKA 90 DRUŠTAVA NAKON MDS KLASIFIKACIJE

Wilks' Lambda: ,40048 approx. F (6,83)=20,709 p< ,0000						
	Wilks' Lambda	Parcijalni Lambda	F-za izlaz (1,83)	p-razina	tolerancija (1-R) ²	1-toler. (R ²)
X1	0,457832	0,874724	11,88703	0,000890	0,414586	0,585414
X2	0,426822	0,938275	5,46022	0,021865	0,951414	0,048586
X9	0,420465	0,952461	4,14267	0,045006	0,743551	0,256449
X10	0,427693	0,936364	5,64072	0,019854	0,500948	0,499052
X12	0,422099	0,948773	4,48139	0,037260	0,913504	0,086496
X13	0,437218	0,915966	7,61469	0,007122	0,887634	0,112366

Wilks lambda za navedeni model iznosi 0,40, što predstavlja visoku diskriminacijsku snagu modela. Najveću diskriminacijsku snagu u modelu ima varijabla X1, a najslabiju diskriminacijsku snagu ima varijabla X9. Model čine pokazatelji likvidnosti (X1, X9), profitabilnosti (X13, X2), zaduženosti (X10) i ekonomičnosti (X12). Uočavamo da se i u ovome modelu ponavljaju financijski pokazatelji X1, X2 i X13 kao kvalitetni diskriminatori grupa unutar uzorka. U tablici 21. prikazane su funkcije klasifikacije dobijenoga modela.

Tablica 21.

FUNKCIJE KLASIFIKACIJE UZORKA 90 DRUŠTAVA
NAKON MDS KLASIFIKACIJE

	D	L
	p=,72222	p=,27778
X1	-0,8143	-9,0325
X2	1,1062	-5,3568
X9	0,0719	1,5555
X10	5,9236	10,0225
X12	39,8157	34,8896
X13	-1,8153	-5,4861
Konstanta	-22,6522	-21,2760

* "D" – dobra društva; "L" – loša društva

Primjena navedenih klasifikacijskih funkcija na financijske pokazatelje društva iz uzorka daje klasifikaciju prikazanu u tablici 22.

Tablica 22.

KLASIFIKACIJSKA MATRICA UZORKA 90 DRUŠTAVA
NAKON MDS KLASIFIKACIJE

	% dobro klasificiranih	D p=,72222	L p=,27778
D	100,00	65	0
L	88,00	3	22
Ukupno	96,66	68	22

Dakle, ovaj model daje točnost klasifikacije od 96,66%. U apsolutnom broju to znači 87 točnih klasifikacija i 3 netočne klasifikacije. Uočavamo da je primjena klasifikacije metodom višedimenzionalnih skala smanjila broj netočnih klasifikacija sa 6 na 3 netočno klasificirana društva, a to ukazuje na kvalitetu te metode u klasifikaciji tvrtki i upućuje na dalja istraživanja mogućnosti njezine primjene u ekonomskim istraživanjima.

Procjena parametara logit modela na osnovi uzorka od 141 društva

Polazimo od pretpostavke da će primjena logit modela na financijske pokazatelje klasificirati društva sukladno s iskustvenim grupiranjem. U analizi je korišteno svih 15 financijskih pokazatelja koji su korišteni i prilikom višestruke diskriminacijske analize. Kreiranjem logističkog modela uz korištenje backward stepwise metode iz modela je isključeno 12 financijskih omjera, a kao značajni izdvojeni su X1, X2 i X13 koji su se pokazali kao najkvalitetniji diskriminatori u modelu višestruke diskriminacijske analize. Rezultati su dobijeni uz korištenje vrijednosti $p_1=0,05$ za uključivanje i $p_2=0,05$ za isključivanje varijable, a parametri logit modela prikazani su u tablici 23.

Tablica 23.

PARAMETRI LOGIT MODELA NA OSNOVI UZORKA
OD 141 DRUŠTVA

	Parametri modela	Standardna greška	p -razina vjerojatnosti
Konstanta	0,53088	0,398269	0,182543
“X1”	8,15365	2,833632	0,004009
“X2”	29,69590	8,119000	0,000255
“X13”	19,28408	4,997109	0,000114

Procijenjena logistička funkcija je ovakva:

$$y = \frac{e^{(0,53088 + 8,15365 * X1 + 29,69590 * X2 + 19,28408 * X13)}}{1 + e^{(0,53088 + 8,15365 * X1 + 29,69590 * X2 + 19,28408 * X13)}}$$

Uvrštavanje vrijednosti financijskih pokazatelja društva iz uzorka rezultira klasifikacijom prikazanom u tablici 24.

Tablica 24.

KLASIFIKACIJA UZORKA OD 141 DRUŠTVA LOGIT MODELOM

	Klasificirano kao "D"	Klasificirano kao "L"	Točno klasificiranih u %
D	101	5	95,28%
L	5	30	85,71%

* "D" – dobra društva; "L" – loša društva

Dobijeni model daje visoku točnost klasifikacije koja iznosi 92,91%. Netočno je klasificirano pet društava iz skupine "dobrih" i 5 društava iz skupine "loših". Usporedba rezultata dobijenih višestrukom diskriminacijskom analizom s rezultatima dobijenim logit modelom daje značajne razlike u broju netočnih klasifikacija. Klasifikacija metodom višestruke diskriminacijske analize rezultirala je sa 15 netočno klasificiranih društva, pri čemu su sva netočno klasificirana društva bila iz skupine "loših" društva, a logit model dao je klasifikaciju od 10 netočno klasificiranih društva iz obje klasifikacijske grupe. Sva su društva iz grupe "loših" također netočno klasificirana modelom višestruke diskriminacijske analize, a za netočno klasificirana društva iz grupe "dobrih" značajno je da su (osim društva pod oznakom "103") modelom višestruke diskriminacijske analize klasificirana točno, ali uz vjerojatnost koja je na granici klasifikacije ili teži u grupu "loših" društva ("društvo 46" – 58%, "društvo 49" - 56%, "društvo 115" - 64% i "društvo 122" - 69,26%).

Procjena parametara logit modela na osnovi uzorka od 90 društava

Zbog statističkih problema s ulaznim podacima (problem konvergencije) u analizi je za ovaj uzorak korišteno samo prvih 10 financijskih pokazatelja (X1 – X10). Pri procjeni parametara modela korišteni su $p1=0,05$ za uključivanje varijable u model i $p2=0,05$ za isključivanje varijable, što je rezultiralo izbacivanjem sedam financijskih pokazatelja iz modela, a kao statistički značajni izabrani su financijski pokazatelji X1, X2 i X3. U nastavku su dani parametri kreiranog modela.

Tablica 25.

PARAMETRI LOGIT MODELA ZA 90 DRUŠTAVA

	Parametri modela	Standardna greška	p -razina vjerojatnosti
Konstanta	0,95103	0,433207	0,028140
“X1”	9,24549	2,796990	0,000948
“X2”	19,66569	7,776632	0,011445
“X3”	4,95066	2,238135	0,026969

Kreirana logistička funkcija je ovakva:

$$y = \frac{e^{(0,95103 + 9,24549 * X1 + 19,66569 * X2 + 4,95066 * X3)}}{1 + e^{(0,95103 + 9,24549 * X1 + 19,66569 * X2 + 4,95066 * X3)}}$$

Klasifikacija koja se dobije ovim modelom prikazana je u tablici 26.

Tablica 26.

KLASIFIKACIJA UZORKA OD 90 DRUŠTAVA LOGIT MODELOM

	Klasificirano kao “D”	Klasificirano kao “L”	Točno klasificiranih u %
D	64	4	94,11%
L	5	17	77,27%

* “D” – dobra društva; “L” – loša društva

Ovaj model daje izrazito visoku točnost klasifikacije pri čemu je netočno klasificirano devet društva, od čega su njih četiri iz grupe “dobrih” i pet iz grupe “loših” društava. Ukupna točnost klasifikacije iznosi 90,00%. Usporedba tih rezultata s rezultatima metode višestruke diskriminacijske analize ne pokazuje značajne razlike. Metodom višestruke diskriminacijske analize šest je društava klasificirano netočno, a logističkom metodom devet. Značajno je da su metodom višestruke diskriminacijske analize sva netočno klasificirana društva bila iz grupe “loših” društva, što nije slučaj kod logističkog modela.

Procjena parametara logit modela na osnovi uzorka od 90 društava nakon MDS klasifikacije

Ulazni su podaci za kreiranje logit modela, kao i u prethodnom poglavlju, prvih deset financijskih pokazatelja ($X_1 - X_{10}$). Korištenjem backward stepwise metode uz vrijednosti $p_1=0,05$ za uključivanje i $p_2=0,05$ za isključivanje varijable, iz modela je eliminirano sedam financijskih pokazatelja, a kao značajni izdvojeni su financijski pokazatelji X_1 , X_3 i X_{10} . Parametri tako kreiranoga modela prikazani su u tablici 27.

Tablica 27.

PARAMETRI LOGIT MODELA ZA UZORAK OD 90 DRUŠTAVA NAKON MDS KLASIFIKACIJE

	Parametri modela	Standardna greška	p -razina vjerojatnosti
Konstanta	4,3077	1,386071	0,001885
“X1”	28,0264	8,270839	0,000703
“X3”	12,5432	4,086453	0,002144
“X10”	-11,4212	3,858220	0,003074

Prema tome je dobijena logistička funkcija:

$$y = \frac{e^{(4,3077 + 28,0264 * X_1 + 12,5432 * X_3 - 11,4212 * X_{10})}}{1 + e^{(4,3077 + 28,0264 * X_1 + 12,5432 * X_3 - 11,4212 * X_{10})}}$$

Uvrštavanje financijskih pokazatelja društava iz uzorka u gornju funkciju rezultira klasifikacijom prikazanom u tablici 28.

Tablica 28.

MATRICA KLASIFIKACIJE UZORKA 90 DRUŠTAVA LOGIT
MODELOM NAKON MDS KLASIFIKACIJE

	Klasificirano kao "D"	Klasificirano kao "L"	Točno klasificiranih u %
D	62	3	95,38%
L	3	22	88,00%

*"D" – dobra društva; "L" – srednja društva

Ovaj model netočno klasificira tri društva iz grupe "dobrih" i tri društva iz grupe "loših" društava uz ukupnu razinu točnih klasifikacija od 93,33%. Dobijena klasifikacija ne pokazuje značajnije razlike u odnosu na metodu višestruke diskriminacijske analize. Metodom višestruke diskriminacijske analize netočno je klasificirano tri društva, a logit modelom šest je društava klasificirano netočno.

Testiranje dobijenih modela na kontrolnom uzorku

Za svrhu testiranja dobijenih modela kreiran je uzorak od deset društava, od kojih je prema klasifikaciji banke njih pet svrstano u grupu loših, a pet u grupu dobrih. Društva su izabrana u uzorak na osnovi istih kriterija kojima se koristilo pri kreiranju prvobitnog uzorka društva. Dakle, u grupu dobrih društava odabrana su ona s kojima banka nije imala problema u poslovanju, kao što je, npr., neredovito podmirivanje obveza, a u grupu loših društava odabrana su ona društva s kojima je banka u poslovanju imala značajnije probleme, npr. nepodmirivanje obveza i najvećim dijelom formiranje rezervacije za njih. Budući da ta društva nisu bila u uzorcima za procjenu modela, ona nisu vrijednostima svojih financijskih pokazatelja utjecala na kreiranje modela višestruke diskriminacijske analize i logit modela. Ta su društva klasificirana uz pomoć kreiranih modela uz pretpostavku da će kreirani modeli klasificirati društva sukladno s iskustvenom klasifikacijom. Modeli pokazuju visok stupanj točne klasifikacije:

- model dobijen diskriminacijskom analizom na osnovi uzorka 141 društva - 90%,
- model dobijen diskriminacijskom analizom na osnovi uzorka 90 društava - 90%,
- model dobijen diskriminacijskom analizom na osnovi uzorka 90 društava nakon MDS klasifikacije - 100%,

- logit model na osnovi uzorka 141 društva - 100%,
- logit model na osnovi uzorka 90 društava - 90%,
- logit model na osnovi uzorka 90 društava nakon MDS klasifikacije - 100%.

Zaključno razmatranje

Provedeno istraživanje potvrdilo je polaznu hipotezu da u financijskim iskazima o poslovanju dužnika banaka postoji određen informacijski sadržaj koji omogućuje da se na osnovi dobijenih modela s visokim stupnjem pouzdanosti razlikuju oni dužnici koji nemaju, od onih koje imaju određenih poslovnih problema. Pritom su modeli bili uspješni u razlikovanju dviju grupa dužnika – «dobrih» i «loših», ali nisu mogli sustavno razlučiti «dobre» od «srednjih». Budući da su u modelima korištene varijable (omjeri) dobijene iz osnovnih financijskih izvješća, valja naglasiti da, zbog karaktera izabranog uzorka (tvrtke iz različitih djelatnosti) i zbog statističkih problema koji se ogledaju u djelomičnom narušavanju pretpostavki korištenih modela, rezultate valja tumačiti i u tome svjetlu. Provedeno je istraživanje gotovo u svim modelima identificiralo omjere radnog kapitala i ukupne imovine, zadržane dobiti i ukupne imovine te EBIT i ukupne imovine kao varijable koje uspješno mogu poslužiti razvrstavanju dužnika banke u dvije skupine. Takav je rezultat korespondentan s Altmanovim «Z» modelom. Isto je tako pouzdanost dobivenih modela da korektno razdvoje “loša” od “dobrih” društava sa stajališta banke približno jednaka pouzdanosti koje je dobio Altman. To je zadovoljavajući rezultat, osobito ako se uzme u obzir činjenica da su u svim uzorcima društva koja su grupirana kao “loša”, zapravo, društva koja posluju, premda imaju problema u podmirivanju obveza prema banci, ali nisu u stečaju kao u Altmanovom modelu. U svim je modelima uočljiva veća vjerojatnost pogrešne klasifikacije društava s problemima u podmirivanju obveza prema banci (pogreška Tipa I Beaver (1966)¹³. Budući da je potencijalni trošak takve netočne klasifikacije veći od netočne klasifikacije skupine bez problema, skupini s problemima potrebno je u daljim istraživanjima posvetiti posebnu pažnju. Razlozi netočne klasifikacije na osnovi dobijenih modela većinom su u nerealnim pozicijama u računovodstvenim iskazima što je češći slučaj u društvima koja imaju poslovnih problema. Zato bi bilo potrebno u daljim istraživanjima u model uključiti i varijable koje nisu iz financijskih izvješća, a mogle bi pridonijeti poboljšanju kvalitete modela. Istraživanje je također verificiralo i korisnost metode višedimenzionalnih skala za grupiranje

¹³ Beaver, W.H.(1966). Financial Ratios as Predictors of Failure, Empirical Research in Accounting Selected Studies, 1966 Supplement to Journal of Accounting Research. pp. 71-111.

društava temeljem financijskih omjera. Da bi se takvo grupiranje moglo postići, potrebno je provesti odgovarajuću transformaciju omjera u niz višestrukih porredaka. Dobijene statističke karte pokazuju se kao koristan vizualni prikaz koji služi za svrhe grupiranja, jer se na njima one jedinice koje su slične po nekim obilježjima nalaze se na kartama blizu jedna drugoj. Testiranja dobijenih modela na kontrolnom uzorku pokazala su da dobijeni modeli imaju, uz uvažavanje navedenih ograničenja, i značajnu prognostičku vrijednost.

LITERATURA

1. Agresti, A.(1966.). *An Introduction to Categorical Data Analysis*, John Wiley and Sons, Inc.
2. Altman, E. (1968.). "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy", *Journal of Finance* 4, 589-609.
3. Altman, E., R. Haldeman and P.Narayanan. (1977.). "Zeta Analysis – a New Model to Identify Bankruptcy Risk of Corporations", *Journal of Banking and Finance* 1, 29-54.
4. Altman I. Edward (1993.). *Corporate Financial Distress and Bankruptcy – A Complete Guide to Predicting & Avoiding Distress and Profiting from Bankruptcy*, second edition. New York, John Wiley & Sons, Inc.
5. Aziz, A., D. Emanuel and G. Lawson. (1988. "Bankruptcy Prediction – an Investigation of Cash Flow Based Model", *Journal of Management Studies* 25, 419-437.
6. Baring, R., Agarwal, A. and Leach, R.(2002)"Predicting Bankruptcy Resolution". *Journal of Business Finance & Accounting*, 29 (3) & (4), 497-520.
7. Beaver, W.H.(1966.) "Financial Ratios as Predictors of Failure, Empirical Research in Accounting Selected Studies", *1966 Supplement to Journal of Accounting Research*. pp. 71-111.
8. Haggstrom, W.G. (1983.) "Logistic Regression and Discriminant Analysis by Ordinary Least Squares", *Journal of Business & Economic Statistics*, Vol. 1, No. 3, 229-238.
9. Mar-Molinero, C. and Serrano-Cinca C.(2001.). "Bank Failure: a Multidimensional Scaling Approach", *The European Journal of Finance* 7, 165-183.
10. Martikainen, T. (1993.). "Stock Returns and Classification Pattern of Firm-Specific Financial Variables: Empirical Evidence with Finish Data". *Journal of Business Finance and Accounting*, 20, 537-557.

11. Mossman, E.C., Bell, G.G., Swartz, L.M. and Turle, H. (1998.). "An Empirical Comparison of Bankruptcy Models". *The Financial Review*, 33, 35-54.
12. Novak, B. (2003.). "Predviđanje poslovnih teškoća banaka u Republici Hrvatskoj na osnovi javno dostupnih financijskih pokazatelja", *Ekonomski pregleđ* 11-12, Zagreb, str. 904-924.
13. O Gorman, W.T. and Woolson, F.R. (1991.). "Variable Selection to Discriminate Between Two Groups: Stepwise Logistic Regression or Stepwise Discriminant Analysis?", *The American Statistician*, Vol. 45, No. 3, 187-193.
14. Pacey, W.J. and Pham, M.T. (1990.). "The Predictiveness of Bankruptcy Models: Methodological Problems and Evidence". *Australian Journal of Management*, 15, 2, 315-337.
15. Platt, D.H. and Platt, B.M. (2002.). "Predicting Corporate Financial Distress: Reflections on Choice-Based Sample Bias". *Journal of Economics and Finance*, Vol. 26 No. 2, 184-199.
16. Ohlson, J. (1980.). "Financial Ratios and the Probabilistic Prediction of Bankruptcy", *Journal of Accounting Research* 18, 109-131.
17. Postom, Kay M. and Harmon, W. Ken. (1994.). "A Test of Financial Ratios as Predictors of Turnaround Versus Failure Among Financially Distressed Firms", *Journal of Applied Business Research*, Vol. 10 Issue 1, p41, 16p.
18. Zmijewski, M.E. (1984.). "Methodological Issues Related to the Estimation of Financial Distress Prediction Models." *Journal of Accounting Research* 22 (Supplement): 59-82.

CLASSIFICATION OF BANK DEBTOR DISTRESS BASED ON OFFICIAL FINANCIAL STATEMENTS

Summary

The paper presents research of models for classification of bank debtor distress based on ratios calculated from official financial statements. Basic sample consists of 168 company's debtors of middle size bank, and 15 financial ratios were used. In research multiple discriminate analyses, logit model and multidimensional scaling method was used for classifying companies based on orderliness in payment of their liabilities. Since discriminate analysis and logit model could not successfully discriminate "good" and "medium" companies, basic sample was appropriately limited to 141 companies classified as "good" or "dubious". All estimated models have high rate of reliability in prediction of orderliness in payment of liabilities that can express the degree of company's efficiency or distress. Reliability of all created models was confirmed on control sample as well. This research also demonstrated that multidimensional scaling methods can be successfully used for classifying of companies based on magnitude of their business problems using appropriate financial ratios.

Key words: business problems, bank debtors, multiple discriminate analysis, logit model, multidimensional scaling method.