

PROCJENA KREDITNOG RIZIKA PODUZEĆA U HRVATSKOJ

Lana IVIČIĆ*
Hrvatska narodna banka, Zagreb

Izvorni znanstveni članak**
UDK 336.71
JEL G12

Saša CEROVAC*
Hrvatska narodna banka, Zagreb

Sažetak

Glavni cilj ovog rada jest modeliranje kreditnog rizika nefinancijskih poslovnih subjekata procjenjivanjem vjerojatnosti migracija rejtinga i prognoziranjem vjerojatnosti neurednog podmirivanja kreditnih obveza u razdoblju od jedne godine na temelju financijskih izvješća poduzeća. Naše istraživanje donosi nekoliko novih važnih spoznaja. Matrice migracija rejtinga, u svakom su promatranom razdoblju simetrične, što pokazuje da neuredno podmirivanje obveza nije konačno stanje. Otkrili smo visok stupanj stabilnosti rejtinga, uz iznimku volatilnosti uzrokovane poduzećima u sredini ljestvice rejtinga. U razdoblju sporijega ekonomskog rasta vjerojatnost prijelaza između različitih kategorija rizika manja je nego u razdoblju bržega ekonomskog rasta. Vjerojatnost neurednog podmirivanja obveza relativno je stabilna u poduzećima koja posluju u različitim gospodarskim područjima. Nakon razmatranja mnoštva potencijalnih pokazatelja neurednog podmirivanja kreditnih obveza, rezultati multivarijantne logističke regresije otkrivaju da su najvažniji omjer dioničkog kapitala prema ukupnoj imovini te omjer zarade prije odbitka kamata i oporezivanja prema ukupnim obvezama, koji negativno koreliraju s vjerojatnošću neurednog podmirivanja kreditnih obveza. Usto, veća likvidnost, profitabilnosti i prodaja, kao i povezanost sa sektorom građevine i nekretnina, smanjuju mogućnost neurednog podmirivanja obveza poduzeća u sljedećoj godini. Model ispravno klasificira relativno razuman postotak poduzeća u uzorku (74% svih poduzeća, 71% poduzeća koja neuredno podmiruju svoje kreditne obveze i 75% poduzeća koja svoje obveze uredno podmiruju) kada je intervencijska vrijednost postavljena tako da maksimizira zbroj ispravno

* Autori zahvaljuju anonimnim recenzentima na korisnim sugestijama koje su pridonijele poboljšanju članka.

** Primljeno (Received): 1.6.2009.

Prihvaćeno (Accepted): 3.11.2009.

predviđenih udjela i poduzeća koja neuredno podmiruju svoje obveze i onih koja ih uredno podmiruju.

Ključne riječi: kreditni rizik, neuredno podmirivanje kreditnih obveza poduzeća, migracijske matrice, logit

1. Uvod

Modeliranje kreditnog rizika područje je istraživanja i sudionika na tržištu i regulatora tržišta, s tim da su regulatori zaduženi za stabilnost ukupnoga financijskog sustava, kao i za obavljanje zadataka nadzora pojedinačnih kreditnih institucija. Stoga su središnje banke i drugi financijski regulatori osobito zainteresirani za modeliranje rizika u bankarskom sektoru (Richter, 2007). Cilj ovog rada jest modeliranje kreditnog rizika hrvatskih nefinancijskih poslovnih subjekata te na taj način omogućivanje procjene profila rizika pojedinih banaka s obzirom na njihove plasmane sektoru poduzeća i fluktuacije u ukupnom riziku.

Ukratko, u radu se istražuju mogućnosti prognoziranja izloženosti kreditnom riziku, uz istodobno identificiranje raspodjele rizika u bankarskom sektoru i predviđanje vjerojatnosti promjene adekvatnosti kapitala. Treba napomenuti da je ovo prvi pokušaj uporabe bonitetne baze podataka HNB-a o kreditnoj izloženosti i bilancama poduzeća (FINA-ina baza podataka) kako bi se dobila procjena vjerojatnosti neurednog podmirivanja obveza na razini bankarskog sektora za svako poduzeće koje je važan klijent hrvatskih banaka. Rad donosi ukupnu procjenu razvoja metoda procjena kreditnog rizika poduzeća u Hrvatskoj i zainteresiranoj strani omogućuje primjenu financijskih mikroindikatora bilo kojega poslovnog subjekta kako bi se procijenila vjerojatnost neurednog ispunjavanja kreditnih obveza ili načinila neka vrsta "rejtinga" bilo kojeg poduzeća u Hrvatskoj. Poseban je naglasak stavljen na promatranje i predviđanje promjena u bankovnim portfeljima poduzeća kao na ukupnoj mjeri kreditnog rizika koja je osobito važna u razdoblju krize.

Taj se cilj postiže na dva načina. Prvi se pristup temelji na procjeni vjerojatnosti promjene kreditnog rejtinga. Drugi se pristup koristi podacima iz bilance poduzeća kako bi se predvidjela vjerojatnost neurednog podmirivanja obveza svakog poduzeća. Ti bi se prognostički alati mogli iskoristiti za predviđanje vjerojatnosti neurednog podmirivanja obveza i u konačnici bi mogli rezultirati točnijom procjenom potencijalnih gubitaka u bankarskom sektoru, koji bi nastali kada bi se ti rizici ostvarili.

Najprije se koristimo modelima migracijske matrice kako bismo dobili uvid u stabilnost rejtinga i predvidjeli njegove promjene, otkrivajući strukturu prognoziranu vjerojatnosti neurednog podmirivanja obveza poduzeća. Nadalje, korištenje dodatnih podataka iz bilanci svakog dužnika omogućuje nam modeliranje rizika neurednog podmirivanja obveza primjenom multivarijantne logit-regresije. Statistički model koji se ovdje primjenjuje općenito dopušta simuliranje različitih šokova i izvođenje važnih podataka o vjerojatnosti neurednog podmirivanja obveza i o gubicima ako podmirivanje obveza bude neuredno gledajući unatrag do pojedine banke ili skupine banaka. Takav se pristup uvelike

primjenjuje kako bi se unaprijedili sustavi stres-testiranja (Andersen i sur., 2008) kojima se koriste središnje banke i ostali sudionici na tržištu (grafikon 1. u dodatku).

Istraživanje je organizirano na sljedeći način: poglavlje 2. daje kratki pregled prijašnjih povezanih istraživanja; poglavlje 3. opisuje skupine podataka i prethodnu potrebnu obradu podataka; poglavlje 4. objašnjava glavne definicije i opće koncepte kreditne ocjene i neispunjenja obveza, a poglavlje 5. prikazuje migracijske matrice kreditnog rejtinga. Modeliranje neurednog podmirivanja kreditnih obveza, primijenjena metodologija, univarijantna analiza i rezultati multivarijantnog modela prikazani su u poglavlju 6. Na kraju, poglavlje 7. ukratko navodi glavna otkrića i zaključuje istraživanje prijedlozima smjerna budućih istraživanja.

2. Pregled literature

Od 1960-ih godina objavljena je opsežna literatura o bankrotu poduzeća. Prve radove napisao je Beaver (1966), koji je otkrio da se prema nekim pokazateljima u univarijantnim analizama mogu razlikovati tvrtke koje su bankrotirale od onih koje nisu, te Altman (1968), koji je predložio primjenu linearne višestruke diskriminacijske analize (MDA). Kasnija istraživanja obuhvaćaju mnoge dopune te rane metodologije, ali su često kritizirana jer nerijetko nisu bile ispunjene restriktivne pretpostavke¹ modela višestruke diskriminacijske analize.

Kako bi izbjegao neke probleme MDA pristupa, Ohlson je (1980) bio prvi koji je upotrijebio logističku regresiju u predviđanju bankrota poduzeća koristeći se objavljenim financijskim izvješćima. Otkrio je negativnu korelaciju između vjerojatnosti bankrota i veličine, profitabilnosti i likvidnosti poduzeća, te pozitivnu korelaciju između vjerojatnosti bankrota i zaduženosti poduzeća.

Otada se logistička regresija uvelike primjenjuje za razvijanje modela bankrota poduzeća koja se ne listaju na burzi, a ispitivano je mnoštvo eksplanatornih varijabli. Nastavak Ohlsonova istraživanja uključuje, među ostalim, istraživanje koje su proveli Platt i Platt (1990), a kojim su razvijeni modeli za posebne gospodarske djelatnosti i otkriveno da vjerojatnost bankrota ovisi o sektoru u kojemu poduzeće posluje; slične zaključke iznijeli su i Bernhardsen (2001) te Lykke, Pedersen i Vinther (2004).

Bernhardsen je (2001) uveo specifikaciju logit-modela koja uzima u obzir fleksibilne stope kompenzacije, što je suprotno uobičajenoj specifikaciji koja se primjenjuje u modelu predviđanja bankrota u kojih su stope prema kojima dvije varijable mogu zamijeniti jedna drugu (uz nepromijenjeni predviđeni rizik) konstantne. Popis eksplanatornih varijabli sadržavao je pokazatelje likvidnosti, profitabilnosti, vlastitog financiranja i zaduženosti, starost i veličinu tvrtke te neke pokazatelje specifične za djelatnost. Uz financijske omjere, Lykke, Pedersen i Vinther (2004) otkrili su da su kvalitativne nefinancijske varijable važne za objašnjenje vjerojatnosti bankrota danskih poduzeća. Među ostalima, vjerojatnost bankrota povećavaju kritički komentari revizora i smanjenje osnove kapitala.

¹ Te restriktivne pretpostavke glase: a) nezavisne su varijable normalna matrica s više od dvije varijable, b) matrice kovarijance dvaju poduzoraka (bankrotiranih i nebankrotiranih) ekvivalentne su.

Charitou, Neophytou i Charalambous (2004) u predviđanju financijskih problema istraživali su inkrementalni sadržaj podataka novčanog toka od primarne djelatnosti. Upotrijebili su i logit-metodologiju i neuralne mreže kako bi razvili model predviđanja za industrijska poduzeća u Ujedinjenom Kraljevstvu te otkrili da se oba modela mogu iskoristiti za predviđanje bankrota. Njihovi empirijski rezultati pokazuju da novčani tok od glavne djelatnosti poduzeća (zajedno s druga dva financijska pokazatelja) u predviđanju bankrota poduzeća ima diskriminatornu moć.

Rad Jacobsona i sur. (2008) empirijski dokazuje da dodavanje makroekonomskih podataka u jednostavne logističke modele s faktorima koji su specifični za određeno poduzeće pridonosi objašnjenju vjerojatnosti neurednog podmirivanja obveza. Takav rezultat navodi na zaključak da makroekonomski faktori mijenjaju distribuciju rizika od neurednog podmirivanja obveza tijekom vremena, zbog čega su najvažniji izvor određivanja razine rizika od neurednog podmirivanja obveza.

Posljednjih se godina mnogo pozornosti pridaje izboru metodologije. Metode poput rekurzivne podjele, neuralnih mreža i genetičkog programiranja uobičajeno se primjenjuju pri problemima predviđanja bankrota. Međutim, još se uvijek često rabe logit-modeli, a središnje banke iz europa područja obično se koriste takvim modelima pri određivanju prikladnih jamstava za refinanciranje poslovanja. Sustav procjene internog kredita austrijske središnje banke (OeNB)² sadržava četiri logit-modela (jedan osnovni i tri modela specifična za industriju), kao i kvalitativnu procjenu kreditnog rizika s austrijskim poduzećima. Eksplanatorne varijable obuhvaćaju računovodstvene pokazatelje i neke opće podatke ovisno o poduzeću. Falcon (2007) prikazuje metodologiju koja se temelji na logit-modelima kojima se koriste Banco i España za internu procjenu kreditne sposobnosti nefinancijskih poduzeća. Nakon testiranja brojnih financijskih pokazatelja uočeno je da su pokazatelji solventnosti najsnažniji faktori u prognoziranju neurednog podmirivanja obveza. Neki opći zaključci govore da nelinearni logiti daju znatno bolje rezultate od linearnih kad je riječ o snazi predviđanja, da makroekonomska okolina ima važnu ulogu u predviđanju neurednog podmirivanja obveza te da je rast BDP-a varijabla koja daje najbolja predviđanja.

3. Podaci

Za ovo istraživanje koristimo se dvjema primarnim skupinama podataka. Relevantni podaci o izloženosti banaka i kreditnom rejtingu (koji se upotrebljavaju pri izradi tromjesečnih statistika o neurednom podmirivanju obveza) dobiveni su iz bonitetne baze podataka Hrvatske narodne banke (HNB), koja utvrđuje izloženost banke s obzirom na značajne dužnike (o pojedinostima v. HNB, 2003). Ta baza podataka služi za analizu kreditnog rejtinga i rizika od neurednog podmirivanja obveza na temelju migracijskih matrica. Godišnja baza podataka financijskih izvješća poduzeća, koju pribavlja Financijska agencija (FINA), služi za izvođenje dodatnih podataka korištenih u regresijskoj analizi rizika od neurednog podmirivanja obveza. Podnošenje godišnjeg izvješća pravna je obveza i FINA navodi da velika većina poduzeća podnosi izvješća i da samo neznatan broj podu-

² Winkler (2008).

zeća zanemaruje tu obvezu. Broj poduzeća u bazi podataka govori u prilog tvrdnjama da je više od 60.000 poduzeća podnijelo svoja izvješća u 2006. i 2007. godini (godine relevantne za našu namjeru), iako je analiza otkrila neke nedostatke u bazi podataka, uključujući i poduzeća koja nedostaju te propuste u podacima.

Poduzeto je nekoliko koraka kako bi se podaci provjerili i uklonile uočene pogreške i propusti te kako bi se uzorak prilagodio primjeni analitičkog okvira. Kao prvo, potpuna pokrivenost banaka u bazi podataka o izloženosti banaka i detaljni podaci o klasifikaciji rizika počinje od lipnja 2006. godine, čime se ograničava analitički vremenski okvir. Kao drugo, izloženost banaka s obzirom na nerezidente, građanstvo, netržišno orijentirana poduzeća (javnu upravu i obranu) te neidentificirane dužnike, kao i ukupna izloženost za skupine dužnika (ostali dužnici i portfelj malih zajmova) uklonjeni su iz statističke mase. Kao treće, izloženost s obzirom na male identificirane dužnike – one čiji iznos nije prelazio 100.000 kuna (oko 15.000 eura) – također je izostavljena kako bi se smanjila volatilitnost koja bi mogla proizaći iz male izloženosti vezane za dužnike s marginalnim udjelom u ukupnim obvezama poduzeća. Nadalje, uzorak je stabiliziran uklanjanjem poduzeća koja su tijekom bilo kojega promatranog razdoblja ušla i/ili izašla iz baze podataka (vrsta lijevoga i desnog cenzuriranja). To je ograničenje ublaženo u analizi tromjesečne migracijske matrice jer su uklonjena samo poduzeća koja tijekom dva uzastopna tromjesečja nisu bila u bazi podataka.³ Na kraju je prema identifikacijskom broju dužnika konsolidirana sva izloženost banaka s obzirom na svakog dužnika, a višestruki su unosi izbjegnuti davanjem prioriteta koji se temeljio na nadzornim poslovima (identifikacija prema kraticama o izvješćima).

Nakon tih prilagodbi, ne uključujući “cenzuriranje”, preostaje godišnji prosjek od 10.670 dužnika (za razdoblje od jedanaest tromjesečja). Međutim, ovdje prikazana procjena procesa promjena rejtinga nakon uzimanja u obzir i četvrtog koraka nameće dodatno ograničenje u smislu da treba kontrolirati i moguću promjenu ekonomske aktivnosti.⁴ Dakle, izuzeta su poduzeća koja mijenjaju osnovnu djelatnost. Svi ti postupci smanjuju broj poduzeća u našem tromjesečnom uzorku prilagođenome migracijskim matricama na oko ¾ početnog broja poduzeća.

Taj dodatni postupak nije bio potreban za stvaranje regresivnog modela neurednog podmirivanja obveza utemeljenoga na godišnjoj učestalosti. Međutim, potreba da se stoga kombiniraju dvije različite baze podataka (HNB-ova i FINA-ina) također je smanjila broj poslovnih subjekata u uzorku odražavajući pretežito nedostatke FINA-ine baze podataka. Osim toga, uzorak je stabiliziran uklanjanjem poduzeća koja tijekom cijele godine nisu bila u HNB-ovoj bazi podataka. Stoga je skup konačnih podataka reduciran na 7.719 poduzeća tijekom 2007. i 2008. godine tvoreći neujednačenu skupinu koja se sastoji od 12.462 promatranja binarne ovisne varijable, odnosno poduzeća za koje imamo podatke o tome jesu li tijekom određene godine podmirivala obveze ili nisu. Taj uzorak razjašnjava više od 75% izloženosti banaka prema tržišno orijentiranim poduzećima.

³ Nažalost, nije bilo moguće provjeriti razlog svakoga pojedinog izuzimanja iz baze podataka, pa nije bilo moguće razlikovati eliminaciju izlaganja (zbog otplate ili smanjenja duga) i nepodnošenje financijskih izvješća.

⁴ Poduzeća smo grupirali u tri sektora ovisno o Nacionalnoj klasifikaciji djelatnosti (NKD): industrija i poljoprivreda (NKD kategorije A, B, C, D, i E), građevina i nekretnine (NKD kategorije F i K) i nefinancijske usluge (NKD kategorije G, H i I).

Skup eksplanatornih varijabli pokriva široku skupinu varijabli (84 potencijalno relevantna financijska pokazatelja) koje su se pokazale uspješnim u predviđanju neurednog podmirivanja obveza u prijašnjim istraživanjima i koje se mogu grupirati na sljedeći način: pokazatelji likvidnosti (16), pokazatelji solventnosti (23), pokazatelji aktivnosti (12), pokazatelji ekonomičnosti (7), pokazatelji profitabilnosti (27) i pokazatelji ulaganja (1) (v. dodatak).

Godišnja financijska izvješća poduzeća, koja sadržavaju podatke za kraj prethodne godine, služe za predviđanje kreditnog rizika u idućem razdoblju. S obzirom na to da se računovodstveni podaci obično objavljuju s vremenskim odmakom od nekoliko mjeseci, financijski podaci obično budu raspoloživi tijekom iste godine za koju se procjenjuje kreditni rizik. Unatoč tome, i takvi su zakašnjeni podaci korisni jer su temelj za prognoze do kraja godine. Osim toga, kako dulji vremenski nizovi postaju raspoloživi, horizont predviđanja se proširuje.

Netipične su vrijednosti korigirane kako bi se spriječila moguća pristranost. Uočene ekstremne vrijednosti financijskih pokazatelja nisu uklonjene kako bi se izbjeglo smanjenje veličine uzorka (imajući na umu da su ta ekstremna opažanja najčešće povezana s poduzećima koja imaju problema, a njihovo bi uklanjanje u uzorku još više smanjilo broj poduzeća koja neuredno podmiruju svoje obveze). Umjesto toga, netipične su vrijednosti zamijenjene odabranim graničnim vrijednostima (tipično 1. i 99. percentilom promatrane varijable, ali neke su varijable transformirane asimetrično, što znači da su zamijenjene samo vrijednosti manje od 0,5. i 1. percentila ili samo vrijednosti iznad 99. ili 99,5 percentila)⁵. Taj postupak dopušta zadržavanje vrlo niskih i vrlo visokih vrijednosti varijabli, što je koristan unos u model bez gubljenja ostalih podataka za to promatranje.

4. Kreditni rejting i neuredno podmirivanje kreditnih obveza

Baza podataka HNB-a daje samo podatke o klasifikaciji rizika pojedinih izloženosti (plasmani i izvanbilančne obveze), odnosno, nema klasifikacije rizika samih dužnika (za više podataka v. HNB, 2009a). S obzirom na to da klasifikacija plasmana nekom dužniku koju načini pojedinačna kreditna institucija može biti raspodijeljena na nekoliko kategorija rizika, što je sve češći primjer kada se zbroji dug svakog dužnika različitim bankama, zadatak klasificiranja dužnika nije jednostavan.

Svi su plasmani klasificirani u tri široke kategorije rizičnosti ovisno o mogućnosti naplate, odnosno, o očekivanim budućim novčanim tokovima:

- A – plasmani na pojedinačnoj bazi, za koje nije uočen dokaz o narušenosti (standard);
- B – plasmani za koje je uočen dokaz o djelomičnoj narušenosti, odnosno, plasmani koji se mogu djelomično vratiti (podstandard);
- C – plasmani za koje je identificiran dokaz o narušenosti jednak njihovu ukupnom iznosu, potpuno nepovratni plasmani (delinkvent).

⁵ Transformacija je zamjena uočenih netipičnih vrijednosti neekstremnim vrijednostima (prilično uobičajen postupak u literaturi o financijskim pokazateljima). Radi provjere robusnosti takve transformacije načinili smo nizove u kojima su izbrisane sve ekstremne vrijednosti; rezultati procjene nisu se značajno razlikovali od onih koji su dobiveni primjenom transformiranih nizova.

Pravodobnost dužnika u ispunjavanju obveza prema kreditnoj instituciji važan je kriterij ugrađen u navedene sheme klasifikacija i implicira premještanje iz skupine dužnika A u lošiju skupinu dužnika B ako dužnik ima dospjele obveze dulje od 90 do 180 dana te iz skupine B u skupinu dužnika C ako dužnik dospjele obveze ima dulje od 365 dana. Osim toga, potkategorija A, koja sadržava dospjele obveze dulje od 90 dana, ali osigurane prikladnim instrumentima jamstva, navodi se kao A90d. Stoga smo mogli utvrditi iznos obveza koje pripadaju u najnižu kategoriju rizičnosti, a koja se označava kao AX (jednake razlici između A i A90d).

Postupak klasificiranja dužnika u pojedine kategorije rizičnosti (R) primijenjen u ovom radu temelji se na rješavanju jednostavnog problema optimizacije koji potječe iz distribucije rizika ukupne izloženosti: tražimo najvišu vrijednost (T) udjela sukcesivnoga kumulativnog iznosa izloženosti (S) koji pripada posebnom rasponu kategorije rizičnosti (r koji se kreće od C do AX) za svakog dužnika tako da je istodobno maksimiziran iznos izloženosti klasificiran kao AX u skupini dužnika koji bi bili klasificirani kao AX i iznos izloženosti klasificiran kao ne-AX među svim ostalim dužnicima. Formalno,

$$Sr = \sum_{r=C}^{\text{sukc. rejting}(m)} \text{izloženost}_r / \text{ukupna izloženost} \geq T \Rightarrow r_m = R_{\text{dužnik}} \quad (1)$$

Nalazimo da je granična vrijednost $T=0,5$ (graf. 2). Rezultati pokazuju da distribucija ukupnih izloženosti koje su “ispravno” dodijeljene poduzećima (usklađivanjem kategorije rizika izloženosti i rejtinga dužnika) nije osobito osjetljiva na varijacije intervensijske vrijednosti u velikoj blizini T .

Definiranje nastanka događaja nepodmirivanja obveza zadnji je korak koji nam kasnije omogućuje da utvrdimo jedan od ključnih parametara u procjeni kreditnog rizika – vjerojatnost neurednog podmirivanja kreditnih obveza. Slijedeći odredbe *Bazelskog odbora za nadzor banaka* (Basel II Accord), prihvaćamo sljedeću definiciju događaja nepodmirivanja obveza (*Official Journal of the European Union*, L177, str. 113):

“Smatra se da se *nepodmirivanje obveza plaćanja* s obzirom na određenog dužnika dogodilo kada se dogode jedan ili oba ova događaja:

- kreditna institucija smatra da je malo vjerojatno da će dužnik u potpunosti platiti svoje kreditne obveze prema instituciji, matici ili nekoj njezinoj podružnici a da kreditna institucija ne poduzme radnje poput aktiviranja instrumenata osiguranja (ako ih ima);
- dužnik nije podmirio nikakve materijalne kreditne obveze prema kreditnoj instituciji, matici ili nekoj njezinoj podružnici više od 90 dana nakon dospijeca.”

To znači da se u promatranom primjeru događaj nepodmirivanja obveza⁶ dogodio dužnicima koji su uvršteni u skupinu ne-AX. Na prvi pogled, kao što se moglo i očekivati, primjećuje se da je većina dužnika u svakom promatranom razdoblju podmirivala svoje

⁶ Važno je razlikovati neuredno podmirivanje kreditne obveze (kada dužnik nije u stanju potpuno ispuniti svoje obveze prema kreditnoj instituciji na temelju glavnice, kamate, provizije i ostaloga u ugovornom iznosu i unutar ugovornih vremenskih granica) od delinkvencije, nesolventnosti, bankrota i likvidacije.

obveze. Raspodjela kreditnog rejtinga drugih dužnika otkriva prilično stabilnu strukturu procjene neurednog podmirivanja obveza od lipnja 2006. do prosinca 2008. godine: gotovo 8% pripada kategoriji rizika B, 5% ulazi u kategoriju rizika C, a oni koji su klasificirani kao A90d čine najmanji dio, samo 2%. Zbroj tih dijelova daje prosječnu stopu neurednog podmirivanja obveza za nefinancijska poduzeća (15%).

5. Promjene rejtinga i vjerojatnost neurednog podmirivanja kreditnih obveza

5.1. Matrica promjene

Primjetno obilježje procesa nastajanja rizika jest stvaranje matrica promjene rizika koje generiraju podatke o vjerojatnosti promjene iz rejtinga i u rejting j . Pomno slijedeći Fuertesa i Kalotychoua (2008, str. 5-6), neka S označava prostor promjene, a $i = 1, 2, \dots, k$ kategorije rizika, tako da $P(s, t)$ označava $k \times k$ matricu vjerojatnosti promjene koju stvara kontinuirani Markov lanac⁷ z . Tada je promjena rejtinga u razdoblju između s i t :

$$p_{ij}(s, t) = P(z_t = j | z_s = i), s < t \quad (2)$$

Za svaki horizont promjene Δt određujemo matricu promjene $P\Delta t$ u općem obliku:

$$P = \begin{bmatrix} P_{11} & P_{12} & \cdots & P_{1k} \\ P_{21} & P_{22} & \cdots & P_{2k} \\ \vdots & \vdots & & \vdots \\ P_{k1} & & \cdots & P_{kk} \end{bmatrix} \quad (3)$$

gdje $p_{ij} \geq 0 \quad \forall i, j, \quad \sum_{j=1}^k p_{ij} = 1 \quad \forall i$.

Ako je $N_i(t)$ broj poduzeća i ocijenjenih na početku razdoblja t , a $N_{ij}(t+1)$ broj poduzeća koja su do kraja razdoblja iz i prešla u j , onda je učestalost promjene omjer $N_{ij}(t+1) / N_i(t)$. Koristimo se diskretnim multinominalnim procjeniteljem:

$$\hat{p}_{ij} = \frac{1}{T} \sum_t \frac{N_{ij}(t+1)}{N_i(t)} \quad (4)$$

koji se često primjenjuje i zapravo predočuje poseban slučaj procjenitelja maksimalne vjerojatnosti (MLE) kada je broj poduzeća tijekom vremena konstantan.

5.2. Učestalosti empirijske promjene i prognoze

Izvođenjem matrica promjene jedne godine i jednog tromjesečja (tabl. 1. i tabl. 2) općenito se uočava visok stupanj stabilnosti rejtinga u (nefinancijskim) poduzećima, uz izu-

⁷ Osnovna pretpostavka ocjenjivača matrice promjene jest da rejtinzi nisu međuvremenski i međusektorski ovisni (uvjeti Markovljeve imovine i homogenosti).

zetak volatilnosti koju su stvorila poduzeća ocijenjena kao A90d. Iz tog se postupka može zaključiti sljedeće.

- Jasno je da najviše i najniže ocijenjena poduzeća (AX odnosno C) imaju najmanju učestalost promjena, dok se volatilnost rejtinga u srednjem dijelu ocjenjivačke strukture povećava: za poduzeća ocijenjena kao A90d i, manje, ona koja su ocijenjena kao B. Taj se uzorak može objasniti činjenicom da se poslovna okolina i financijski uvjeti za poduzeća ocijenjena kao AX i C vjerojatno neće znatno promijeniti u kratkom roku (u smislu promjene koja bi utjecala na njihov rejting). Ipak, ti su rizici važniji za poduzeća ocijenjena kao A90d i B, pa je i vjerojatnost da će biti premještena u bolji ili lošiji razred, naravno, veća. To osobito vrijedi za poduzeća koja su ocijenjena kao A90d, a čija ocjena velikim dijelom ovisi o njihovu jamstvu.
- Poduzeća ocijenjena kao A90d i B pokazuju i asimetrični uzorak migracije: vjerojatnost da budu premještena u viši razred veća je od vjerojatnosti da budu premještena u niži.
- Monotonost promjene rejtinga – postupna izmjena učestalosti promjena do krajnjih ocjena za svaku početnu ocjenu – uopće nije promatrana u jednogodišnjoj matrici promjena, ali je djelomično promatrana za tromjesečnu učestalost, barem za poduzeća koja su ocijenjena kao A.
- Marica tromjesečja, koja ima više informativni sadržaj, mijenja učestalost promjena tako da se vrijednosti parametara na dijagonali matrice povećavaju, odnosno, otkriva se još veća stabilnost rejtinga. Za razliku od jednogodišnje matrice, relativni stupanj učestalosti promjena za svako poduzeće ocijenjeno kao i na početku promatranog tromjesečja promijenio se samo za poduzeća koja su ocijenjena kao A90d: $\hat{P}_{A90d} \quad A90d > \hat{P}_{A90d} \quad B$.
- Sve su matrice simetrične, tj. nema apsorbirajućeg stanja i koje zadovoljava $P_{ik} = 1, \sum_{j=1}^k P_{ij} = 1$. Važno je da to implicira kako stanje neurednog podmirivanja obveza (ocjena A90d, B ili C) nije konačno stanje, odnosno kako je svako stanje reverzibilno, pa da je zavisna varijabla u našoj logit-regresiji (pogl. 6) oblikovana dvosmjerno. Na primjer, jednogodišnja matrica promjena pokazuje da vjerojatnost neurednog podmirivanja obveza (PD) iznosi 5%, a vjerojatnost promjene iz stanja neurednog podmirivanja obveza u stanje njihova urednog podmirivanja (PR)⁸ blizu 12%. Stoga se broj poduzeća u stanju neurednog podmirivanja obveza povećava za ΔN_D , ovisno o obje te vjerojatnosti⁹:

$$\Delta N_D = PD * N_{AX} - PR * N_{non-AX} \quad (5)$$

- Zanimljivo je da struktura PD-a (na temelju godišnje učestalosti) pokazuje dominantan udjel poduzeća ocijenjenih kao B, poduzeća ocijenjena kao A90d čine sred-

⁸ Formalno, $PR_i = 1 - D_i, \forall i \neq AX$; pri tome je D vjerojatnost ostajanja u stanju neurednog podmirivanja kreditnih obveza (A90d, B ili C).

⁹ PD "prilagođen" broju poduzeća koja se vraćaju iz stanja neispunjenja obveza u prosjeku je tri puta manji (na temelju tromjesečne učestalosti).

nji udjel, a ona ocijenjena kao C njegov najmanji dio. Istodobno, dok A90d još uvijek obuhvaća većinu poduzeća koja neuredno podmiruju svoje obveze, a ostala su u tom stanju više od godine dana, ostatak poduzeća gotovo isključivo čine najniže ocijenjena poduzeća.

- Redosljed ocjena prema relativnom udjelu i učestalosti migracija iza PR jest: A90d, B, odnosno C.
- Ocjene i PD (PR) pokazuju pozitivnu (negativnu) korelaciju (graf. 3).
- Uvjetne tromjesečne matrice daju daljnji uvid u proces migracije rejtinga. Učestalost promjena uvjetovali smo konjunkturnim ciklusom i ekonomskom aktivnošću¹⁰.
- Očito je da razdoblje zakašnjenja povećava stabilnost kreditnog rejtinga dok se PR sustavno smanjuje. Promatrajući povijesne vremenske nizove stopa neispunjenja obveza (graf. 4), također je jasno da su tijekom posljednja četiri tromjesečja stope sklone rastu (u svim sektorima), ali ništa ne pokazuje da na njih znatnije utječe (s obzirom na njihove povijesne vrijednosti) nedavna financijska kriza, što se teško može očekivati u bliskoj budućnosti.
- Čini se da PD nije osjetljiv na ekonomsku aktivnost. Nefinancijske usluge pokazuju najveću sličnost sa svojstvima bezuvjetne matrice, ali je PR umjereno manji u industriji i veći u sektoru građevine, gdje nalazimo i dokaz relativno najveće nestabilnosti rejtinga.

Nedovoljan broj opažanja ne dopušta nam izgradnju modela uređene ovisne varijable (multinomijalni logit) koji bi nam omogućio stvaranje prognoza o vjerojatnosti neurednog podmirivanja obveza uvjetovanih razdobljem ciklusa i ekonomskom aktivnošću (v. npr. Nickell, Perraudin i Varotto, 2001), tako da se zasad koristimo samo jednostavnim bezuvjetnim pristupom modelu promjene rejtinga. Za horizont $n\Delta t$ (gdje je Δt jedno tromjesečje ili jedna godina, ovisno o matrici) vjerojatnost promjene predviđa se kao $P^n_{\Delta t}$. Jednogodišnja prognoza promjena, koja se temelji na matrici jedne godine ($n = 1$) i matrici jednog tromjesečja ($n = 4$), prikazana je u tablici 3. Vjerojatnost neurednog podmirivanja obveza za 2009. godinu povećana je (PD doseže gotovo 6%), kao i vjerojatnost preokreta, i to najviše za poduzeća koja su ocijenjena kao A90d, a najmanje za ona koja su ocijenjena kao C.

¹⁰ Za vrijeme promatranog razdoblja nije bilo klasičnih konjunkturnih ciklusa (kontrakcija ekonomske aktivnosti), pa smo se koristili konceptom ciklusa porasta (razdoblje ubrzanja: 3q2006-3q2007; razdoblje zakašnjenja: 4q2007-4q2008; na temelju kratkoročnih fluktuacija realnog bruto domaćeg proizvoda). Uvjeti su općenito ograničeni na mali broj varijacija (ovdje na dva ciklička razdoblja i tri kategorije ekonomske aktivnosti) kako bi se izbjeglo smanjenje veličine poduzorka. Mogući učinci uvjetovanja matrica prikazani su na grafu 5. u dodatku.

6. Modeliranje neurednog podmirivanja kreditnih obveza

6.1. Multivarijantna logit-regresija

Vjerojatnost neurednog podmirivanja obveza u ovom se radu procjenjuje uz pomoć metode maksimalne vjerojatnosti u sklopu logističke regresije.¹¹

Neka je binarno promatranje stope neurednog podmirivanja obveza poduzeća (kontinuirana varijabla):

$$Y_{i,t} = 1 \text{ ako je poduzeće } i \text{ u stanju neurednog podmirivanja obveza}^{12} \text{ i } 0 \text{ ako nije} \quad (6)$$

Binarnu varijablu neurednog podmirivanja obveza $y_{i,t}$ objašnjava skup faktora X . Stoga je vjerojatnost da poduzeće neuredno podmiruje svoje obveze:

$$P(y_{i,t} = 1 \mid X_i) = F[X_i, \beta] \quad (7)$$

gdje je X_i skup K eksplanatornih varijabli za poduzeće i , a β skup parametara. Koristeći se logit-funkcijom, očekivana se vjerojatnost da poduzeće neće uredno podmirivati svoje obveze može napisati kao:

$$F[X_i, \beta] = 1 / (1 + e^{-w}); \quad w = \beta_0 + \beta_{1,t}x_{1,t} + \dots + \beta_{k,t}x_{k,t} \quad (8)$$

Logit-model jamči da je $F[X_i, \beta]$ ograničen na interval $[0, 1]$.

6.2. Odabir eksplanatornih varijabli

Kako bi se identificirale moguće razlike između poduzeća koja neuredno podmiruju svoje obveze i onih koja ih uredno podmiruju, najprije se za svaku eksplanatornu varijablu izračuna nekoliko glavnih deskriptivnih statističkih podataka (srednja vrijednost, medijan, standardna devijacija, minimum i maksimum). Slijedi nekoliko koraka s ciljem ispitivanja njihova statističkog odnosa s neurednim podmirivanjem obveza poduzeća i eksplanatornom moći.

Najprije je statistički testirana jednakost srednje vrijednosti svih pokazatelja u odnosu prema zavisnoj varijabli. Tablica 5. u dodatku pokazuje da su poduzeća koja ne ispunjavaju obveze općenito manje likvidna, više zadužena, imaju manji promet i niže pokazatelje profitabilnosti. Provedeni su testovi omogućili identificiranje eksplanatornih varijabli koje najviše obećavaju pri uključivanju u model. Odabrane su varijable ušle u sljedeću fazu testiranja, u kojoj su grafički analizirani vrsta i predznak odnosa između oda-

¹¹ U kontekstu modeliranja kreditnog rizika logit-modeli imaju nekoliko prednosti: ne pretpostavljaju multivarijantnu normalnost; transparentne su u procjeni važnosti svake varijable; dopuštaju dobivanje direktne procjene *PD*; pokazuju dobre prognostičke rezultate u usporedbi s drugim tehnikama i dobro rade s kvalitativnim eksplanatornim varijablama (Falcon, 2007).

¹² Razlikujemo vjerojatnost da se bude u stanju neurednog podmirivanja kreditnih obveza (razdoblje koje karakterizira neuspjeh dužnika da u potpunosti ispuni svoje obveze prema kreditnoj instituciji) i vjerojatnost neurednog podmirivanja kreditnih obveza (dogadaj prelaska u stanje neurednog podmirivanja obveza).

branih varijabli i vjerojatnost neurednog podmirivanja obveza. Za svaku je varijablu¹³ načinjen grafikon raspršenja koji pokazuje prosječnu stopu neurednog podmirivanja obveza za svaki raspon percentila eksplatorne varijable (v. graf. 7. u dodatku). Ti su brojevi pokazali postoji li značajan odnos između neispunjenja obveza i svake varijable, kao i monotonost, oblik i predznak tog odnosa. Nadalje, provjereno je je li znak odnosa za svaku varijablu bio očekivan, a varijable koje su pokazivale neočekivani predznak odnosa, kao i varijable kojima je nedostajala bilo kakva korelacija s rizikom od neurednog podmirivanja obveza ili one koje su pokazivale jasno nemonoton odnos također su uklonjene iz skupine. Predznak odnosa za većinu je eksplanatornih varijabli bio u skladu s prethodnim očekivanjima – npr. čini se da se rizik od neurednog podmirivanja obveza smanjuje kako se poboljšavaju pokazatelji likvidnosti i ekonomske aktivnosti; nasuprot tome, rizik od neurednog podmirivanja obveza veći je kada se povećava financijska poluga.

Kako bi se prepoznale varijable s najvećom eksplanatornom moći, za svaku je odabranu varijablu procijenjen univarijantni logit-model, a izvedene su i odgovarajuće ROC krivulje.¹⁴ Odabir statistički značajnih varijabli sa zadovoljavajućom razinom pseudo R² i područjem ispod ROC krivulje doveo je do odabira 28 varijabli kandidata: 4 pokazatelja likvidnosti, 10 pokazatelja vlastitog financiranja/financijske poluge, 3 pokazatelja ekonomske aktivnosti, 1 pokazatelj ekonomičnosti, 8 pokazatelja profitabilnosti i 2 pokazatelja veličine poduzeća (tabl. 6. u dodatku).

Čini se da među njima pokazatelji profitabilnosti imaju najveću sposobnost univarijantne klasifikacije s područjima ispod ROC krivulje (AUC) od 0,69 do 0,75 (najbolji je omjer ukupne prodaje prema ukupnim obvezama s AUC od 0,75). Među pokazateljima likvidnosti najbolji je omjer gotovine prema ukupnoj imovini. Usto, čini se da je pokazatelj vlastitog financiranja ujedno i dobar individualni pokazatelj neurednog podmirivanja obveza jer omjeri vlasničkog kapitala prema ukupnoj imovini i ukupnim obvezama dosežu područje AUC vrijednosti veće od 0,70.

6.3. Procjena modela multivarijantne logističke regresije

Nakon univarijantne analize i uzimanja u obzir korelacija između varijabli¹⁵, testirani su brojni modeli koji su obuhvaćali različite skupine varijabli. Problemi koji su proizašli iz multikolinearnosti, kao i dodatni gubici opažanja do kojih je došlo kada je povećan broj eksplanatornih varijabli, ograničili su preširok skup varijabli. Stoga je među najboljim kombinacijama triju, četiriju, pet i šest računovodstvenih varijabli odabran konačni multivarijantni model (tabl. 7), zajedno s indikatorskom varijablom koja pokazuje bavi li se poduzeće građevinom i poslovanjem s nekretninama, što se pokazalo jedinim značajnim indikatorom ekonomske aktivnosti.

¹³ Neke varijable koje su pokazivale veliko rasipanje preoblikovane su kako bi bile bliže normalnoj raspodjeli; promjena koja je primijenjena bila je $(\text{znak}(y) * \text{abs}(y)^\lambda + 1) / \lambda$ uz $\lambda = 0,1, 0,15$ ili $0,2$.

¹⁴ ROC (Receiver Operating Characteristics) krivulja jest grafičko predočivanje odnosa između osjetljivosti i (1-specifičnosti) modela svih mogućih intervencijskih vrijednosti, pri čemu osjetljivost znači mogućnost ispravne klasifikacije pojedinca čija je promatrana situacija "neuredno podmirivanje kreditnih obveza", a specifičnost vjerojatnost ispravnog klasificiranja pojedinca čija promatrana situacija "nije neuredno podmirivanje kreditnih obveza". Područje ispod ROC krivulje mjera je prognostičke snage modela: više područje odgovara većoj točnosti predviđanja.

¹⁵ Podaci o matrici korelacija dostupni su na zahtjev.

Glavna načela u odabiru najboljeg modela od pet modela kandidata bila su: a) već predložene i teoretski opravdane varijable, b) statistička važnost procijenjenih parametara, c) podobnost modela s obzirom na pseudo-R² ¹⁶, d) područje ispod ROC krivulje kao mjera točnosti modela i e) ukupna sposobnost modela za točnu klasifikaciju. Važno je napomenuti da sve varijable u mogućim modelima kandidatima pokazuju isti predznak i sličnu veličinu procijenjenih koeficijenata u različitim specifikacijama i da pokazuju robusnost s obzirom na uključivanje dodatnih varijabli ili njihovo uklanjanje iz procijenjene jednadžbe.

Modele kandidate s tri, četiri i pet financijskih pokazatelja pomalo su nadmašila dva modela sa šest financijskih pokazatelja, osobito u odnosu prema sposobnosti točne klasifikacije poduzeća. Ta se dva modela razlikuju samo u jednoj varijabli i daju vrlo slične rezultate s obzirom na pseudo-R², područje ispod ROC krivulje i postotak točno klasificiranih poduzeća koja neuredno podmiruju svoje obveze i onih koja ih uredno podmiruju. Međutim, više malih razlika utjecalo je na to da se odlučimo za model 6.1.¹⁷

Odabranim se modelom procjenjuje vjerojatnost neurednog podmirivanja obveza na temelju veličine poduzeća (mjerene ukupnom prodajom), indikatorske varijable građevine i nekretnina te pet financijskih pokazatelja: pokazatelja likvidnosti (mjerena kao omjer gotovine prema ukupnoj imovini), pokazatelja vlastitog financiranja (dionički kapital prema ukupnoj imovini), pokazatelja aktivnosti (promet potraživanja u danima) i dva pokazatelja profitabilnosti (zarada prije kamata i oporezivanja prema ukupnim obvezama te prodaja i amortizacija prema ukupnoj imovini). Ta jednadžba glasi:

$$F[X_i, \beta] = \frac{1}{1 + e^{-(0,17 - 0,28D_{it} - 0,63w_{-1}_{10_{it}} - 1,96w_{-2}_{2_{it}} + 0,09w_{-3}_{4_{it}} - 0,14w_{-5}_{16_{it}} - 0,37w_{-5}_{22_{it}} - 0,01w_{-7}_{5_{it}})}}} \quad (9)$$

Sve varijable u procijenjenom modelu značajne su na razini 1%, a koeficijenti povezani s tim varijablama imaju očekivane predznake. Magnitude procijenjenih marginalnih učinaka¹⁸ u skladu su s našim očekivanjima (v. tabl. 8. u dodatku): najveći marginalni učinci povezani su s pokazateljem vlastitog financiranja (dionički kapital prema ukupnoj imovini) i pokazateljem profitabilnosti.

¹⁶ Pseudo-R² slično konvencionalnoj R² mjeri modela linearne regresije. Moguće ga je interpretirati kao stupanj na kojemu se distribucija predviđenih vjerojatnosti neurednog podmirivanja obveza zdravih poduzeća ne podudara s distribucijom predviđenih vjerojatnosti neurednog podmirivanja obveza za poduzeća koja svoje obveze nisu uredno podmirivala.

¹⁷ Kao prvo, model 6.1. ima malo manji tip greške I, što je bankama skuplje od tipa greške II (na temelju praga odabranoga za maksimizaciju prosjeka između broja točno klasificiranih pozitivnih i negativnih opažanja). Kao drugo, u modelu 6.4. postoji nešto veća korelacija između dva indikatora financijske autonomije/poluge (0,44) nego između dva pokazatelja profitabilnosti u modelu 6.4. (0,39). Usto, model 6.1. ima veći broj opažanja od modela 6.4, što je vezano za bolju raspoloživost korištenih podataka. Na kraju, eksplanatorna varijabla dobit prije kamata i oporezivanja/ukupne obveze u 6.1. izravnija je u interpretaciji i uobičajenija u povezanoj literaturi nego ona u modelu 6.4. (dobit nakon oporezivanja + amortizacija)/(dug/365).

¹⁸ Marginalni su učinci vrednovani na uzorku srednjih vrijednosti svake varijable. Za kontinuirane varijable izračunava se nagib funkcije vjerojatnosti kako bi se izmjerila promjena prognozirane vjerojatnosti zbog infinitezimalne promjene te varijable. Marginalni učinak na predviđenu vjerojatnost od promjene standardne devijacije za 1 u toj se varijabli tada ekstrapolira iz toga. Za indikatorsku varijablu marginalni se učinak izračunava kao promjena u predviđenoj vjerojatnosti neurednog podmirivanja kreditnih obveza, kada se varijabla promijeni od 0 na 1, uz sve ostale varijable vrednovane prema njihovoj prosječnoj vrijednosti u uzorku.

Veći udjel vlastitog financiranja smanjuje vjerojatnost neurednog podmirivanja obveza. Marginalni učinak povezan s omjerom dioničkog kapitala prema imovini pokazuje da povećanje standardne devijacije za jedan u tom omjeru, na prosječnoj razini, smanjuje mogućnost neurednog podmirivanja obveza u sljedećoj godini za 3 postotna boda, *ceteris paribus*. Vjerojatnost neurednog podmirivanja obveza smanjuje se s rastom profitabilnosti mjerenim zaradom prije kamata i oporezivanja prema ukupnim obvezama te omjerom zbroja prodaje i amortizacije prema ukupnoj imovini. Porast standardne devijacije za jedan od prosječne vrijednosti zarade prije kamata i oporezivanja prema ukupnim obvezama smanjuje vjerojatnost neurednog podmirivanja obveza za tri postotna boda, dok isto povećanje omjera zbroja prodaje i amortizacije prema ukupnoj imovini rezultira vjerojatnošću neurednog podmirivanja obveza manjom za 1,1 postotni bod.

Što je poduzeće likvidnije (mjereno omjerom novca prema ukupnoj imovini), to je manje vjerojatno da neće uredno podmirivati svoje obveze. Porast standardne devijacije za 1% prosječne vrijednosti omjera novca prema ukupnoj imovini smanjuje vjerojatnost neurednog podmirivanja obveza tijekom sljedeće godine za 2 postotna boda, *ceteris paribus*. Manja aktivnost, mjerena brojem dana potrebnih za plaćanje dobavljačima, dovodi do veće vjerojatnosti neurednog podmirivanja obveza, a porast standardne devijacije za 1 iznad prosjeka broja dana povećava vjerojatnost da poduzeće neće uredno podmirivati svoje obveze za 0,3 postotna boda, *ceteris paribus*.

Nakon kontrole svih ostalih faktora također nalazimo veću vjerojatnost da mala poduzeća (mjereno ukupnom prodajom) neuredno podmiruju svoje obveze nego da to čine velika poduzeća. Međutim, koeficijent povezan s tom varijablom vrlo je nizak i porast standardne devijacije za 1 u odnosu prema prosjeku ukupne prodaje smanjuje vjerojatnost neurednog podmirivanja obveza poduzeća za samo 0,04 postotna boda, uz konstantne ostale faktore.

Koeficijent indikatorske varijable sektora građevine i nekretnina negativan je i značajno različit od nule. To implicira da je vjerojatnost neurednog podmirivanja obveza poduzeća, ako ono posluje u sektoru građevine i nekretnina, a ne bavi se poljoprivredom i proizvodnjom ili nefinancijskim uslugama, manja za 0,9 postotnih bodova, *ceteris paribus*. To je uvjerljiv rezultat ako uzmemo u obzir intenzivni rast u sektoru građevine i nekretnina u 2006. i 2007. godini.

Procijenjene distribucije prognozirane vjerojatnosti neurednog podmirivanja obveza poduzeća koja svoje obveze podmiruju i onih koja ih ne podmiruju prikazane su na grafikonu 8. u dodatku. Koristili smo se Kolmogorov-Smirnovim testom (K-S testom)¹⁹ kako bismo testirali nultu hipotezu da su dva uzorka uzeta iz iste distribucije. Kako je i očekivano, nulta je hipoteza bila odbačena na razini od 1%. Model rezultira područjem ispod ROC krivulje od 0,80 (graf. 9. u dodatku). Postotak “lažnih negativna” (pogreška tipa I²⁰)

¹⁹ Test dvaju uzoraka K-S jedna je od neparametrijskih metoda uspoređivanja dvaju uzoraka. Test K-S statistički mjeri udaljenost između empirijske distribucijske funkcije dvaju uzoraka.

²⁰ Modeli binarne klasifikacije imaju jedan od četiri moguća rezultata: a) “istinito pozitivno” (poduzeće koje uredno podmiruje svoje kreditne obveze klasificirano je kao ono koje uredno podmiruje obveze); b) “lažno pozitivno” (poduzeće koje uredno podmiruje obveze klasificirano je kao poduzeće koje neuredno podmiruje obveze); c) “istinito negativno” (poduzeće koje neuredno podmiruje obveze klasificirano je kao poduzeće koje neuredno podmiruje obveze) i d) “lažno negativno” (poduzeće koje neuredno podmiruje kreditne obveze klasificirano je kao poduzeće koje uredno podmiruje svoje obveze). Pogreška vrste I pogreška je klasifikacija poduzeća koja neuredno podmiruju obve-

i "lažnih pozitivna" (pogreška tipa II) ovisi o odabranom pragu neurednog podmirivanja obveza. Odluka koju specifičnu vrijednost vjerojatnosti neurednog podmirivanja obveza treba odrediti kao mjeru vrijednosti donesena je rješavanjem jednostavnog problema optimizacije, pri čemu smo tražili i prag stope neurednog podmirivanja obveza koja maksimizira zbroj postotaka ispravno klasificiranih poduzeća koja neuredno podmiruju obveze i onih koja ih uredno podmiruju.

Nalazimo da granična vrijednost vjerojatnosti neurednog podmirivanja obveza od 0,14 rezultira najvećim zbrojem ispravno klasificiranih postotaka poduzeća koja podmiruju svoje obveze i onih koja ih ne podmiruju. Taj je prag vrlo blizu promatranj učestalosti neurednog podmirivanja obveza u odabranom uzorku (0,15 u 2007; 0,13 u 2008. i 0,14 u razdoblju od dvije godine). Primjenom praga određujemo broj prihvatljivih poduzeća (procijenjena vjerojatnost neurednog podmirivanja obveza manja je od praga) i neprihvatljivih poduzeća (procijenjena vjerojatnost neurednog podmirivanja obveza veća je od praga) te broj pogrešaka u klasifikaciji. Model je sveobuhvatno točno klasificirao 74,4% poduzeća ili 74,9% poduzeća koja uredno podmiruju obveze i 71,2% poduzeća koja ih ne podmiruju uredno.

Alternativno se prag vjerojatnosti neurednog podmirivanja obveza može postaviti na razinu koja maksimizira postotak ukupno ispravno klasificiranih opažanja. Postavljanje praga na 0,55 dalo je 88% ispravno klasificiranih poduzeća. Međutim, korištenjem ovakvog praga ispravno je klasificirano 99% poduzeća koja podmiruju svoje obveze i samo 17% poduzeća koja svoje obveze neuredno podmiruju.²¹ Razlozi te asimetrije u točnosti predviđanja jesu dominacija poduzeća koja uredno podmiruju svoje obveze u uzorku, u kombinaciji s preklapanjem između poduzeća koja neuredno podmiruju svoje obveze, i onih koja ih podmiruju u odnosu prema njihovim profilima rizika, kako je ustanovljeno procjenom modela kreditnog rizika. Imajući na umu da je pogreška tipa I (pogrešna klasifikacija poduzeća koja neuredno podmiruju svoje obveze) općenito skuplja, nalazimo da je prva vrijednost praga relevantnija za tu analizu. Drugo se pitanje odnosi na način na koji banke dodjeljuju rejting rizika svakoj izloženosti i na izradu rejtinga poduzeća. Značajno preklapanje s obzirom na našu procjenu rizika između poduzeća klasificiranih kao poduzeća koja neuredno podmiruju svoje obveze i onih koja ih uredno podmiruju navodi na mogućnost da su neke ocjene precijenjene. O toj vrsti pristranosti selektiranja već je pisano u literaturi. Na primjer, Horink i sur. (2007) uspoređuju rejtinge koje dodjeljuju različiti subjekti i traže primjere mogućega sustavnog precjenjivanja što ga čine neke institucije. Postoje i općenitiji postupci za ispravljanje pristranosti selektiranja koji se primjenjuju u literaturi poput multinomijalnog logita (Bourguignon i sur., 2004). Ta je dopuna ipak ostavljena za buduća istraživanja.

ze, a pogreška vrste II pogrešna je klasifikacija poduzeća koje uredno podmiruju obveze kao poduzeća koja ih podmiruju neuredno.

²¹ Ako je vrijednost praga postavljena niže, općenito će više promatranih poduzeća biti ispravno klasificirano (visoka senzibilnost), ali će se pojaviti velik broj lažnih pozitivna. Nasuprot tome, veća vrijednost praga povećava broj lažnih negativna (poduzeća koja neuredno podmiruju kreditne obveze a klasificirana su kao podobna).

7. Zaključak i preporuke za daljnja istraživanja

Glavni cilj ovog rada jest modeliranje kreditnog rizika nefinancijskih poslovnih subjekata procjenom vjerojatnosti promjene rejtinga i prognoziranjem vjerojatnosti neurednog podmirivanja njihovih obveza u razdoblju od jedne godine, na temelju financijskog računovodstva poduzeća. Relevantni podaci potrebni za procjenu modela dobiveni su iz regulatorne baze bonitetnih podataka HNB-a i financijskog računovodstva pojedinačnih poduzeća koje prikuplja FINA, dok je zavisna varijabla – stanje neurednog podmirivanja obveza – načinjena na temelju rejtinga što su ga poduzećima dužnicima dodijelile komercijalne banke.

Naše istraživanje dalo je neke važne uvide. Otkrili smo da ni u jednoj promatranoj matrici nema apsorbirajućeg stanja, što pokazuje da stanje neurednog podmirivanja obveza nije konačno stanje, tako da je zavisna varijabla u našoj logit-regresiji formirana dvo-smjerno. Općenito nalazimo visok stupanj stabilnosti rejtinga poduzeća, uz iznimku volatilnosti koju stvaraju poduzeća ocijenjena kao A90d. Poduzeća u sredini ljestvice rejtinga također pokazuju asimetrični model promjene što je vjerojatnost njihova prijelaza u bolju skupinu veća od vjerojatnosti prijelaza u lošiju skupinu. To pokazuje da se neka poduzeća koriste neurednim podmirivanjem obveza za vrijeme kriznog razdoblja kao poslovnom strategijom, što banke toleriraju. Nalazimo da je učestalost promjena prilično neosjetljiva na ekonomsku aktivnost poduzeća. Čini se da konjunktorni ciklus ima malu važnost: opazili smo da je u razdoblju sporijeg rasta vjerojatnost obrata (PR) sustavno smanjena. Nefinancijske usluge imaju sličan profil kao bezuvjetna matrica, ali PR je nešto niži u industriji i veći u građevini, gdje nalazimo i dokaze o relativno najvećoj nestabilnosti rejtinga.

Nakon razmatranja širokog niza financijskih pokazatelja i drugih faktora kao potencijalnih pokazatelja neurednog podmirivanja obveza, konačni model predviđa vjerojatnost neurednog podmirivanja obveza tijekom sljedeće godine koristeći se multivarijantnom logističkom regresijom na temelju veličine poduzeća (mjerene ukupnom prodajom), ekonomske aktivnosti (građevina i nekretnine prema ostalim sektorima) i pet financijskih pokazatelja: pokazatelja likvidnosti (mjerena kao gotovina prema ukupnoj imovini), pokazatelja vlastitog financiranja (dionički kapital prema ukupnoj imovini), pokazatelja aktivnosti (promet potraživanja od kupaca u danima) i dva pokazatelja profitabilnosti (zarada prije oporezivanja i kamata prema ukupnim obvezama te prodaja i amortizacija prema ukupnoj imovini). Otkrili smo da su najvažniji pokazatelji rizika neurednog podmirivanja obveza omjer dioničkog kapitala prema ukupnoj imovini i omjer zarade prije kamata i oporezivanja prema ukupnim obvezama (oba su omjera u negativnom odnosu prema vjerojatnosti neurednog podmirivanja obveza). K tome, veća likvidnost, profitabilnost i prodaja, kao i poslovanje u sektoru građevine i nekretnina, smanjuju vjerojatnost neurednog podmirivanja kreditnih obveza poduzeća u sljedećoj godini. Kad je riječ o ulozu gospodarskog sektora, otkriveno je da samo indikatorska varijabla sektora građevine i nekretnina ima značajnu eksplanatornu moć rizika neurednog podmirivanja kreditnih obveza poduzeća. Model ispravno klasificira relativno prihvatljiv postotak poduzeća u uzorku (74% svih poduzeća, 71% poduzeća koja neuredno podmiruju obveze i 75% poduzeća koja ih uredno podmiruju) kada je vrijednost praga postavljena tako da maksimizira zbroj

ispravno predviđenih omjera i poduzeća koja neuredno podmiruju svoje obveze i onih koja ih uredno podmiruju. Unatoč tome, broj poduzeća koja uredno podmiruju svoje kreditne obveze a čija procijenjena vjerojatnost neurednog podmirivanja obveza prelazi izabranu vrijednost praga znatno je veća od broja poduzeća koja doista neuredno podmiruju svoje kreditne obveze, što upućuje na mogućnost pristrane selekcije podataka.

Postoji i nekoliko načina unapređenja opisanog modela kako bi se povećali njegovo područje primjene i eksplanatorna moć. Moguća pristranost selekcije mogla bi se ispraviti verifikacijom ocjena koje daju različiti ocjenjivači (Hornik i sur., 2007) ili multinomijalnim logit-pristupom, kako predlažu Bourguignon i sur. (2004). Osim toga, redefiniranje zavisne varijable (modeliranje događaja neurednog podmirivanja obveza umjesto stanja neurednog podmirivanja obveza) omogućilo bi lakšu interpretaciju i praktičnu primjenu modela. Konačno, promatrani je uzorak ograničen dimenzijom vremenskih serija. Povećano razdoblje uzorkovanja (koje pokriva i sadašnju silaznu fazu konjunktarnog ciklusa) omogućilo bi uključivanje makroekonomskih varijabli u model, na koje povezane studije upućuju kao na značajne pokazatelje vjerojatnosti neurednog podmirivanja kreditnih obveza poduzeća.

Budući da se obilježja podataka razlikuju, važno je biti svjestan činjenice da svaka modifikacija može promijeniti rezultate u smislu stvaranja faktora rizika za različite vremenske horizonte ("točka u vremenu" prema "kroz ciklus"). Zbog toga ne bismo trebali tražiti samo poboljšanje prognoze, već i različite podatke, ovisno o analitičkim potrebama.

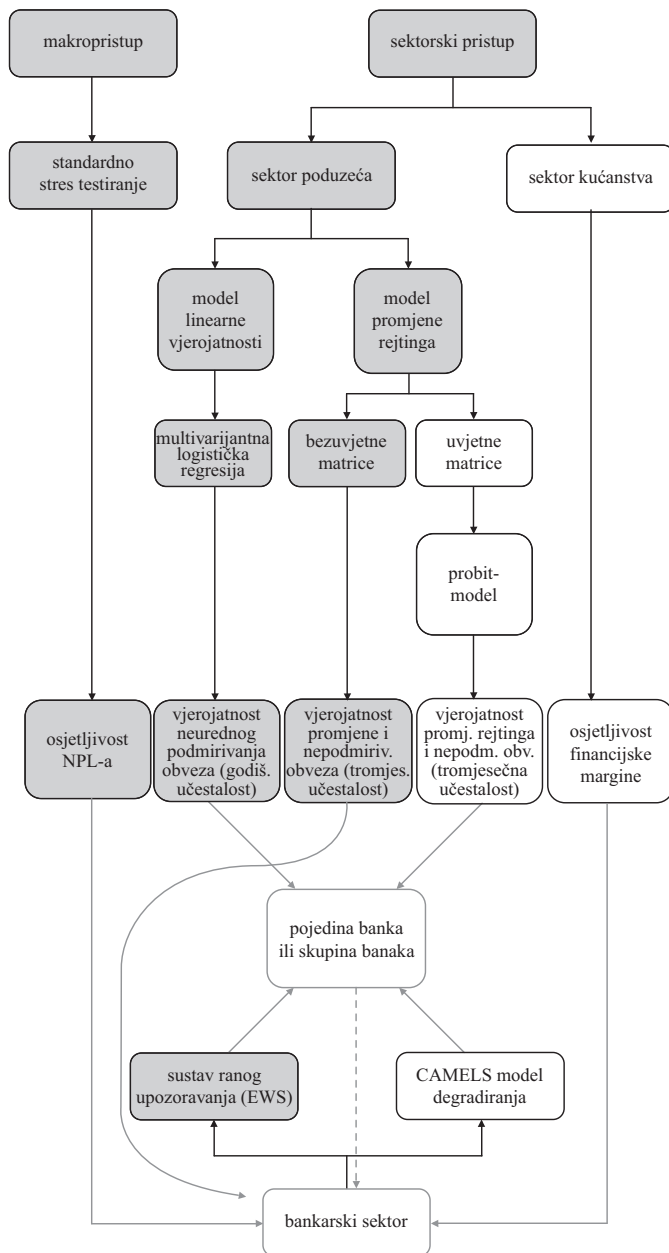
Zaključno, ovaj rad pridonosi razvoju tehničke infrastrukture dizajnirane za procjenu cjelokupnoga kreditnog rizika i nudi brojne moguće primjene:

- prognoziranje vjerojatnosti neurednog podmirivanja kreditnih obveza i izlaganje neurednom podmirivanju obveza za svaku banku na redovitoj osnovi;
- dodatnu verifikaciju bankovnih modela internoga kreditnog rizika;
- usporedbu rejtinga što ga je poduzeću dodijelilo više banaka i identificiranje mogućih sustavnih precjenjivanja te usporedbu ocjena izloženosti koje dodjeljuju same banke s modelom procjene kreditnog rizika;
- stres-testiranje pojedinih banaka nakon identificiranja odnosa između makrovarijabli i financijskih pokazatelja poduzeća (ili uključivanje makrovarijabli u model kreditnog rizika poduzeća kada to vremenski razmak dopušta);
- testiranje različitih *ad-hoc* hipoteza vezano za kreditni rizik (npr. odnos između direktnog zaduživanja domaćih poduzeća u inozemstvu i izloženosti domaćih banaka kreditnom riziku).²²

²² Jedna od glavnih kritika politike HNB-a usmjerene prema obuzdavanju domaćeg zaduživanja koje potiče zaduživanje banaka u inozemstvu jest da kvari kvalitetu bankovnih bilanci. Razlog takvoga gledišta bilo je shvaćanje kako je vjerojatnije da se kreditno sposobni zajmoprincipi oslanjaju na eksterno financiranje, dok domaće banke zapijnu s bilancama inferiornih poduzeća. Međutim, taj je argument izrazito hipotetičan, a čvrste empirijske pokušaje mjerenja učinaka kreditnog rizika većega stranog zaduživanja tek treba podastrijeti.


Dodatak

Grafikon 1. Okvir procjene kreditnog rizika



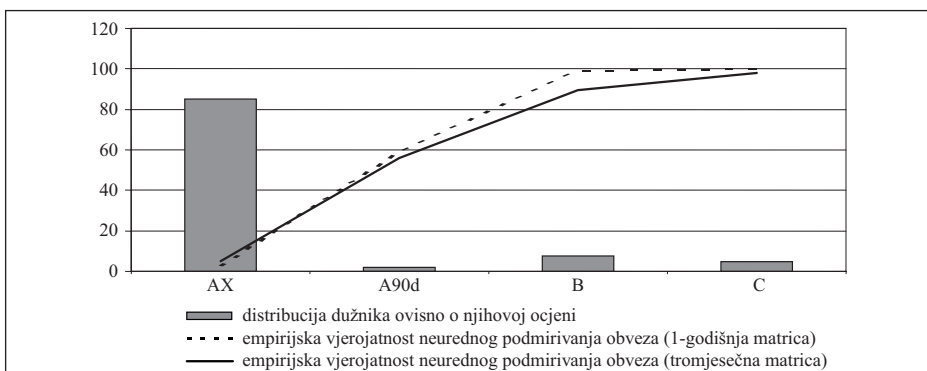
Izvor: autori

Grafikon 2. Ukupni zbroj obveza klasificiranih kao AX u skupini dužnika klasificiranih kao AX i obveza klasificiranih kao ne-AX među svim ostalim dužnicima ovisno o pragu (u mil.)




Izvor: HNB, izračun autora

Grafikon 3. Početni rejting i vjerojatnost neurednog podmirivanja obveza (%)



Izvor: HNB, izračun autora

Grafikon 4. Razvoj PD-a od trećeg tromjesečja 2006. do četvrtog tromjesečja 2008.



Izvor: HNB, izračun autora

Tablica 1. Bezuvjetne matrice promjena

Jedna godina	AX	A90d	B	C
AX	95,0	2,0	2,7	0,3
A90d	43,0	22,0	32,3	2,6
B	10,1	1,8	81,9	6,1
C	1,7	0,1	1,3	96,9

Jedno tromjesečje	AX	A90d	B	C
AX	97,5	1,5	0,9	0,1
A90d	40,6	43,6	14,9	0,8
B	6,0	0,9	90,8	2,3
C	1,5	0,2	0,8	97,5

Napomena: Početni je rejting u recima, a konačni rejting u stupcima.

Izvor: HNB, izračun autora

Tablica 2. Uvjetne matrice promjena (jedno tromjesečje)

a) Matrice promjena ovisne o ekonomskoj aktivnosti

Industrija	AX	A90d	B	C
AX	97,5	1,5	0,9	0,2
A90d	34,6	48,2	16,4	0,8
B	5,3	0,6	91,9	2,3
C	1,2	0,3	0,8	97,7

Građevina	AX	A90d	B	C
AX	97,5	1,5	0,9	0,1
A90d	46,5	40,8	12,1	0,6
B	8,7	1,5	87,1	2,8
C	1,7	0,0	1,	97,0

Nefinancijske usluge	AX	A90d	B	C
AX	97,5	1,5	0,8	0,1
A90d	40,9	42,8	15,4	0,9
B	5,6	0,9	91,4	2,1
C	1,6	0,2	0,7	97,5

b) Matrice promjena ovisne o konjunktornom ciklusu

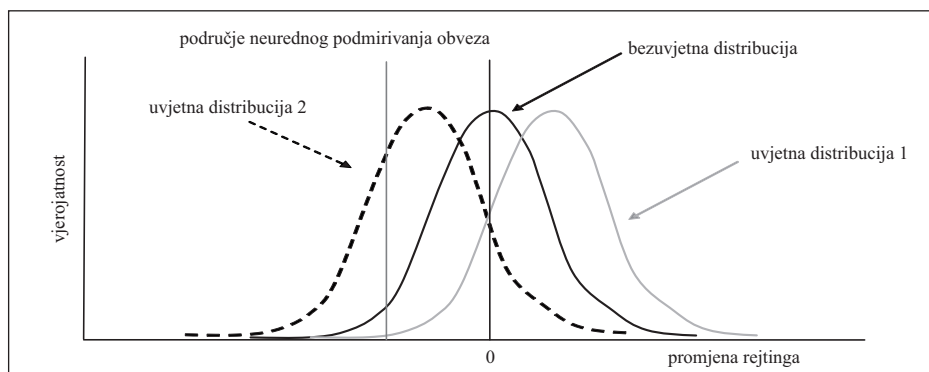
Faza ubrzanja	AX	A90d	B	C
AX	97,2	1,7	0,9	0,2
A90d	45,2	40,2	13,9	0,7
B	6,1	1,0	90,3	2,6
C	2,3	0,2	0,8	96,7

Faza zakašnjenja	AX	A90d	B	C
AX	97,8	1,3	0,8	0,1
A90d	36,1	47,1	16,0	0,9
B	5,9	0,9	91,2	1,9
C	0,7	0,2	0,9	98,2

Napomena: a) početni je rejting u recima, a konačni rejting u stupcima; b) razlike u učestalosti promjena koje su statistički značajne (razina 5%) s obzirom na parametre bezuvjetne matrice pisanje su kurzivom. T-statistika je izvedena iz binomialne standardne pogreške $\sqrt{\hat{p}_{ij}(1-\hat{p}_{ij})/N}$, gdje je p_{ij} vjerojatnost populacije, a \hat{p}_{ij} vjerojatnost uzorka (s ukupnim brojem poduzeća N).

Izvor: HNB, izračun autora

Grafikon 5. Hipotetička distribucija prijelaza u bolju/lošiju skupinu rejtinga



Izvor: autori

Tablica 3. Godišnja prognoza vjerojatnosti promjena

Godišnja prognoza na temelju jednogodišnje matrice promjena

Jedna godina	AX	A90d	B	C
AX	95,0	2,0	2,7	0,3
A90d	43,0	22,0	32,3	2,6
B	10,1	1,8	81,9	6,1
C	1,7	0,1	1,3	96,9

Godišnja prognoza na temelju matrice promjena jednog tromjesečja

Jedna godina	AX	A90d	B	C
AX	93,1	2,5	3,9	0,5
A90d	69,6	5,4	22,0	2,8
B	21,8	1,6	68,9	7,8
C	6,2	0,4	2,9	90,5

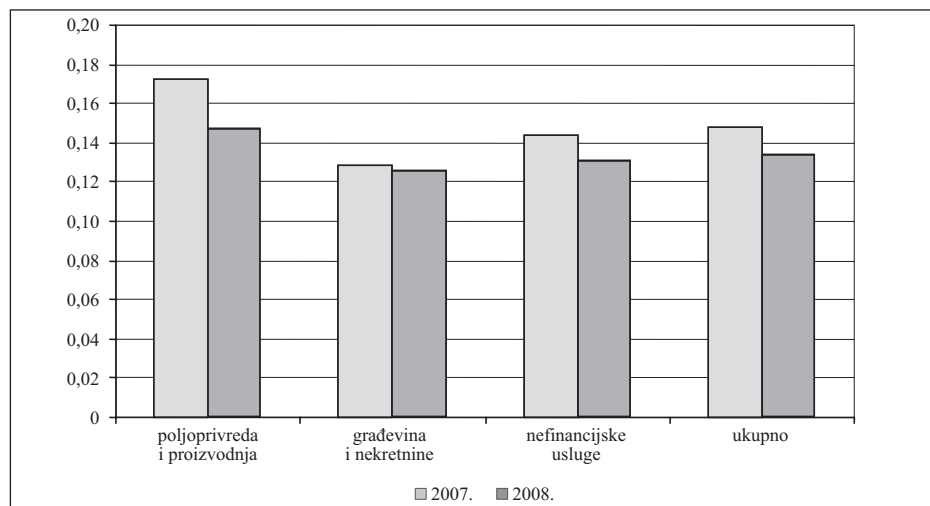
Izvor: HNB, izračun autora

Tablica 4. Broj poduzeća i neurednog podmirivanja obveza prema godini
 i gospodarskom sektoru

Sektor	2007.			2008.			Ukupno		
	poduzeća	broj	stopa	poduzeća	broj	stopa	poduzeća	broj	stopa
poljoprivreda i proizvodnja	1,887	326	0,173	1,915	281	0,147	3,802	607	0,160
građevina i nekretnine	1,747	225	0,129	2,048	258	0,126	3,795	483	0,127
nefinancijske usluge	2,410	346	0,144	2,455	320	0,130	4,865	666	0,137
ukupno	6,044	897	0,148	6,418	832	0,130	12,462	1,729	0,139

Izvor: HNB, FINA

Grafikon 6. Broj poduzeća i prikaz neurednog podmirivanja obveza prema godini
 i gospodarskom sektoru



Izvor: HNB, FINA

Tablica 5. Intermedijalni skup eksplanatornih varijabli

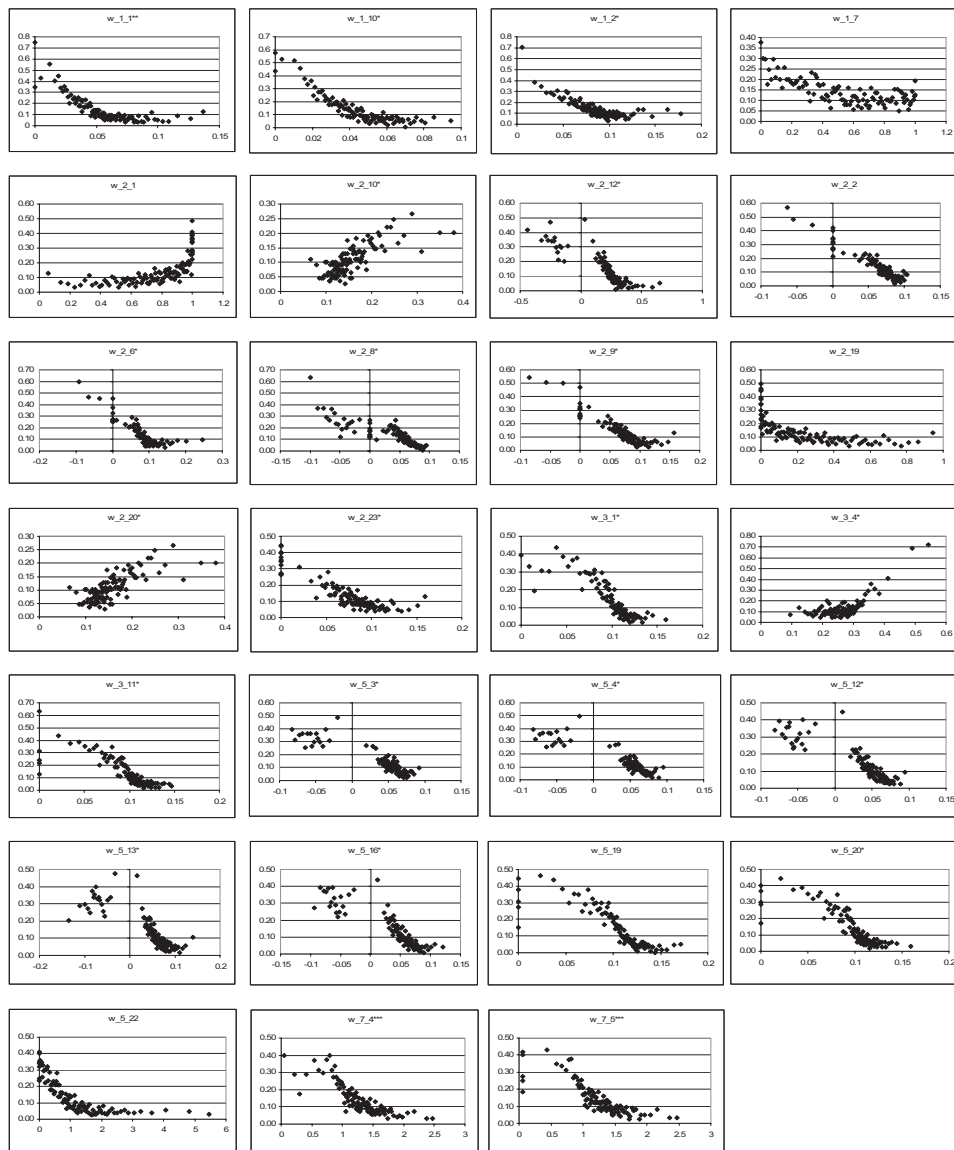
Varijabla	Numerator	Denominator	Sva poduzeća			Poduzeća koja neuredno podm. obveze			Poduzeća koja uredno podm. obveze		
			Sred. vrijed.	Medijan	Std. dev.	Sred. vrijed.	Medijan	Std. dev.	Sred. vrijed.	Medijan	Std. dev.
W_1_1**	novac	kratkoročne obveze	0,19	0,04	0,49	0,11	0,01	0,42	0,21	0,05	0,50
W_1_2*	novac + kratkoročna financijska imovina	kratkoročne obveze	0,85	0,42	1,73	0,60	0,19	1,53	0,89	0,46	1,75
W_1_7	kratkoročna imovina	ukupna imovina	0,55	0,56	0,28	0,46	0,44	0,30	0,56	0,58	0,28
W_1_10*	novac	ukupna imovina	0,04	0,02	0,08	0,02	0,00	0,05	0,05	0,02	0,09
W_2_1	ukupne obveze	ukupna imovina	0,75	0,80	0,23	0,85	0,94	0,20	0,73	0,78	0,23
W_2_2	dionički kapital	ukupna imovina	0,22	0,16	0,21	0,11	0,04	0,18	0,23	0,18	0,21
W_2_6*	dionički kapital	dugoročna imovina	1,81	0,46	6,89	1,11	0,10	6,04	1,92	0,53	7,01
W_2_8*	zadržana dobit	ukupna imovina	0,06	0,03	0,16	-0,03	0,00	0,20	0,08	0,04	0,15
W_2_9*	dionički kapital	ukupne obveze	0,53	0,20	1,04	0,26	0,04	0,87	0,57	0,23	1,05
W_2_10*	ukupne obveze	ukupna imovina - ukupne obveze	1,5	3	45	25	5	60	14	3	43
W_2_12*	dobit nakon poreza + amortizacija	dug/365	252	60	898	33	10	585	288	71	935
W_2_19	ukupna imovina - ukupne obveze	ukupna imovina	0,25	0,20	0,23	0,15	0,06	0,20	0,27	0,22	0,23
W_2_20*	ukupne obveze	ukupna imovina - ukupne obveze	1,5	3	45	25	5	60	14	3	43
W_2_23*	ukupna imovina - ukupne obveze	ukupne obveze	0,63	0,24	1,16	0,36	0,07	0,96	0,67	0,28	1,19
W_3_1*	ukupni prihod	ukupna imovina	1,22	1,00	1,21	0,65	0,42	0,86	1,32	1,10	1,23
W_3_4*	365	tekuća potraživanja promet	134	71	314	353	100	675	101	69	191
W_3_11*	prodaja	ukupna imovina	1,16	0,96	1,02	0,60	0,37	0,75	1,25	1,06	1,03
W_5_3*	dobit nakon poreza + troškovi kamate	ukupna imovina	0,05	0,04	0,10	0,01	0,01	0,10	0,06	0,04	0,10
W_5_4*	dobit nakon poreza + troškovi kamate	ukupna imovina	0,06	0,04	0,11	0,01	0,01	0,11	0,07	0,05	0,11
W_5_12*	dobit prije kamata i poreza	ukupna imovina	0,04	0,02	0,11	-0,01	0,00	0,11	0,05	0,03	0,11
W_5_13*	dobit prije kamata i poreza	kratkoročne obveze	0,15	0,05	0,68	-0,04	0,00	0,64	0,18	0,06	0,69
W_5_16*	dobit prije kamata i poreza	ukupne obveze	0,10	0,03	0,27	-0,01	0,00	0,19	0,11	0,04	0,28
W_5_19	prodaja	ukupne obveze	1,83	1,37	1,89	0,80	0,46	1,20	1,99	1,55	1,93
W_5_20*	prodaja	ukupna imovina	1,18	0,96	1,19	0,61	0,37	0,84	1,28	1,06	1,22
W_5_22	prodaja + amortizacija	ukupna imovina	1,20	1,01	1,03	0,63	0,40	0,77	1,29	1,11	1,04
W_7_4****	ukupni prihod		43.691.386	10.179.726	118.000.000	18.635.509	3.512.595	66.281.680	47.801.055	11.737.942	124.000.000
W_7_5****	prodaja		41.764.357	9.577.616	115.000.000	17.220.656	3.031.529	63.267.968	45.790.019	11.165.791	120.000.000

Napomena: Varijable označene s *, ** i *** pretvorene su uz pomoć izraza:

$*(\text{sign}(x) * \text{abs}(x)^{0,2}) / 0,2$; $**(\text{sign}(x) * \text{abs}(x)^{0,15} + 1) / 0,15$.

Izvor: HNB, FINA, izračun autora

Grafikoni 7. Raspršeni dijagrami intermedijalnog skupa eksplanatornih varijabli



Napomene:

- a) Na osi x: prosjek raspona percentila eksplanatorne varijable; na osi y: prosječna stopa neurednog podmirivanja obveza.
- b) Varijable označene s *, ** i *** pretvorene su primjenom izraza:
 - * $(\text{sign}(x) * \text{abs}(x)^0,2)/0,2$
 - ** $(\text{sign}(x) * \text{abs}(x)^0,1+1)/0,1$
 - *** $(\text{sign}(x) * \text{abs}(x)^0,15+1)/0,15$.

Izvor: FINA, izračun autora

Tablica 6. Rezultati univarijantne logističke regresije

Varijable	Numerator	Denominator	Znak	Pseudo R ²	Područje ispod ROC
W_1_1**	novac	kratkoročne obveze	negativan	0,0875	0,7167
W_1_2*	novac + kratkoročna financijska imovina	kratkoročne obveze	negativan	0,0498	0,6547
W_1_7	kratkoročna imovina	ukupna imovina	negativan	0,0177	0,5957
W_1_10*	novac	ukupna imovina	negativan	0,0963	0,7184
W_2_1	ukupne obveze	ukupna imovina	pozitivan	0,0457	0,6791
W_2_2	dionički kapital	ukupna imovina	negativan	0,0618	0,7071
W_2_6*	dionički kapital	dugoročna imovina	negativan	0,0767	0,7000
W_2_8*	zadržana dobit	ukupna imovina	negativan	0,0606	0,6891
W_2_9*	dionički kapital	ukupne obveze	negativan	0,0829	0,7060
W_2_10*	ukupne obveze	ukupna imovina – ukupne obveze	pozitivan	0,0195	0,6153
W_2_12*	dobit nakon poreza + amortizacija	dug/365	negativan	0,0807	0,7270
W_2_19	ukupna imovina – ukupne obveze	ukupna imovina	negativan	0,0457	0,6792
W_2_20*	ukupne obveze	ukupna imovina – ukupne obveze	pozitivan	0,0195	0,6153
W_2_23*	ukupna imovina – ukupne obveze	ukupne obveze	negativan	0,0649	0,6788
W_3_1*	ukupna imovina	ukupna imovina	negativan	0,0706	0,7220
W_3_4*	365	tekuća potraživanja promet	pozitivan	0,0595	0,6290
W_3_11*	prodaja	ukupna imovina	negativan	0,0703	0,7253
W_5_3*	dobit nakon poreza + troškovi kamate	ukupna imovina	negativan	0,0681	0,6900
W_5_4*	dobit nakon poreza + troškovi kamate	ukupna imovina	negativan	0,0697	0,6965
W_5_12*	dobit prije kamata i poreza	ukupna imovina	negativan	0,0771	0,7168
W_5_13*	dobit prije kamata i poreza	kratkoročne obveze	negativan	0,0707	0,7134
W_5_16*	dobit prije kamata i poreza	ukupne obveze	negativan	0,0805	0,7246
W_5_19	prodaja	ukupne obveze	negativan	0,1021	0,7502
W_5_20*	prodaja	ukupna imovina	negativan	0,0703	0,7253
W_5_22	prodaja + amortizacija	ukupna imovina	negativan	0,0851	0,726
W_7_4***	ukupna imovina		negativan	0,0519	0,6731
W_7_5***	prodaja		negativan	0,0557	0,6829

Napomena: Varijable označene s *, ** i *** pretvorene su primjenom izraza:

$$*(\text{sign}(x) * \text{abs}(x)^{0,2}) / 0,2$$

$$**(\text{sign}(x) * \text{abs}(x)^{0,1+1}) / 0,1$$

$$***(\text{sign}(x) * \text{abs}(x)^{0,15+1}) / 0,15.$$

Izvor: izračun autora

Tablica 7. Izbor modela: rezultati multivarijantne logističke regresije

	Model 3_1	Model 4_1	Model 5_1	Model 6_1	Model 6_4
C	4,41 (0,22)	-0,41 (0,17)	-0,30 (0,22)	-0,17 (0,22)	-0,06 (0,22)
Dummy građevine i nekretnine	-0,45 (0,06)	-0,26 (0,07)	-0,24 (0,07)	-0,28 (0,07)	-0,30 (0,07)
Novac prema kratkoročnim obvezama	-0,29 (0,01)				
Novac prema ukupnoj imovini		-0,67 (0,04)	-0,67 (0,04)	-0,63 (0,04)	-0,65 (0,04)
Dionički kapital prema ukupnoj imovini			-1,87 (0,19)	-1,96 (0,19)	-2,17 (0,20)
Dionički kapital prema ukupnim obvezama	-0,23 (0,01)	-0,27 (0,01)			
Dobit nakon poreza + amortizacija prema dugu / 365					-0,04 (0,00)
365 / promet potraživanja od kupaca		0,10 (0,01)	0,11 (0,01)	0,09 (0,01)	0,09 (0,01)
Dobit prije kamata i poreza prema ukupnim obvezama			-0,17 (0,01)	-0,14 (0,01)	
Sales + depreciation to total assets	-0,75 (0,04)	-0,51 (0,05)		-0,37 (0,05)	-0,41 (0,05)
Prodaja			-0,01 (0,00)	-0,01 (0,00)	-0,01 (0,00)
R ²	0,18	0,19	0,19	0,20	0,20
AUC	0,79	0,79	0,79	0,80	0,80
% of correct 0	71,57	72,37	71,29	74,89	75,90
% of correct 1	73,21	71,20	72,99	71,20	69,50
% of total correct	71,80	72,22	71,51	74,41	75,05

Izvor: izračun autora


Tablica 8. Model 6.1 – rezultati procjene

Varijabla	Koeficijent	Standardna pogreška	z-statistika	Marginalni učinak	Marginalni učinak * 1 std. dev.
C	-0,17	0,22	-0,80		
Indik. varij. građevine i nekretnina	-0,28	0,07	-3,95	-0,020	-0,009
Novac prema ukupnoj imovini	-0,63	0,04	-16,21	-0,048	-0,020
Dionički kapital prema ukupnoj imovini	-1,96	0,19	-10,29	-0,149	-0,032
365 / promet potraživanja od kupaca	0,09	0,01	9,32	0,007	0,003
Zarada prije kam. i por. prema ukupnim obvezama	-0,14	0,01	-10,47	-0,011	-0,011
Prodaja + amortizacija prema ukupnoj imovini	-0,37	0,05	-7,38	-0,028	-0,029
Prodaja	-0,01	0,00	-4,50	-0,001	-0,0004

Broj promatranja 11503
 Log vjerojatnost -3589,861
 Pseudo R² 0,1963


Izvor: izračun autora

Grafikon 8. Kernel procjena gustoće distribucije neurednog podmirivanja obveza za poduzeća koja neuredno podmiruju svoje obveze i ona koja uredno podmiruju obveze prema modelu 6.1.



Izvor: izračun autora

Grafikon 9. Model 6.1 – ROC krivulja



S engleskoga prevela
Mirna Jakšić, Zagreb

LITERATURA

Altman, E. I., 1968. “Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy”. *Journal of Finance*, 23 (4), 589–609.

Andersen, H. [et al.], 2008. *A suite-of-models approach to stress-testing financial stability. Staff Memo*, Norges Bank Financial Stability.

Beaver, W., 1966. “Financial Ratios as Predictors of Failure”. *Journal of Accounting Research*, 4, 71-102.

Bernhardsen, E., 2001. “A Model of Bankruptcy Prediction”. *Norges Bank Working Paper*, No. 10.

Bourguignon, F., Fournier, M. i Gurgand, M., 2004. “Selection Bias Corrections Based on the Multinomial Logit Model: Monte-Carlo Comparisons”. *DELTA (Département et Laboratoire D'économie Théorique et Appliquée)*, Working paper, No. 20.

Charitou, A., Neophytou, E. i Charalambous, C., 2004. “Predicting Corporate Failure: Empirical Evidence for the UK”. *European Accounting Review*, 13 (3), 465-497.

Falcon, L. T., 2007. *Logit Models to Assess Credit Risk, Credit Risk Assessment Revisited: Methodological Issues and Practical Implications*. European Committee of Central Balance Sheet Data Offices.

Fuertes, A. i Kalotychou, E., 2005. *On Sovereign Credit Migration: Small-sample Properties and Rating Evolution Faculty of Finance*. London: Cass Business School.

HNB, 2003. *Nadzor nad bankama* [online]. Zagreb: Hrvatska narodna banka. Dostupno na: [<http://www.hnb.hr/supervizija/hsupervizija.htm>].

HNB, 2009. *Financial Stability Report*, No. 2. Zagreb: Hrvatska narodna banka.

HNBa, 2009. Odluka o klasifikaciji plasmana i izvanbilančnih obveza kreditnih institucija [online]. Zagreb: Hrvatska narodna banka. Dostupno na: [<http://www.hnb.hr/supervizija/odgovori-zoki/h-odgovori-klasifikacija-plasmana.pdf>].

Hornik, K. [et al.], 2007. “Validation of credit rating systems using multi-rater information”. *Journal of Credit Risk*, 3 (4), 3-29.

IMF, 2008. *Republic of Croatia: Financial System Stability Assessment Update*. Washington: IMF; World Bank.

Jacobson, T. [et al.], 2008. “Firm Default and Aggregate Fluctuations”. *Sveriges Riksbank, Working Paper*, No. 226.

Lykke, M., Pedersen, K. J. i Vinther, H. M., 2004. “A failure-Rate Model for the Danish Corporate Sector”. *Danmark Nationalbank Working Paper*, No. 16.

Nickell, P., Perraudin, W. i Varotto, S., 2001. “Stability of ratings transition”. *Bank of England Working Paper Series*, No. 133.

Ohlson J., 1980. “Financial ratios and the probabilistic prediction of bankruptcy”. *Journal of Accounting Research*, 18 (1), 109-131.

Richter, F., 2007. *Introduction in Credit Risk Assessment Revisited: Methodological Issues and Practical Implications*. ECCBSDO.

Winkler, G., 2008. *Assessing Credit Risk of the Companies Sector*. Presentation at Annual Regional Seminar On Financial Stability Issues held by IMF and National Bank of Romania.

Lana Ivičić and Saša Cerovac

Credit Risk Assessment of Corporate Sector in Croatia

Abstract

The main goal of this paper is modeling credit risk of non-financial businesses entities by assessing the rating migration probabilities and predicting the probability of default over one year horizon on the basis of corporate financial accounts. Our research provides a number of new important insights. Ratings migration matrices are symmetrical in every observed period, which implies that default state is not final terminal state. We find a high degree of rating stability, with the exception of some volatility generated by firms in the middle of the ratings scale. In the period of lower economic growth probabilities of transition between different risks categories are lower than in the period of higher economic growth. Probabilities of default are relatively stable across enterprises operating in different economic activities. After considering a wide range of potential predictors of default, multivariate logistic regression results reveal that the most important are the ratio of shareholders' equity to total assets and the ratio of EBIT to total liabilities, both negatively related to the probability of default. In addition, higher liquidity, profitability and sales as well as construction and real estate sector affiliation all decrease the companies' probability of default in the following year. The model correctly classifies relatively reasonable percentage of companies in the sample (74% of all the companies, 71% of defaulted and 75% of non-defaulted companies) when the threshold is set in such a way to maximize the sum of correctly predicted proportions for both defaulted and non-defaulted companies.

Keywords: credit risk, corporate default, migration matrices, logit