HRVATSKA NARODNA BANKA

Istraživanja I-53

Bihevioralni model procjene vjerojatnosti nastanka događaja neispunjavanja obveza i rejting nefinancijskih poduzeća

Tomislav Grebenar

Zagreb, siječanj 2018.



ISTRAŽIVANJA I-53

IZDAVAČ
Hrvatska narodna banka
Direkcija za izdavačku djelatnost
Trg hrvatskih velikana 3, 10000 Zagreb
Telefon centrale: 01/4564-555
Telefon: 01/4565-006
Telefaks: 01/4564-687

WEB-ADRESA
www.hnb.hr

GLAVNI UREDNIK
Ljubinko Jankov

UREDNIŠTVO
Vedran Šošić
Gordi Sušić
Davor Kunovac
Tomislav Ridzak
Evan Kraft
Maroje Lang

UREDNICA
Romana Sinković

LEKTORICA
Dragica Platužić

DIZAJNER
Vjekoslav Gjergja

GRAFIČKI UREDNIK
Slavko Križnjak

Za stajališta iznesena u ovom radu odgovorni su autori i ta stajališta nisu nužno istovjetna službenim stajalištima Hrvatske narodne banke.
Molimo korisnike ove publikacije da pri korištenju podataka obvezno navedu izvor.
Sve eventualno potrebne korekcije bit će unesene u web-verziju.

ISSN 1334-0077 (online)

HNB

HRVATSKA NARODNA BANKA

ISTRAŽIVANJA I-53

Bihevioralni model procjene vjerojatnosti nastanka događaja neispunjavanja obveza i rejting nefinancijskih poduzeća

Tomislav Grebenar

Zagreb, siječanj 2018.

Sažetak

Regulativa Basel II, naslijeđena i u regulatornom okviru Basel III, uvela je standarde i smjernice za upravljanje rizicima u bankarstvu. Budući da su definirana tri različita pristupa, kreditnim institucijama ostavljena je mogućnost izbora pristupa na temelju kojeg će procijeniti svoju izloženost riziku, a u središtu je pozornosti upravo kreditni rizik. Ako kreditna institucija ima dovoljno financijskih i ljudskih resursa te znanja, neće se osloniti na standardizirani pristup, u kojem su mjere faktora rizika regulatorno propisane, već će se koristiti pristupima zasnovanima na internim procjenama rejtinga (IRB), za što prethodno treba ispuniti niz kriterija i dokazati regulatoru da su interne procjene primjerene i da se primjenjuju u svakodnevnom poslovanju. Ključni je faktor rizika u IRB pristupu vjerojatnost neispunjavanja obveza (PD), koja se procjenjuje s pomoću prediktivnih PD modela. Hrvatska narodna banka razvila je PD model koji se primjenjuje u procjeni rizika sektora nefinancijskih poduzeća na sustavnoj razini kao i na razini pojedinačnih kreditnih institucija, pri visokim koncentracijama rizika te u sklopu testiranja otpornosti na stres.

U ovom istraživanju prikazan je postupak razvoja PD modela i dokazan pozitivan utjecaj bihevioralnih varijabla na diskriminatorna i prediktivna svojstva takvog modela u odnosu na model koji ne uključuje bihevioralne varijable. Poseban naglasak stavljen je na metodološki pristup usklađen s regulativom Basel II i III u ključnim točkama, a koji je rezultirao znatnim poboljšanjima u ciljanim karakteristikama modela: prediktivnosti i diskriminatornoj snazi.

Ključne riječi:

IRB, vjerojatnost neispunjavanja obveza (PD), rejting-skala, nefinancijska poduzeća, Basel III, bihevioralne varijable, aplikacijske varijable, model, logistička regresija, informacijska vrijednost, težina dokaza (WoE), diskriminatorna snaga, Lorenzova (CAP) krivulja, Ginijev koeficijent, ROC krivulja, binomni test, kalibracija, validacija, stabilnost

JEL klasifikacija:

G32, G02, C51

Sadržaj

Sažetak v

1. Uvod 1

2. Pregled literature 2

3. Podaci 3

4. Metodologija 4
4.1. Definicija događaja neispunjavanja obveza 5
4.2. Težina dokaza (WoE) i informacijska vrijednost (IV) 5
4.3. Procjena parametara modela 6
4.4. Diskriminatorna snaga modela 7
Lorenzova krivulja (CAP) i Ginijev koeficijent 7
4.5. Kalibracija modela 8
Binomni test 9

5. Rezultati regresije 10
5.1. Univarijatna analiza 10
5.1.1. Aplikacijske i bihevioralne varijable 10
5.1.2. Inicijalni odabir varijabla na temelju rezultata univarijatne analize 10
5.1.3. Ograničavanje netipičnih vrijednosti varijabla 12
5.2. Multivarijatna analiza 12
5.2.1. Korelacijske matrice 13
5.2.2. Transformacija varijabla s pomoću težine dokaza (WoE) 14
5.3. Procjena parametara modela logističke regresije 16
5.3.1. Segmentacija i procjena parametara modela 16
5.3.2. Utjecaj bihevioralnih varijabla na diskriminatornu snagu modela 22
5.3.3. Kalibracija modela i definiranje rejting-skale 23

6. Zaključak 27

Literatura 28

Pojmovnik i kratice 30

1. Uvod

Vjerojatnost nastanka događaja neispunjavanja obveza (*PD*) jedna je od najvažnijih mjera kreditnog rizika prema regulativi Basel III (Uredba br. 575/2013) koja se rabi u naprednim pristupima (*IRB*) za izračun očekivanoga gubitka (*EL*) i rizikom ponderirane aktive (*RWA*). Procjena vjerojatnosti nastanka događaja neispunjavanja obveza najčešće se temelji na financijskim i kvalitativnim pokazateljima poslovanja poduzeća odnosno na financijskim, imovinskim i socio-demografskim obilježjima fizičkih osoba. Ti se podaci često nazivaju aplikacijskim podacima, jer su kreditnoj instituciji jedini dostupni za analizu u trenutku traženja odobrenja (apliciranja) kreditnog plasmana, ako klijent još nema dužnički odnos s kreditnom institucijom. Nasuprot tome, ako klijent već ima ili je u bliskoj prošlosti imao dužnički odnos s kreditnom institucijom (odobrena prekoračenja, kreditni plasmani, garancije i slični proizvodi), ona ima na raspolaganju i podatke koji proizlaze iz ponašanja klijenta u poslovnom odnosu s institucijom, tzv. bihevioralne podatke. U ovom je radu iz skupa dostupnih pokazatelja s pomoću metode logističke regresije odabran ograničeni skup pokazatelja koji najbolje diskriminiraju dužnike s obzirom na njihov status neispunjavanja obveza i koji ulaze u model za procjenu PD-a. Ovo istraživanje ograničeno je na procjenu vjerojatnosti nastupanja događaja neispunjavanja obveza za sektor nefinancijskih poduzeća.

Motivacija je za provedbu ovog istraživanja unapređenje modela koji su se do sada upotrebljavali u HNB-u za interne procjene rizičnosti kreditnog portfelja kreditnih institucija u Republici Hrvatskoj u redovnim uvjetima poslovanja. Osim u praksi najčešće primjenjivanih aplikativnih podataka, uglavnom financijskih indikatora utemeljenih na godišnjim financijskim izvješćima poduzetnika (GFI-POD), procjena rizičnosti uključuje i podatke iz poslovnog odnosa klijenta s kreditnim institucijama (bihevioralne podatke) koji dodatno upućuju na rizične obrasce ponašanja poduzeća i povećavaju vjerojatnost nastanka situacije u kojoj poduzeće ne može uredno podmirivati dospjele obveze. Na taj se način unosi dodatna osjetljivost i dinamičnost u funkciju PD-a. Prediktivni PD modeli pogodni su i za provedbu stresnih scenarija jer procjenjuju utjecaj financijskih šokova na kvalitetu kreditnog portfelja za sektor nefinancijskih poduzeća simulirajući porast PD-a poduzeća s pomoću promjene kalibracijske krivulje ili direktnim "šokiranjem" ulaznih varijabla modela za odabrane segmente kreditnog portfelja. Rezultati kvantitativne validacije prošlih modela također upućuju na potrebu ponovnog dizajna PD modela u skladu s regulativom Basel III i najboljom poslovnom praksom. Proces razvoja prediktivnog PD modela počiva na definiciji događaja neispunjavanja obveza usklađenoj s regulativom Basel III s povijesnim podacima od najmanje pet godina za uzorak na kojemu je model razvijan i validiran. Inicijalna validacija modela na podacima izvan uzorka (OOS) i/ili izvan vremena (OOT) dodatna je provjera nepristranosti modela i nepostojanja prekomjerne prilagodbe modela podacima na kojima se procjenjuju parametri regresije.

Nakon definiranja i procjene PD modela u sklopu ovog istraživanja razvijena je i rejting-skala, koja je također usklađena s regulativom Basel III. Rejting-skala razvrstava prihodonosna i neprihodonosna poduzeća i

pripadajuće plasmane, odnosno izloženosti u razrede rejtinga, što omogućuje kontinuirano i *a priori* praćenje promjena u rizičnosti pojedinačnih dužnika i kvaliteti kreditnog portfelja sektora nefinancijskih poduzeća, dok je dosadašnjom klasifikacijom dužnika u klasifikacijske skupine A, A90, B1 – B3 i C to bilo moguće *ex ante,* ali samo za neprihodonosne plasmane.

2. Pregled literature

Godine 2009. razvijen je prvi PD model za procjenu kreditnog rizika poduzeća u Hrvatskoj narodnoj banci (Ivičić i Cerovac) koji je uključivao financijske pokazatelje temeljene na godišnjim financijskim izvješćima poduzeća. Rezultati multivarijatne logističke regresije pokazali su da najznačajnije utjecaje na prognoziranje vjerojatnosti neurednog podmirivanja obveza[1] imaju omjer dioničkoga kapitala prema ukupnoj imovini te omjer dobiti prije odbitka troškova kamata i poreza (EBIT) prema ukupnim obvezama, koji su negativno korelirani s vjerojatnošću neurednog podmirivanja obveza. Uz navedene pokazatelje značajan utjecaj imaju i pokazatelji likvidnosti, profitabilnosti i prodaje kao i pripadnost djelatnosti građevinarstva i poslovanja s nekretninama. S obzirom na tadašnju dostupnost podataka prikupljenih od kreditnih institucija u sklopu regulatornog i statističkog izvještavanja Hrvatske narodne banke prema tada važećoj *Odluci o klasifikaciji plasmana i potencijalnih obveza banaka* iz 2003. godine, podaci o izloženostima kreditnih institucija prema pojedinačnim poslovnim subjektima prikupljani su samo za tzv. "portfelj velikih kredita" kod kojih su plasmani prema jednom dužniku, ovisno o veličini ukupne aktive kreditne institucije, iznosili više od 200.000, 300.000, 500.000 i 700.000 kuna. Godine 2009. na snagu je stupila nova *Odluka o klasifikaciji plasmana i potencijalnih obveza kreditnih institucija*, koja je redefinirala pragove za tzv. "pojedinačno značajne izloženosti" na 500.000, 1.000.000 i 1.500.000 kuna, ovisno o veličini ukupne aktive kreditne institucije. Ta podatkovna ograničenja omogućavala su procjenu parametara regresije samo na portfelju pojedinačno značajnih izloženosti kreditnih institucija prije krize.

Nehrbecka (2015.) je analizirala PD za nefinancijska poduzeća ukupne izloženosti od najmanje 1,5 mil. EUR u razdoblju 2007. – 2012. godine. Uz financijske pokazatelje i indikatorske varijable upotrijebljene su i neke bihevioralne varijable, poput broja odnosa banka – poduzeće, udjela dospjelih kamata u ukupnoj izloženosti, udjela kredita u nacionalnoj valuti prema ukupnoj izloženosti i udjela otvorenih kreditnih linija prema ukupnoj izloženosti (4-mjesečni – 6-mjesečni medijani). Procjena parametara modela napravljena je na transformiranim ulaznim varijablama s pomoću metode težine dokaza (WoE), a kao jedan od kriterija u univarijatnoj selekciji neovisnih varijabla primijenjena je njihova informacijska vrijednost (IV) i Ginijev koeficijent. Diskriminatorna snaga modela testirana je s pomoću Ginijeva koeficijenta i Kolmogorov-Smirnovljeva testa (K-S test).

Upotrebu bihevioralnih varijabla u PD modelu opisali su Flores i dr. (2010.) za portfelj deset najvećih kartičnih institucija. Specifičnost je opisanog modela primjena isključivo bihevioralnih varijabla od kojih se dvije temelje na neurednom podmirivanju dospjelih obveza u prethodnim razdobljima.

Procjene PD-a u skladu s bazelskom regulativom moraju biti validirane najmanje jednom godišnje na podacima izvan uzorka (OOS) i/ili na novim podacima (OOT). Kvantitativni testovi uključuju testiranje prediktivne snage rejting-sustava, njegove učinkovitosti, kalibracije i stabilnosti. Različiti autori rabe različite kvantitativne metode za navedena testiranja. Tako u zbirci radova urednika Engelmanna i Rauhmeiera (2011.) za testiranje diskriminatorne snage više autora preporučuje CAP krivulju i Ginijev (AR) koeficijent kao i ROC krivulju i AUROC koeficijent te Brierov skor, a za testiranje kalibracije binomni test, Hosmer-Lemeshowljev test i Spiegelhalterov test. Tasche (2006.) kao testove diskriminatorne snage opisuje CAP krivulju i pripadajući Ginijev koeficijent, ROC i AUROC, Pietrin koeficijent, CIER, informacijsku vrijednost i Brierov skor i druge,

1 Kriteriji za neuredno podmirivanje obveza iz navedenog istraživanja neznatno se razlikuju od kriterija za utvrđivanje statusa neispunjavanja obveza usklađenih s bazelskim smjernicama i direktivom.

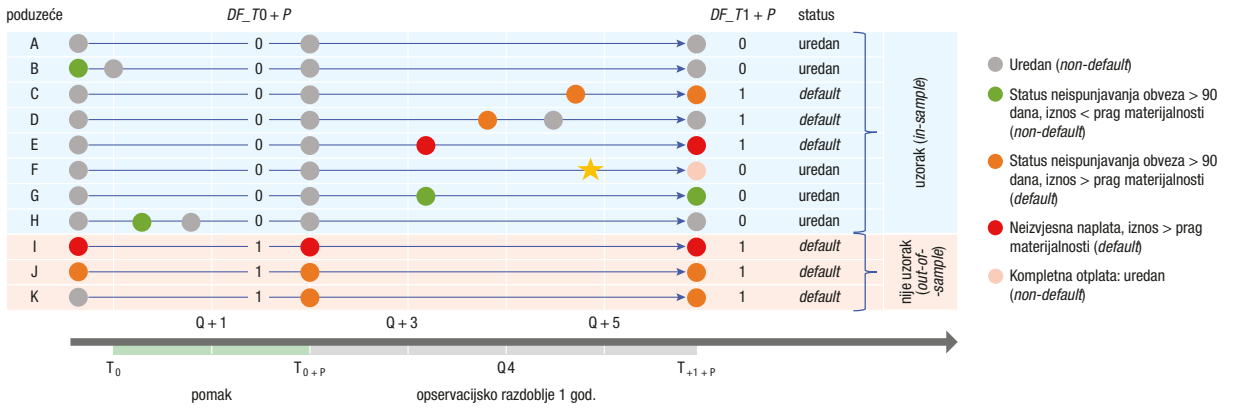
a kao testove kalibracije binomni test, Hosmer-Lemeshowljev test (χ^2-test), normalni test i "semafore". Neke od spomenutih testova rabe i autori Medena i dr. (2006.), a autor Baesens (2016.) opisuje i kriterije za ocjenu diskriminatorne snage modela s pomoću Ginijeva koeficijenta.

3. Podaci

Razvojni uzorak za procjenu parametara regresija obuhvaća podatke o nefinancijskim poduzećima (po standardu ESA 2010[2]) prema kojima su kreditne institucije izložene u razdoblju 2011. – 2015. godine. Da bi se parametri regresije mogli procijeniti, uvjet je da za sva poduzeća u uzorku postoje podaci o financijskim izvješćima GFI-POD za poslovne godine neposredno prije početka opservacijskog razdoblja (T_0 2011. – 2014.) i da su poznate promjene statusa neispunjavanja obveza tijekom razdoblja od 1. siječnja do 31. prosinca u godini opservacijskog razdoblja T_{+1}, 2012. – 2015. Validacijski uzorak izvan vremena (*OOT*) obuhvaća nefinancijska poduzeća prema kojima su kreditne institucije izložene u 2015. godini i s poznatim ishodima statusa neispunjavanja obveza u 2016. godini, a parametri rizika temeljili su se na GFI-POD iz 2015. godine. Iz oba uzorka isključena su poduzeća koja su u statusu neispunjavanja obveza bila u nekom trenutku tijekom godine T_0 koja prethodi opservacijskom razdoblju (mjesečna frekvencija podataka). Na taj su način u uzorak uključena samo ona poduzeća za koja su raspoloživi neophodni podaci i prema kojima su kreditne institucije izložene, uz dodatni kriterij da takva poduzeća prije početka opservacijskog razdoblja uredno ispunjavaju svoje obveze (nisu bila u statusu neispunjavanja obveza u godini T_0), jer se procjenjuje vjerojatnost nastanka statusa neispunjavanja obveza (Slika 1.).

Opservacijsko razdoblje za jednogodišnji PD uvijek je na horizontu od jedne godine, ali početak opservacijskog razdoblja ne mora se nužno podudarati s kalendarskim početkom godine. Ovisno o pomaku početnog trenutka opservacijskog razdoblja u odnosu na datum godišnjega financijskog izvješća poduzeća, promatrana su razdoblja za pomak od 0 mjeseci: 31. 12. T_0 – 31. 12. T_{+1}, za pomak od 3 mjeseca: 31. 3. T_{+1} – 31. 3. T_{+2} te za pomak od 6 mjeseci: 30. 6. T_{+1} – 30. 6. T_{+2}, gdje je T_0 godina na koju se odnosi financijsko izvješće, a indeksi u oznakama godine +1 i +2 predstavljaju broj proteklih godina od godišta financijskog izvješća (Slika 1.). Pomak se može rabiti kako bi se premostio vremenski jaz između datuma financijskog izvješća i njegove javne dostupnosti, koji je u praksi između četiri i šest mjeseci, te se na taj način produljio rok do kojega je

Slika 1. Kreiranje razvojnog uzorka



Izvor: Autorov izračun

2 Poduzeća sektorizirana prema Europskom sustavu računa *(European System of Accounts)*, ESA 2010

izračun rejtinga valjan. Cijena koja se pritom plaća mogu biti nešto slabija prediktivna svojstva modela zbog veće "zastarjelosti" financijskih izvješća koja se uključuju u model.

Za konačnu procjenu parametara regresije upotrijebljen je pomak od 0 mjeseci, tako da je u uzorku jednogodišnje opservacijsko razdoblje 31. 12. T_0 – 31. 12. T_{+1}. Razdoblje za trening-uzorak odabrano je s obzirom na dostupnost konzistentnih podataka kreditnih institucija o pojedinačnim izloženostima prema sektoru nefinancijskih poduzeća.

Početni uzorak za trening modela sadržava ukupno 144 varijable, od čega 79 aplikacijskih (financijskih pokazatelja temeljenih na godišnjim financijskim izvješćima) i 65 bihevioralnih varijabla (varijabla iz podataka prikupljenih iz regulatornih i statističkih izvješća kreditnih institucija). Trening-uzorak čini 69.049 opservacija (nefinancijska poduzeća za razdoblje 2011. – 2014. godine). Validacijski uzorak izvan vremena sadržava 17.455 nefinancijskih poduzeća s godišnjim financijskim izvješćima za 2015. godinu i ishodom statusa neispunjavanja obveza tijekom 2016. godine.

Razvoj statističkih prediktivnih modela statistički je utemeljen proces odabira faktora rizika, odnosno neovisnih varijabla modela koji najbolje predviđaju vjerojatnost nastanka modeliranog događaja, tj. ovisne varijable, u ovom slučaju binarne varijable događaja nastupanja statusa neispunjavanja obveza (varijabla s dva moguća stanja: 0 – uredno poslovanje, 1 – status neispunjavanja obveza). Najbolja poslovna praksa pritom podrazumijeva pripremu uzorka koji uključuje sve potencijalno prediktivne neovisne varijable za svako poduzeće u uzorku te poznati ishod na kraju opservacijskog razdoblja, u ovom slučaju u trajanju od jedne godine od trenutka u kojemu se procjenjuje vjerojatnost. Referentni trenutak određen je godištem financijskog izvješća poduzeća: 31. prosinca godine za koju je sastavljeno financijsko izvješće.

4. Metodologija

Temeljna pretpostavka za razvoj PD modela usklađenog s regulativom Basel III počiva na definiciji statusa neispunjavanja obveza. Inicijalna selekcija objašnjavajućih varijabla modela provodi se tzv. univarijatnom analizom kojom se procjenjuju prediktivna svojstva svake pojedinačne neovisne varijable, te se iz daljnje analize isključuju sve varijable koje ne zadovoljavaju kriterije prediktivnosti (diskriminatorne snage modela) i popunjenosti podacima (udio nedostajućih vrijednosti varijable u uzorku treba biti što manji). Multivarijatna analiza iz uzorka isključuje varijable visokog stupnja međusobne korelacije kako bi se izbjegla moguća prekomjerna prilagodba modela podacima na kojima su procijenjeni parametri regresije. Konačni popis varijabla kandidata za model čine niskokorelirane i visoko prediktivne, dovoljno popunjene varijable, a koje mogu biti i prethodno transformirane (ograničene s obzirom na netipične vrijednosti, transformirane prema težini dokaza, standardizirane ili linearizirane s pomoću transformacijskih funkcija) kako bi se postigla što bolja monotona linearna ovisnost između neovisne i ovisne varijable. U regresijsku analizu uključuje se konačan skup odabranih varijabla, a u konačnom modelu ostaju varijable koje zadovoljavaju uvjete ekonomske opravdanosti procjenitelja (varijabla je smislena, predznak procjenitelja u skladu je s očekivanim predznakom glede korelacije rizika s vrijednošću varijable) i testove signifikantnosti (p-vrijednosti). Odabrani se modeli dalje validiraju, nakon što se kalibriraju kako bi izračunate vjerojatnosti odražavale stvarne vjerojatnosti nastupanja događaja neispunjavanja obveza. Nakon kalibracije modela definira se rejting-skala. Inicijalni validacijski testovi provode se na trening-uzorku, a rezultati se potvrđuju i na testnom uzorku (OOT).

Najčešći kvantitativni testovi u ocjeni diskriminatorne snage modela spomenuti u poglavlju 2. Pregled literature, a koji su primijenjeni i u ovom istraživanju, jesu CAP krivulja i pripadajući Ginijev koeficijent kao testovi diskriminatorne snage modela te binomni test za testiranje pojedinačnih kategorija rejtinga kao kalibracijski test za izradu i procjenu prikladnosti rejting-skale.

4.1. Definicija događaja neispunjavanja obveza

Za potrebe izračuna iznosa aktive ponderirane rizikom primjenom IRB pristupa, kao i ponderiranja izloženosti sa statusom neispunjavanja obveza prema standardiziranom pristupu[3], stupanje dužnika u status neispunjavanja obveza nastaje kada je ispunjen barem jedan od sljedećih uvjeta:

a) institucija smatra vjerojatnim da dužnik neće u cijelosti podmiriti svoje obveze prema instituciji, njezinu matičnom društvu ili bilo kojem od njezinih društava kćeri ne uzimajući u obzir mogućnost naplate iz kolaterala (engl. *unlikely to pay*)
b) dužnik više od 90 dana nije ispunio svoju dospjelu obvezu po bilo kojoj značajnoj kreditnoj obvezi prema instituciji, njezinu matičnom društvu ili bilo kojem od njezinih društava kćeri.

Značajnost dospjele kreditne obveze (za potrebe točke a)) procjenjuje se u odnosu na prag koji utvrđuju nadležna tijela. Taj prag mora odražavati razinu rizika koju nadležno tijelo smatra primjerenom. Europsko nadzorno tijelo za bankarstvo (EBA) sastavilo je nacrt regulatornih tehničkih standarda (RTS) kojima se pobliže određuju uvjeti po kojima nacionalno nadležno tijelo utvrđuje prag značajnosti dospjele kreditne obveze, kao i smjernice o stupanju dužnika u status neispunjavanja obveza.

S ciljem najveće moguće usklađenosti s regulatornom definicijom statusa neispunjavanja obveza i prihvaćenog praga značajnosti (koji se donosi u skladu s predmetnim RTS-om) koji će institucije u RH primjenjivati za potrebe izračuna iznosa ponderiranih rizikom za izloženosti prema trgovačkim društvima, odabrana je definicija statusa neispunjavanja obveza koja uzima u obzir dvije komponente:

a) 90 dana zakašnjenja po značajnoj kreditnoj obvezi većoj od utvrđenog praga značajnosti prema mjesečnim podacima o dospjelim nenaplaćenim potraživanjima i
b) neizvjesnost naplate, koja se prepoznaje tako da su u barem jednoj kreditnoj instituciji formirani specifični ispravci vrijednosti za iznos veći od praga značajnosti ili postoji zakašnjenje prema značajnoj kreditnoj obvezi (rizične skupine A90, B1, B2, B3 ili C).

Prag značajnosti kreditne obveze definiran je u apsolutnom iznosu od 3750 kn. U analizi su razmatrane i druge dvije mogućnosti: 1750 kn i 5000 kn. Propisana relativna komponenta (2,5% ukupne izloženosti prema dužniku) nije bila uključena u definiciju statusa neispunjavanja obveza uglavnom zbog supervizorske prakse prema kojoj je svaki specifični ispravak vrijednosti izravno prepoznavan kao status neispunjavanja obveza.

4.2. Težina dokaza (WoE) i informacijska vrijednost (IV)

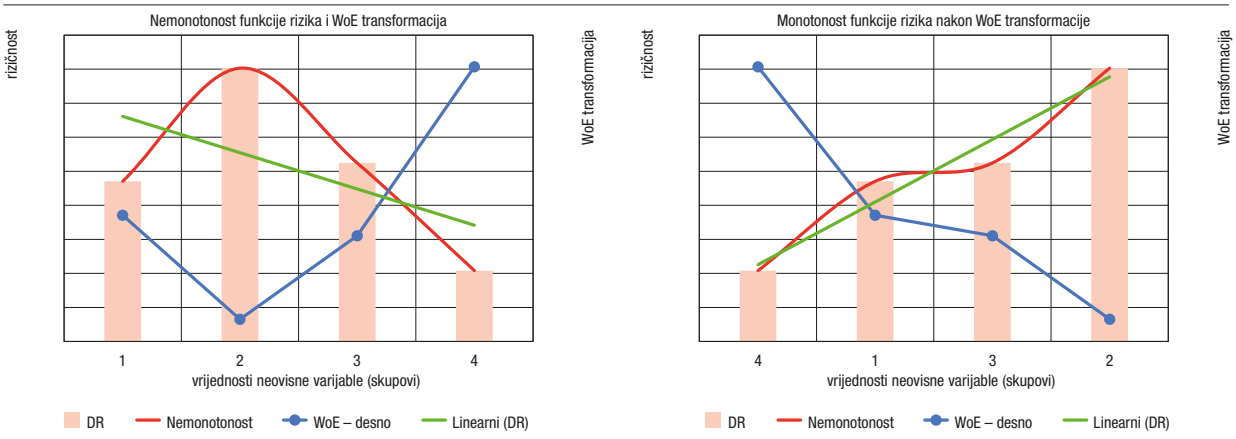
Logistička regresija podrazumijeva monotono rastuću (ili padajuću) funkciju neovisne varijable. U nekim slučajevima uvjet monotonog rasta funkcije rizičnosti nije zadovoljen, što uzrokuje veće pogreške regresije u dijelovima prekida monotonog rasta: Slika 2. na lijevom grafikonu prikazuje značajno odstupanje regresijskog pravca *Linearni (DR)* od ostvarene stope nastupanja statusa neispunjavanja obveza DR u odnosu na desni grafikon s malim odstupanjima ostvarene stope DR i procjenu regresijskog pravca *Linearni (DR)* na WoE transformiranim vrijednostima stope nastupanja statusa neispunjavanja obveza DR. U takvim se slučajevima neovisne varijable najčešće transformiraju upotrebom težine dokaza (WoE) kako bi se postigla monotono rastuća ovisnost funkcije rizika o vrijednosti transformirane varijable (Slika 2.) te tako povećala prediktivna snaga varijable (informacijska vrijednost).

Transformacija s pomoću težine dokaza (*WoE*[4]) transformacija je koja povezuje prediktivnu snagu neovisne varijable s obzirom na njezinu vrijednost u odnosu na zavisnu varijablu. Izračun WoE temelji se na kategorizaciji vrijednosti ulazne varijable u skupove, tako da se maksimizira informacijska vrijednost skupa, a samim time i razlika između skupina (metoda nadziranog uzorkovanja, engl. *supervised discretization*), te se za svaki skup *i* i ukupno za sve vrijednosti varijable izračunavaju transformirane vrijednosti WoE i informacijska vrijednost:

3 Za kapitalni zahtjev kreditne institucije izračunavaju iznos rizikom ponderirane aktive (RWA). Kreditne institucije pritom mogu primjenjivati standardizirani pristup (STA), u kojem su ponderi za stavke aktive regulatorno propisani ili mogu primjenjivati pristupe utemeljene na vlastitim procjenama faktora rizika udovolje li kriterijima nadležnog tijela za odobrenje pristupa zasnovanog na internim procjenama rejtinga (IRB).

4 Siddiqi (2006.)

Slika 2. WoE transformacija u monotono rastuću funkciju



Izvor: Autorov izračun

$$WoE_i = \ln\left(\frac{\%\text{ “dobrih”}}{\%\text{ “loših”}}\right) \tag{1}$$

Informacijska vrijednost pomaže u odabiru varijabla modela koje imaju veću prediktivnu snagu. Ukupna informacijska vrijednost varijable rangira varijable prema prediktivnoj snazi, a izračunava se kao:

$$IV_i = \sum(\%\text{ “dobrih”} - \%\text{“loših”}) \cdot WoE_i \tag{2}$$

Informacijske vrijednosti varijable koje mogu biti potencijalni kandidati u modeliranju prema autoru Siddiqi (2006.), jer sadržavaju dovoljnu razinu informacije, vrijednosti su više od 0,1 (srednja snaga, Tablica 1.).

Tablica 1. Prediktivna snaga s obzirom na informacijsku vrijednost

Informacijska vrijednost	Prediktivna snaga
< 0,02	nije upotrebljiva za modeliranje
0,02 – 0,1	slaba snaga
0,1 – 0,3	srednja snaga
0,3 – 0,5	izvrsna snaga
> 0,5	iznimna snaga

Izvor: Siddiqi (2006.)

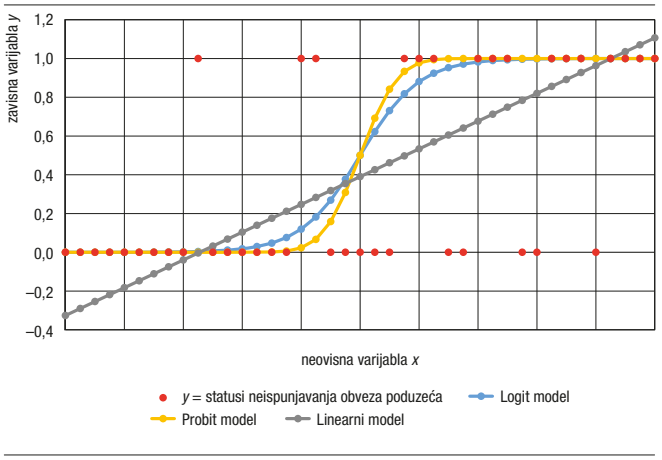
4.3. Procjena parametara modela

Status neispunjavanja obveza čini zavisnu binarnu varijablu y_i u procjeni parametara regresije, koja poprima vrijednost 0 ako poduzeće *i* nije u statusu neispunjavanja obveza ili vrijednost 1 ako je poduzeće *i* u statusu neispunjavanja obveza:

$$y_i = \begin{cases} 0 & \text{... nije u statusu neispunjavanja obveza} \\ 1 & \text{... jest u statusu neispunjavanja obveza} \end{cases} \tag{3}$$

Statusi neispunjavanja obveza mogu se procijeniti s pomoću različitih regresijskih funkcija poput linearne regresije opisane jednadžbom pravca (koja nije prikladna ako je zavisna varijabla binarna jer funkcija pravca nije ograničena na raspon 0 – 1) i najčešće primjenjivanih regresija u slučaju binarnih zavisnih varijabla: logističke regresije (logit) koja rabi logaritamsku transformaciju i probit regresije koja rabi funkciju normalne kumulativne distribucije[5] (Slika 3.).

Slika 3. Regresijske funkcije



Izvor: Autorov prikaz

Funkcija vjerojatnosti nastupanja statusa neispunjavanja obveza procijenjena je multivarijatnom logističkom regresijom (logit). Logistička regresija ima nekoliko prednosti pred ostalim regresijama: rezultat logističke regresije može se direktno poistovjetiti s vjerojatnošću nastupanja statusa neispunjavanja obveza, a istodobno je olakšana i provjera ekonomske smislenosti međuovisnosti procijenjene vjerojatnosti rizika i neovisne varijable. Multivarijatna logistička regresija procjenjuje koeficijente vektora β' polazeći od pretpostavke linearne regresije (4) i njezine nelinearne transformacije s pomoću funkcije (u ovom slučaju logističke funkcije (5)) kako bi dobivene procjene odgovarale vjerojatnostima u rasponu od 0 do 1.

$$Score_i = \beta' \boldsymbol{x}_i \tag{4}$$

$$PD_{i\ nekalib.} = \frac{1}{1 + e^{-Score_i}} = \frac{1}{1 + e^{-\beta' \boldsymbol{x}_i}} \tag{5}$$

pri čemu je $\boldsymbol{\beta}' = (c_1, \beta_1, ..., \beta_k)$ vektor k + 1 procijenjenih koeficijenata PD modela, uključujući konstantu c1 i koeficijente β_j za transformirane aplikacijske i bihevioralne varijable (njihove WoE vrijednosti), $\boldsymbol{x_i} = (1, x_{i1}, ..., x_{i,k})$ vektor transformiranih aplikacijskih i bihevioralnih varijabla, a broj 1 je konstanta u vektoru.

4.4. Diskriminatorna snaga modela

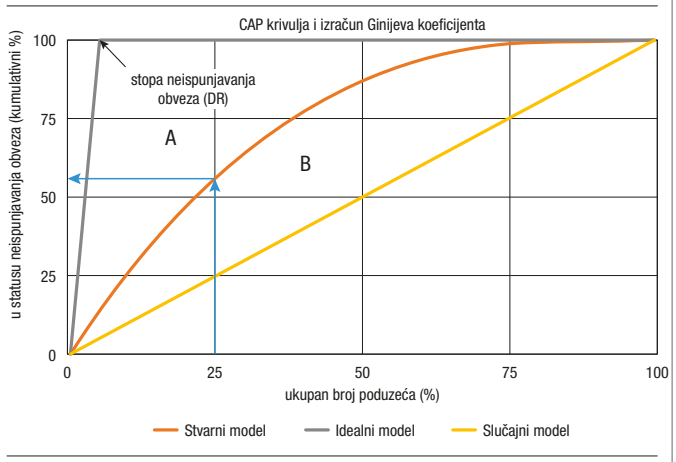
Diskriminatorna je snaga modela sposobnost modela da razdvoji "dobra" poduzeća (nisu u statusu neispunjavanja obveza) od "loših" poduzeća (jesu u statusu neispunjavanja obveza). Najčešće su mjere diskriminatorne snage modela Brierov skor i Lorenzova (CAP) krivulja s pripadajućim Ginijevim koeficijentom. U sklopu ovog istraživanja primjenjuje se Ginijev koeficijent kao mjera diskriminatorne snage modela i Lorenzova krivulja za vizualizaciju mjere diskriminatorne snage.

Lorenzova krivulja (CAP) i Ginijev koeficijent

Najčešći grafički prikaz diskriminatorne snage modela jest CAP ili Lorenzova krivulja. CAP krivulja prikazuje postotak obuhvaćenih "loših" poduzeća (os y, *"u statusu neispunjavanja obveza"*) uključenih u postotku ukupnih poduzeća (os x, *"ukupni broj poduzeća"*) kada su poduzeća poredana po vrijednostima analizirane varijable padajućim redoslijedom s obzirom na rizičnost (Slika 4.). Diskriminatorna snaga pojedine varijable (ili cijelog modela) utoliko je veća što su "loša" poduzeća više koncentrirana na lijevoj strani osi x. Npr. u 25%

5 Detalji o opisanim regresijama i iznesenim interpretacijama mogu se pronaći u radu Hyden i Porath (2011.).

Slika 4. Ilustracija diskriminatorne snage modela



Izvor: Autorov prikaz

ukupnog broja poduzeća na danom prikazu obuhvaćeno je više od 55% ukupnog broja poduzeća koja su u statusu neispunjavanja obveza ("loša").

Ginijev koeficijent (AR) kvantificirana je mjera diskriminatorne snage modela koja proizlazi iz CAP krivulje i računa se kao omjer dviju površina koje zatvaraju krivulje stvarnog i slučajnog modela (površina B) te idealnog i slučajnog modela (površina $A + B$):

$$GINI = B / (A + B) \tag{6}$$

Prihvatljiva razina diskriminatorne snage modela u praksi podrazumijeva vrijednosti Ginijeva koeficijenta veće od 0,4 (Tablica 2.).

Tablica 2. Diskriminatorna snaga Ginijeva koeficijenta

Ginijev koeficijent (AR)	Kvaliteta
AR < 0	**ne diskriminira**
0 < AR < 0,4	slabo diskriminira
0,4 < AR < 0,6	prihvatljiva diskriminacija
0,6 < AR < 0,8	izvrsna diskriminacija
0,8 < AR < 1	**iznimna diskriminacija**

Izvor: Baesens (2016.)

4.5. Kalibracija modela

Za procijenjene parametre β PD modela svakog segmenta nekalibrirani PD pojedinačnog poduzeća i izračunava se na način opisan izrazima (4) i (5) u poglavlju 4.3.

Relativna frekvencija nastajanja statusa neispunjavanja obveza RDF definira se kao omjer broja poduzeća kod kojih je nastupio status (broj "loših") i broja poduzeća kod kojih nije nastupio status neispunjavanja obveza (broj "dobrih"), izraz (7), dok je veza relativne frekvencije nastajanja statusa neispunjavanja obveza i vjerojatnosti dana izrazom (8).

$$RDF = \frac{\text{broj "loših"}}{\text{broj "dobrih"}} \tag{7}$$

$$RDF = \frac{PD}{1 - PD} \tag{8}$$

Izvor: OeNB i FMA (2004.)

Prilagodba (kalibriranje) relativne frekvencije nastajanja statusa neispunjavanja obveza uzorka relativnoj frekvenciji populacije (centralnoj tendenciji) definira se izrazom:

$$RDF_{kalibrirani} = RDF_{nekalibrirani} \frac{RDF^{CT}}{RDF^{S}} \tag{9}$$

Izvor: OeNB i FMA (2004.)

pri čemu je:

$RDF_{kalibrirani}$ – kalibrirana relativna frekvencija nastajanja statusa neispunjavanja obveza

$RDF_{nekalibrirani}$ – nekalibrirana relativna frekvencija nastajanja statusa neispunjavanja obveza

RDF^{CT} – višegodišnji prosjek relativne frekvencije nastanka događaja neispunjavanja obveza za populaciju

RDF^{S} – prosječna relativna frekvencija nastanka događaja neispunjavanja obveza uzorka.

Kombinacijom izraza (7), (8) i (9) može se izračunati kalibracijska funkcija za prilagodbu nekalibriranoga modelskog PD-a PD_i poduzeća na centralnu tendenciju prema prikazanoj formuli:

$$PD_i^{CT} = \frac{PD_i \cdot (1 - DR^{S}) \cdot DR^{CT}}{(1 - PD_i) \cdot DR^{S} \cdot (1 - DR^{CT}) + PD_i \cdot (1 - DR^{S}) \cdot DR^{CT}} \tag{10}$$

pri čemu je:

PD_i^{CT} – prema centralnoj tendenciji kalibrirani PD poduzeća i

PD_i – nekalibrirana modelska procjena PD-a poduzeća i

DR^{CT} – izračunata centralna tendencija (višegodišnji prosjek) stope nastanka događaja neispunjavanja obveza

DR^{S} – prosječna stopa nastanka događaja neispunjavanja obveza uzorka za procjenu parametara modela.

Binomni test

Pod pretpostavkom neovisnosti nastanka događaja neispunjavanja obveza, binomni test rabi se za ocjenu korektnosti predviđenih PD-ova (kalibracije) za pojedinačne kategorije rejtinga[6]. Na taj se način određuju kritične vrijednosti broja, odnosno stope nastupanja statusa neispunjavanja obveza za svaku kategoriju rejtinga. Modificirani binomni test upotrebljava aproksimaciju binomne distribucije s normalnom distribucijom prema centralnom graničnom teoremu kada je broj poduzeća dovoljno velik. Minimalni broj poduzeća u razredu rejtinga može se procijeniti s pomoću uvjeta za aproksimaciju binomne distribucije normalnom:

$$N_i \overline{PD_t}(1 - \overline{PD_t}) > 9 \Rightarrow N_{i\min} = \frac{9}{\overline{PD_t}(1 - \overline{PD_t})} \tag{11}$$

gdje je N_i broj poduzeća u razredu rejtinga i prosječne procijenjene vjerojatnosti nastupanja stanja neispunjavanja obveza $\overline{PD_t}$, a $N_{i\min}$ je minimalni broj poduzeća u razredu rejtinga i za koji vrijedi aproksimacija binomne distribucije normalnom.

U testu je primijenjena razina pouzdanosti $\alpha = 95\%$. Za svaku kategoriju rejtinga i modela izračunate su kritične vrijednosti za odabranu razinu pouzdanosti α: Inf_i – donja i Sup_i – gornja granica testa za ostvarene stope neispunjavanja obveza:

$$Inf_i = \overline{PD_t} - \Phi^{-1}(\alpha) \cdot \sqrt{\frac{\overline{PD_t} \cdot (1 - \overline{PD_t})}{N_i}} \tag{12}$$

$$Sup_i = \overline{PD_t} + \Phi^{-1}(\alpha) \cdot \sqrt{\frac{\overline{PD_t} \cdot (1 - \overline{PD_t})}{N_i}} \tag{13}$$

6 Prema autorima Blochwitz i dr. (2011.)

gdje je $\overline{PD_i}$ prosječna procijenjena vrijednost PD-a kategorije rejtinga i, N_i je ukupan broj poduzeća u kategoriji rejtinga i, a $\Phi^{-1}(\alpha)$ je inverzna kumulativna funkcija normalne distribucije za razinu pouzdanosti α, srednju vrijednost 0 i standardnu devijaciju 1. Ako je opažena stopa neispunjavanja obveza manja od kritične vrijednosti Inf_i za $\alpha = 95\%$, kategorija rejtinga osigurava dodatnu razinu konzervativnosti (PD je precijenjen), ako je opažena stopa neispunjavanja obveza između kritičnih vrijednosti Inf_i i Sup_i, kategorija rejtinga adekvatna je ostvarenim stopama uz zadanu razinu pouzdanosti (PD dobro procjenjuje vjerojatnost) te ako je opažena stopa neispunjavanja obveza iznad kritične vrijednosti Sup_i, kategorija rejtinga podcjenjuje rizik, što nije prihvatljivo za rejting-skalu. Binomni test primijenjen je pri određivanju rejting-skale u sklopu ovog istraživanja.

5. Rezultati regresije

5.1. Univarijatna analiza

5.1.1. Aplikacijske i bihevioralne varijable

Aplikacijske varijable temelje se na kvantitativnim i, ovisno o dostupnosti, kvalitativnim podacima o poduzećima koja se ocjenjuju. Kvantitativne aplikacijske varijable uglavnom se temelje na financijskim izvješćima poduzetnika iz kojih se izračunavaju pokazatelji poslovanja: pokazatelji likvidnosti, zaduženosti, aktivnosti, ekonomičnosti, profitabilnosti i investiranja. Kvalitativni aplikacijski podaci mogu biti broj zaposlenih (također dostupan iz financijskih izvješća), tržišni udio, nastup na tržištima, starost poduzeća, postojanje poslovne strategije, dostupnosti javnih objava i podataka o povezanim osobama, subjektivna procjena kvalitete menadžmenta i druge dostupne informacije. Frekvencija aplikacijskih varijabla je niska, uglavnom godišnja i zbog toga su one manje prediktivne od bihevioralnih varijabla. Inicijalni set aplikacijskih podataka uključivao je godišnja financijska izvješća iz razdoblja 2008. – 2015. godine, budući da su obrasci GFI-POD za navedeno razdoblje konzistentni, odnosno postoje manje razlike u obrascima za godine 2008. i 2009. u odnosu na obrasce od 2010. do 2015. godine, a struktura izvješća prije 2008. godine značajnije se razlikuje od novijih izvješća.

Bihevioralne varijable na kvantitativan način reflektiraju ponašanje poduzeća prije svega u poslovnom odnosu s kreditnom institucijom. Bihevioralne varijable mogu biti rezultat transakcijskog poslovanja u kreditnoj instituciji (otplate, korištenja, otpisi, platno-prometne transakcije) i poslovnog odnosa s kreditnim institucijama (broj kreditnih institucija, broj korištenih proizvoda, iznosi izloženosti, ugovorene kamatne stope) te varijable koje proizlaze iz kreditnog odnosa s kreditnim institucijama (klasifikacija izloženosti, kašnjenja u oplati dospjelih potraživanja i sl.). Bihevioralne varijable mogu biti i podaci o blokadama, o uvrštavanju na popise poduzeća koja ne isplaćuju plaće zaposlenicima, o poduzećima nad kojima se pokreću predstečajni i stečajni postupci i podaci iz sličnih izvora negativnih ili pozitivnih informacija. Frekvencija bihevioralnih kudikamo je viša od one aplikacijskih varijabla, može biti i dnevna frekvencija, a u HNB-u uglavnom su dostupne na dekadnoj ili mjesečnoj razini. Budući da se neke značajne bihevioralne varijable nisu sistematizirano prikupljale u prošlosti, zbog podatkovnih ograničenja bihevioralne varijable u trening-uzorku naposljetku su ograničene na razdoblje od 2011. do 2014. godine, a u validacijskom uzorku na 2015. godinu, zato što su potrebna i saznanja o ishodima statusa neispunjavanja obveza tijekom 2016. godine.

5.1.2. Inicijalni odabir varijabla na temelju rezultata univarijatne analize

Kriteriji za inicijalni odabir varijabla jesu zadovoljavajuća diskriminatorna snaga varijable, odnosno univarijatnog modela (modela sa samo jednom varijablom) iskazana Ginijevim koeficijentom te popunjenost varijable iskazana udjelom opservacija koji nisu prazne vrijednosti (*"null"*) u ukupnom broju opservacija.

Kao kriterij za inicijalni odabir varijabla potencijalnih kandidata za model u univarijatnoj analizi uzet je kriterij za Ginijev koeficijent iznad vrijednosti 0,3 i popunjenost varijabla iznad 80% u svim analiziranim godinama. Oba kriterija zadovoljava 29 varijabla (Tablica 3.).

Tablica 3. Univarijatna analiza – odabrani “dugi” popis varijabla

Opis varijable	Varijabla	Ukupno min. od Ginijeva koeficijenta	Ukupno min. od popunj.	Kriteriji (> od)		
				0,3	80%	
				Ginijev koeficijent	Popunjenost	Kompozitni
udio prosječnih dospjelih nenaplaćenih potraživanja > 90 dana u T0 + 3 mjeseca u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP_3MF_R	0,458	91,5%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja > 90 dana u T0 ± 3 mjeseca u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP_3MPF_R	0,451	91,5%	1	1	1
udio maksimalnih dospjelih nenaplaćenih potraživanja (KI-instrument) > 90 dana u T0 godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP_MAX_T0_R	0,305	92,6%	1	1	1
udio sume dospjelih nenaplaćenih potraživanja > 90 dana u T0 godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP_SUM_T0_R	0,342	92,6%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 30 dana u T0 + 3 mjeseca u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP30_3MF_R	0,320	91,5%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 30 dana u T0 ± 3 mjeseca u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP30_3MPF_R	0,353	91,5%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 30 dana u T0 + 6 mjeseci u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP30_6MF_R	0,372	91,5%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 60 dana u T0 + 3 mjeseca u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP60_3MF_R	0,529	91,5%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 60 dana u T0 ± 3 mjeseca u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP60_3MPF_R	0,556	91,5%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 60 dana u T0 + 6 mjeseci u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP60_6MF_R	0,657	91,5%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 60 dana u T0 – 7 mjeseci do T0 – 1 mjesec u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP60_71MP_R	0,390	91,2%	1	1	1
udio maksimalnih dospjelih nenaplaćenih potraživanja (KI-instrument) do 60 dana u T0 godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP60_MAX_T0_R	0,439	92,6%	1	1	1
udio sume dospjelih nenaplaćenih potraživanja do 60 dana u T0 godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP60_SUM_T0_R	0,444	92,6%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 90 dana u T0 + 3 mjeseca u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP90_3MF_R	0,425	91,5%	1	1	1
udio prosječnih dospjelih nenaplaćenih potraživanja do 90 dana u T0 + 6 mjeseci u godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP90_6MF_R	0,576	91,5%	1	1	1

udio maksimalnih dospjelih nenaplaćenih potraživanja (KI-instrument) do 90 dana u T0 godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP90_MAX_T0_R	0,315	92,6%	1	1	1
udio sume dospjelih nenaplaćenih potraživanja do 90 dana u T0 godišnjoj prosječnoj kreditnoj izloženosti	BH_DNP90_SUM_T0_R	0,316	92,6%	1	1	1
koeficijent trenutačne likvidnosti: novac / kratkoročne obveze	I1	0,354	100,0%	1	1	1
pokazatelj likvidnosti III: novac / ukupna imovina	I10	0,309	100,0%	1	1	1
prosječni dani plaćanja obveza: kratkoročne obveze / ukupni rashodi	I16	0,313	100,0%	1	1	1
novčano pokriće neto obveza: dobit nakon oporezivanja + amortizacija / (dug – rezerve) / 365	I27	0,347	100,0%	1	1	1
novčani tok II: dobit nakon oporezivanja + amortizacija / dug / 365	I28	0,368	100,0%	1	1	1
omjer pokrića servisiranja ukupnog duga DSCR II: EBITD / dug prema FI	I30	0,324	100,0%	1	1	1
koeficijent obrtaja obveza prema dobavljačima: obveze prema dobavljačima / prihodi od prodaje	I39	0,325	100,0%	1	1	1
neto rentabilnost imovine (ROA): dobit nakon oporezivanja / ukupna imovina	I57	0,310	100,0%	1	1	1
bruto rentabilnost imovine: dobit prije poreza / ukupna imovina	I58	0,315	100,0%	1	1	1
EBIT II: dobit prije poreza / kratkoročne obveze	I67	0,333	100,0%	1	1	1
EBIT V: dobit prije poreza / ukupne obveze	I70	0,340	100,0%	1	1	1
pokazatelj profitabilnosti III: prihod iz redovnog poslovanja / ukupne obveze	I72	0,337	100,0%	1	1	1

Izvori: Fina; HNB; autorov izračun

5.1.3. Ograničavanje netipičnih vrijednosti varijabla

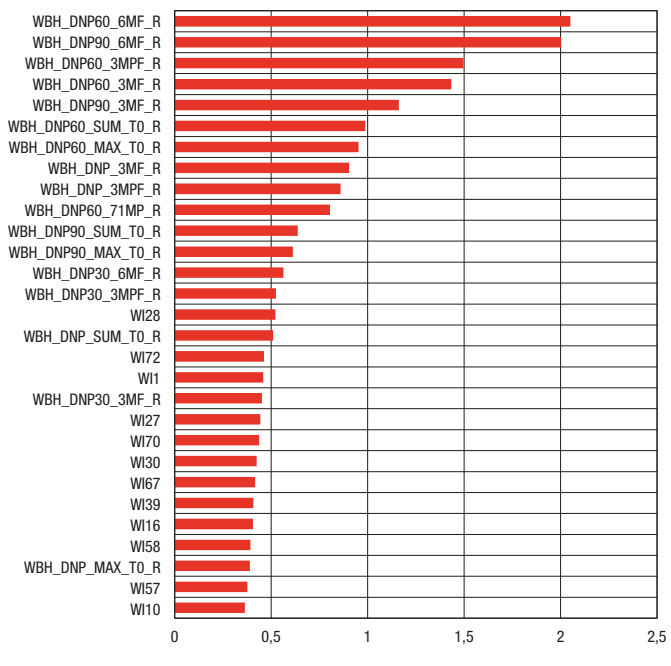
Ograničavanje netipičnih vrijednosti varijabla (tzv. winsorizacija prema Charlesu P. Winsoru) postupak je uklanjanja ekstremnih vrijednosti varijabla iz uzorka, tj. zamjena ekstremnih vrijednosti zadanim percentilom distribucije varijable. Primjena varijabla s neograničenim vrijednostima u regresiji rezultirala je visokom regresijskom pogreškom, tako da su u odabranim aplikacijskim i biheviоralnim varijablama ekstremne vrijednosti ograničene na repovima distribucije u 2% slučajeva, odnosno donji ekstremi zamijenjeni su 1. percentilom, a gornji ekstremi s 99. percentilom distribucije. Na taj način postiže se bitno manja varijabilnost u uzorku, što omogućuje uključivanje ekstremno visokih i ekstremno niskih vrijednosti varijabla u regresiju, bez gubitka informacije te se prema Yaffee (2002.) postiže bolja robusnost i reprezentativnost regresije (npr. korigirani koeficijent determinacije i procijenjena standardna devijacija regresije). Varijablama s ograničenjem netipičnih vrijednosti u nazivu je dodan prefix *"W"*.

5.2. Multivarijatna analiza

Multivarijatna analiza ispituje međusobne korelacije odabranih varijabla i isključuje visoko korelirane varijable (osim najznačajnije) iz daljnje analize radi otklanjanja mogućeg problema multikolinearnosti. U multivarijatnoj analizi upotrijebljene su korelacijske matrice, a kriterij za odbacivanje visokokoreliranih varijabli jest koeficijent korelacije viši od 60%[7]. Kao dodatni kriteriji za odabir jedne od visokokoreliranih varijabla upotrijebljeni

7 Farrar i Glauber (1967.) preporučuju ograničavanje jednostavno koreliranih neovisnih varijabla do maksimalno 80% – 90%.

Slika 5. Informacijska vrijednost varijabla s “dugog” popisa



Izvor: Autorov izračun

su diskriminatorna snaga (viša je bolja), popunjenost i informacijska vrijednost (više je bolje, Slika 5.). Način izračuna informacijske vrijednosti i njezino značenje opisani su detaljno u poglavlju 5.2.2. Transformacija varijabla. Na Slici 5. Informacijska vrijednost varijabla s “dugog” popisa vidljivo je da biheviorалne varijable imaju veće informacijske vrijednosti od aplikacijskih, što potvrđuje i njihovu bolju prediktivnu snagu (Tablica 1.).

5.2.1. Korelacijske matrice

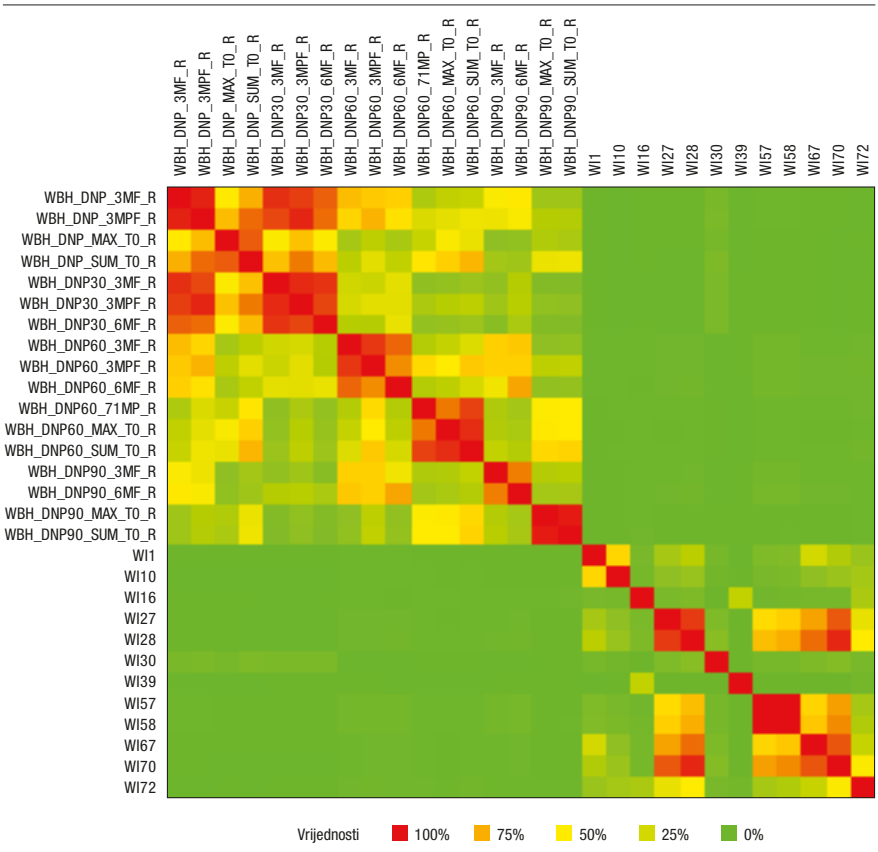
Matrice međusobnih korelacija neovisnih varijabla prikazane su s pomoću termalne mape, a visina korelacije parova varijabla kodirana je zeleno-žuto-crvenim spektrom (Slika 6.). U tako prikazanoj korelacijskoj matrici vidljivi su parovi visoko koreliranih varijabla. Međutim, međusobna je koreliranost aplikacijskih

Tablica 4. Korelacijska matrica odabranih varijabla s “kratkog” popisa

Indikator	IV	Ginijev koeficijent	Popunjeno	WBH_DNP60_71MP_R	WBH_DNP60_SUM_T0_R	WI1	WI16	WI27	WI30	WI39	WI72
WBH_DNP60_71MP_R	0,81	0,39	91%		53%	4%	5%	5%	2%	1%	7%
WBH_DNP60_SUM_T0_R	0,99	0,44	93%	53%		3%	6%	4%	2%	2%	6%
WI1	0,46	0,35	100%	4%	3%		11%	28%	10%	0%	24%
WI16	0,41	0,31	100%	5%	6%	11%		12%	3%	36%	30%
WI27	0,44	0,35	100%	5%	4%	28%	12%		15%	4%	45%
WI30	0,42	0,32	100%	2%	2%	10%	3%	15%		2%	11%
WI39	0,41	0,33	100%	1%	2%	0%	36%	4%	2%		9%
WI72	0,46	0,34	100%	7%	6%	24%	30%	45%	11%	9%	

Izvor: Autorov izračun

Slika 6. Termalna mapa korelacija varijabla s “dugog” popisa



Izvor: Autorov izračun

i bihevioralnih varijabla niska, što potvrđuje opravdanost upotrebe obiju vrsta neovisnih varijabla. Konačni odabir varijabla na temelju opisanih kriterija rezultira skupom od dvije bihevioralne varijable i šest aplikacijskih varijabla koje će biti ulazne varijable za procjenu parametara regresije.

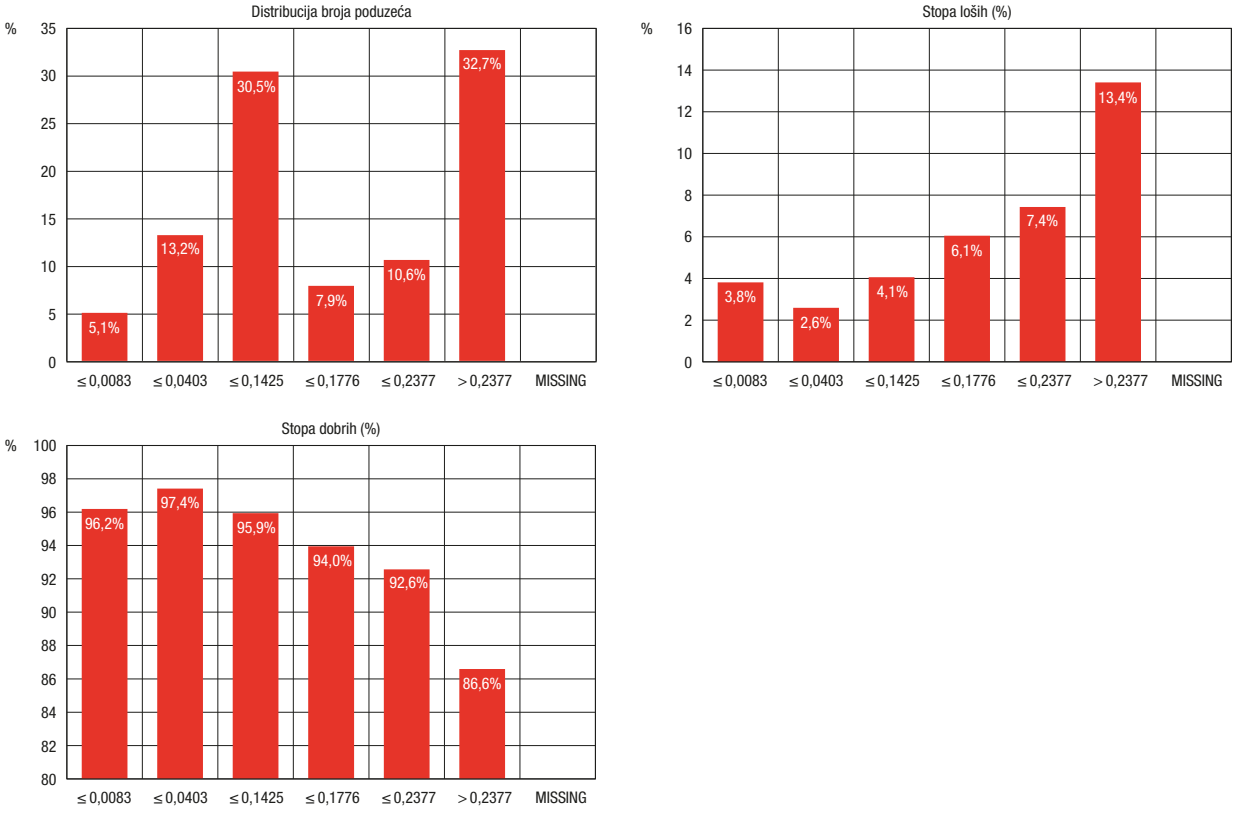
Iz daljnje analize izostavljene su i sve bihevioralne varijable koje mogu biti ranim znakom neispunjavanja obveza, kako bi se izbjegla autoregresivna komponenta u modelu, poput udjela prosječnih dospjelih nenaplaćenih potraživanja do 60 dana u $T_0 + 3$ mjeseca u godišnjoj prosječnoj kreditnoj izloženosti, budući da izostanak plaćanja do trenutka $T_0 + 4$ mjeseca može rezultirati kašnjenjem materijalno značajnog potraživanja duljim od 90 dana, što je u skladu s definicijom statusa neispunjavanja obveza.

5.2.2. Transformacija varijabla s pomoću težine dokaza (WoE)

Na sve varijable s kratkog popisa (izuzevši indikatorske) primijenjena je transformacija s pomoću težine dokaza, kako bi se na taj način, maksimiziranjem informacijske vrijednosti varijable, postigla što bolja prediktivna svojstva modela. Na primjeru varijable WI39 (indikator I39 s ograničenim netipičnim vrijednostima) vidljiv je prekid monotonog rasta funkcije rizika (Slika 7., grafikon “Stopa loših (%)”). Rizičnost prvog skupa veća je od rizičnosti drugog skupa, a nakon čega rizičnost skupova nastavlja monotono rasti. Zbog toga je WoE transformirana vrijednost prvog skupa manja od WoE vrijednosti drugog skupa, a potom WoE vrijednosti nastavljaju padati (veća WoE vrijednost uvijek znači manju rizičnost skupa jer je proporcionalna udjelu “dobrih” poduzeća, a obrnuto proporcionalna udjelu “loših”).

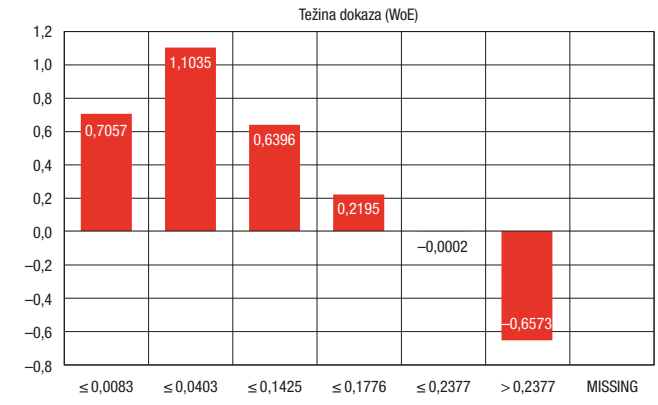
Tako transformirane varijable jesu ulazne varijable za procjenu parametara modela logističke regresije.

Slika 7. Distribucija varijable WI39 po skupovima



Izvor: Autorov izračun

Slika 8. WoE transformirana varijabla WI39



Izvor: Autorov izračun

5.3. Procjena parametara modela logističke regresije

5.3.1. Segmentacija i procjena parametara modela

Dosadašnja analiza provedena je na kompletnom trening-uzorku. Budući da postoje potencijalne razlike u rizičnosti poduzeća ovisno o nekim kvalitativnim faktorima, prije procjene parametara logističke regresije potrebno je provjeriti rizične profile određenih segmenata te donijeti odluku o broju modela i o broju kvalitativnih indikatorskih varijabla kako bi model što bolje odražavao vjerojatnost nastanka događaja neispunjavanja obveza s obzirom na specifičnosti segmenata. Rizičnost segmenta iskazana je stopom nastanka statusa neispunjavanja obveza (*DR*), koja se računa kao udio poduzeća u statusu neispunjavanja obveza u ukupnom broju poduzeća segmenta.

Tablica 5. Rizični profil prema segmentima

Segmentacija prema varijabli	Segment	Broj poduzeća	DR
Sektor	Javna poduzeća	1.407	5,8%
	Privatna većinski domaća poduzeća	63.096	7,5%
	Privatna većinski strana poduzeća	4.546	7,2%
Ukupno		**69.049**	
Projektno financiranje (SPV)	Poduzeća	68.958	7,4%
	Projektno financirana poduzeća (SPV)	91	18,7%
Ukupno		**69.049**	
NKD	Građevinarstvo i nekretnine	8.347	11,5%
	Poljoprivreda i rudarstvo	2.070	9,3%
	Hotelijerstvo	3.915	8,7%
	Prerađivačka industrija	12.964	7,9%
	Trgovina	21.838	6,9%
	Prijevoz, skladištenje i veze	6.087	6,7%
	Uslužne djelatnosti	11.956	5,1%
	Ostale djelatnosti	1.872	3,8%
Ukupno		**69.049**	
Veličina	Mali	64.826	7,3%
	Srednji	3.287	9,8%
	Veliki	936	9,3%
Ukupno		**69.049**	

Izvor: Autorov izračun

Profile rizičnosti prema različitim segmentacijama prikazuje Tablica 5. Segmentacija poduzeća napravljena je po sektorizaciji, projektnom financiranju, grupi NKD-a i veličini poduzeća (prema Fini). Prema rizičnom profilu odskaču privatna poduzeća u odnosu na javna, projektno financiranje u odnosu na ostala poduzeća, građevinarstvo (GRAD) u odnosu na ostale grupe NKD-a te srednja i velika poduzeća u odnosu na mala. S obzirom na navedene povišene rizičnosti nekih segmenata poduzeća, specifičnosti poslovanja, ali i broj dostupnih opservacija u segmentiranom uzorku, posebno onih u statusu neispunjavanja obveza, u uzorak se dodaju nove indikatorske varijable (tzv. *dummy* varijable), koje poprimaju vrijednosti 1 i 0, ovisno o obilježju koje označavaju:

a) indikatorska varijabla za oznaku sektora javnih poduzeća: DMY_SOE
b) indikatorska varijabla za oznaku projektnog financiranja: DMY_SPV
c) indikatorska varijabla za oznaku djelatnosti građevinarstva: DMY_GRAD.

Budući da postoji značajnija razlika u rizičnom profilu poduzeća iz segmenta malih poduzeća u odnosu na segmente srednjih i velikih poduzeća (Tablica 5.), kao i u njihovim poslovnim modelima, načinima i uvjetima financiranja, nastupu na tržištu i mnogim drugim poslovnim i bihevioralnim aspektima, a broj opservacija i

statusa neispunjavanja obveza dovoljan je za neovisnu procjenu parametara regresije, procijenjena su dva modela: model za segment malih poduzeća (oznaka S) te model za segment srednjih i velikih poduzeća (oznaka ML). Prema rezultatima regresija vidljivo je da se signifikantne varijable za tako odabrane segmente razlikuju, odnosno da većina varijabla koje su signifikantne za segment malih poduzeća, nisu signifikantne za model srednjih i velikih poduzeća, što dodatno opravdava primijenjenu segmentaciju (Tablica 6. i Tablica 7.).

Za procjenu parametara regresije β upotrijebljen je programski paket R, funkcija GLM za binomial(logit) regresiju (binomna logistička regresija).

Rezultati su regresije nakon isključivanja nesignifikantnih varijabla iz modela sljedeći[8]:

Tablica 6. Rezultati regresije za segment malih poduzeća

Segment malih poduzeća (S)	Procjenitelj ß	Std. Error	z value	Pr(>|z|)	Značajnost
c1	–2,58767	0,01922	–134,63505	< 2E–16	***
WOEWBH_DNP60_71MP_R	–0,81597	0,01655	–49,29403	< 2E–16	***
WOEWI72	–0,25233	0,03153	–8,00404	1,20403E–15	***
WOEWI1	–0,53027	0,02765	–19,17474	< 2E–16	***
WOEWI27	–0,22311	0,03623	–6,15810	7,36236E–10	***
WOEWI30	–0,48226	0,03254	–14,82144	< 2E–16	***
WOEWI39	–0,33080	0,03000	–11,02689	< 2E–16	***
DMY_GRAD	0,23379	0,04305	5,43094	5,60577E–08	***
signif. codes	'***' 0,001	'**' 0,01	'*' 0,05	'.' 0,1	' ' 0
residual deviance:	27475,1	residual degrees of freedom:	64818		
null deviance:	33824,6	null degrees of freedom:	64825		
AIC	27491,1	iterations:	6		

Izvor: Autorov izračun

Tablica 7. Rezultati regresije za segment srednjih i velikih poduzeća

Segment srednjih i velikih poduzeća (ML)	Procjenitelj ß	Std. Error	z value	Pr(>|z|)	Značajnost
c1	–2,13712	0,06476	–33,00142	< 2E–16	***
WOEWBH_DNP60_71MP_R	–0,62819	0,05683	–11,05450	< 2E–16	***
WOEWI1	–0,67525	0,10908	–6,19049	5,99758E–10	***
WOEWI30	–0,74384	0,09210	–8,07674	6,65221E–16	***
WOEWI39	–0,57762	0,10751	–5,37280	7,75231E–08	***
DMY_GRAD	0,38332	0,17550	2,18417	0,028949917	*
signif. codes	'***' 0,001	'**' 0,01	'*' 0,05	'.' 0,1	' ' 0
residual deviance:	2140,3	residual degrees of freedom:	4217		
null deviance:	2682,3	null degrees of freedom:	4222		
AIC	2152,3	iterations:	6		

Izvor: Autorov izračun

Provjerom ekonomskog značenja pojedinih neovisnih varijabla (Tablica 9.) te očekivanog predznaka koeficijenata netransformiranih i transformiranih varijabla s obzirom na rast ili pad rizičnosti s porastom vrijednosti varijable, ustanovljeno je da su parametri regresije u skladu s očekivanjima[9] i primijenjenim transformacijama te da smisleno opisuju rizik koji proizlazi iz predmetnih faktora rizika. U tablicama su prikazane varijable modela kao i njihov pretpostavljeni ekonomski smisao u kontekstu rizičnosti: znači li visoka ili niska vrijednost indikatora višu ili nižu razinu rizičnosti, tj. je li varijabla u pozitivnoj ili negativnoj korelaciji s rizikom

8 Tablica 3. sadržava detaljnije opise navedenih varijabla.

9 Iste rezultate za većinu primijenjenih aplikacijskih varijabla dobili su i autori Ivičić i Cerovac (2009.).

Tablica 8. Popis varijabla modela i primijenjenih transformacija

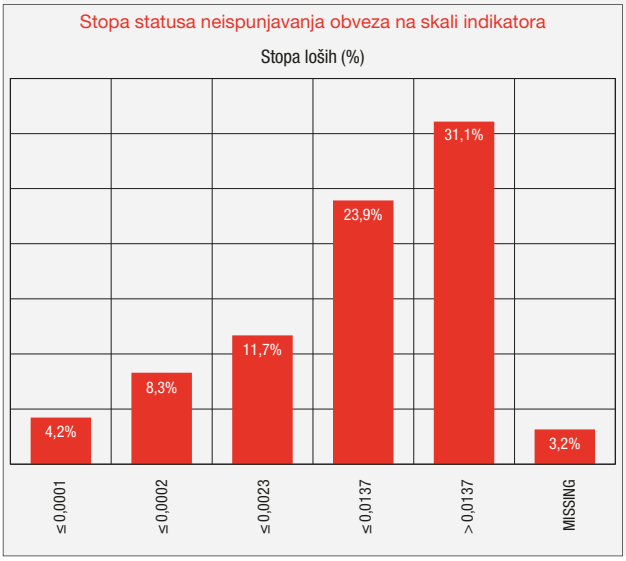
Izvorni naziv varijable	Opis varijable	Oznaka nakon transformacije		Model	
		ograničavanje netipičnih vrijednosti	težina dokaza	S	ML
BH_DNP60_71MP_R	udio prosječnih dospjelih nenaplaćenih potraživanja do 60 dana od 7 mjeseci do 1 mjesec prije datuma GFI-POD u godišnjoj prosječnoj kreditnoj izloženosti	WBH_DNP60_71MP_R	WOEWBH_DNP60_71MP_R	1	1
I1	Koeficijent trenutne likvidnosti: Novac / Kratkoročne obveze	WI1	WOEWI1	1	1
I27	Novčano pokriće neto obveza: Dobit nakon oporezivanja + amortizacija / (Dug* – rezerve) / 365	WI27	WOEWI27	1	0
I30	Omjer pokrića servisiranja ukupnog duga DSCR II: EBITD / Dug prema FI	WI30	WOEWI30	1	1
I39	Koeficijent obrtaja obveza prema dobavljačima: Obveze prema dobavljačima / Prihodi od prodaje	WI39	WOEWI39	1	1
I72	Pokazatelj profitabilnosti III: Prihod iz redovnog poslovanja / Ukupne obveze	WI72	WOEWI72	1	0
DMY_GRAD	Indikatorska varijabla: pripadnost djelatnosti građevinarstva	ne transformira se	ne transformira se	1	1

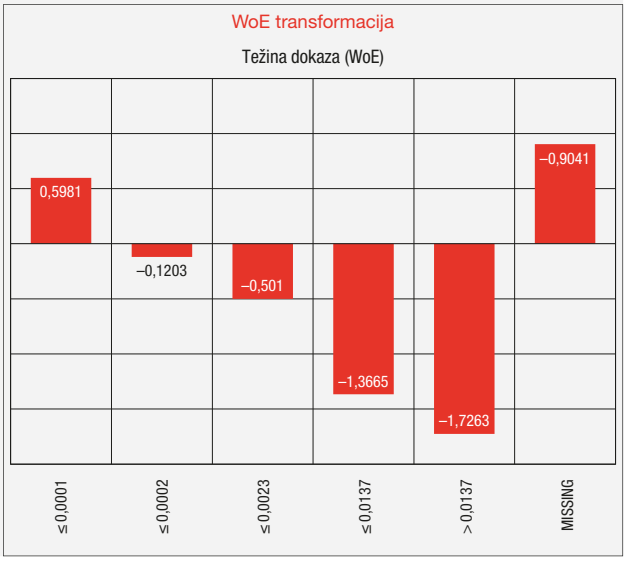
Izvor: Autorov izračun

nastajanja statusa neispunjavanja obveza (ovisna varijabla). Ostvarena prosječna stopa nastajanja statusa neispunjavanja obveza (DR) u trening-uzorku kategorizirane ulazne varijable dokazuje postavljenu hipotezu ekonomskog smisla varijable djelomično (hipoteza vrijedi u većem dijelu raspona) ili u potpunosti (u cijelom rasponu vrijednosti varijable). Primijenjene WoE transformacije ulaznih varijabla korigiraju eventualne prekide monotonog tijeka funkcije u korelaciji neovisne i ovisne varijable i ujednačavaju smjer korelacije (manja vrijednost transformirane varijable odgovara većoj razini rizika nastajanja statusa neispunjavanja obveza, stoga je i očekivani predznak procjenitelja β negativan, što odgovara predznacima procjenitelja dobivenih regresijom).

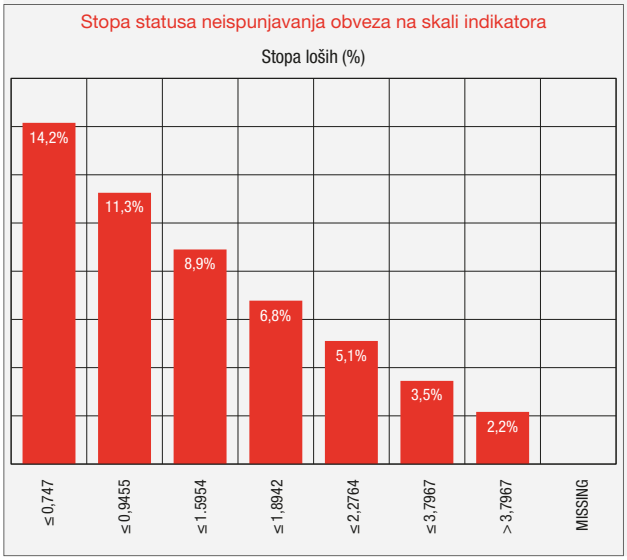
Tablica 9. Potvrda ekonomske smislenosti parametara regresije: segment malih poduzeća (S) i segment srednjih i velikih poduzeća (ML)

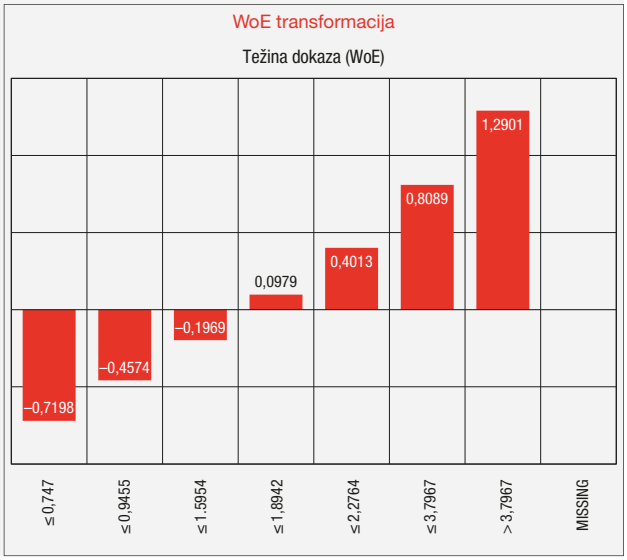
Oznaka indikatora	Ekonomski smisao	Ekonomski smisao OK?	Transformacija	Rizičnost transf. varijable	Očekivani predznak ß	ß	Značajnost	Predznak OK?
BH_DNP60_71MP_R	manje je bolje	OK	WoE	manje je rizičnije	–	S: –0,8160	0,1%	OK
						ML: –0,6282	0,1%	OK



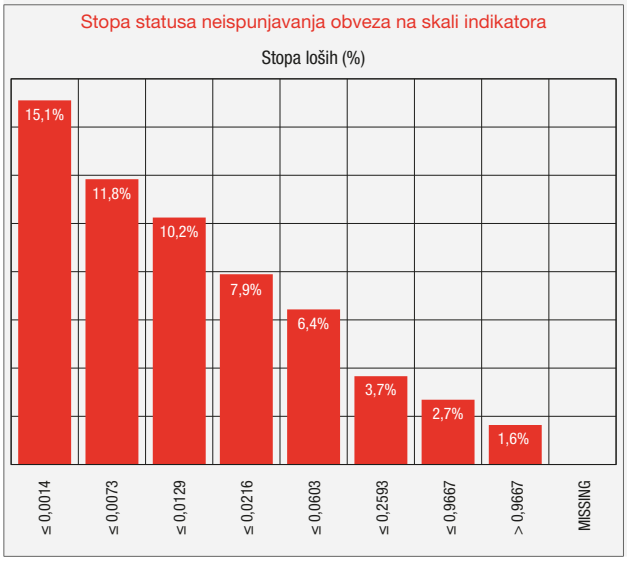


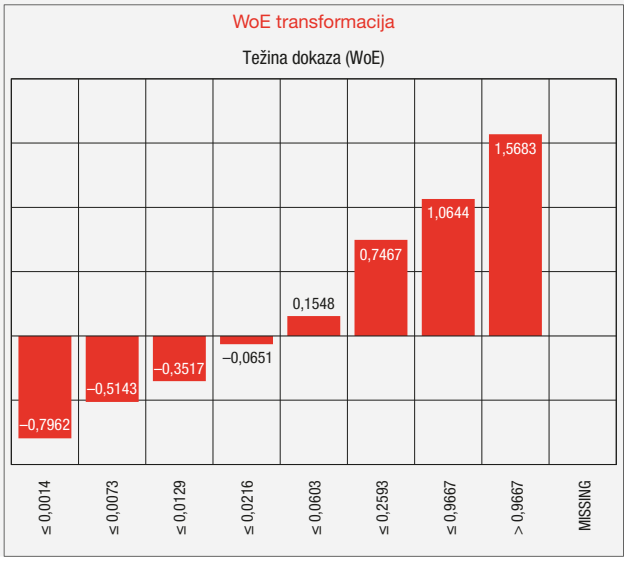
Oznaka indikatora	Ekonomski smisao	Ekonomski smisao OK?	Transformacija	Rizičnost transf. varijable	Očekivani predznak ß	ß	Značajnost	Predznak OK?
I72	više je bolje	OK	WoE	manje je rizičnije	–	S: –0,2523	0,1%	OK



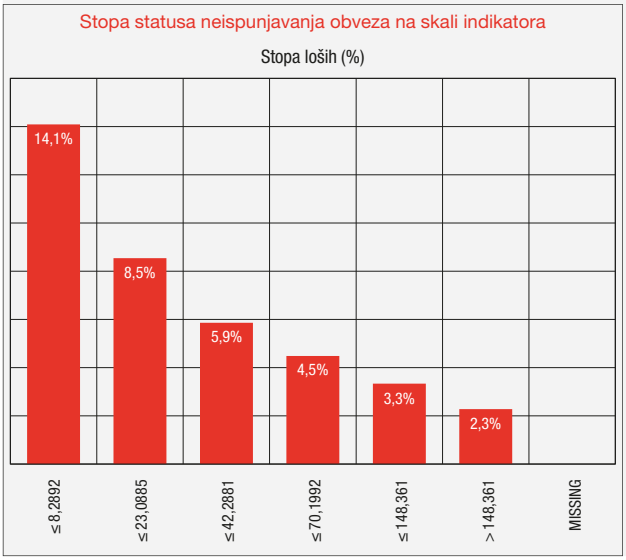


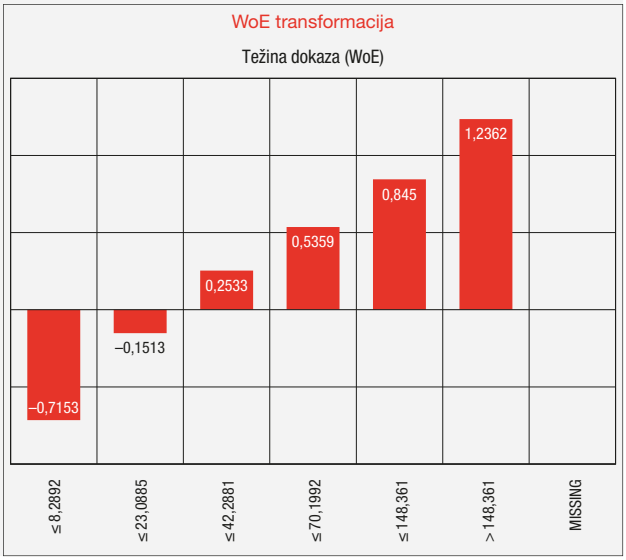
Oznaka indikatora	Ekonomski smisao	Ekonomski smisao OK?	Transformacija	Rizičnost transf. varijable	Očekivani predznak ß	ß	Značajnost	Predznak OK?
I1	više je bolje	OK	WoE	manje je rizičnije	–	S: –0,5303	0,1%	OK
						ML: –0,6753	0,1%	OK



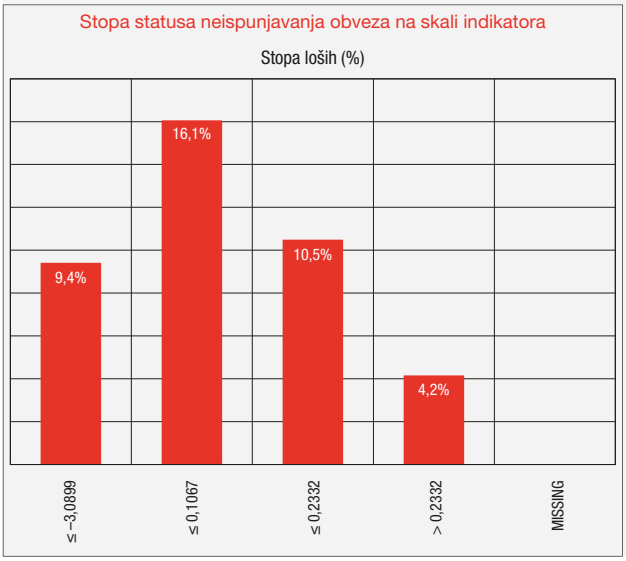


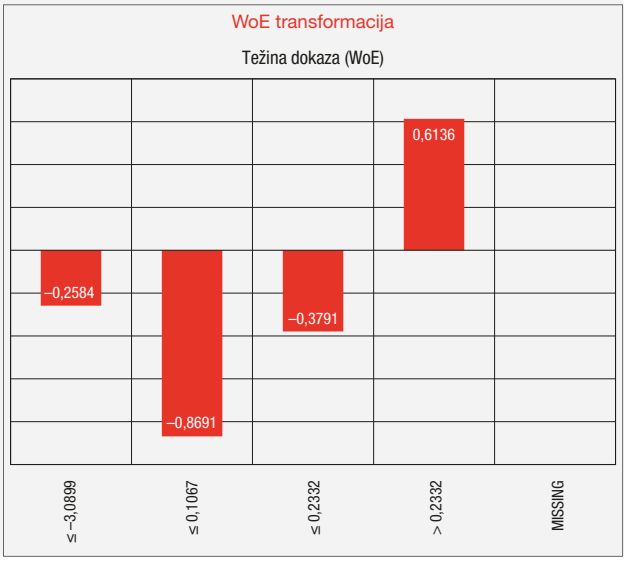
Oznaka indikatora	Ekonomski smisao	Ekonomski smisao OK?	Transformacija	Rizičnost transf. varijable	Očekivani predznak ß	ß	Značajnost	Predznak OK?
I27	više je bolje	OK	WoE	manje je rizičnije	–	S: –0,2231	0,1%	OK





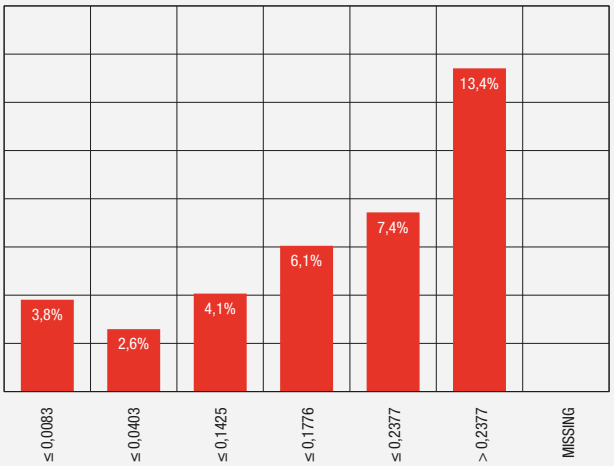
Oznaka indikatora	Ekonomski smisao	Ekonomski smisao OK?	Transformacija	Rizičnost transf. varijable	Očekivani predznak ß	ß	Značajnost	Predznak OK?
I30	više je bolje	OK	WoE	manje je rizičnije	–	S: –0,4823	0,1%	OK
						ML: –0,7438	0,1%	OK



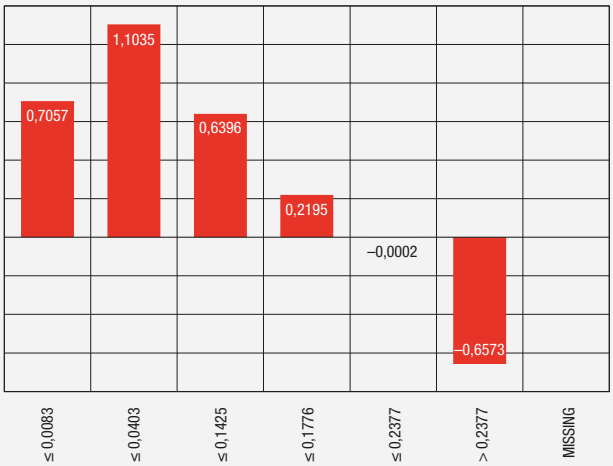


Oznaka indikatora	Ekonomski smisao	Ekonomski smisao OK?	Transformacija	Rizičnost transf. varijable	Očekivani predznak ß	ß	Značajnost	Predznak OK?
I39	manje je bolje	OK	WoE	manje je rizičnije	–	S: –0,3308	0,1%	OK
						ML: –0,5776	0,1%	OK

Stopa statusa neispunjavanja obveza na skali indikatora

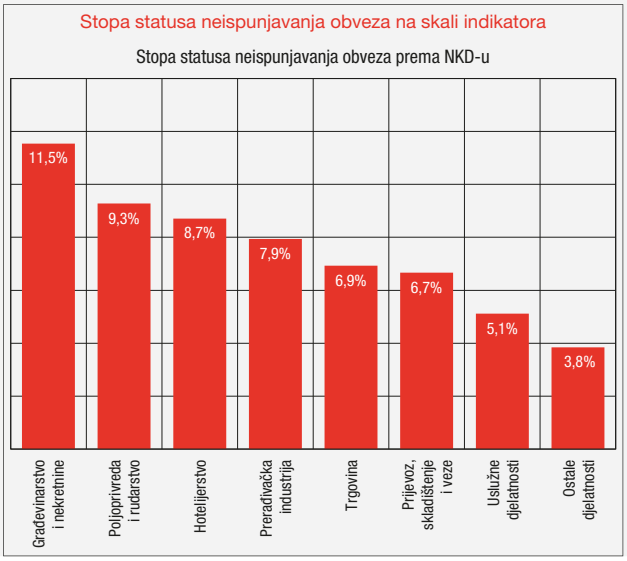


WoE transformacija



Oznaka indikatora	Ekonomski smisao	Ekonomski smisao OK?	Transformacija	Rizičnost transf. varijable	Očekivani predznak ß	ß	Značajnost	Predznak OK?
DMY_GRAD	manje (0) je bolje	OK	–	više je rizičnije	+	0,2338	0,1%	OK

Stopa statusa neispunjavanja obveza na skali indikatora



Izvor: Autorov izračun

Indikatorske varijable ne trasformiraju se, pa predznaci njihovih procjenitelja odgovaraju predznacima u postavljenoj hipotezi (ekonomski smisao).

Bihevioralna varijabla BH_DNP60_71MP_R ima najmanju stopu neispunjavanja obveza za poduzeća koja nemaju vrijednost te varijable (vrijednost MISSING na grafičkom prikazu), a to znači da u promatranom razdoblju nemaju evidentirana kašnjenja ni po jednoj kreditnoj obvezi. S porastom vrijednosti varijable, očekivano, raste i rizičnost iskazana stopom neispunjavanja obveza, što je u skladu s ekonomskim smislom varijable. Rezultirajući predznak procjenitelja za transformiranu varijablu također je u skladu s ekonomskim smislom i očekivanjima (pri transformaciji s pomoću težine dokaza manja vrijednost transformacije predstavlja veći rizik, što vrijedi za sve transformirane varijable).

Rezultati regresije za financijske pokazatelje I72, I1 i I27 u skladu su s njihovim ekonomskim smislom, tj. viša vrijednost indikatora upućuje na nižu rizičnost poduzeća i vrijedi za cijeli raspon pokazatelja. Predznaci parametara regresije očekivano su negativni.

Funkcija rizičnosti za pokazatelje I30 i I39 nije monotona, već u početnom dijelu intervala vrijednosti indikatora dolazi do infleksije funkcije rizičnosti (za oba indikatora u drugom skupu), što transformacija s pomoću težine dokaza (WoE) ispravlja dodjeljujući težinu dokaza svakom skupu obrnuto proporcionalnu sadržanom riziku.

Indikatorska varijabla temeljena na Nacionalnoj klasifikaciji djelatnosti (NKD) po rizičnosti izdvaja poduzeća iz djelatnosti građevinarstva i poslovanja s nekretninama, a pozitivni parametar regresije doprinosi povećanju vjerojatnosti nepodmirivanja obveza za poduzeća iz navedene djelatnosti.

5.3.2. Utjecaj bihevioralnih varijabla na diskriminatornu snagu modela

Diskriminatorna snaga dobivenih modela testirana je s pomoću CAP krivulje i Ginijeva koeficijenta (vidi poglavlje 5.1.2. Inicijalni odabir varijabla na temelju rezultata univarijatne analize). Procjena parametara napravljena je i na istovrsnim uzorcima bez bihevioralnih varijabla, primjenom isključivo aplikacijskih i indikatorskih varijabla te je s pomoću tako dobivenih aplikacijskih modela izračunat odgovarajući PD na cijelom trening-uzorku. Rezultati modela koji upotrebljavaju bihevioralne varijable u skladu s očekivanjem bolji su od modela koji rabe isključivo aplikacijske varijable.

Aplikacijski modeli za oba segmenta imaju **prihvatljivu** diskriminatornu snagu, dok isti modeli prošireni bihevioralnim varijablama imaju **izvrsnu** diskriminatornu snagu (Tablica 2. i Tablica 10.).

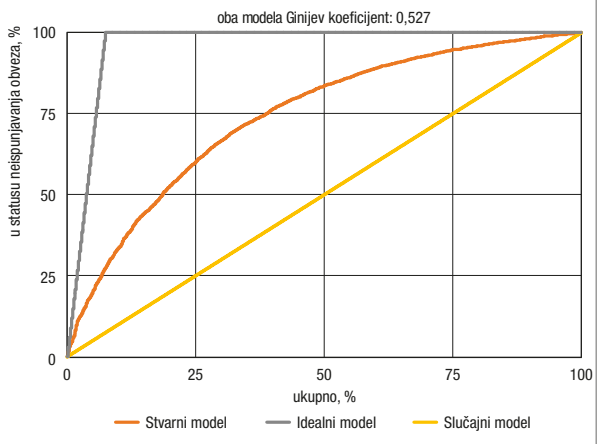
Tablica 10. Rezultirajući Ginijevi koeficijenti aplikacijskih i bihevioralnih modela

Model	Ginijev koeficijent (aplikacijski model)	Ginijev koeficijent (bihevioralni model)
Srednji i veliki (ML)	0,560	0,615
Mali (S)	0,524	0,626
Oba modela	0,527	0,626

Izvor: Autorov izračun

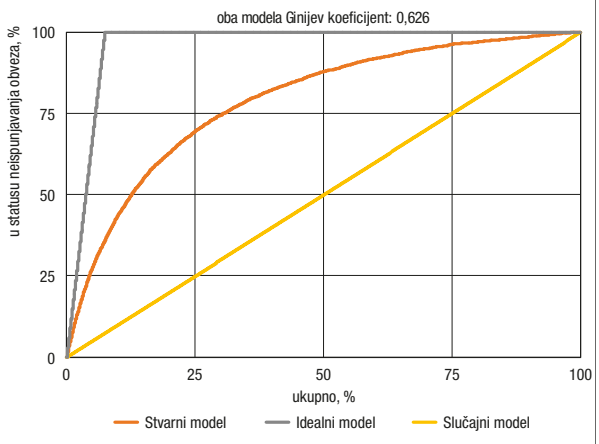
Diskriminatorna snaga modela i njezina razlika među aplikacijskim i bihevioralnim modelima vidljiva je i na CAP krivuljama prema površinama koje zatvaraju krivulje stvarnog modela i slučajnog modela (Slika 9. i Slika 10.).

Slika 9. CAP krivulja i Ginijev koeficijent za oba segmenta
aplikacijski modeli



Izvor: Autorov izračun

Slika 10. CAP krivulja i Ginijev koeficijent za oba segmenta
bihevioralni modeli



Izvor: Autorov izračun

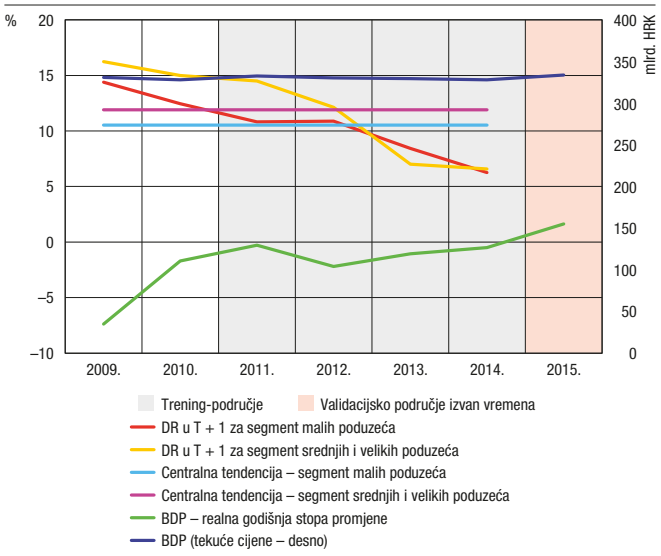
Primjena bihevioralnih varijabla svoje opravdanje, osim u povećanju diskriminatorne snage modela, ima i u činjenici da se bihevioralne varijable mogu pratiti s većom učestalošću od aplikacijskih varijabla. U modelima su upotrijebljene bihevioralne informacije o danima kašnjenja u podmirivanju dospjelih obveza do 60 dana u vremenskom "prozoru" od šest mjeseci (od sedam mjeseci do jednog mjeseca prije referentnog datuma godišnjega financijskog izvješća poduzetnika) za segment malih te srednjih i velikih poduzeća. Iako takva sporadična kašnjenja do maksimalno 60 dana nisu početna faza nastanka statusa neispunjavanja obveza koji nastupa nakon 90 dana kašnjenja (svi takvi isključeni su iz uzorka, Slika 1.), jer nakon evidentiranog kašnjenja do 60 dana slijedi oporavak dužeg ili kraćeg trajanja, ipak takva poduzeća s visokom vjerojatnošću u roku od jedne godine dolaze u ozbiljnije probleme, odnosno u status neispunjavanja obveza i/ili reklasifikaciju u neprihodonosne klijente kreditnih institucija. Premda aplikacijske varijable možda još ne upozoravaju na probleme u poslovanju, upravo zbog niže frekvencije njihova osvježavanja (jednogodišnje), bihevioralne varijable kontinuirano se prate i kreditne institucije izvještavaju HNB o takvim dužnicima na mjesečnoj razini, pa su takve informacije dostupne tijekom cijele godine.

Upotrebom istih aplikacijskih varijabla (npr. prema GFI-POD za 2015. godinu) i osvježavanjem bihevioralnih varijabla najnovijim podacima (unutar identičnih vremenskih "prozora", samo s pomakom referentnog datuma), modeli izračunavaju novu vjerojatnost nastupanja statusa neispunjavanja obveza i rejting za takva poduzeća. Na taj se način gotovo kontinuirano može pratiti rizičnost pojedinih poduzeća, skupine poduzeća ili portfelja neke kreditne institucije te naposljetku cijelog sustava u domeni nefinancijskih poduzeća.

5.3.3. Kalibracija modela i definiranje rejting-skale

Modelski izračunata vrijednost $PD_{i\ nekalib.}$ nekalibrirana je vjerojatnost nastanka statusa neispunjavanja obveza poduzeća koja odražava vjerojatnost nastanka statusa neispunjavanja obveza u odnosu na uzorak na kojemu je napravljena procjena koeficijenata β. Tako izračunatu vjerojatnost potrebno je kalibrirati prema centralnoj tendenciji stope nastanka statusa neispunjavanja obveza svakog segmenta u određenom razdoblju. Razdoblje bi trebalo po mogućnosti obuhvaćati cijelu fazu ekonomskog ciklusa. Međutim, zbog nedostupnosti podataka starijih datuma, centralna tendencija izračunata je za stope nastanka statusa neispunjavanja obveza u vremenu 2010. – 2015., što odgovara izračunu PD-a prema aplikacijskim i bihevioralnim podacima za razdoblje 2009. – 2014. godine.

Slika 11. Kretanje BDP-a, stope neispunjavanja obveza i izračun centralne tendencije



Izvori: HNB; autorov izračun

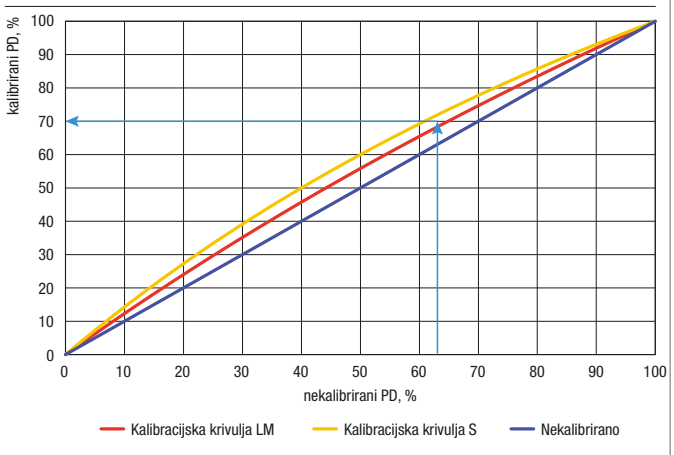
Tablica 11. Stope DR i centralna tendencija

Segment	DR^S	DR^{CT}
Srednji i veliki (ML)	9,66%	11,91%
Mali (S)	7,28%	10,54%

Izvor: Autorov izračun

Primijenjene stope nastanka statusa neispunjavanja obveza (DR) i centralne tendencije za kalibraciju modela za segmente prikazane su u Tablici 11.

Slika 12. Kalibracija PD-a prema centralnoj tendenciji



Izvor: Autorov izračun

Definiranje rejting-skale PD poduzeća omogućuje praćenje "kvarenja" portfelja prihodonosnih klijenata kreditnih institucija te uočavanje potencijalno problematičnih poduzeća prije nastupanja statusa neplaćanja obveza. Rejting-sustavi usklađeni s IRB pristupom trebaju imati rejting-skalu koja odražava isključivo rizik nastupanja statusa neispunjavanja obveza od minimalno sedam kategorija rejtinga za prihodonosne klijente i minimalno jednu kategoriju rejtinga za neprihodonosne[10]. Broj kategorija rejtinga uobičajeno se odabire prema razini diversifikacije koju pojedinim rejting-sustavom želimo postići.

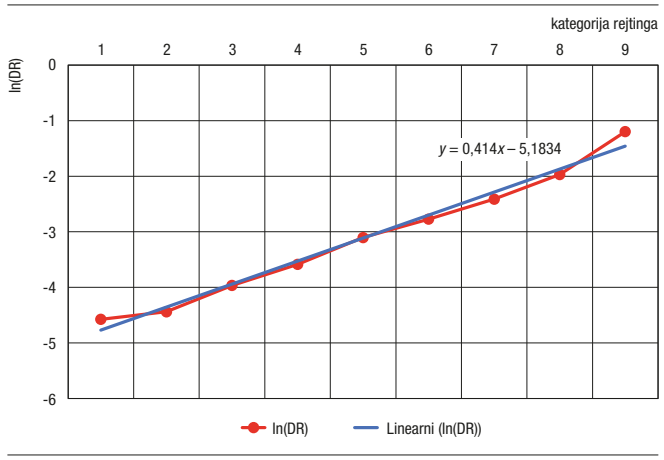
Granice razreda rejtinga i njihov broj mogu se ustanoviti i istom tehnikom nadzirane diskretizacije koja se upotrebljava pri izračunu WoE transformacija i informacijske vrijednosti. Na taj se način iskorištava svojstvo koje takvi skupovi (kategorije rejtinga) imaju: maksimiziranje razlika između skupova, odnosno kategorija rejtinga i minimiziranje varijance unutar skupa.

Kreiranjem kategorija rejtinga na temelju godišnjih stopa neispunjavanja obveza "zaobilaze" se potencijalni nedostaci u postojećim procjenama PD-a (ili općenito u rangiranju dužnika prema riziku), jer upotrebljavamo podatke o ostvarenim stopama neispunjavanja obveza (DR). Metoda zahtijeva iterativnu analizu linearnog odnosa prirodnog logaritma stope neispunjavanja obveza ln(DR) i kategorija rejtinga (logaritamska skala). Tako definirana rejting-skala odražava eksponencijalni porast rizičnosti poduzeća s porastom kategorije rejtinga, čime je osigurana razlikovnost u rizičnosti među poduzećima susjednih kategorija rejtinga (rizičnost raste gotovo tri puta s porastom za jednu kategoriju rejtinga):

$$PD \sim e^{rejting} \tag{14}$$

10 3. dio, glava II, poglavlje 3 Uredbe 575

Slika 13. Linearni odnos ln(DR) i kategorija rejtinga – podloga



Izvor: Autorov izračun

Svako redefiniranje rejting-skale mijenja i točke za koje je potrebno prilagoditi pravac na logaritamskoj skali. Pravac s minimalnom mjerom prilagodbe najpovoljniji je odabir. Početak iteracije pravac je koji se dobije na rejting-skali klasteriranjem uz maksimiziranje informacijske vrijednosti (Slika 13.).

Definiranom rejting-skalom trebaju biti ispunjeni sljedeći dodatni uvjeti:

- Izbjegnuta prekomjerna koncentracija. Uobičajeni je kriterij da udio pojedine kategorije rejtinga (po broju i volumenu) ne bi trebao biti veći od 25%.
- Rejting-skala osigurava smislene raspone PD-ova.

Navedena metoda rezultira s devet kategorija rejtinga (Tablica 12., Slika 14., Slika 15.). Tablica 12. prikazuje distribuciju "dobrih", "loših" i ukupnog broja poduzeća po razredima rejtinga, ostvarenu stopu nastajanja statusa neispunjavanja obveza DR, prosječni kalibrirani PD razreda rejtinga, raspon i granice PD-a razreda rejtinga, uvjet minimalnog broja opservacija za razred rejtinga za primjenu aproksimacije binomne distribucije normalnom[11] N_{min}, donju i gornju kritičnu vrijednost[12] uz granicu pouzdanosti $\alpha = 95\%$ i rezultate binomnog testa na donjoj i gornjoj granici pouzdanosti. Zelena polja označavaju ispunjavanje pretpostavki binomnog testa, a crvena polja ne zadovoljavaju test.

Tablica 12. Izrada rejting-skale

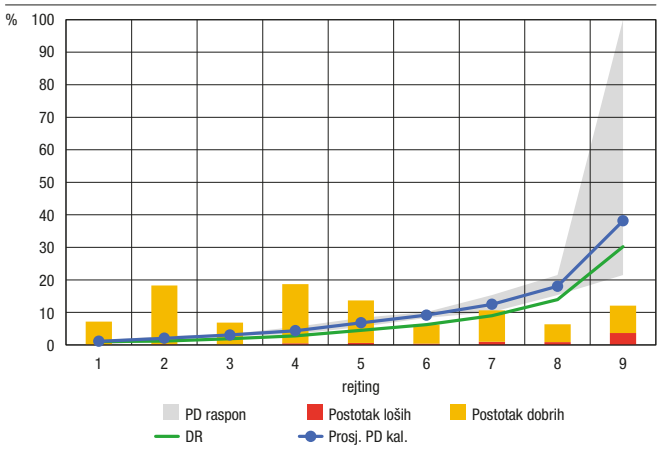
Izrada rejting skale													CL	0,95			
Distribucija													Binomni test				
Kategorija	Dobri	Loši	Ukupno	DR	Postotak dobrih	Postotak loših	Postotak ukup. br.	Prosj. PD kal.	Očekivani DFLT	PD raspon	PD MIN	PD MAX	Nmin	Inf	Sup	Test Inf	Test Sup
1	4.895	51	4.946	1,03%	7,09%	0,07%	7,16%	1,11%	54,79	1,40%	0,00%	1,40%	822	0,86%	1,35%	ok	ok
2	12.479	149	12.628	1,18%	18,07%	0,22%	18,29%	2,04%	257,31	1,32%	1,40%	2,72%	451	1,83%	2,24%	ne	ok
3	4.658	90	4.748	1,90%	6,75%	0,13%	6,88%	3,05%	144,62	0,62%	2,72%	3,34%	305	2,64%	3,46%	ne	ok
4	12.560	358	12.918	2,77%	18,19%	0,52%	18,71%	4,36%	563,62	2,20%	3,34%	5,54%	216	4,07%	4,66%	ne	ok
5	9.015	424	9.439	4,49%	13,06%	0,61%	13,67%	6,81%	642,70	2,78%	5,54%	8,32%	142	6,38%	7,24%	ne	ok
6	4.045	270	4.315	6,26%	5,86%	0,39%	6,25%	9,15%	394,82	1,79%	8,32%	10,11%	108	8,43%	9,87%	ne	ok
7	6.687	659	7.346	8,97%	9,68%	0,95%	10,64%	12,48%	916,66	5,22%	10,11%	15,33%	82	11,84%	13,11%	ne	ok
8	3.764	610	4.374	13,95%	5,45%	0,88%	6,33%	18,04%	789,25	6,16%	15,33%	21,49%	61	17,09%	19,00%	ne	ok
9	5.817	2518	8.335	30,21%	8,42%	3,65%	12,07%	38,18%	3182,25	78,50%	21,49%	99,99%	38	37,30%	39,05%	ne	ok
Ukup.	63.920	5.129	69.049	7,42806%				10,060%									

Izvor: Autorov izračun

11 Vidi izraz (11).

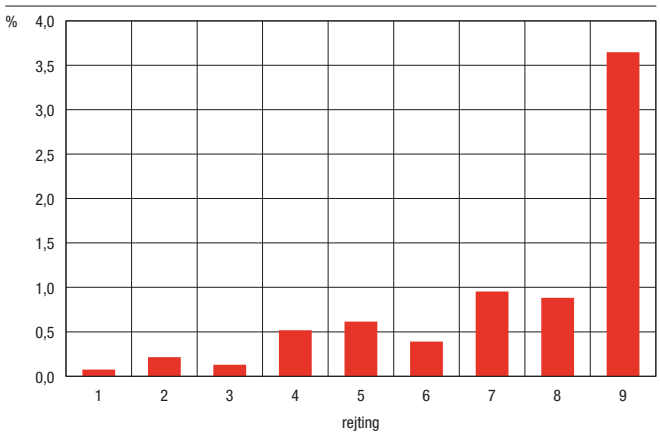
12 Vidi izraze (12) i (13).

Slika 14. Distribucija poduzeća, DR i PD po kategorijama rejtinga



Izvor: Autorov izračun

Slika 15. Distribucija loših poduzeća po kategorijama rejtinga



Izvor: Autorov izračun

Binomni testovi odražavaju maržu konzervativnosti u svim razredima rejtinga, koja je dobivena kalibracijom PD-a prema centralnoj tendenciji i obuhvaća veći udio recesijskog dijela ciklusa i samo početnu fazu izlaska iz recesije. Broj prihodonosnih kategorija rejtinga zadovoljava IRB uvjete za rejting-skalu prema kojima ona treba imati najmanje sedam kategorija rejtinga za prihodonosne i jednu kategoriju rejtinga za neprihodonosne izloženosti, tj. poduzeća. Koncentracije broja poduzeća izraženije su u prve dvije kategorije rejtinga, no još uvijek ispod uobičajene granice prekomjerne koncentracije od 25%. Takva povišena koncentracija u prve dvije kategorije rejtinga govori da su razlike između poduzeća u visokim razredima vrlo male i teško mjerljive, čak i kad se primjenjuju bihevioralne varijable. Ipak, bihevioralne varijable utječu na bolje razvrstavanje poduzeća prema njihovoj rizičnosti upravo u dijelu skale lošijih razreda rejtinga. U sklopu ovog istraživanja testirana je i rejting-skala koja ima finiju podjelu na početku skale, međutim upravo zbog manje diskriminatorne snage aplikacijskih varijabla koje prevladavaju u izračunu PD-a kod najboljih poduzeća te malog broja poduzeća u najboljoj kategoriji rejtinga, rezultati binomnih testova tijekom vremena ne zadovoljavaju u potpunosti tako da je zadržana prva verzija skale, što je s obzirom na potrebe procjene rizičnosti portfelja nefinancijskih poduzeća zadovoljavajuće. Kreditne institucije u tom će dijelu imati finiju podjelu rejting-skale zbog potrebe boljeg razlikovanja kvalitete dužnika u procesu odobravanja, što ovdje nije slučaj. Konačna rejting-skala prikazana je u Tablici 13.

Tablica 13. Rejting-skala

Opis	Oznaka razreda rejtinga	Brojčana oznaka razreda rejtinga	PD_{min}	Prosječni PD	PD_{max}
Poduzeća s najnižom vjerojatnošću neispunjavanja obveza	A0	1	0,00%	1,11%	1,40%
Poduzeća s vrlo niskom vjerojatnošću neispunjavanja obveza	A1	2	1,40%	2,04%	2,72%
Poduzeća s niskom vjerojatnošću neispunjavanja obveza	A2	3	2,72%	3,05%	3,34%
Poduzeća s povišenom vjerojatnošću neispunjavanja obveza	A3	4	3,34%	4,36%	5,54%
Poduzeća s ispodprosječnom vjerojatnošću neispunjavanja obveza	A4	5	5,54%	6,81%	8,32%
Poduzeća s prosječnom vjerojatnošću neispunjavanja obveza	A5	6	8,32%	9,15%	10,11%
Poduzeća s iznadprosječnom vjerojatnošću neispunjavanja obveza	A6	7	10,11%	12,48%	15,33%
Poduzeća s visokom vjerojatnošću neispunjavanja obveza	A7	8	15,33%	18,04%	21,49%
Poduzeća s vrlo visokom vjerojatnošću neispunjavanja obveza	A8	9	21,49%	38,18%	99,99%
Poduzeća u statusu neispunjavanja obveza klasificirana u A90	A9	10			
Poduzeća u statusu neispunjavanja obveza klasificirana u B1	B1	11			
Poduzeća u statusu neispunjavanja obveza klasificirana u B2	B2	12		100%	
Poduzeća u statusu neispunjavanja obveza klasificirana u B3	B3	13			
Poduzeća u statusu neispunjavanja obveza klasificirana u CC	CC	14			

Izvor: Autorov izračun

Tablica ima devet razreda rejtinga za prihodonosna poduzeća, dok su za neprihodonosna poduzeća zadržani postojeći razredi rejtinga prema klasifikacijskim skupinama "A90 dana"[13], "B1", "B2", "B3" za djelomično nadoknadive plasmane i "CC" za plasmane u potpunosti nenadoknadive. Tako konačna rejting-skala ima 9 + 5 razreda rejtinga.

6. Zaključak

Poštujući pravila razvoja PD modela koja proizlaze iz regulative i najbolje poslovne prakse, razvijena su dva PD modela za sektor nefinancijskih poduzeća: jedan za segment malih poduzeća, a drugi za segment srednjih i velikih poduzeća. Odabir segmentacije proizlazi prije svega iz različitosti rizičnih karakteristika tako odabranih segmenata, a faktori rizika uključeni u konačne modele odraz su specifičnosti, ali i nekih sličnosti u poslovanju segmenata. Neovisno o segmentu, u analiziranom razdoblju poduzeća iz građevinske djelatnosti bila su rizičnija od ostalih industrijskih grana. Na povišenu rizičnost obaju segmenata također utječu nepovoljni odnosi pokazatelja likvidnosti, koeficijenta obrtaja obveza prema dobavljačima i omjera pokrića servisiranja ukupnog duga. Iako su pokazatelji profitabilnosti i novčanog pokrića neto obveza faktori rizika koji značajnije utječu na vjerojatnost nastanka statusa neispunjavanja obveza u segmentu malih poduzetnika, njihov utjecaj na povećanje rizičnosti segmenta srednjih i velikih poduzeća nije značajan zbog drugačijih poslovnih modela koji srednjim i velikim poduzećima ostavljaju više prostora i mogućnosti za dodatno upravljanje imovinom pa su tako manje osjetljiva na kolebljivosti prihoda iz redovnog poslovanja i ostvarene dobiti. U modele je uključena i jedna bihevioralna varijabla s pomoću koje se detektira postojanje ranih znakova poteškoća u podmirivanju obveza prema kreditnim institucijama, a koje se spontano i samostalno popravljaju prije opservacijskog razdoblja. Uvođenjem bihevioralne varijable u modele značajno je poboljšana diskriminatorna snaga modela u odnosu na modele s istim faktorima rizika, ali bez bihevioralne varijable. Procjene PD-a kalibrirane su i mapirane na novu rejting-skalu, a rezultati validacijskih testova[14] napravljeni na trening-uzorku i na uzorku izvan vremena vrlo su dobri i dobri.

13 Odlukom o klasifikaciji izloženosti u rizične skupine i načinu utvrđivanja kreditnih gubitaka (NN, br. 114/2017.) rizična skupina A90 ukinuta je.

14 Rezultati validacijskih testova dostupni su na upit.

Razvoj PD modela u skladu s regulativom Basel III i primjenom principa najbolje poslovne prakse rezultirao je PD modelom koji zadovoljava najvažnije kriterije iz domene diskriminatorne snage, preciznosti klasifikacije, kalibracije i stabilnosti te je vrijedan instrument mjerenja komponente kreditnog rizika kojemu je izložen financijski sustav prema sektoru nefinancijskih poduzeća.

Literatura

Arvanitis, A. i dr. (1998.): *Building Models for Credit Spreads,* Paribas

Baesens, B. (2016.): *Credit Risk Analytics: Measurement Techniques, Applications, and Examples in SAS*, Wiley

Blochwitz, S. i dr. (2011.): *Statistical Approaches to PD Validation*, zbirka radova, The Basel II Risk Parameters Estimation, Validation, Stress Testing – with Applications to Loan Risk Management, urednici Engelmann, B. i Rauhmeier, R., Springer

Blochwitz, S. i Hohl, S. (2011.): *Validation of Banks' Internal Rating Systems: A Supervisory Perspective*, zbirka radova, The Basel II Risk Parameters Estimation, Validation, Stress Testing – with Applications to Loan Risk Management, urednici Engelmann, B. i Rauhmeier, R., Springer

Engelmann, B. (2011.): *Measures of a Rating's Discriminative Power: Applications and Limitations*, zbirka radova, The Basel II Risk Parameters Estimation, Validation, Stress Testing – with Applications to Loan Risk Management, urednici Engelmann, B. i Rauhmeier, R., Springer

Engelmann, B. i Ermakov, K. (2011.): *Transition Matrices: Properties and Estimation Methods*, zbirka radova, The Basel II Risk Parameters Estimation, Validation, Stress Testing – with Applications to Loan Risk Management, urednici Engelmann, B. i Rauhmeier, R., Springer

Europski parlament i Vijeće (2013.): *Uredba (EU) br. 575/2013 Europskog parlamenta i Vijeća od 26. lipnja 2013. o bonitetnim zahtjevima za kreditne institucije i investicijska društva i o izmjeni Uredbe (EU) br. 648/2012*

Farrar, D. E. i Glauber, R. R. (1967.): *Multicollinearity in Regression Analysis: The Problem Revisited*, MIT Press

Fawcett, T. (2005.): *An introduction to ROC analysis*

Flores, J. A. E. i dr. (2010.): *Regulatory use of system-wide estimations of PD, LGD i EAD*, Comisión Nacional Bancaria y de Valores Mexico, 2010. (FSI Award 2010 Winning Paper)

Gadidov, B. (2015.): *Population Stability and Model Performance Metrics Replication for Business Model at Sun Trust Bank*

Hrvatska narodna banka (2009.): *Odluka o klasifikaciji plasmana i potencijalnih obveza kreditnih institucija*, HNB

Hyden, E. i Porath, D. (2011.): *Statistical Methods to Develop Rating Models*, zbirka radova, The Basel II Risk Parameters Estimation, Validation, Stress Testing – with Applications to Loan Risk Management, urednici Engelmann, B. i Rauhmeier R., Springer

Ivičić, L. i Cerovac, S. (2009.): *Procjena kreditnog rizika poduzeća u Hrvatskoj*, HNB

Jafry, Y. i Schuermann, T. (2004.): *Measurement, estimation and comparison of credit migration matrices,* Journal of Banking & Finance

Medema, L. i dr. (2007.): *A Practical Approach to Validating a PD Model,* Journal of Banking & Finance

Nehrbecka, N. (2015.): *Approach to the assesment of credit risk for non-financial corporations. Evidence from Poland,* NBP

OeNB i FMA (2004.): *Guidelines on Credit Risk Management: Rating Models and Validation*, Nacionalna banka Austrije

Pluto, K. i Tasche, D. (2011.): *Estimating Probabilities of Default for Low Default Portfolios*, zbirka radova, The Basel II Risk Parameters Estimation, Validation, Stress Testing – with Applications to Loan Risk Management, urednici Engelmann, B. i Rauhmeier, R., Springer

Priutt, R. (2010.): *The Applied Use of Population Stability Index (PSI) in SAS Enterprise Miner™*, SAS Global Forum 2010

Rauhmeier, R. (2011.): *PD-Validation: Experience from Banking Practice*, zbirka radova, The Basel II Risk Parameters Estimation, Validation, Stress Testing – with Applications to Loan Risk Management, urednici Engelmann, B. i Rauhmeier, R., Springer

Siddiqi, N. (2006.): *Credit Risk Scorecards Developing and Implementing Intelligent Credit Scoring*, Wiley

Spiegelhalter, D. (1986.): *Probabilistic prediction in patient management and clinical trails*, Statistics in Medicine

Tasche, D. (2006.): *Validation of internal rating systems and PD estimates*; https://arxiv.org/abs/physics/0606071v1

Yaffee, R. A. (2002.): *Robust Regression Analysis: Some Popular Statistical Package Options*

Pojmovnik i kratice

aplikativni podaci – podaci koji se uobičajeno prikupljaju od klijenta kreditne institucije u trenutku zaprimanja kreditnog zahtjeva, a za poduzeća to su godišnja financijska izvješća, informacije o bonitetu (BON-1, BON-2), kvalitativni podaci iz pristupnog obrasca i sl.

AR – engl. *Accuracy Ratio*; mjera diskriminatorne snage modela temeljena na CAP krivulji, upotrebljava se i naziv Ginijev koeficijent

AUROC – engl. *Area Under Receiver Operating Characteristic*; površina ispod ROC krivulje

bihevioralni podaci – podaci koji proizlaze iz poslovnog odnosa klijenta i kreditne institucije, poput urednosti otplata dospjelih obveza, broja i vrsta financijskih proizvoda koje klijent koristi i uvjeta koje pritom ostvaruje, ažurnosti dostavljanja traženih informacija kreditnoj instituciji i sl.

CAP krivulja – engl. *Cumulative Accuracy Profile*; poznata još i kao Lorenzova krivulja, prikazuje diskriminatornu snagu modela

DR – engl. *Default rate*; stopa nastanka statusa neispunjavanja obveza

EL – engl. *Expected Loss*; očekivani gubitak

GFI-POD – godišnje financijsko izvješće poduzetnika prema obrascima Financijske agencije

indikatorska varijabla – varijabla koja upućuje na određeno svojstvo poduzeća i u tom slučaju poprima vrijednost 1, dok u protivnom, ako poduzeće ne ispunjava zadani kriterij, varijabla poprima vrijednost 0; na taj se način ocjenjuje utjecaj navedenog svojstva poduzeća (npr. pripadnost nekoj djelatnosti) na procjenu njegova PD-a

IRB – engl. *Internal Ratings Based Approach*; pristup temeljen na internim rejtinzima prema regulativi Basel II/III propisan Uredbom (EU) br. 575/2013 Europskog parlamenta i Vijeća od 26. lipnja 2013. o bonitetnim zahtjevima za kreditne institucije i investicijska društva i o izmjeni Uredbe (EU) br. 648/2012

IV – engl. *Information Value*; mjera informacijske vrijednosti opisana je podrobnije u poglavlju 4.2. Težina dokaza (WoE) i informacijska vrijednost (IV)

kohortna metoda – engl. *cohort approach* prikazuje promjenu početnog rejtinga u odnosu na rejting dodijeljen na kraju promatranog razdoblja (jedne godine)

matrica kontingencije – engl. *confusion matrix, error matrix*; matrica pogrešaka modela iz koje se izračunava preciznost klasifikacije modela

metoda intenziteta tranzicije – engl. *duration* ili *hazard rate approach*; uzima u obzir sve promjene rejtinga unutar promatranog razdoblja i njihovo trajanje

OOS – engl. *Out-of-Sample*; skup podataka o poduzećima koja nisu bila uključena u uzorak na kojemu je napravljena procjena parametara modela za razdoblje upotrijebljeno pri procjeni

OOT – engl. *Out-of-Time*; skup podataka o poduzećima koja su bila uključena u uzorak na kojemu je napravljena procjena parametara modela, ali za razdoblje koje nije upotrijebljeno pri procjeni

opservacijsko razdoblje – za procjenu jednogodišnje vjerojatnosti nastanka statusa neispunjavanja obveza (PD-a), opservacijsko razdoblje je razdoblje od jedne godine tijekom kojeg se promatra promjena statusa neispunjavanja obveza; kao početno stanje uzima se stanje na dan 31. prosinca godine T_0, a konačan ishod na kraju opservacijskog razdoblja u godini T_{+1} ovisi o promjeni statusa neispunjavanja obveza u razdoblju od 1. siječnja do 31. prosinca godine T_{+1}

PD – engl. *Probability of Default*; vjerojatnost nastanka događaja neispunjavanja obveza

prekomjerna prilagodba modela podacima na kojima su procijenjeni parametri regresije – engl. *overfitting*; procjena parametara regresijskog modela koji jako dobro opisuje pojavu na podacima na kojima je napravljena procjena, ali na drugim podacima izvan uzorka i/ili vremena odziv i karakteristike modela značajno su oslabljeni

ROC krivulja – engl. *Receiver Operating Characteristic*; krivulja koja prikazuje odziv kao funkciju pogreške klasifikatora

RWA – engl. *Risk Weighted Assets*; rizikom ponderirana aktiva

STA – engl. *Standardized Approach*; standardizirani pristup prema regulativi Basel II/III propisan Uredbom (EU) br. 575/2013 Europskog parlamenta i Vijeća od 26. lipnja 2013. o bonitetnim zahtjevima za kreditne institucije i investicijska društva i o izmjeni Uredbe (EU) br. 648/2012

status neispunjavanja obveza – engl. *Default*; status neispunjavanja obveza opisan je definicijom u Uredbi (EU) br. 575/2013

trening-uzorak – uzorak na kojemu su procijenjeni parametri regresije

validacijski uzorak – uzorak na kojemu se provjeravaju performanse regresijskog modela (uzorak OOT ili OOS)

WOE – engl. *Weight of Evidence*; transformacija varijabla metodom težine dokaza opisana je podrobnije u poglavlju 4.2. Težina dokaza (WoE) i informacijska vrijednost (IV)

Do sada objavljena Istraživanja

Broj	Datum	Naslov	Autor(i)
I-1	studeni 1999.	Je li neslužbeno gospodarstvo izvor korupcije?	Michael Faulend i Vedran Šošić
I-2	ožujak 2000.	Visoka razina cijena u Hrvatskoj – neki uzroci i posljedice	Danijel Nestić
I-3	svibanj 2000.	Statističko evidentiranje pozicije putovanja – turizam u platnoj bilanci Republike Hrvatske	Davor Galinec
I-4	lipanj 2000.	Hrvatska u drugoj fazi tranzicije 1994. – 1999.	Velimir Šonje i Boris Vujčić
I-5	lipanj 2000.	Mjerenje sličnosti gospodarskih kretanja u Srednjoj Europi: povezanost poslovnih ciklusa Njemačke, Mađarske, Češke i Hrvatske	Velimir Šonje i Igeta Vrbanc
I-6	rujan 2000.	Tečaj i proizvodnja nakon velike ekonomske krize i tijekom tranzicijskog razdoblja u Srednjoj Europi	Velimir Šonje
I-7	rujan 2000.	OLS model fizičkih pokazatelja inozemnoga turističkog prometa na hrvatskom tržištu	Tihomir Stučka
I-8	prosinac 2000.	Je li Srednja Europa optimalno valutno područje?	Alen Belullo, Velimir Šonje i Igeta Vrbanc
I-9	svibanj 2001.	Nelikvidnost: razotkrivanje tajne	Velimir Šonje, Michael Faulend i Vedran Šošić
I-10	rujan 2001.	Analiza pristupa Republike Hrvatske Svjetskoj trgovinskoj organizaciji upotrebom računalnog modela opće ravnoteže	Jasminka Šohinger, Davor Galinec i Glenn W. Harrison
I-11	travanj 2002.	Usporedba dvaju ekonometrijskih modela (OLS i SUR) za prognoziranje dolazaka turista u Hrvatsku	Tihomir Stučka
I-12	veljača 2003.	Strane banke u Hrvatskoj: iz druge perspektive	Evan Kraft
I-13	veljača 2004.	Valutna kriza: teorija i praksa s primjenom na Hrvatsku	Ivo Krznar
I-14	lipanj 2004.	Privatizacija, ulazak stranih banaka i efikasnost banaka u Hrvatskoj: analiza stohastičke granice fleksibilne Fourierove funkcije troška	Evan Kraft, Richard Hofler i James Payne
I-15	rujan 2004.	Konvergencija razina cijena: Hrvatska, tranzicijske zemlje i EU	Danijel Nestić
I-16	rujan 2004.	Novi kompozitni indikatori za hrvatsko gospodarstvo: prilog razvoju domaćeg sustava cikličkih indikatora	Saša Cerovac
I-17	siječanj 2006.	Anketa pouzdanja potrošača u Hrvatskoj	Maja Bukovšak
I-18	listopad 2006.	Kratkoročno prognoziranje inflacije u Hrvatskoj korištenjem sezonskih ARIMA procesa	Andreja Pufnik i Davor Kunovac
I-19	svibanj 2007.	Kolika je konkurencija u hrvatskom bankarskom sektoru?	Evan Kraft
I-20	lipanj 2008.	Primjena hedonističke metode za izračunavanje indeksa cijena nekretnina u Hrvatskoj	Davor Kunovac, Enes Đozović, Gorana Lukinić, Andreja Pufnik
I-21	srpanj 2008.	Modeliranje gotovog novca izvan banaka u Hrvatskoj	Maroje Lang, Davor Kunovac, Silvio Basač, Željka Štaudinger
I-22	listopad 2008.	Međunarodni poslovni ciklusi u uvjetima nesavršenosti na tržištu dobara i faktora proizvodnje	Ivo Krznar
I-23	siječanj 2009.	Rizik bankovne zaraze u Hrvatskoj	Marko Krznar
I-24	kolovoz 2009.	Optimalne međunarodne pričuve HNB-a s endogenom vjerojatnošću krize	Ana Maria Čeh i Ivo Krznar
I-25	veljača 2010.	Utjecaj financijske krize i reakcija monetarne politike u Hrvatskoj	Nikola Bokan, Lovorka Grgurić, Ivo Krznar, Maroje Lang
I-26	veljača 2010.	Priljev kapitala i učinkovitost sterilizacije – ocjena koeficijenta sterilizacije i ofset koeficijenta	Igor Ljubaj, Ana Martinis, Marko Mrkalj
I-27	travanj 2010.	Postojanost navika i međunarodne korelacije	Alexandre Dmitriev i Ivo Krznar
I-28	studeni 2010.	Utjecaj vanjskih šokova na domaću inflaciju i BDP	Ivo Krznar i Davor Kunovac
I-29	prosinac 2010.	Dohodovna i cjenovna elastičnost hrvatske robne razmjene – analiza panel-podataka	Vida Bobić
I-30	siječanj 2011.	Model neravnoteže na tržištu kredita i razdoblje kreditnog loma	Ana Maria Čeh, Mirna Dumičić, Ivo Krznar
I-31	travanj 2011.	Analiza kretanja domaće stope inflacije i Phillipsova krivulja	Ivo Krznar
I-32	svibanj 2011.	Identifikacija razdoblja recesija i ekspanzija u Hrvatskoj	Ivo Krznar
I-33	listopad 2011.	Globalna kriza i kreditna euroizacija u Hrvatskoj	Tomislav Galac

Broj	Datum	Naslov	Autor(i)
I-34	studeni 2011.	Središnja banka kao krizni menadžer u Hrvatskoj – analiza hipotetičnih scenarija	Tomislav Galac
I-35	siječanj 2012.	Ocjena utjecaja monetarne politike na kredite stanovništvu i poduzećima: FAVEC pristup	Igor Ljubaj
I-36	ožujak 2012.	Jesu li neke banke blaže od drugih u primjeni pravila klasifikacije plasmana	Tomislav Ridzak
I-37	veljača 2012.	Procjena matrica kreditnih migracija pomoću agregatnih podataka – bajesovski pristup	Davor Kunovac
I-38	svibanj 2012.	Procjena potencijalnog outputa u Republici Hrvatskoj primjenom multivarijantnog filtra	Nikola Bokan i Rafael Ravnik
I-39	listopad 2012.	Način na koji poduzeća u Hrvatskoj određuju i mijenjaju cijene svojih proizvoda: rezultati ankete poduzeća i usporedba s eurozonom	Andreja Pufnik i Davor Kunovac
I-40	ožujak 2013.	Financijski uvjeti i gospodarska aktivnost	Mirna Dumičić i Ivo Krznar
I-41	travanj 2013.	Trošak zaduživanja odabranih zemalja Europske unije i Hrvatske – uloga prelijevanja vanjskih šokova	Davor Kunovac
I-42	lipanj 2014.	Brza procjena BDP-a upotrebom dostupnih mjesečnih indikatora	Davor Kunovac, Borna Špalat
I-43	lipanj 2014.	Pokazatelji financijskog stresa za male otvorene visokoeuroizirane zemlje – primjer Hrvatske	Mirna Dumičić
I-44	srpanj 2014.	Kratkoročne prognoze BDP-a u uvjetima strukturnih promjena	Rafael Ravnik
I-45	srpanj 2015.	Mikroekonomski aspekti utjecaja globalne krize na rast nefinancijskih poduzeća u RH	Tomislav Galac
I-46	rujan 2015.	Pokazatelji financijske stabilnosti – primjer Hrvatske	Mirna Dumičić
I-47	veljača 2017.	Odgođeni oporavak kreditne aktivnosti u Hrvatskoj: uzrokovan ponudom ili potražnjom?	Mirna Dumičić i Igor Ljubaj
I-48	travanj 2017.	Učinkovitost makroprudencijalnih politika u zemljama Srednje i Istočne Europe	Mirna Dumičić
I-49	rujan 2017.	Struktura tokova kapitala i devizni tečaj: Primjer Hrvatske	Maja Bukovšak, Gorana Lukinić Čardić, Nina Ranilović
I-50	rujan 2017.	Primjena gravitacijskog modela u analizi utjecaja ekonomske integracije na hrvatsku robnu razmjenu	Nina Ranilović
I-51	listopad 2017.	Usklađenost poslovnih ciklusa i ekonomskih šokova između Hrvatske i država europodručja	Karlo Kotarac, Davor Kunovac i Rafael Ravnik
I-52	studeni 2017.	Prekomjerni dug poduzeća u Hrvatskoj: mikroprocjena i makroimplikacije	Ana Martinis i Igor Ljubaj

Upute autorima

Hrvatska narodna banka objavljuje u svojim povremenim publikacijama Istraživanja, Pregledi i Tehničke bilješke znanstvene i stručne radove zaposlenika Banke i vanjskih suradnika.

Prispjeli radovi podliježu postupku recenzije i klasifikacije koji provodi Komisija za klasifikaciju i vrednovanje radova. Autori se u roku od najviše dva mjeseca od primitka njihova rada obavještavaju o odluci o prihvaćanju ili odbijanju članka za objavljivanje.

Radovi se primaju i objavljuju na hrvatskom i/ili na engleskom jeziku.

Radovi predloženi za objavljivanje moraju ispunjavati sljedeće uvjete.

Tekstovi moraju biti dostavljeni elektroničkom poštom ili optičkim medijima (CD, DVD), a mediju treba priložiti i ispis na papiru. Zapis treba biti u formatu Microsoft Word.

Na prvoj stranici rada obvezno je navesti naslov rada, ime i prezime autora, akademske titule, naziv ustanove u kojoj je autor zaposlen, suradnike te potpunu adresu na koju će se autoru slati primjerci za korekturu.

Dodatne informacije, primjerice zahvale i priznanja, poželjno je uključiti u tekst na kraju uvodnog dijela.

Na drugoj stranici svaki rad mora sadržavati sažetak i ključne riječi. Sažetak mora biti jasan, deskriptivan, pisan u trećem licu i ne dulji od 250 riječi (najviše 1500 znakova). Ispod sažetka treba navesti do 5 ključnih pojmova.

Tekst treba biti otipkan s proredom, na stranici formata A4. Tekst se ne smije oblikovati, dopušteno je samo podebljavanje (bold) i kurziviranje (italic) dijelova teksta. Naslove je potrebno numerirati i odvojiti dvostrukim proredom od teksta, ali bez formatiranja.

Tablice, slike i grafikoni koji su sastavni dio rada, moraju biti pregledni, te moraju sadržavati broj, naslov, mjerne jedinice, legendu, izvor podataka te bilješke. Bilješke koje se odnose na tablice, slike ili grafikone treba obilježiti malim slovima (a, b, c…) i ispisati ih odmah ispod. Ako se posebno dostavljaju (tablice, slike i grafikoni), potrebno je označiti mjesta u tekstu gdje dolaze. Numeracija mora biti u skladu s njihovim slijedom u tekstu te se na njih treba referirati prema numeraciji. Ako su već umetnuti u tekst iz nekih drugih programa, onda je potrebno dostaviti i te datoteke u formatu Excel (grafikoni moraju imati pripadajuće serije podataka).

Ilustracije trebaju biti u standardnom formatu EPS ili TIFF s opisima u Helvetici (Arial, Swiss) veličine 8 točaka. Skenirane ilustracije trebaju biti rezolucije 300 dpi za sivu skalu ili ilustraciju u punoj boji i 600 dpi za lineart (nacrti, dijagrami, sheme).

Formule moraju biti napisane čitljivo. Indeksi i eksponenti moraju biti jasni. Značenja simbola moraju se objasniti odmah nakon jednadžbe u kojoj se prvi put upotrebljavaju. Jednadžbe na koje se autor poziva u tekstu potrebno je obilježiti serijskim brojevima u zagradi uz desnu marginu.

Bilješke na dnu stranice treba označiti arapskim brojkama podignutima iznad teksta. Trebaju biti što kraće i pisane slovima manjima od slova kojima je pisan tekst.

Popis literature dolazi na kraju rada, a u njega ulaze djela navedena u tekstu. Literatura treba biti navedena abecednim redom prezimena autora, a podaci o djelu moraju sadržavati i podatke o izdavaču, mjesto i godinu izdavanja.

Uredništvo zadržava pravo da autoru vrati na ponovni pregled prihvaćeni rad i ilustracije koje ne zadovoljavaju navedene upute.

Pozivamo zainteresirane autore koji žele objaviti svoje radove da ih pošalju na adresu Direkcije za izdavačku djelatnost, prema navedenim uputama.

Hrvatska narodna banka izdaje sljedeće publikacije:

Godišnje izvješće Hrvatske narodne banke
Redovita godišnja publikacija koja sadržava godišnji pregled novčanih i općih ekonomskih kretanja te pregled statistike.

Polugodišnje izvješće Hrvatske narodne banke
Redovita polugodišnja publikacija koja sadržava polugodišnji pregled novčanih i općih ekonomskih kretanja te pregled statistike.

Tromjesečno izvješće Hrvatske narodne banke
Redovita tromjesečna publikacija koja sadržava tromjesečni pregled novčanih i općih ekonomskih kretanja.

Bilten o bankama
Redovita publikacija koja sadržava pregled i podatke o bankama.

Bilten Hrvatske narodne banke
Redovita mjesečna publikacija koja sadržava mjesečni pregled novčanih i općih ekonomskih kretanja te pregled monetarne statistike.

Istraživanja Hrvatske narodne banke
Povremena publikacija u kojoj se objavljuju kraći znanstveni radovi zaposlenika Banke i vanjskih suradnika.

Pregledi Hrvatske narodne banke
Povremena publikacija u kojoj se objavljuju stručni radovi zaposlenika Banke i vanjskih suradnika.

Tehničke bilješke
Povremena publikacija u kojoj se objavljuju informativni radovi zaposlenika Banke i vanjskih suradnika.

Hrvatska narodna banka izdaje i druge publikacije: numizmatička izdanja, brošure, publikacije na drugim medijima (CD-ROM, DVD), knjige, monografije i radove od posebnog interesa za Banku, zbornike radova s konferencija kojih je organizator ili suorganizator Banka, edukativne materijale i druga slična izdanja.

ISSN 1334-0077 (online)