

4. cjelina: Modeli kreditnog rizika bazirani na računovodstvenim podacima i tržišnoj vrijednosti

- 4.1. Nedostaci i problemi klasične kreditne analize
- 4.2. Potreba za modelima kreditnog rizika
- 4.3. Modeli bazirani na računovodstvenim podacima
- 4.4. Modeli bazirani na cijeni dionice
- 4.5. Reference

4.1. Nedostaci i problemi klasične kreditne analize

Klasična kreditna analiza se mijenja i razvija u skladu s fundamentalnim promjenama koje se događaju u bankarskom poslu. Kroz vrijeme se pokazalo da je klasična kreditna analiza zaista neophodna i dragocjena, ali i problematična te da ima mnoge ozbiljne nedostatke. Najvažniji među njima su:

1. Klasična kreditna analiza koju provodi stručnjak je dobra koliko je dobar stručnjak. Naime, različiti bankari odnosno kreditni analitičari analizirajući jedan te isti dokument mogu doći do različitih zaključaka.
2. Sistem temeljen na radu eksperata vrlo je skup za održavanje.
3. Banka cijelo vrijeme mora imati dovoljno eksperata za nastali volumen posla.
4. Banka mora neprestano ulagati u obrazovanje novih stručnjaka koji će provoditi klasičnu kreditnu analizu
5. Može se dogoditi da centralna banke ima paralelan skup pravila i zahtjeva, a koji su iznad onoga što je prihvaćeno i što funkcionira u podružnicama banke. Preklapanje i neefikasnost, koji su rezultat takvog načina rada, uzrokuju ozbiljne probleme.
6. Primjenjujući dugo ista pravila i procedure, banka se može uljuljkati u lažnu sigurnost.
7. Iako se puno stručnjaka kontinuirano obrazuje za obavljanje kreditne analize, banke često doživljavaju ozbiljne kreditne probleme. Naime, dok su neke finansijske institucije uspjele u kreiranju vrlo uspješnih stručnjaka, neke nisu dovoljno uložile u razvoj svojih ekspertiza jer su možda naišle na jače organizacijske potrebe. Ima i takvih slučajeva gdje su neke banke puno uložile u ljude koji su nakon nekog vremena otišli.
8. Mnoge banke su otkrile da je vrlo teško zadržati tržišni udio bez povećanja rizika. Klasična kreditna analiza ne omogućuje kvalitetno upravljanje kreditnim rizikom.
9. Klasična kreditna analiza je vrlo tijesno povezana s birokratskim načinom rada. Zbog hijerarhijske strukture banka je pogodno tlo za konvencionalan pristup. No, u današnjim tržišnim uvjetima nagrađuje se agilnost, sofisticiranost i fleksibilnost.

10. Razlika između klasične bankarske prakse i finansijske realnost se sve više povećava.

Što se tiče još jednog dodatnog problema kojeg uzrokuje klasična kreditna analiza, treba istaknuti da su mnogi kreditni gubici koje su banke pretrpjeli rezultat koncentracije portfelja u određenim sektorima. Naime, klasična kreditna analiza se bazira na naputku da svaki kredit treba biti napravljen prema nekim normama. Mudar bankar pokušava izgraditi snažan kreditni portfelj pažljivo određujući veličinu kredita svim individualnim zajmotražiteljima tako da svaki od njih predstavlja prihvativ rizik. Oni su koncentracijski rizik određivali limitiranjem veličine rizika svakog pojedinog klijenta. No, ta se metoda pokazala neadekvatnom u upravljanju kreditnim rizikom. Koncentracija portfelja se tiče i ljudskog faktora. Naime, kako bi osoba postala stručnjak, mora se fokusirati na relativno uzak skup poduzeća unutar jedne industrije. U tom je slučaju nemoguće stvoriti diverzificirani kreditni portfelj. Nadalje, banke su davale kredite na tržištima koja su puno rizičnija nego ona za koja je dizajnirana klasična kreditna analiza. K tome, klasičan pristup temelji se na klijentima i odnosima s njima i ima tendenciju da proizvede koncentraciju rizika. Problem se pojavljuje kada postoji signifikantna korelacija između različitih klijenata. U modernom svijetu, donošenje dobre kreditne odluke na osnovi slučaj po slučaj jednostavno nije dovoljno.

4.2. Potreba za modelima kreditnog rizika

U prethodnom poglavlju navedeni su glavni nedostaci koje uzrokuje primjena subjektivnog načina ocjene kreditne sposobnosti odnosno klasična kreditna analiza. Unazad zadnjih nekoliko desetljeća, izazvane spomenutim problemima i nedostacima, započele su promjene u cijelokupnom poslovanju banke. Naime, klasična kreditna analiza se pokazala nedovoljnog za upravljanje kreditnim rizicima. Stoga su se u zadnjih 20-ak godina pojavile nove tehnike, a čije je pojavljivanje uvjetovano sljedećim:¹

1. Deregulacija, što je potaklo finansijske inovacije i omogućilo novim subjektima ulaz na tržište

¹ Caouette, J.B., Altman, E.I., Narayanan, P., Managing Credit Risk, John Wiley & Sons, New York, 1998, p.102

-
- 2. Širenje kreditnih tržišta
 - 3. Pomak s pozajmljivanja na temelju bilance na pozajmljivanje na temelju tijeka gotovine
 - 4. Porast izvanbilančnih rizika
 - 5. Smanjivanje zarada na kreditima što je prisililo banke da istraže jeftinije načine mjerena i upravljanja kreditnim rizikom
 - 6. Sekuritizacija
 - 7. Napredak u finansijskoj teoriji

Inovacije su promijenile klasičnu kreditnu analizu u dva fundamentalna smjera. Što se tiče transakcija, razvoj odobravanja kredita na temelju imovine utjecao je na pojavljivanje osiguranog financiranja i sekuritizacije. Što se tiče kreditnog managementa, niz prednosti je napravljeno u kvantifikaciji kreditnog rizika uvođenjem kreditnih scoring i rejting modela. Dugo se prije toga smatralo da je upravljanje kreditnim rizicima umjetnost, no, današnja metodologija daje prizvuk znanosti.

Modeli kreditnog rizika su naročito važni danas zato što donosiocima odluka daju uvid i potrebno znanje da se suoče s nastupajućim rizicima. Naime, u uvjetima gdje su zarade male i gdje stalno postoji pritisak za smanjivanje troškova, kada banka posluje na različitim geografskim područjima s mnogo zaposlenih, kvantitativni modeli kreditnog rizika svojom objektivnošću pomažu u donošenju pravilnih poslovnih odluka.

Ono što svakako treba istaknuti je da se klasična kreditna analiza mijenja i razvija u skladu s fundamentalnim promjenama koje se događaju u bankarskom poslu.² Naime, kada su u pitanju krediti poduzećima, prvotno je banka financirala obrtni kapital i trgovinu, a krediti su bili osigurani aktivom ili drugim oblicima kolaterala. K tome, banke su tradicionalno davale jednogodišnje ili kraće kredite kako bi omogućile svojim klijentima da podmire svoje sezonske potrebe. Banke su bile fokusirane na obrtni kapital nastojeći odrediti hoće li biti dovoljno sredstava da bi se otplatio kredit ako posao propadne što zapravo znači da su kreditni analitičari detaljno analizirali bilancu stanja, ali su zanemarivali račun dobiti i gubitka. Budući da se dug mora

² Tintor, J., Potraživanja, kreditna sposobnost i zarada, Poslovna analiza i upravljanje, Zagreb, 1996, p. 3-8

isplatiti u gotovini, bankari su shvatili da se treba fokusirati na tijek gotovine zajmotražitelja.

Statistički utemeljen kredit scoring sistem omogućuje finansijskim institucijama da automatski prihvate ili odbace rutinske odluke te da preostalo vrijeme poklone onim zajmotražiteljima koji su granični slučajevi i kod kojih nije sasvim jasno treba li ih odbaciti ili prihvati. Banka može koristiti samo kreditni scoring, a može i dopuniti skor sa skupom pravila koji su bazirani na specifičnim potrebama, zahtjevima i karakteristikama finansijske institucije, a može se uvesti i prethodno procesiranje koje podrazumijeva svojstvene kriterije.³ Primjerice, banka može zahtijevati da svakako podvrgne detaljnijem pregledu ona poduzeća koja su primjerice bila u bankrotu, zatim koja su na tržištu manje od 1 godine i slično.

4.3. Modeli bazirani na računovodstvenim podacima

S obzirom na činjenicu da kreditni rizik posljednjih godina raste, od izuzetnog su značaja postali modeli kreditnog rizika zato što donosiocima odluka daju potrebno znanje da se suoče s nastupajućim rizicima.

Modeli kreditnog rizika traže odgovor na sljedeće pitanje: S obzirom na proteklo iskustvo i prepostavke o budućnosti, koja je vjerojatnost danog zajma odnosno koji je rizik da obećani tijek gotovine neće dolaziti. Mnogo odvojenih elemenata ulazi u konstrukciju modela kreditnog rizika:⁴

1. Moraju biti postavljene veze između varijabli za koje se smatra da utječu na rizik neplaćanja. Tu je potrebno znanje teorije.
2. Za izradu formalnog modela mora biti primijenjen skup alata i metode za procjenu odnosno simulaciju ishoda. U ovoj su fazi ključni podaci.
3. Mora biti primijenjena serija testova kako bi se utvrdilo ponaša li se dobiveni model prema očekivanjima.

Cilj novih kredit scoring modela koji se razvijaju upotrebom različitih metodologija je svakako i povećanje preciznosti što znači dodjeljivanje kredita kreditno sposobnim

³ Rowland,J., Credit Scoring – Big Opportunities for Small and Start-up Businesses, Credit World, Sep/Oct95, Vol.84, Issue 1, p. 21-25

⁴ Caouette, J.B., Altman, E.I., Narayanan, P., Managing Credit Risk, John Wiley & Sons, New York, 1998, p.104

klijentima čega je posljedica povećanje dobiti i odbijanje što više onih klijenata koji nisu kreditno sposobni što znači smanjenje gubitaka.

Područja primjene finansijskih modela:⁵

1. Odobravanje kredita

Modeli se koriste samostalno ili zajedno sa sistemom individualnog prosuđivanja (klasična kreditna analiza koju rade kreditni analitičari) u odobravanju kredita.

2. Određivanje kreditnog rejtinga

Kvantitativni modeli se koriste za određivanje rejtinga firme odnosno izdavatelja, ali i za određivanje rejtinga izdanja.

3. Određivanje cijene kredita

Modeli kreditnog rizika mogu biti upotrebljeni za određivanje premije rizika koja se treba naplatiti kao mjera vjerojatnosti i veličine gubitka.

4. Rana finansijska upozorenja

Kreditni modeli se upotrebljavaju radi ranog otkrivanja potencijalnih problema u portfelju kako bi se poduzele rane korektivne mjere.

5. Kreditni modeli se mogu upotrebljavati za odabiranje one imovine iz cijele aktive radi konstruiranja portfelja koji je prihvatljiv investitorima ili radi postizanja minimalne kreditne kvalitete potrebne za ostvarivanje željenog kreditnog rejtinga.

6. Strategije naplaćivanja dugovanja

Kreditni modeli mogu biti upotrebljeni za definiranje najbolje strategije praćenja i prikupljanja dugovanja. Oni mogu pokazati koji je najpovoljniji način djelovanja prema svakog komitentu.

U modelima kreditnog rizika kod poslovnih kredita banke su se u početnim godinama kreditne analize oslanjale isključivo na kreditne analitičare koji su koristeći svoje znanje i iskustvo donosili odluku o odobravanju odnosno odbijanju kreditnog zahtjeva. Kako je bankarska praksa postojala sve složenija tako su se počeli razvijati statistički kredit scoring modeli koji su znanje eksperata pretvarali u matematičko-statistički model. Takvi su modeli pronalazili funkciju knjigovodstvenih i tržišnih varijabli koja najbolje diskriminira između dvije grupe zajmotražitelja – onih koji

⁵ Caouette, J.B., Altman, E.I., Narayanan, P., Managing Credit Risk, John Wiley & Sons, New York, 1998, p.105

plaćaju i onih koji ne plaćaju. Postoje i modeli koji mjere financijsko stanje financijskih institucija dodjeljujući im vjerojatnost da će postati problematične.

Dok se kredit scoring upotrebljava već određeno vrijeme za ocjenjivanje potrošačkih kredita, ta se tehnologija tek odnedavno počela primjenjivati za ocjenjivanje kreditne sposobnosti malih poduzetnika. Kreditni analitičari su otkrili da je osobna kreditna povijest vlasnika poduzeća visoko prediktivna za buduću otplatu kredita malog poduzeća.⁶ Osobne informacije koje se mogu koristiti u kredit scoringu za mala poduzeća su primjerice, mjesecna primanja vlasnika kredita, dugovi, financijska imovina, povijest zaposlenja poduzetnika, prethodna kašnjenja u plaćanju kredita.⁷ Osobne informacije dobivene iz jednog ili više kreditnih biroa mogu biti kombinirani s podacima dobivenim iz komercijalnih kreditnih biroa zatim s osnovnim podacima specifičnima za to poduzeće odnosno posao, a koje prikuplja svaka banka za sebe. Različiti kredit scoring modeli za mala poduzeća (Fair Isaac, Dun & Bradstreet, Experian i dr.) variraju u odnosu na količinu i tip informacija koju zahtijevaju kako bi se odluka donijela kao i u odnosu na način kako se dolazi do informacija. Primjerice neki traže samo djelatnosti dok drugi traže dosta detaljne financijske informacije.

Napredak u mjerenu kreditnog rizika svakako su omogućile i statističke metode, kao što su regresijska analiza, probit, logit analiza, diskriminacijska analiza, 'survival' analiza, zatim matematičko programiranje, simulacije, neuralne mreže, cluster metode i tako dalje. Neki su istraživači u svojim radovima pronašli da tradicionalne statističke metode ispravno klasificiraju veću proporciju aplikacija nego li metode umjetne inteligencije dok drugi pak pronalaze obrnuto.

Poduzeća mogu koristiti kredite za financiranje kratkoročnih potreba kao što su privremene potrebe za obrtnim sredstvima ili za finaciranje dugoročnih potreba kao što je kupovina nove opreme. Bilo da se radi o jednom ili o drugom obliku kredita, kreditni referent mora provesti detaljnu analizu prije odobravanja kredita. Proces procjene kreditnog rizika poduzeća koje traži kredit prije 30-ak godina se obavlja upotrebom znanja ekperata koji se sastojao u pregledavanju financijskih izvještaja poduzeća, poslovnog plana te razgovora s vlasnikom poduzeća. Rezultat takvog

⁶ Berger, A.N., Scott Frame, W., Credit Scoring and the Price and Availability of Small Business Credit, Credit Scoring and Credit Control VII Conference, Credit Research Centre – University of Edinburgh, 5-7 September, 2001

⁷ Berger, A.N., Scott Frame, W., Credit Scoring and the Price and Availability of Small Business Credit, Credit Scoring and Credit Control VII Conference, Credit Research Centre – University of Edinburgh, 5-7 September, 2001

procesa je raspoređivanje poduzeća u jednu od rizičnih kategorija koje označavaju odobravanje ili odbijanje kreditnog zahtjeva. No, takvi sistemi nisu bili dovoljni kako bi se donosile odluke u sve složenijoj bankarskoj praksi. Stoga su se počeli razvijati statistički modeli. U univarijatnim kredit scoring sistemima, donosioci odluke u finansijskim institucijama uspoređuju različite finansijske pokazatelje zajmotražitelja s industrijskim normama odnosno normama grane djelatnosti. Beaver⁸ prezentira moderan statistički model za predviđanje finansijskog neuspjeha. Kod korištenja multivarijatnih modela, ključne računovodstvene varijable se kombiniraju kako bi se proizveo skor kreditnog rizika ili mjera vjerovatnosti da će komitent kasniti u plaćanju. Do sada se najviše primjenjivala diskriminacijska analiza koju slijedi logit regresija. Prvi model u kojem počinje primjena takvog pristupa bio je Altmanov Z-skor model⁹ koji koristi multivarijatni pristup koji uključuje omjerne i kategorijalne vrijednosti koje se kombiniraju kako bi se dobila mjera, nazvana skor kreditnog rizika, koja najbolje diskriminira između uspješnih i neuspješnih poduzeća. Scott¹⁰ je komparirao brojne empirijske modele s teorijskim modelima. On je zaključio da ZETA model najbliže aproksimira njegov model bankrota. Svrha ZETA modela¹¹ bila je analizirati i testirati klasificiranje poduzeća na ona koja će bankrotirati i na ona koja neće bankrotirati. Bardos¹² odabire metodologiju statističkog kredit scoringa kako bi odredila rizik neuspjeha poduzeća. Upotrijebila je Fisherovu linearu diskriminacijsku analizu čiji se princip sastoji u pronašlasku optimalne granice između uspješnih i neuspješnih poduzeća. Platt i Platt¹³ koriste logit regresiju kako bi otkrili jesu li za predviđanje bankrota poduzeća bolji finansijski omjeri u odnosu na industriju od jednostavnih finansijskih omjera poduzeća. Johnsen i Melicher¹⁴ upotrebljavaju multinomne logit modele kako bi predvidjeli bankrot poduzeća. Altman, Marco i Varetto¹⁵ na uzorku talijanskih banaka uspoređuju rezultate u identificiranju poduzeća s finansijskim

⁸ Beaver,W., Financial Ratios as Predictors of Failure, Empirical Research in Accounting, 1966

⁹ Altman,E.I., Financial Ratios, Disriminant Analysis and the Prediction of Corporate Bankruptcy, Journal of Finance 23, 1968, p.189-209

¹⁰ Scott, J., The Probability of Bancruptcy, Journal of Banking and Finance 5, 1981, p. 317-344

¹¹ Altman, E.I., Haldeman, R.G., Narayanan, P., ZETA Analysis, Journal of Banking and Finance, 1, 1977, p. 29-54

¹² Bardos, M., Detecting the Risk of Company Failure, Journal of Banking and Finance, 22, 1998, p. 1-13

¹³ Platt, H.D., Platt, M.B., A Linear Programming Aproach to Bond Portfolio Selection, Economic Financial Computing, 1991, p.71-84, citirano u: Altman,E.I., Saunders,A., Credit Risk Measurement: Development Over the last 20 Years, Journal of Banking and Finance, 21, 1998, p.1721-1742

¹⁴ Johnsen, T., Melicher, R.W., Predicting Corporate Bankruptcy and Financial Distress: Information Value Added by Multinomial Logit Models, Journal of Economics and Business, 1994, p. 269-286

¹⁵ Altman, E.I., Marco, G., Varetto, F., Corporate Disteress Diagnosis: Comparison Using Linear Discriminant Analysis and Neural Networks (the Italian Experience), Journal of Banking and Finance, 18, 1994, p. 505-529

poteškoćama dobivene diskriminacijskom analizom i neuralnim mrežama. Piramuthu¹⁶ se bavi upotrebom neuralnih mreža i 'fuzzy' sistema pri donošenju odluka o odobravanju kredita poduzećima.

Ekonomski pritisci koji su rezultirali iz povećane potražnje za kreditima zajedno s povećanom konkurenčijom poduzeća na tržištu, te razvijanje kompjutorske tehnologije dovelo je do razvoja statističkih kredit scoring modela kako bi bio potpomognut proces donošenja odluka vezanih uz odobravanje kredita. Standardne statističke metode korištene u industriji razvoja skor-kartica su: diskriminacijska analiza, linearna regresija, logistička regresija i stablo odlučivanja. U univarijatnim kredit scoring modelima različiti finansijski pokazatelji zajmotražitelja uspoređuju se s industrijskim normama odnosno normama grane djelatnosti. Kod korištenja multivarijatnih modela, ključne računovodstvene varijable se kombiniraju kako bi se proizveo skor kreditnog rizika ili mjera vjerojatnosti da će komitent kasniti u plaćanju. Ako skor kreditnog rizika odnosno vjerojatnost da će doći do kašnjenja zauzme vrijednost iznad odabrane kritične vrijednosti, zajmotražitelj će biti odbijen ili podvrgnut pomnoj kontroli. Najuobičajeniji oblik diskriminacijske analize pokaušava pronaći linearu funkciju knjigovodstvenih i tržišnih varijabli koja najbolje diskriminira između dvije grupe zajmotražitelja – onih koji plaćaju i onih koji ne plaćaju. To zahtijeva analizu skupa varijabli kako bi se maksimizirala varijanca između grupa i minimizirala varijanca unutar grupe. Slično tome, logit analiza koristi skup knjigovodstvenih varijabli za predviđanje vjerojatnosti da će zajmotražitelj kasniti u plaćanju, prepostavljajući da je ta vjerojatnost logistički distribuirana.

Beaver model

Beaver¹⁷ prezentira prvi moderan statistički model za predviđanje finansijskog neuspjeha. On je svoj model bazirao na finansijskim omjerima koje je izračunava na temelju računovodstvenih podataka. Od 30 omjera, pokazalo se da 3 najbolje predviđaju finansijski neuspjeh:

- 1.) tijek novca/ukupna imovina

¹⁶ Piramuthu,S., Financial Credit-Risk Evaluation with Neural and NeroFuzzy Systems, European Journal of Operational Research, 112, 1999, p.310-312

¹⁷ Beaver,W., Financial Ratios as Predictors of Failure, Empirical Research in Accounting, 1966

- 2.) čisti prihod/ukupni dugovi
- 3.) tijek novca/ukupni dugovi

Za svaki pojedini omjer Beaver je izračunavao graničnu vrijednost pa je poduzeće s omjerom iznad te vrijednosti smješteno u grupu potencijalno uspješnih dok je poduzeće s vrijednošću omjera ispod definirane smješteno u grupu potencijalno neuspješnih poduzeća.

Tablica 1: Preciznost klasifikacije Beaverovog modela

Broj godina prije neuspjeha	tijek novca /ukupna imovina	čisti prihod/ ukupni dugovi	tijek novca/ ukupni dugovi	Veličina uzorka
1	0.10 (0.10)	0.13 (0.10)	0.15 (0.08)	158
2	0.20 (0.17)	0.21 (0.18)	0.20 (0.16)	153
3	0.24 (0.20)	0.23 (0.21)	0.22 (0.20)	150
4	0.28 (0.26)	0.24 (0.24)	0.26 (0.26)	128
5	0.28 (0.25)	0.22 (0.22)	0.32 (0.26)	117

Izvor: Beaver,W., Financial ratios as predictors of failure, Empirical Research in Accounting, 1966.

Prvi broj u svakoj ćeliji tablice 1. prikazuje udio pogrešno klasificiranih poduzeća u test uzorcima, a brojevi u zagradama prikazuju udio pogrešno klasificiranih poduzeća u originalnom uzorku. Može se primjetiti da udio pogrešno klasificiranih poduzeća raste zajedno s brojem godina koje prethode neuspjehu.

Iako je Beaverov model bio vrlo jednostavan univarijatni statistički model, on predstavlja početak upotrebe i primjene statističke metodologije u problemima kreditnog rizika.

Altmanov z-skor model

Prvi model u kojemu počinje primjena multivarijatnog pristupa bio je Altmanov Z-skor model.¹⁸ On koristi multivarijatni pristup koji uključuje omjerne i kategorijalne

¹⁸ Altman,E.I., Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy, Journal of Finance 23, 1968, p.189-209

vrijednosti koje se kombiniraju kako bi se dobila mjera, nazvana skor kreditnog rizika, koja najbolje diskriminira između poduzeća koja su neuspješna i onih koja su uspješna. Očekuje se da će neuspješna poduzeća imati kretanje finansijskih omjera drugačije no što to imaju finansijski zdrava poduzeća. I kod Altmanovog modela se definira granična vrijednost na temelju koje finansijska institucija donosi odluku. Naime, zahtjevi za kredit se prihvataju ako je Z-skor poduzeća iznad definiranog Z-skora i obrnuto.

Istaživanje koje je proveo Altman napravljeno je na uzorku koji se sastojao od 33 neuspješna i 33 uspješna poduzeća. Kao rezultat višestruke diskriminacijske analize, dobiveni su slijedeći finansijski omjeri:

1.) obrtni kapital/ukupna imovina (X_1)

Mjera neto likvidnosti u odnosu na ukupnu kapitalizaciju. Firma koja doživljava operativne gubitke imat će smanjenje tekuće imovine prema ukupnoj imovini.

2.) zadržana zarada/ukupna imovina (X_2)

Kod relativno mladih firmi će ovaj omjer biti niži jer one nisu imale vremena kumulirati dobit.

3.) dobit prije poreza /ukupna imovina (X_3)

Kako se egzistencija poduzeća bazira na mogućnosti firme da svojim sredstvima ostvari zaradu, ovaj je omjer naročito prikladan za zaključivanje o mogućnosti bankrota poduzeća.

4.) tržišna vrijednost vlastitog kapitala /knjigovodstvena vrijednost obveza (X_4)

Ovaj omjer pokazuje koliko sredstva poduzeća gube na svojoj vrijednosti prije no što obveze premaže imovinu i poduzeće postane nesolventno.

5.) ukupni prihodi/ukupna imovina (X_5)

Rezultirajuća diskriminacijska funkcija:¹⁹

$$Z = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,999X_5$$

Donja granična vrijednost iznosi 1.81, što znači da je procjena da će poduzeća čiji je Z-skor ispod te granice bankrotirati, dok je gornja granična vrijednost 2.99 iznad koje poduzeća neće bankrotirati. Za skorove između 1.81 i 2.99 su pronađene greške u originalnom uzorku. Preciznost kojom model diskriminira između uspješnih i

¹⁹ Ibidem

neuspješnih poduzeća 1 godinu prije bankrota iznosi 95%, a dvije godine prije bankrota 82%.

Altman je 1993 revidirao originalan model kako bi se mogao napraviti skor za privatna poduzeća, zamjenjujući tržišnu vrijednost knjigovodstvenom vrijednosti prilikom izračunavanja X₄. Rezultat toga je Z'-skor model:²⁰

$$Z' = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,420X_4 + 0,998X_5$$

Donja granica iznosi Z'=1.23. Poduzeća ispod te granice se smatraju takvima da će bankrotirati, pa im neće biti odobren kredit, a gornja granica Z'=2.90 predstavlja granicu iznad koje se poduzeće smatra uspješnim.

ZETA model kreditnog rizika

Nakon Z-skor modela Altman, Haldeman i Narayanan²¹ kreiraju ZETA model. Svrha ZETA modela, koji je kreiran 1977, bila je analizirati i testirati klasificiranje poduzeća na ona koja će bankrotirati i na ona koja neće. Model je uspješan u klasificiranju poduzeća 5 godina prije bankrota na uzorku proizvodnih i trgovačkih poduzeća. Prosječna visina imovine analiziranih poduzeća bila je približno 100 milijuna dolara. Niti jedno poduzeće nije bilo slabije od 20 milijuna dolara u aktivi.

Točnost modela iznosi više od 90% za klasificiranje poduzeća jednu godinu prije bankrota i 70% pet godina prije bankrota.

Iako je uzorak bio sastavljen od proizvodnih i trgovačkih poduzeća, to nije negativno utjecalo na rezultat. Uzorak za ovo istraživanje sastojao se od 53 neuspješna poduzeća od kojih je 29 proizvodnih i 24 trgovačkih, te od 58 uspješnih poduzeća među kojima je bilo 32 proizvodna i 26 trgovačkih poduzeća.

Analizirano je 27 varijabli²² dok se konačan model sastoji od sljedećih sedam:

- 1.) X₁: Povrat na imovinu, što se mjeri omjerom dobit prije poreza/ukupna imovina.
- 2.) X₂: Stabilnost zarade, što se mjeri standardnom greškom procjene 5 do 10 godišnjeg trenda varijable X₁ (standardna devijacija reziduala).
- 3.) X₃: Servisiranje dugova, što se mjeri omjerom dobit prije poreza/ukupne plaćene kamate.

²⁰ Caouette, J.B., Altman, E.I., Narayanan, P., Managing Credit Risk, John Wiley & Sons, New York, 1998, p. 119

²¹ Altman, E.I., Haldeman, R.G., Narayanan, P., ZETA Analysis, op.cit.

²² lista svih varijabli nalazi se u cf. Altman, E.I., Haldeman, R.G., Narayanan, P., ZETA Analysis, op.cit., p. 54

4.) X4: Kumulativna profitabilnost, što se mjeri omjerom zadržana dobit/ukupna imovina.

Ovo je najvažnija varijabla u modelu. Ona uključuje starost poduzeća, dividendnu politiku kao i profitabilnost mjerenu tijekom vremena.

5.) X5: Likvidnost, što se mjeri omjerom ukupna tekuća aktiva/ukupna tekuća pasiva.

6.) X6: Kapitalizacija, što se mjeri omjerom kapital/ukupne obveze i kapital.

Kapital je mjerjen kao 5 godišnji prosjek tržišne vrijednosti.

7.) X7: Veličina poduzeća, mjerena ukupnom imovinom poduzeća.

Upotrebljena je multivarijatna diskriminacijska analiza uz primjenu linearne i kvadratne strukture. Točnost linearog modela, za klasificiranje poduzeća jednu godinu prije bankrota, iznosi 96.2% za grupu neuspješnih poduzeća i 89.7% za grupu uspješnih poduzeća. Kod kvadratne strukture, točnost za uspješna poduzeća iznosi 91.4%, a za neuspješna 94.3%. Prema očekivanjima, točnost se smanjuje za neuspješna poduzeća kako podaci postaju udaljeniji od bankrota. Najznačajnija razlika između kvadratne i linearne strukture je u testiranju test uzoraka za grupu neuspješnih poduzeća. Ovdje se linearni model pokazao puno uspješnijim za razliku od kvadratnog koji bilježi pogrešku preko 50% za bankrote pet godina ranije.

ZETA model ima veću točnost u odnosu na Z-skor model u klasifikaciji neuspješnih poduzeća u razdoblju od 2 do 5 godina prije bankrota, dok je točnost za prvu godinu gotovo jednaka za oba modela. Z-model je pokazao nešto veću točnost u odnosu na ZETA model u klasificiranju uspješnih poduzeća za razdoblje od dvije godine u slučaju kada je moguća direktna usporedba.

Ukoliko se ZETA model želi upotrijebiti pri odlučivanju o dodjeli kredita, postavljanje granične vrijednosti zahtijeva malo razmišljanja. Ako je granična vrijednost previšoka, slabiji krediti će biti odbačeni, ali isto tako i neki dobri. Ako se pak granična vrijednost postavi prenisko, dobit će se obrnuta situacija. Naime, granična vrijednost skora treba biti funkcija troškova greške tipa I (gubitak zbog prihvatanja lošeg kredita) i troškova greške tipa II (gubitak zbog neodobravanja kredita dobrom kreditnom riziku).²³ K tome, na graničnu vrijednost će utjecati prior vjerojatnost da će kredit biti loš. Ako se postave jednake prior vjerojatnosti za dobare i loše komitente i ako su

²³ Caouette, J.B., Altman, E.I., Narayanan, P., Managing Credit Risk, John Wiley & Sons, New York, 1998, p. 124

troškovi greške tipa I i tipa II jednaki, linearni model će dati graničnu vrijednost u nuli, a prior vjerojatnost će iznositi 0.5. No, samo mali dio zajmotražitelja će zapravo kasniti odnosno biti loši što znači da će prior vjerojatnost biti manja od 0.5. Stoga se ona ne može znati s potpunom preciznošću pa se procjenjuje u rasponu od 1-5%. Sva poduzeća koja imaju skor iznad nule su klasificirana kao ona čije su karakteristike slične uspješnim poduzećima dok ona s negativnim skorom pripadaju grupi neuspješnih poduzeća. Isti skor će se dobiti ako se žele minimizirati ukupni troškovi pogrešne klasifikacije pouzeća. Optimalna granična vrijednost skora jednaka je sljedećem:

$$ZETA_c = \ln \frac{q_1 C_I}{q_2 C_{II}} \quad (3.3)$$

q_1 je prior vjerojatnost bankrota

q_2 je prior vjerojatnost ne-bankrota

C_I je trošak greške tipa I²⁴

C_{II} je trošak greške tipa II²⁵

Očekivani troškovi ZETA modela:

$$EC_{ZETA} = q_1(M_{12}/N_1)C_I + q_2(M_{21}/N_2)C_{II} \quad (3.4)$$

M_{12}, M_{21} je broj pogrešnih klasifikacija poduzeća

N_1 je broj neuspješnih poduzeća (bankrot)

N_2 je broj uspješnih poduzeća (ne-bankrot)

S obzirom na različite pretpostavke glede prethodne vjerojatnosti i troškove grešaka, definiraju se različite strategije klasifikacije, a treba i naglasiti da će se preciznost modela mijenjati s obzirom na odabranu graničnu vrijednost. Praktična upotreba ZETA modela postoji pri ocjeni kreditne sposobnosti za finansijske i nefinansijske institucije te pri identifikaciji nepoželjnog investicijskog rizika.

Multinomni model

Johnsen i Melicher²⁶ kreirali su istraživanje kojim su ispitali dodanu vrijednost dva tipa informacija dobivenih multinomnim logit modelima koji su korišteni u objašnjavanju i predviđaju bankrota:

²⁴ greška u identificiranju neuspješnih poduzeća

²⁵ greška u identificiranju uspješnih poduzeća

²⁶ Johnsen, T., Melicher, R.W., Predicting Corporate Bankruptcy and Financial Distress: Information Value Added by Multinomial Logit Models, Journal of Economics and Business, 1994, p. 269-286

1. Informacija dobivena proširenjem modelaliteta izlazne varijable odnosno uključivanjem dodatnog trećeg stupnja – financijski oslabljeno poduzeće
2. Informacija sekundarne klasifikacije

Multinomni logit modeli su upotrijebljeni za klasifikaciju poduzeća u razdoblju od 1970. do 1983. Status svakog financijski slabog poduzeća i onog koje je bankrotiralo promatran je 5 godina nakon inicijalne klasifikacije. Autori su odlučili kreirati zavisnu varijablu koja označava stanje poduzeća s tri kategorije iz jednostavnog razloga što sva poduzeća koja imaju financijskih poteškoća ne završavaju u bankrotu već se financijske poteškoće mogu shvatiti kao kontinuirani proces koji ide od financijske slabosti, poteškoća pa do bankrota.

Prvi cilj rada bio je pokazati model s dva stanja - bankrot i uspjeh, ali i pokazati model s više stanja odnosno više modaliteta financijskog stresa. Drugi cilj rada je bio odrediti dodanu vrijednost sekundarne klasifikacije u predviđanju promjena u financijskim uvjetima.

U slučaju kada zavisna varijabla ima dva modaliteta gdje 1 označava poduzeće u bankrotu, a 0 poduzeće koje nije u bankrotu, za modeliranje je upotrebljen logit model baziran na kumulativnoj logističkoj funkciji vjerojatnosti gdje se vjerojatnost za $P_t=1$ odnosno vjerojatnost da će poduzeće biti u bankrotu računa na slijedeći način:

$$P_t = \frac{1}{1 + \exp(-(\alpha + \beta X_t))} ; \quad t=1,2, \dots, T \text{ su poduzeća}$$

$$\log \frac{P_t}{1-P_t} = \alpha + \beta X_t$$

α je konstantni član modela

β je regresijski koeficijent

X_t je nezavisna varijabla

Kada zavisna varijabla sadrži više od dvije kategorije, za modeliranje se upotrebljava multinomni model. Općenito, za J kategorija vjerojatnosti da će poduzeće biti u bankrotu se računaju na slijedeći način:

$$P_{tj} = \frac{\exp(\alpha_j + \beta_j X_t)}{\sum \exp(\alpha_j + \beta_j X_t)}$$

gdje je $\alpha_1 = \beta_1 = 0$, a kategorija 1 je test za usporedbu.

Kako bi se dobio model s tri stanja, neka je $Y_{ij} = 1$ ako je t poduzeće raspoređeno u j -to stanje [$j=0$ poduzeće koje je bankrotiralo, $j=1$ poduzeće koje je uspješno, $j=2$ finansijski slabo poduzeće]. Ako se uzme da je $P_{tj}=1$, multinomni logit model postaje:

$$\log(P_{t2}/P_{t1}) = \alpha_2 + \beta_2 X_t,$$

$$\log(P_{t3}/P_{t1}) = \alpha_3 + \beta_3 X_t,$$

$$P_{t1} = 1 - P_{t2} - P_{t3}$$

P_{tj} je vjerojatnost da će se j -to stanje dogoditi.

Uzorak upotrebljen za istraživanje sadržavao je 112 (17%) poduzeća koja su bankrotirala, 300 (44.4%) uspješnih poduzeća, 255 (38.6%) finansijski oslabljenih poduzeća. Ova posljednja poduzeća su identificirana kroz analiziranje proteklog rasta i stabilnost dividendi i zarada kao i nekih drugih faktora.

U radu su ispitana dva modela koja su preživjela testiranje varijable vrijeme kao prediktora bankrota poduzeća: Beaver (1966) i Altman (1977). Autori ovog članka su odlučili ispitati primarnu i sekundarnu sposobnost klasifikacije svakog modela tako da ih se razmatra u multinomnom logit okviru. Odvojeno su procijenjene tri binomne funkcije (bankrot vs uspješno; bankrot vs slabo; uspješno vs slabo) te je na taj način dobiveno ukupno 6 mogućih tipova grešaka u klasifikaciranju. Za multinomni model su procijenjene tri iste funkcije, proizvodeći iste tipove grešaka samo što su rezultati klasifikacije dobiveni iz jedne procjene. Vjerojatnosti za binomne i multinomne modele su upotrebljene za kategoriziranje svakog poduzeća u j stanje upotrebljavajući najveću predviđenu vjerojatnost za indikaciju stanja svakog poduzeća. Poduzeće je pogrešno klasificirano ako u stvarnosti nije ušlo u to odabranou stanje. Sveukupno gledajući, rezultati su pokazali poboljšanje u klasifikaciranju kada se primjenjuju multinomni modeli za 14.3% kod Beaver modela i za 14.2% u Zeta modelu. Ako se pažnja usmjeri na individualne komponente ukupne stope pogrešne klasifikacije, treba promotriti 2 stanja:

- 1.) Pogrešna klasifikacija bankrot poduzeća kao uspješnog i uspješnog poduzeća kao bankrot

Zeta model rezultira u 41 (od ukupno 405) pogrešnoj klasifikaciji kod primjene binomnog modela. Kada se doda kategorija 'slabo poduzeće' i napravi multinomna procjena, ukupna greška pada na 11, odnosno za 73%. Beaver model pogrešno klasificira 38 poduzeća (od 405) kada se primjenjuje binomni

model, a kod primjene multinomnog broj pogrešne klasifikacije pada na 16 što u postotku iznosi 58%.

Za ZETA model, na razini 1% značajnosti, izdvojene su varijable: dobit/ukupna imovina, standardna devijacija za dobit/ukupna imovina, zadržana zarada/ukupna imovina i ukupna imovina. Jedino standardna greška za 'dobit/ukupna imovina' otpada kod multinomnog modela.

2.) Pogrešna klasifikacija bankrot poduzeća kao slabih te slabih poduzeća kao bankrot

Osnovni Zeta model proizvodi ukupnu grešku od 60 pogrešno klasificiranih poduzeća (od 367) u binomnoj procjeni. Kada se doda kategorija 'slabo poduzeće' i upotrijebi multinomna procjena, ukupna greška se smanjuje od 60 na 56 što u postotku iznosi 7%. Osnovni Beaver model proizvodi ukupnu grešku od 59 poduzeća (od 367) u binomnom modelu. S dodavanjem «slabog poduzeća» i procjenom s multinomnim modelom, greška se smanjuje na 51 odnosno 14%. Varijable: standardna devijacija varijable dobit/ukupna imovina, dobit/ukupna imovina i zadržana zarada/ukupna imovina su značajni prediktori za obe grupe, no, ukupna imovina je značajna varijabla u razlikovanju 'bankrot' vs 'uspješno', ali nije značajna u 'bankrot' vs 'slabo poduzeće'.

Autori su ocjenjivali pouzdanost rezultata klasifikacije ispitujući sekundarne izbore napravljene za financijski slaba poduzeća i bankrot poduzeća. Sekundarni izbor se postiže odabiranjem onog stanja koje je označeno drugom po redu najvećom vjerojatnošću dobivenom Zeta modelom. Bilo je 18 bankrot i 82 uspješna poduzeća koja su originalno pogrešno klasificirana kao slaba poduzeća, a koja su ispravno klasificirana na sekundarnoj osnovi. Ako bi se ta sekundarna klasifikacija uključila u računanje ukupne greške, tada bi Zeta model pogrešno klasificirao samo 41 poduzeće, što je manje u usporedbi s 253 koja su originalno pogrešno klasificirana. S druge strane, bilo je 6 bankrot poduzeća koja su originalno pogrešno klasificirana kao uspješna, a koja su i na sekundarnoj osnovi pogrešno klasificirana. Ta se poduzeća mogu smatrati stršećim vrijednostima. Postoji još 22 poduzeća koja su originalno klasificirana kao slaba, a također su pogrešno klasificirana na sekundarnoj osnovi.

Kako bi se odredila pouzdanost ispravne klasifikacije dobivene Zeta modelom, izračunata je razlika između najveće i druge po redu najveće predviđene vjerojatnosti. Ta je razlika definirana kao skor razlike. Poduzeća s relativno velikim

skorom trebaju biti pouzdano klasificirana, a ona s relativno malim skorom nepouzdano klasificirana. Autori su definirali grupu neupouzdano klasificiranih poduzeća sa skorom razlike koji je manji ili jednak 0.20.

Sva bankrot poduzeća korektno klasificirana svrstana su u grupu slaba poduzeća kod sekundarnog izbora. 11 od tih poduzeća koja su bila unutar 0.20 su bila klasificirana kao slaba što je sugeriralo manjak povjerenja u kategoriju 'bankrot'. Za razliku od toga, 22 od korektno klasificiranih bankrot poduzeća su imala najveće razlike skorova. Za tu grupu, visok stupanj povjerenja postoji u 'bankrot' klasifikaciju i nisko očekivanje za poboljšanje finansijskih uvjeta. Za slaba poduzeća, sekundarni izbor za 20 slučajeva bio je bankrot. 8 od tih poduzeća koje su bile unutar 0.20 je bilo klasificirano kao bankrot poduzeća sugerirajući povećanu vjerovatnost daljnog opadanja finansijskih uvjeta. Preostalih 121 ispravno klasificiranih slabih poduzeća klasificirana su kao uspješna poduzeća u sekundarnom izboru. 8 od tih poduzeća bila su unutar 0.20 i klasificirana su kao uspješna sugerirajući povećanu vjerovatnost napretka u finansijskim uvjetima. 21 od 80 poduzeća doživjelo je pomak u ocjeni, unutar 3 godine. Ostala poduzeća ostala su isto klasificirana.

Primjena neuralnih mreža

Odluke o ocjeni kreditnog rizika su važne za sve finansijske institucije koje daju kredite i to zbog visokog rizika koji je povezan s lošom odnosno pogrešnom odlukom. Proces donošenja odluke o tome odobriti li kredit ili ne kompleksan je i nestrukturiran, a neuralne mreže se dobro snalaze upravo u takvim okolnostima. Neuralne mreže imaju odlične sposobnosti generalizacije, jednostavnosti modeliranja bez potrebe za specifikacijom modela, nije nužno zadovoljenje prepostavki o distribucijama podataka upotrebljenih u modelu, sposobnost učenja bilo koje funkcije itd. Najčešće korištene arhitekture su: neuralne mreže «širenje unatrag» i njene varijante zato što su vrlo dobre za probleme klasifikacije.

CASA²⁷ je razvio model neuralnih mreža u području predviđanja kašnjenja u otplati kredita.²⁸ Baza podataka koja je korištena u svrhu izgradnje modela sadržavala je finansijske izvještaje poduzeća u razdoblju od 1985. do 1995., a upotrebljena je

²⁷ Centre for Adaptive Systems Applications, Los Alamos

²⁸ Caouette,J.B., Altman,E.I., Narayanan,P., Managing Credit Risk, op.cit., p. 132

mreža «širenje unatrag». U usporedbi s modelima baziranim na linearnoj diskriminacijskoj analizi, performance mjerene prosječnom greškom neispravne klasifikacije, neuralne mreže nadvisile su diskriminacijsku analizu. Pokazalo se da finansijski omjeri iz knjigovodstvenih izvještaja sadrže informacije o neuspjehu poduzeća.

Altman, Marco i Varetto²⁹ na uzorku talijanskih banaka uspoređuju rezultate u identificiranju poduzeća s finansijskim poteškoćama dobivene diskriminacijskom analizom i neuralnim mrežama. Statistički scoring sistem temeljen na diskriminacijskim funkcijama kreiran je 1988., a 1989. godine distribuiran je bankama i rezultati su pokazali da sistem radi jako dobro. Inicijalna verzija bazirana je na paru linearnih diskriminacijskih funkcija. Funkcije su procjenjene iz uzorka od 213 kompanija s finansijskim poteškoćama u usporedbi s uzorkom od 213 zdravih poduzeća. Procjena je napravljena dvije godine prije no što je ustanovljeno da poduzeće ima finansijskih poteškoća. Sistem je ispravno klasificirao, u godini prije no što su poteškoće nastupile, 87.6% zdravih i 92.6% slabih poduzeća. Nakon toga je kreirana i druga verzija sistema koja je dana na korištenje 1991. godine, a iste je godine proveden i inicijalni test o upotrebi neuralnih mreža za identifikaciju poduzeća koja pokazuju ekonomske i finansijske poteškoće. Ključne karakteristike sistema su bile:

- Dizajniran je za mala i srednja poduzeća u Italiji.
- Obuhvaćen je period između 1985. i 1991.
- Korišten je izbalansiran uzorak zdravih i oslabljenih poduzeća.
- Diskriminacijska analiza je pokazala poteškoće u diskriminiranju između dva oslabljena poduzeća, lošeg i slabog, dok je puno lakše diskriminirala između zdravog i lošeg poduzeća. Prvi model, koji diskriminira između zdravih i loših poduzeća, se sastojao od linearne funkcije s 9 finansijskih omjera koja je razlikovala zdrava poduzeća od finansijski loših ili slabih. Drugi model, koji diskriminira između slabih i loših poduzeća, se upotrebljavao nakon što je prvi model dijagnosticirao da su poduzeća loša.
- Iz oba modela su zadržane one varijable koje su povećavale kapacitet klasificiranja loših i zdravih poduzeća.

²⁹ Altman, E.I., Marco, G., Varetto, F., Corporate Disteress Diagnosis: Comparison Using Linear Discriminant Analysis and Neural Networks (the Italian Experience), op.cit.

- Procjene su napravljene upotrebom logit i diskriminacijske analize, ali kako nije uočena nikakva signifikantna razlika kod naknadnog ispitivanja uspješnosti klasifikacije, zadržane su diskriminacijske funkcije.

Testiranje statističkog kredit scoring modela dobivenog upotrebom diskriminacijske analize pokazuje da postotak uspješne klasifikacije ide od 86.3% u periodu od 3 godine prije otkrivanja stvarnog stanja do 96.5% u periodu od jedne godine prije identifikacije stvarnog stanja. Točnost klasifikacije je provjerena i na test uzorku od 150 loših i 150 zdravih poduzeća gdje su dobiveni slični rezultati, 90.3% za zdrave i 95.1% za loše firme. Drugi model, koji diskriminira između loših i slabih poduzeća, kao što se i očekivalo, ima niži kapacitet razlikovanja pogotovo za loša poduzeća. Zabilježena je ispravna klasifikacija od 82.7% za loša poduzeća u jednogodišnjem periodu prije ispitivanja stvarnog stanja i 81% u test uzorku.

Incijalni uzorak za kreiranje kredit scoring modela neuralnih mreža sastojao se od 1212 poduzeća od čega su 404 zdrava, 404 loša i 404 slaba poduzeća. Drugi nezavisni uzorak brojao je 453 poduzeća, 151 od svakog tipa s podacima limitiranim na 1 godinu prije bankrota. Konačan uzorak, nezavisan od dva prethodna, analiziran je skupljanjem 900 zdravih i 900 slabih poduzeća za tri godine povijesne serije. Višeslojne mreže različitih stupnjeva kompleksnosti su trenirane koristeći omjere iz perioda tri godine prije identificiranja stanja poduzeća iza čega je slijedilo testiranje u periodu jedne godine prije identificiranja stanja poduzeća. Upotrebljeni su isti uzorci. Najbolji rezultati su dobiveni s trošlojnom mrežom - 15 neurona u prvom skrivenom sloju, 6 u drugom te 1 neuron u izlaznom sloju. Na kraju trenirajućeg perioda mreža je bila u stanju korektno prepoznati 97.7% zdravih i 97% loših poduzeća.

Usporedba rezultata neuralnih mreža i diskriminacijske analize pokazuje da je sposobnost neuralnih mreža da identificira poduzeća bila veća nego sposobnost diskriminacijske analize iako je dobivena s većim brojem indikatora: 15 nasuprot 9. Greške za loša poduzeća se značajno smanjuju kako broj ciklusa raste do 560, a tada točnost klasifikacije postaje nepredvidiva. Mreža trenirana u periodu tri godine prije identificiranja stanja poduzeća pokazuje nižu razinu prepoznavanja nego ona u periodu treniranja upotrebljavajući omjere iz perioda jedne godine prije identificiranja stanja poduzeća gdje je greška identifikacije bila je 10.6% za zdrava poduzeća i 5.2% za loša poduzeća. Kod diskriminacijske analize greške su bile 7.2% za zdrava i 3.5% za loša poduzeća.

Pored toga što su u neuralne mreže ubačeni omjeri različiti od onih korištenih u diskriminacijskim funkcijama, autori su kreirali i takve mreže u koje su ubacili indikatore dobivene diskriminacijskim funkcijama. Namjera je bila ispitati sposobnost mreža da reproduciraju znanje nađeno u diskriminacijskoj funkciji i konvertiraju ga u znanje distribuirano preko neuralnih konekcija. Najbolji rezultati su dobiveni s 9 ulaznih neurona, 5 neurona u srednjem sloju i jednim izlaznim neuronom. Usporedba rezultata dobivenih neuralnim mrežama i diskriminacijskom funkcijom pokazuje da nema bitnih razlika iako su nešto niže stope ispravne klasifikacije postignute neuralnim mrežama.

Budući da neuralne mreže mogu imati poteškoća kada pokušavaju riješiti neki kompleksan problem, autori predlažu pravljenje malih jednostavnih mreža od ukupne mreže te njihovo međusobno povezivanje. Oni su napravili 8 jednostavnih mreža s jednim skrivenim i jednim izlaznim slojem. Svaka je mreža opskrbljena onim financijskim omjerima koji su specifični za pojedinu karakteristiku:

1. Zaduženost: imovina/obveze
2. Sposobnost ispunjavanja financijskih obveza
3. Likvidnost
4. Profitabilnost
5. Akumulacija dobiti
6. Sposobnost podnošenja troškova duga
7. Opća efikasnost
8. Trgovinska zaduženost

Rezultati pokazuju da se točnost klasifikacije pojedinih mreža razlikuje od mreže do mreže, ali da generalno to nije bitna razlika. Sistem jednostavnih mreža primijenjen u periodu jedne godine prije identifikacije stanja daje odlične rezultate u ovom slučaju također, 92.8% za zdrava te 94.5% za loša poduzeća. U test uzorku rezultati su također dobri, 93.6% za zdrava i 89.1% za loša poduzeća. U usporedbi s diskriminacijskom funkcijom postoji signifikantan pad u broju loših poduzeća identificarnih korektno (-6%) ali to nije dovoljno da odbacimo uspješnost tog sistema. Autori predlažu integriranje neuralnih mreža i diskriminacijske analize, primjenjujući diskriminacijsku analizu kod manje kompleksnih problema klasifikacije u kojima fleksibilnost mreža i njihova sposobnost strukturiranja u uzorak može biti vrlo korisna.

'Neurofuzzy' sistemi

Problem neuralnih mreža je u tome što je teško objasniti ono što leži iza odluka dobivenih neuralnim mrežama. Istraživači razvijaju metode upotrebom neuralnih mreža kako bi proizveli pravila koja se onda koriste za racionalno objašnjavanje odluka. No, ta pravila ne obuhvaćaju naučeno znanje dovoljno dobro pa se stoga odnedavno razvijaju 'neurofuzzy' sistemi koji imaju karakteristike i neuralnih i 'fuzzy' sistema. Upravo se Piramuthu³⁰ bavi upotrebom neuralnih mreža i 'fuzzy' sistema pri donošenju kreditnih odluka. 'Fuzzy' sistemi su u prednosti za upotrebu kada se raspolaže podacima, odnosno informacijama koje su nepotpune i stoga, ne mogu biti tretirane uobičajenim mjerama vjerojatnosti. Stupanj pripadnosti dodjeljuje se kvantitetima koji ne pripadaju u binarne kategorije. 'Neurofuzzy' sistemi³¹ kombiniraju poželjne karakteristike neuralnih mreža i 'fuzzy' sistema. Oni generiraju pravila u formi 'ako-onda'.³² Problem interpretacije rezultata neuralnih mreža na taj je način izbjegnut. Naime, dobiju se 'ako-onda' pravila koja su lako razumljiva ljudskom mozgu. U 'neurofuzzy' sistemima nova znanja u obliku 'ako-onda' pravila se samo dodaju postojećem skupu pravila što znači da se sistem može stalno poboljšavati dodavanjem novih odnosno neotkrivih pravila. 'Neurofuzzy' sistem odabire najbolju kombinaciju od svih ponuđenih pravila i s tim ide u novu iteraciju.³³ Autor je primijenio neuralne mreže i 'neurofuzzy' sisteme za klasificiranje poduzeća na ona za koja se smatra da će kasniti u plaćanju kredita i na ona koja neće. Uzorak za treniranje činilo je 16 poduzeća koja kasne i 16 koja ne kasne u plaćanju. Uzorak za testiranje je imao 16 poduzeća koja su sva bila dobra u plaćanju. U model je uključeno 18 varijabli. Neuralne mreže su imale 18 ulaznih neurona, 10 skrivenih i 1 izlazni, a 'neurofuzzy' sistemi 18 ulaznih neurona, 30 skrivenih i 1 izlazni neuron. Oba sistema rade dok ukupna suma kvadrata greške ne dosegne 0,04 ili broj iteracija ne bude

³⁰ Piramuthu,S., Financial Credit-Risk Evaluation with Neural and Neurofuzzy Systems, European Journal of Operational Research, 112, 1999, p.310-312

³¹ Cf. Buckley,J.J., Hayashi, Y., Fuzzy Neural Networks: A Survey, Fuzzy Sets and Systems 66, 1994, p.1-13; Gupta, M.M., Rao, D.H., On the Principles of Fuzzy Neural Networks, Fuzzy Sets and Systems 61 (1), 1994, p. 1-18; Kuncheva, L.I., Mitra, S., A Two-Level Classification Scheme Trained by a Fuzzy Neural Networks, Proceedings of 12th International Conference on Pattern Recognition, vol.II, 1994, p. 467-469 citirano u Piramuthu,S., Financial Credit-Risk Evaluation with Neural and Neurofuzzy Systems, European Journal of Operational Research, 112, 1999, p.310-312

³² engleska riječ: if-then

³³ detaljniji opis upotrebljenog algoritma učenja u cf.: Halmuge,S.K., Glesner,M., Neural Networks in Designing Fuzzy Systems for Real World Applications, Fuzzy Sets and Systems 65, 1994, p. 1-12 & Nauck,D., Klawonn,F., Kruse,R., Combining Neural Networks and Fuzzy Controllers, Proceedings of 8th Austrian AI Conference, June 1993, p.35-46

2000. Stopa učenja za neuralne mreže je 0.19. Neuralne mreže su ponovljene 10 puta. Prosječna točnost klasifikacije za trening podatke iznosila je 98.12%, a za test podatke 73.75%. 'Neurofuzzy' sistem je ponovljen samo jedom. Broj iteracija je iznosio 500, a točnost klasifikacije za trening skup podataka je iznosila 50%, a za test podatke 68.75%. Rezultati za test podatke se razlikuju tek kod 4% značajnosti. Kod 'neurofuzzy' sistema dobiveno 'ako-onda' pravilo za poduzeća koji ne kasne u otplati kredita nalazi se u tablici dolje.

Tablica: Pravilo 'ako-onda' za poduzeća koji ne kasne u otplati kredita dobivena 'neurofuzzy' sistemom

Veliko	Srednje	Malo
čisti prihod/ukupna imovina	ukupane obveze /ukupna imovina	čisti prihod/prodaja
radni kapital/prodaja	tekuća imovina /tekuća pasiva	tijek gotovine /ukupne obveze
trend radni kapital/prodaja	trend zarade	dugoročne obveze/kapital
	koeficijent tekuće likvidnosti	novac+potraživanja /prodaja
	trend čisti prihod/prodaja	novac+potraživanja /tekuća pasiva
	trend tijek gotovine /ukupne obveze	gotovina na kraju godine/ukupne obveze
		trend prodaje
		trend za dugoročne obveze/kapital
		trend za čisti prihod/ukupna imovina

Izvor: Piramuthu,S., Financial credit-risk evaluation with neural and neurofuzzy systems, European Journal of Operational Research, 112, 1999, pp.310-312

4.4. Modeli bazirani na cijeni dionice

Cijene dionica fluktuiraju tijekom cijelog poslovnog ciklusa, a varijacija u cijeni dionice neke kompanije osigurava pouzdan dokaz promjene u kreditnoj sposobnosti. Vodeći primjer kreditne mjere bazirane na cijeni dionica je EDF mjera. EDF odnosno 'expected default frequency' je mjera vjerojatnosti da će firma otići u default kroz

određeni specifični period vremena, tipično 1 godinu. Prema tom modelu firma defaultira kada tržišna vrijednost imovine (vrijednost on going biznisa) padne ispod obveza koje firma mora podmiriti. Ta se točka naziva 'default point'.

Komponente EDF kreditne mjere:

1. Trenutna tržišna vrijednost firme (tržišna vrijednost imovine)
2. Razina obveza firme (default point)
3. Osjetljivost tržišne vrijednosti na velike promjene (volatilnost imovine)

Tržišna vrijednost imovine

Tržišna vrijednost firme određena je firminom vrijednošću kapitala, volatilnošću kapitala i strukturu obveza. Za izračunavanje tržišne vrijednosti može se primijeniti option-theoretic model. Vrijednost kapitala firme je 'call' opcija (hrv. opcija kupnje) firmine imovine. Opcija daje pravo imatelju da kupi određenu količinu, obično se radi o 100 dionica, od izdavatelja opcije po određenoj cijeni do određenog datuma.

Default point

Default point ili točka defaulta je vrijednost odnosno razina tržišne vrijednosti imovine firme ispod koje bi firma bila neuspješna u plaćanju obveza. Default point je funkcija stukture obveza firme. Kod Moody's KMV EDF točka defaulta je bazirana na ekstenzivnom empirijskom istraživanju koje je obuhvatilo veliki broj defaultiranih firmi gdje se za svaku firmu promatrala točka defaulta u relaciji s tržišnom vrijednošću imovine te firme u vrijeme defaulta.

Volatilnost imovine

Volatilnost imovine je mjeru poslovnog rizika firme. To je standardna devijacija godišnje postotne promjene u tržišnoj vrijednosti imovine firme. Što je veća vrijednost, to je investor manje siguran u tržišnu vrijednost firme i veća je vjerojatnost da će firma pasti ispod točke defaulta.

EDF se izračunava na temelju kapitalne strukture firme, volatilnosti povrata na imovinu i vrijednosti imovine. Model najbolje funkcioniра za one firme koje kotiraju na burzi i za koje je vrijednost kapitala određena na tržištu.

Vjerovatnost defaulta se po ovom modelu određuje u 3 koraka:

1. korak: Procjena vrijednosti imovine i volatilnosti povrata na imovinu

Financijski modeli obično uzimaju u obzir tržišnu vrijednost imovine, a ne knjigovodstvene vrijednosti koja zapravo samo predstavlja povijesni trošak imovine. Izračun tržišne vrijednosti imovine poduzeća i volatilnosti je jednostavan ako se dionicama kompanije svakodnevno trguje na burzi. Alternativno, KMV koristi 'option pricing model' za vrednovanje kao što je Merton postavio u "On the pricing of corporate debt: The risk structure of interest rates (Merton, R., 1974 in Journal of Finance 28, 449-470)".

Primjer:

<i>Vremenski horizont u godinama, H:</i>	1
<i>Tržišna vrijednost imovine (\$ tisuće), V(0):</i>	100
<i>Očekivani godišnji rast imovine, μ:</i>	20%
<i>Volatilnost imovine, σ:</i>	25%
<i>Kratkoročne obveze (\$ tisuće), STD:</i>	40
<i>Dugoročne obveze (\$ tisuće), LTD:</i>	40

2. korak: Izračunati distance to default

Prema Moody's KMV, default se dogodi kada vrijednost imovine dosegne razinu negdje između vrijednosti ukupnih obveza i vrijednosti kratkoročnih obveza. Ta se točka naziva default point (DPT) i prema KMV to je zbroj kratkoročnih obveza i pola dugoročnih obveza. DD odnosno 'distance to default' je broj standardnih devijacija između aritmetičke sredine distribucije vrijednosti imovine i default point odnosno broj standardnih devijacija koliko je dužnik udaljen od defaulta.

Točka defaulta, $DPT = STD + 0.5 LTD$

$$\text{Distance to default, } DD = \frac{1}{\sigma\sqrt{H}} \left[\ln\left(\frac{V(0)}{DPT}\right) + ((\mu - 0.5\sigma^2) \cdot H) \right]$$

Primjer:

<i>Točka defaulta, DPT:</i>	60
<i>Distance to default, DD:</i>	2.7183

3. korak: Izračunati vjerojatnost defaulta

Vjerojatnost defaulta je normalna distribucija od DD.

Vjerojatnost defaulta se može mapirati na rejting skalu.

Primjer:

Vjerojatnost defaulta, $PD=N (-DD)$: 0.003

4.5. Reference

1. Altman,E.I., Financial Ratios, Disriminant Analysis and the Prediction of Corporate Bankruptcy, Journal of Finance 23, 1968, p.189-209
2. Altman, E.I., Haldeman, R.G., Narayanan, P., ZETA Analysis, Journal of Banking and Finance, 1, 1977, p. 29-54
3. Altman, E.I., Marco, G., Varetto, F., Corporate Disteress Diagnosis: Comparison Using Linear Discriminant Analysis and Neural Networks (the Italian Experience), Journal of Banking and Finance, 18, 1994, p. 505-529
4. Altman,E.I., Saunders,A., Credit Risk Measurement: Development Over the last 20 Years, Journal of Banking and Finance, 21, 1998, p.1721-1742
5. Bardos, M., Detecting the Risk of Company Failure, Journal of Banking and Finance, 22, 1998, p. 1-13
6. Beaver,W., Financial Ratios as Predictors of Failure, Empirical Research in Accounting, 1966.
7. Berger, A.N., Scott Frame, W., Credit Scoring and the Price and Availability of Small Business Credit, Credit Scoring and Credit Control VII Conference, Credit Research Centre – University of Edinburgh, 5-7 September, 2001
8. Caouette, J.B., Altman, E.I., Narayanan, P., Managing Credit Risk, John Wiley & Sons, New York, 1998
9. Johnsen, T., Melicher, R.W., Predicting Corporate Bankruptcy and Financial Distress: Information Value Added by Multinomial Logit Models, Journal of Economics and Business, 1994, p. 269-286
10. Piramuthu,S., Financial Credit-Risk Evaluation with Neural and NeroFuzzy Systems, European Journal of Operational Research, 112, 1999, p.310-312

11. Platt, H.D., Platt, M.B., A Linear Programming Approach to Bond Portfolio Selection, Economic Financial Computing, 1991, p.71-84.
12. Rowland,J., Credit Scoring – Big Opportunities for Small and Start-up Businesses, Credit World, Sep/Oct95, Vol.84, Issue 1, p. 21-25
13. Scott, J., The Probability of Bankruptcy, Journal of Banking and Finance 5, 1981, p. 317-344
14. Tintor, J., Potraživanja, kreditna sposobnost i zarada, Poslovna analiza i upravljanje, Zagreb, 1996