

Dokumentacija PD modela i metodologije za izračun kreditne procjene poduzetnika korištenjem tehnike strojnog učenja (ML.PD)

ver. 3.2.1

Financijska agencija
Ulica grada Vukovara 70
Zagreb

Zagreb, listopad 2024.

Izrada dokumenta

Autorska prava	Financijska agencija
Tajnost dokumenta	Za javnu objavu
Datum izrade	16.09.2018.

Revizija dokumenta

Verzija dokumenta	Datum izrade	Opis /promjena	Vlasnik
1.0	16.09.2018.	Izrada dokumenta	Financijska agencija
2.1	19.11.2019.	Nadopuna ekspertnom korekcijom procjene zbog dana blokade, defaulta i izlaska iz defaulta; Ažuriranje tablica i grafikona prema rezultatima validacije 2019. godine	Financijska agencija
2.2	31.12.2019	Nadopuna MSFI 9 kreditnom procjenom	Financijska agencija
3.0	21.07.2022	Metodološka izmjena sustava procjene: prelazak na ML.PD	Financijska agencija
3.1	01.12.2022	Prilagodba za EUR	Financijska agencija
3.2	24.06.2024	Validacija i recalibracija	Financijska agencija
3.2.1	10.10.2024	Usklađivanje kategorija procjena i terminologije	Financijska agencija

Sadržaj

1	Uvod	4
2	Definicija statusa neispunjavanja obveza (Default)	8
2.1	Izlazak iz defaulta	10
3	Odabir uzorka i transformacija varijabli	10
3.1	Varijable modela i njihove transformacije	11
3.2	Razvoj PD modela za izračun kreditne procjene poduzeća korištenjem tehnika strojnog učenja 13	
3.2.1	Treniranje i testiranje modela te odabir modela najboljih diskriminatornih karakteristika	17
3.2.2	Inicijalna Kalibracija.....	21
3.3	Dizajn modela	22
3.3.1	Dizajn modela za segment M: PD_M_v1	22
3.3.2	Dizajn modela za segment LM: PD_LM_v1	23
3.3.3	Dizajn modela za segment S: PD_S_v1.....	24
3.3.4	Preciznost modela na „neviđenim“ podacima (OOT)	26
4	Centralna tendencija (kalibracija).....	29
5	Kalibracija skale kreditne procjene (master skala)	30
6	Kvantitativna validacija PD modela	31
6.1	Preciznost klasifikacije modela	31
6.1.1	Distribucija frekvencije dobrih i loših s obzirom na klasu kreditne procjene.....	31
6.1.2	Tablica kontigencije (Confusion matrix).....	32
6.1.3	Krivulja snage (CAP)	32
6.1.4	Omjer točnosti (Accuracy ratio AR, gini)	33
6.1.5	ROC krivulja (Receiver Operating Characteristic).....	34
6.1.6	Površina ispod ROC krivulje (Area Under Receiver Operating Characteristic AUC)	35
6.1.7	Brier score (MSE).....	35
6.2	Testovi kalibracije PD modela.....	36
6.2.1	Test pojedinačnog razreda (Binomial test)	36
6.2.2	Test većeg broja razreda	37
6.3	Testiranje stabilnosti modela	38
6.3.1	Vremenska stabilnost.....	38
6.3.2	Stabilnost razreda kreditne procjene (migracijske matrice)	39
7	Rekapitulacija kvantitativnih validacijskih testova	41
8	Kvalitativna validacija sustava kreditne procjene	42
9	Pravila za korekciju modelski izračunate kreditne procjene	43

1 Uvod

FINA je 2010. godine razvila metodologiju za izračun kreditne procjene poduzetnika temeljenu na procjeni vjerojatnosti nastupanja statusa neispunjavanja obveza (eng. Probability of Default, PD) kao osnovnog faktora rizika. Razvoj modela i inicijalna validacija učinkovitosti modela temeljeni su na godišnjim financijskim izvješćima poduzetnika (GFI-POD) iz razdoblja 2003.-2008. godina i promatranom ishodu u godini koja je slijedila nakon financijskog izvješća (jednogodišnji PD). Rezultat modela iskazuje procjenu rizika u vremenskoj točki (Point-in-Time; PIT).

Kvantitativna validacija modela napravljena je 2013. godine na podacima temeljenim na izvještajnom razdoblju za 2010. i 2011. godinu sa promatranim ishodom u 2011. odnosno 2012. godini.

Tijekom 2015. i 2016. godine napravljena je opsežna kvalitativna i kvantitativna validacija sustava kreditne procjene u skladu s Basel III smjernicama na podacima za 2012. i 2013. godinu sa promatranim ishodom u 2013. i 2014. godini, čiji su rezultati ukazivali na potrebu redizajna PD modela za kreditnu procjenu. Validacija je obuhvaćala kvalitativnu ocijenu dokumentiranosti sustava, modelskog dizajna, metodologije i procesa izračuna i dodjele kreditne procjene, robusnosti IT sustava te kvantitativnu ocijenu robusnosti, integriteta i stabilnosti modela. Područja revizije kvalitativne validacije uključivala su:

- Kvalitativna validacija sustava kreditne procjene
 - (1) Revizija dokumentacije sustava kreditne procjene
 - (2) Definicija statusa neispunjavanja obveza (defaulta) i usklađenost sa Basel III smjernicama
 - (3) Revizija razvoja scoring modela
 - Struktura sustava kreditne procjene
 - Egzogene varijable modela
 - Vremenski horizont
 - Karakteristike PD modela
 - (4) IT i kvaliteta podataka
 - (5) Revizija procesa dodjele kreditne procjene
 - (6) Upotreba modela i izvještavanje
 - (7) Korporativno upravljanje

Kvantitativna validacija modela statističkim tehnikama i testovima procijenjuje učinkovitost, prediktivnu snagu i točnost kalibracije modela. Kvantitativna validacija scoring modela uključuje

- (1) Preciznost klasifikacije modela
 - (1.1) Preciznost klasifikacije modela – uspješnost klasifikacije
 - a) Distribucija frekvencije dobrih i loših s obzirom na klasu kreditne procjene
 - b) Postotak uspješne klasifikacije (ukupno, dobri, loši)
 - c) Greška tipa I i greška tipa II
 - (1.2) Preciznost klasifikacije modela - diskriminacijska snaga modela
 - d) ROC krivulja (Receiver Operating Characteristic)
 - e) CAP krivulja (cumulative accuracy profile/krivulja snage)
 - f) GINI koeficijent (omjer točnosti Accuracy ratio AR)

- g) AUROC (površina ispod ROC krivulje, Area Under Receiver Operating Characteristic AUROC)
- h) Hit Rate, False Alarm Rate
- i) Brier score
- (2) Postupak kalibracije modela
 - a) Binomial test (test pojedinačnog razreda)
 - b) Hosmer-Lemeshow test ili χ^2 -test (test većeg broja razreda)
 - c) Spiegelhalter test (test većeg broja razreda)
- (3) Testiranje stabilnosti modela
 - a) Stabilnost grupe (stability over groups)
 - b) Vremenska stabilnost (stability over time)
- (4) Stress testing

Prema nalazu revizije metodologije za izračun kreditne procjene iz 2015./2016. godine, tijekom 2016. godine napravljena je reestimacija parametara modela logističkom regresijom, kalibracija modela s ciljem poboljšanja njegove stabilnosti zbog izmjene GFI-POD obrazaca u 2010. godini te usklađivanja definicije defaulta s Basel III smjernicama i izrada kreditne skale također u skladu s bazelskim smjernicama. Kvantitativna validacija reestimiranog i rekalibriranog modela napravljena je na Out-of-time podacima (GFI-POD 2014.). Rezultati kvantitativne validacije pokazali su da model za srednje velike i velike poduzetnike zadovoljava testove, dok je za segment malih poduzetnika model bilo potrebno doraditi uvođenjem novih varijabli (uključujući i ispitivanje bihevioralnih varijabli koje su raspoložive u FINA-i) i transformacija nekih od njih kako bi se postigla bolja diskriminatorna snaga modela i kalibracija. Tijekom 2017. godine napravljeno je poboljšanje karakteristika modela uvođenjem transformiranih i bihevioralnih varijabli u PD modele za izračun kreditne procjene poduzetnika u skladu s Basel III smjernicama. Transformacije varijabli i procjena parametara modela za oba segmenta rezultirale su značajnim poboljšanjem karakteristika oba modela. Oba modela na ukupnoj razini imaju izvrsnu ocjenu, a model za segment malih poduzetnika se redovito monitorira, posebno u dijelu kalibracije modela.

Procjena parametara i kalibracija PD modela za izračun kreditne procjene poduzetnika u skladu s Basel III smjernicama u 2017. godini podijeljena je u četiri ključne aktivnosti:

1. **TRANSFORMACIJA ULAZNIH VARIJABLI** – Prije procjene parametara modela napravljena je transformacija ulaznih varijabli pomoću Weight-of-Evidence metodologije (WoE) koja vrijednosti ulazne varijabla dijeli na klustere na način da se maksimizira informacijska vrijednost (Information Value) tako transformirane varijable.
2. **PROCJENA PARAMETARA MODELA** - Procjena parametara PD modela s transformiranim varijablama za izračun kreditne procjene poduzetnika u skladu s Basel III smjernicama temeljena je na ulaznim varijablama koje zadovoljavaju kriterije prediktivnosti informacijske vrijednosti. Dodatno je estimacijski uzorak „očišćen“ eliminacijom neaktivnih poduzetnika korištenjem kriterija da u razdoblju 2010.-2015. nemaju ukupne prihode veće od 10.000 kn niti u jednoj godini.
3. **KALIBRACIJA MODELA** - Kalibracija modela prema centralnoj tendenciji ostvarenih stopa nastanka statusa neispunjavanja obveza poduzetnika (cijela populacija) za razdoblje 2006. – 2015. Kalibracija modela provodi se jednom godišnje.

4. **KVANTITATIVNA VALIDACIJA PD MODELA** - Korištenjem estimiranih i kalibriranih parametara modela te definirane kreditne skale provedeno je testiranje diskriminatorne snage modela (CAP i AR) i testovi kalibracije (binomni test, Spiegelhalter test) na podacima o kreditnim procjenama prema financijskim izvješćima poduzetnika za razdoblje 2010. – 2014.

Kvantitativni testovi snage i kalibracije modela obuhvaćaju sljedeće:

(1) Preciznost klasifikacije modela:

- a) *distribucija frekvencija dobrih i loših s obzirom na klasu kreditne procjene*
- b) *tablica kontingencije*
- c) *CAP krivulja (cumulative accuracy profile)*
- d) *ROC (receiver operating characteristic) krivulja*
- e) *GINI koeficijent (AR)*
- f) *AUROC*
- g) *Brier Score*

(2) Postupak kalibracije modela:

- a) *Binomial test (test pojedinačnog razreda)*
- b) *Spiegelhalter test (test većeg broja razreda)*

(3) Testiranje stabilnosti modela

- a) *vremenska stabilnost (stability over time)*

Kvantitativna validacija i kalibracija modela provedena je i na podacima izračunatim prema GFI-POD 2017. i ostvarenjima defaulta tokom 2018. godine. Na taj je način ispitana učinkovitost modela na novim podacima da se provjeri zadovoljavaju li prediktivna i diskriminacijska svojstva modela definirane kriterije i na najnovijim podacima. Kao testni uzorak koriste se podaci izvan vremena, konkretno podaci GFI-POD i bihevioralni podaci iz 2017. godine i ishodi tijekom 2018. godine. Nova kalibracija PD-a napravljena je prema centralnoj tendenciji ostvarenih stopa defaulta u razdoblju 2003.-2018. godina, a potom je sustav kreditne procjene redovito kalibriran godišnje i za 2019., 2020. i 2021.

Kvantitativna validacija sustava kreditne procjene provodi se redovito jednom godišnje, a kvalitativna provjera sustava kreditne procjene jednom u dvije godine.

U 2022. godini Fina uvodi novi sustav kreditne procjene temeljen na dubokom strojnom učenju pod nazivom ML.PD, koji je razvijen tijekom 2019. godine i od tada je bio redovito testiran i kontroliran u odnosu na postojeći sustav kreditne procjene temeljen na logističkoj regresiji. Algoritmi dubokog strojnog učenja daju značajno bolje rezultate od klasičnih regresijskih metoda. Njihova glavna osobina je učenje na greškama iz prethodnih iteracija čime se postižu značajno bolja diskriminatorna i prediktivna svojstva modela te kalibracija.

Izračun Point-in-time (PIT) i kalibracija PD modela za izračun vjerojatnosti defaulta poduzetnika za potrebe MSFI 9 standarda podijeljena je u četiri ključne aktivnosti:

1. **PROCJENA PARAMETARA SATELITSKIH MODELA**–Satelitski modeli za procjenu očekivane stope defaulta u nadolazećem razdoblju procijenjuju se na podacima o ostvarenim stopama

defaulta (DR; default rate) korištenjem makroekonomskih pokazatelja i varijabli. Procjenjuje se linearni regresijski modela sa logističkom transformacijom zavisne varijable DR.

2. **KALIBRACIJA PD-a** - Kalibracija postojećih PD modela za procjenu jednogodišnjeg "point-in-time" PD-a provodi se u cilju postizanja što preciznije procjene vjerojatnosti nastupanja statusa neispunjavanja obveza za tekuće razdoblje, a prema očekivanim stopama nastupanja statusa neispunjavanja obveza DR u tekućoj godini (2021.). Takva kalibracija rezultira procjenom vjerojatnosti nastanka defaulta u vremenskom horizontu od jedne godine uvažavajući procjenu kretanja gospodarske situacije i poslovanje poduzetnika („point-in-time“) u godini za koju se izračunava PD. Na taj se način postiže "forward-looking" procjena PD-a koja je definirana MSFI 9 standardom.
3. **KVANTITATIVNA VALIDACIJA Point-in-Time PD MODELA** - Kalibracija jednogodišnjeg PIT PD-a provjerena je pomoću kalibracijskih testova na podacima za 2021. godinu (GFI-POD 2020). Kvantitativni testovi kalibracije modela obuhvaćaju sljedeće:

(1) Kalibracija modela:

- a) *Binomial test (test pojedinačnog razreda)*
- b) *Hosmer – Lemeshov test (test većeg broja razreda)*
- c) *Spiegelhalter test (test većeg broja razreda)*

4. **IZRAČUN CJELOŽIVOTNOG PD-A**- Za procjenu cjeloživotnog PD-a procijenjena je funkcija koja temeljem raspoloživih podataka iz prethodnih godina najbolje opisuje moguće kretanje PD-a poduzetnika u budućnosti od zadnje dostupne procjene jednogodišnjeg PIT PD-a i kreditne procjene temeljem aktualnih financijskih podataka, u ovisnosti o proteku vremena za zadani vijek dospijeca financijskog instrumenta.

Usklađenost:

Proizvodi i usluge koje nudi FINA, a u koje se svrstava i kreditna procjena opisana ovom metodologijom, nisu klasificirani kao 'kreditni rejting' kako je definirano Uredbom CRA. FINA nije registrirana kao bonitetna agencija i nije pod nadzorom Europskih tijela za vrijednosne papire i tržišta (ESMA). Proizvodi i usluge FINA-e ne bi se trebali smatrati ekvivalentima reguliranih kreditnih rejtinga i nisu namijenjeni za korištenje u regulatorne svrhe.

Procjena parametara ML modela

2 Definicija statusa neispunjavanja obveza (Default)

Definicija statusa neispunjavanja obveza, odnosno defaulta, ispada ili zastoja u plaćanju, ovisno o terminologiji, polazište je za izgradnju sustava kreditne procjene i razvoja prediktivnih modela za procjenu kreditnog rizika, odnosno vjerojatnost materijalizacije izloženosti kreditnom riziku što dovodi do direktnih i indirektnih gubitaka s kojima se kreditna institucija ili drugi vjerovnici suočavaju u slučaju nemogućnosti naplate svojih potraživanja od dužnika.

Baselska definicija statusa neispunjavanja obveza koja se primjenjuje i u hrvatskoj regulativi kreditnih institucija u kontekstu izloženosti kreditnom riziku određuje dva osnovna kriterija za određivanje statusa defaulta:

- a) ako institucija smatra vjerojatnim da dužnik neće u cijelosti podmiriti svoje obveze prema instituciji ne uzimajući u obzir mogućnost naplate iz kolateralala;
- b) dužnik više od 90 dana nije ispunio svoju dospjelu obvezu po bilo kojoj značajnoj kreditnoj obvezi prema instituciji.

Drugi (b) kriterij, kriterij kašnjenja dužeg od 90 dana u plaćanju dospjelih kreditnih obveza, relativno je egzaktno određen i mjerljiv kriterij kojega je lako izmjeriti i provjeriti. Pojam „značajne kreditne obveze“ nije definiran Uredbom, već je prepušten lokalnim regulatornim tijelima da sama definiraju prag materijalne značajnosti dospjelih obveza. Hrvatska narodna banka definirala je prag materijalno značajnih kreditnih obveza u ukupnom iznosu od 1.750 kn Člankom 18. Stavak 9. Odluke o klasifikaciji plasmana i izvanbilančnih obveza kreditnih institucija HNB-a.

Kriterij naveden u Stavku 1. pod (a) u Članku 178. Uredbe 575, u engleskom žargonu često nazivan i „unlikelihood to pay“ nije temeljen na lako mjerljivim, kvantificirajućim kriterijima već je predmet subjektivne procjene vjerojatnosti da dužnik neće u cijelosti moći podmiriti svoje obveze prema kreditnoj instituciji, i drugim vjerovnicima. Kriteriji za procjenu vjerojatnosti da dužnik neće podmiriti svoje obveze i time će nastupiti default su slučajevi kada kreditna institucija ne priznaje kamatne prihode i prihode od provizija i naknada (nekamatne prihode), kada izdvaja specifične ispravke vrijednosti za identificirane gubitke, prodaje potraživanja uz značajni ekonomski gubitak (diskont), kada pristaje na restrukturiranje kreditnih obveza uz vjerojatne gubitke te kada je nad dužnikom pokrenut stečajni ili slični postupak (na pr. predstečajna nagodba, likvidacijski postupak). U takvim slučajevima status neispunjavanja obveza može biti određen i dužnicima koji kasne manje od 90 dana u podmirivanju svojih obveza, ali ipak postoji velika vjerojatnost da kreditna institucija neće u cijelosti naplatiti svoja potraživanja od dužnika.

Za slučajeve kada institucija smatra da kriteriji za status neispunjavanja obveza nisu više ispunjeni za dužnika koji je ranije bio u statusu neispunjavanja obveza, dužnik se svrstava u razrede kreditne procjene za prihodujuće dužnike, a nastupe li ponovno kriteriji za određivanje statusa neispunjavanja obveza, dužnik se raspoređuje u razrede kreditne procjene za neprihodujuće izloženosti te se takav događaj smatra novim statusom neispunjavanja obveza. Dobra poslovna praksa koristi „periode

oporavka“ u cilju sprječavanja pretjerane volatilnosti događaja ulaska i izlaska iz statusa neispunjavanja obveza što bi moglo rezultirati uvećanim procjenama kreditnog rizika. Period oporavka u takvim slučajevima definira minimalno potrebno vrijeme u kojemu dužnik mora uredno podmirivati dospjele obveze da bi se smatralo da dužnik više nije u statusu neispunjavanja obveza. Za vrijeme trajanja perioda oporavka, unatoč urednom podmirivanju dospjelih obveza, dužnik je u statusu neispunjavanja obveza. Ako u vremenu trajanja perioda oporavka dužnik ponovno počne kasniti u ispunjavanju dospjelih obveza duže od 90 dana ili ponovno ispuni neki drugi kriterij za definiranje statusa neispunjavanja obveza, dužnik ostaje u statusu neispunjavanja obveza i smatra se da je kontinuirano u statusu neispunjavanja obveza. Po urednom isteku perioda oporavka, eventualni sljedeći nastanak događaja statusa neispunjavanja obveza smatrat će se novim statusom neispunjavanja obveza. U observacijskom periodu nastanak barem jednog događaja neispunjavanja obveza rezultira i konačnim statusom neispunjavanja obveza (statusom *default*) na kraju observacijskog perioda (DF_T1=1), neovisno je li se u međuvremenu poduzetnik oporavio i bio uredan duže od perioda oporavka.

Za procjenu parametara PD modela uzet je period oporavka od 6 mjeseci (2 kvartala) te granica za materijalno značajni iznos nepodmirenih obveza u kontinuiranom trajanju duljem od 90 dana od 250,00 EUR (blokada).

Za poduzetnike koji nemaju otvoren račun u Hrvatskoj, ne izračunava se kreditne procjene.

Kriterij za utvrđivanje povećane vjerojatnosti da dužnik neće u cijelosti podmiriti svoje obveze prema instituciji ne uzimajući u obzir mogućnost naplate iz kolaterala

Pokretanje stečajnog ili likvidacijskog postupka tokom obzervacijskog perioda dodatni su događaji koji upućuju na povećanu vjerojatnost da poduzetnik neće u cijelosti ispuniti svoje dospjele obveze prema vjerovnicima. Pri tome su u uzorak uključeni oni poduzetnici koji su na početku observacijskog perioda poslovali regularno (nisu bili u postupku stečaja ili likvidacije), dok su poduzetnici sa kontinuiranim stečajnim ili likvidacijskim postupkom na početku i na kraju observacijskog perioda isključeni iz uzorka.

Kriteriji za status neispunjavanja obveza (default): kasni u podmirivanju obveza više od 90 dana

U dokumentaciji sustava kreditne procjene, ovisno o duljini blokade evidentirane u bazi podataka FINA-e, definirani su sljedeći tipovi blokada (kodeksi) za razdoblje do kraja 2010. godine:

- KODEX 1 poduzetnici koji su u kontinuiranoj blokadi do 30 dana
- KODEX 2 poduzetnici koji su u kontinuiranoj blokadi između 31 i 60 dana
- KODEX 3 poduzetnici koji su u kontinuiranoj blokadi između 61 i 180 dana
- KODEX 4 poduzetnici koji su u kontinuiranoj blokadi između 181 i 360 dana
- KODEX 5 poduzetnici u kontinuiranoj blokadi preko 360 dana

Do kraja 2010. godine baza blokiranih poduzetnika je mjesečne granulacije i koriste se navedeni kodeksi kao indikatori duljine trajanja blokade i evidentiran je iznos dospjelih potraživanja u blokadi. Za periode od 2011. godine nadalje, u bazi postoji točna evidencija o početku i trajanju blokade, tako da se za svaku blokadu može izračunati točan broj dana u blokadi i iznos dospjelih obveza na određeni datum.

Brojanje dana u blokadi

Za vremenski period do 2010. godine (uključujući i 2010. godinu), kao indikator defaulta korišteni su KODEX 4 i KODEX 5, čime su obuhvaćeni poduzetnici u kontinuiranoj blokadi dužoj od 180 dana, dok je za KODEX 3, budući da uključuje blokade u kontinuiranom trajanju između 61 i 180 dana korištena indirektna metoda određivanja statusa poduzetnika u kontinuiranoj blokadi dužoj od 90 dana, usporedbom dva uzastopna kodeksa:

Za godine gdje postoji točna informacija o datumu ulaska u blokadu, broj dana u blokadi se izračunava od datuma stupanja u blokadu (za obveze > 250,00 EUR) pa sve do promatranog trenutka, odnosno do dana izlaska iz blokade.

Materijalna značajnost dospjelih obveza

U postupku određivanja statusa poduzetnika u cijelom promatranom periodu (observacijskom periodu i periodu oporavka) primjenjen je prag materijalne značajnosti dospjelih obveza u visini od 250,00 EUR.

2.1 Izlazak iz defaulta

Period oporavka nije regulatorno propisan, već se njegovo određivanje oslanja na uobičajenu poslovnu praksu. Period oporavka u takvim slučajevima može varirati između 90, 180 pa čak i 270 ili više dana. Kako bi se izbjegle prevelike oscilacije promjene statusa defaulta i urednog poslovanja, te dodatno isključili utjecaji sezonalnosti, period oporavka je određen u trajanju od 6 mjeseci unutar kojeg poduzetnik mora uredno podmirivati svoje obveze da bi se moglo smatrati da se poduzetnik oporavio od zadnjeg događaja defaulta. To vrijedi samo kod određivanja statusa na prelasku godine, kako bi se u uzorak (in-sample) uključili samo poduzetnici koji uredno posluju na početku observacijskog perioda i kako bi rezultat procjene odgovarao vjerojatnosti nastanka (novog) statusa neispunjavanja obveza, odnosno defaulta.

Izlazak iz statusa defaulta moguć je tek nakon isteka vremena oporavka (trenutno se uzima 6 mjeseci), uz uvjet da od trenutka izlaska iz blokade ili iz postupka predstečajne nagodbe (postignuta nagodba) u vremenu oporavka nije bilo novih uvjeta za default poduzetnika (novih materijalno značajnih blokada preko 90 dana u kontinuitetu, prelaska iz predstečajne nagodbe u stečajni postupak ili likvidaciju). Budući da poduzetnici tijekom stečajnog postupka mogu stabilizirati svoje poslovanje, sklopiti stečajni sporazum i potom poslovati uredno, izlazak iz statusa defaulta zbog pokretanja stečajnog postupka (Z2) i prelazak na modelski izračunata kreditna procjena, moguć je nakon isteka vremena oporavka od trenutka sklapanja stečajnog sporazuma i deblokade (kasniji datum od ta dva), ako u tom vremenu nije bilo novih kontinuiranih blokada dužih od 90 dana po materijalno značajnom dugovanju i nije bilo novih pokretanja postupaka predstečajnih ili sličnih nagodbi. Izlazak iz statusa defaulta za poduzetnike u likvidaciji nije moguć, budući da je likvidacija trajni prestanak poslovanja poduzetnika.

3 Odabir uzorka i transformacija varijabli

Zavisna varijabla koja se koristi u PD modela za izračun kreditne procjene poduzeća je binominalna varijabla o nastupanju defaulta. Podaci iz GFI-POD i pokazatelji poslovanja temeljeni na GFI-POD dopunjeni su podacima o datumima i iznosima te trajanju blokada poduzetnika.

Kako bi uzorci bili što homogeniji, korištene su podjele na 3 segmenta prema veličini poduzetnika. Zbog malog broja subjekata u segmentu velikih poduzetnika i relativno sličnih poslovnih karakteristika sa srednje velikim poduzetnicima, ta dva segmenta su spojena u jedan segment za izradu modela. Na taj način je uzorak podijeljen u tri segmenta:

Tablica 1

Oznaka segmenta	Segment
M	Mikro poduzetnici
LM	Srednje veliki i veliki poduzetnici
S	Mali poduzetnici

Trening uzorak je kreiran iz GFI-POD za razdoblje 2012.-2017., a Out-of-Time uzorak na podacima GFI-POD iz razdoblja 2018.-2019. godine.

3.1 Varijable modela i njihove transformacije

Prije početka modeliranja, određene varijable koje potencijalno ulaze u model su transformirane. Transformacije koje su korištene prilikom pripreme podataka su %-tna promjene za varijable kod kojih se promatra i dinamika, a ne samo apsolutna vrijednost varijable. Testirane su i izvorne varijable iz GFI-POD.

Tablica 2

Skupina	Transformacija	Dodani sufix nazivu varijable	Varijabla	Opis
Info.Biz	- nema -	o	BV_MX_IBLK	Maksimalni blokirani iznos u prethodnoj godini (u kunama po fiksnom konverzijijskom tečaju 1 EUR=7,53450 kn)
Info.Biz	- nema -	o	BV_MX_DBLK	Maksimalni broj dana u blokadi u prethodnoj godini
GFI-POD	% promjena	pp	RN101	Koeficijent trenutne likvidnosti
GFI-POD	% promjena	pp	RN102	Koeficijent kratkoročne likvidnosti
GFI-POD	% promjena	pp	RN103	Koeficijent vlastitog financiranja
GFI-POD	% promjena	pp	RN104	Novčani tok
GFI-POD	% promjena	pp	RN105	Omjer pokrića servisiranja duga
GFI-POD	% promjena	pp	RN106	Koeficijent obrtaja potraživanja
GFI-POD	% promjena	pp	RN107	Koeficijent obrtaja obveza prema dobavljačima
GFI-POD	% promjena	pp	RN108	Pokazatelj aktivnosti
GFI-POD	% promjena	pp	RN109	Produktivnost
GFI-POD	% promjena	pp	RN110	Bruto rentabilnost imovine
GFI-POD	% promjena	pp	RN111	Rentabilnost kapitala (ROE)
GFI-POD	% promjena	pp	RN112	EBITDA Marža
GFI-POD	% promjena	pp	RN113	EBIT II
GFI-POD	% promjena	pp	RN114	EBIT II
GFI-POD	% promjena	pp	RN115	Profitabilnost
GFI-POD	% promjena	pp	RN10	Profitabilnost

Skupina	Transformacija	Dodani sufix nazivu varijable	Varijabla	Opis
GFI-POD	% promjena	pp	RN13	Pokazatelj likvidnosti III
GFI-POD	% promjena	pp	RN23	Dani vezivanja kratkoročnih obveza
GFI-POD	% promjena	pp	RN27	Udio duga prema bankama u aktivi
GFI-POD	% promjena	pp	RN53	Ekonomičnost poslovne aktivnosti
GFI-POD	% promjena	pp	RN77	Pokazatelj Obrta Potraživanja
GFI-POD	% promjena	pp	RN9	Povrat na aktivu (ROA Leverage Ratio)
GFI-POD	% promjena	pp	RN33	Pokazatelj Samofinanciranja
GFI-POD	% promjena	pp	RN0d	Pokriće kamata 2
GFI-POD	% promjena	pp	RN38	Omjer novčanog toka i duga
GFI-POD	% promjena	pp	RN48	Koeficijent obrtaja dobavljača
GFI-POD	% promjena	pp	RN51	Proizvodnost rada
GFI-POD	% promjena	pp	RN116	Neto operativna profitabilnost
GFI-POD	% promjena	pp	RN117	Neto profitna marža
GFI-POD	% promjena	pp	RN118	Stopa promjene aktive
GFI-POD	% promjena	pp	RN119	Omjer imovine i obveza
GFI-POD	% promjena	pp	RN121	Udio dugoročnih obveza u aktivi
GFI-POD	% promjena	pp	RN122	Koeficijent obrtaja zaliha
GFI-POD	% promjena	pp	RN123	Koeficijent obrtaja kratkotrajne imovine
GFI-POD	% promjena	pp	RN124	Koeficijent obrtaja dugotrajne imovine
GFI-POD	% promjena	pp	RN125	Koeficijent obrtaja aktive
GFI-POD	% promjena	pp	RN126	Koeficijent obrtaja radnog kapitala
GFI-POD	% promjena	pp	RN128	Omjer NT i dugotrajne imovine
GFI-POD	% promjena	pp	RN129	Udio radnog kapitala u aktivi
GFI-POD	% promjena	pp	RN130	Pokazatelj aktivnosti IV
GFI-POD	% promjena	pp	RN131	Neto potraživanja od kupaca / poslovni prihodi
GFI-POD	% promjena	pp	RN132	EBITDA / poslovni prihodi
GFI-POD	% promjena	pp	RN133	EBIDA / poslovni prihodi
GFI-POD	% promjena	pp	RN134	Zamjenski CAPEX u aktivi
GFI-POD	% promjena	pp	RN135	Sposobnost zaduživanja u aktivi
GFI-POD	% promjena	pp	RN136	Sposobnost zaduživanja 2 u aktivi
GFI-POD	% promjena	pp	RN137	Kratkoročna sposobnost zaduživanja u aktivi
GFI-POD	% promjena	pp	RN138	Kratkoročna sposobnost zaduživanja 2 u aktivi
GFI-POD	% promjena	pp	RN139	Kratkoročne obveze u aktivi
GFI-POD	% promjena	pp	RN140	Kratkoročna imovina u aktivi
GFI-POD	% promjena	pp	RN141	Kratkoročni krediti u aktivi
GFI-POD	% promjena	pp	RN142	Neto kratkoročni krediti u aktivi
GFI-POD	% promjena	pp	RN143	CAPEX u aktivi
GFI-POD	% promjena	pp	RN144	Razlika novca / poslovni prihodi
GFI-POD	% promjena	pp	RN145	Novčani tok od poslovnih aktivnosti / poslovni prihodi
GFI-POD	% promjena	pp	RN146	Novčani tok od investicijskih aktivnosti / poslovni prihodi
GFI-POD	% promjena	pp	RN147	Novčani tok od financijskih aktivnosti / poslovni prihodi
GFI-POD	% promjena	pp	RN148	Neto novčani tok / poslovni prihodi
GFI-POD	% promjena	pp	PP_DVZ	Dani vezivanja zaliha
GFI-POD	% promjena	pp	PP_DVPK	Dani vezivanja kupaca
GFI-POD	% promjena	pp	PP_DVOD	Dani vezivanja dobavljača

Skupina	Transformacija	Dodani sufix nazivu varijable	Varijabla	Opis
GFI-POD	% promjena	pp	PP_CGAP	Novčani jaz
GFI-POD	- nema -	o	D_ABC	pripadnost djelatnosti A, B ili C (proizvodnja)
GFI-POD	- nema -	o	D_FL	pripadnost djelatnosti F ili L (nekretnine)
GFI-POD	- nema -	o	D_G	pripadnost djelatnosti G (trgovina)

Relativna (postotna) promjena varijabli računa se kao omjer trenutne i prethodne vrijednosti podijeljeno sa prethodnom vrijednošću:

$$x_{pp} = \frac{x^{(t)} - x^{(t-1)}}{x^{(t-1)}} \quad (1)$$

Transformirana varijabla označava se sufixom "_pp".

Izvorne (netransformirane) varijable imaju sufix "_o".

Indikatorske varijable

Budući da postoje potencijalne razlike u rizičnosti poduzetnika ovisno o pripadnosti grani djelatnosti, prije procjene modela potrebno je provjeriti rizične profile određenih segmenata te donijeti odluku o broju kvalitativnih indikatorskih varijabli kako bi model što bolje odražavao vjerojatnost defaulta s obzirom na specifičnosti segmenata.

Segmentacija poduzetnika napravljena je prema grupi NKD-a gdje odskaču građevinarstvo (FL) i trgovina (G) u odnosu na ostale grupe NKD-a, a zatim proizvođačke djelatnosti: poljoprivreda, rudarstvo i vađenje i prerađivačka industrija (ABC). S obzirom na navedene povišene rizičnosti spomenutih djelatnosti u uzorak se dodaju nove indikatorske varijable (tzv. "dummy" varijable) koje poprimaju vrijednosti 1 i 0, ovisno o obilježju koje označavaju:

- indikatorska varijabla za proizvodnju: D_ABC
- indikatorska varijabla za trgovinu: D_G
- indikatorska varijabla za nekretninski sektor: D_FL

Sve ostale djelatnosti (pretežito uslužne) nisu označene niti jednom indikatorskom varijablom i poprimaju vrijednosti D_ABC=D_G=D_FL=0.

3.2 Razvoj PD modela za izračun kreditne procjene poduzeća korištenjem tehnika strojnog učenja

Razvoj PD modela za izračun kreditne procjene poduzeća korištenjem tehnika strojnog učenja proveden je u dvije faze.

1. Priprema podataka za treniranje i testiranje modela

Iz GFI-POD podataka i podataka o blokadama poduzetnika izračunati je skup pokazatelja koji su potencijalne varijable za razvoj PD modela za izračun kreditne procjene poduzeća korištenjem tehnika strojnog učenja. Na podacima su potom definirani trening i testni uzorci za usporedbu performansi modela na razvojnim podacima i podacima koji nisu bili uključeni u razvoj modela. Podaci koji se koriste u primjeru su GFI-POD od 2012. – 2017. godine, a zavisna varijabla (default) tijekom jedne godine nakon godišta GFI-POD, 2013.-2018. godina. Kao validacijski uzorak izvan vremena (eng. Out-of-Time) koriste se podaci GFI-POD iz 2018. i 2019. te blokade pokrenute tijekom 2019.-2020. godine.

2. Treniranje i testiranje modela te odabir modela najboljih diskriminatornih karakteristika

Treniranje modela provodi se na odabranom trening uzorku korištenjem jedne od tehnika dubokog strojnog učenja s binomialnom zavisnom varijablom (u periodu do jedne godine poduzetnik je dospio u default). Performanse dobivenog modela se uspoređuju s performansama na testnom uzorku (eng. Out-of-Sample). Treniranje i testiranje modela napravljeno je 10 puta, te su od dobivenih modela odabrani oni gdje su diskriminatorne snage na trening podacima i testnim podacima zajedno najviše. Na taj način odabire se model koji ima podjednako dobre rezultate na trening i test uzorcima, što smanjuje mogućnost prekomjerne prilagodbe modela.

U tu svrhu korišten je binomni logistički (logit) klasifikacijski model izračunat korištenjem tehnika dubokog strojnog učenja "*Extreme Gradient Boosting*" (XGBoost) metodologijom nadziranog učenja (eng. *supervised learning*). XGB se pokazao kao superioran model u binomnoj logističkoj klasifikaciji i u području procjene rizika (Petropoulos, A., et al.), kako među ostalim algoritmima dubokog učenja, tako i u odnosu na logističku regresiju. Njihovi rezultati testirani su empirijski, usporednom procjenom korištenjem logističke regresije, kojom su također postignuta nešto slabija diskriminatorna svojstva modela u odnosu na XGB.

Metoda XGBoost polazi od osnovnog linearnog modela (T. Chen, 2016.):

$$\hat{y}_i = \sum_j w_j x_{ij} \quad (2)$$

odnosno njegove logističke transformacije dane izrazom:

$$Pr(Y = 1|X) = \frac{1}{1 + e^{-\hat{y}_i}} \quad (3)$$

čiji se parametri

$$\theta = \{w_j | j = 1, \dots, d\} \quad (4)$$

optimiziraju na način da se minimizira pogreška na trening uzorku, ali i na svim ostalim "neviđenim" podacima:

$$Obj(\theta) = L(\theta) + \Omega(\theta) \quad (5)$$

U ciljnoj funkciji $Obj(\theta)$, $L(\theta)$ predstavlja funkciju minimizacije pogreške na trening podacima, a $\Omega(\theta)$ regularizaciju, najčešće pomoću L2 euklidske norme kako bi se regresija "izgladila" i prilagodila

"neviđenim" podacima. Korišteni oblik ciljne funkcije je binomna logistička funkcija (objective = "binary:logistic").

Za K stabala odlučivanja model poprima oblik

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (6)$$

te slično za bilo koje za t-to stablo

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) \quad (7)$$

Funkcija gubitaka za binomnu logističku klasifikaciju poprima oblik

$$L = -\frac{1}{N} \sum_{i=1}^N (y_i \log(p_i) + (1 - y_i) \log(1 - p_i)) \quad (8)$$

a regularizacijska funkcija za T broj listova u stablu definirana je oblikom

$$\Omega = \gamma T + \frac{\lambda}{2} \sum_{j=1}^T w_j^2 \quad (9)$$

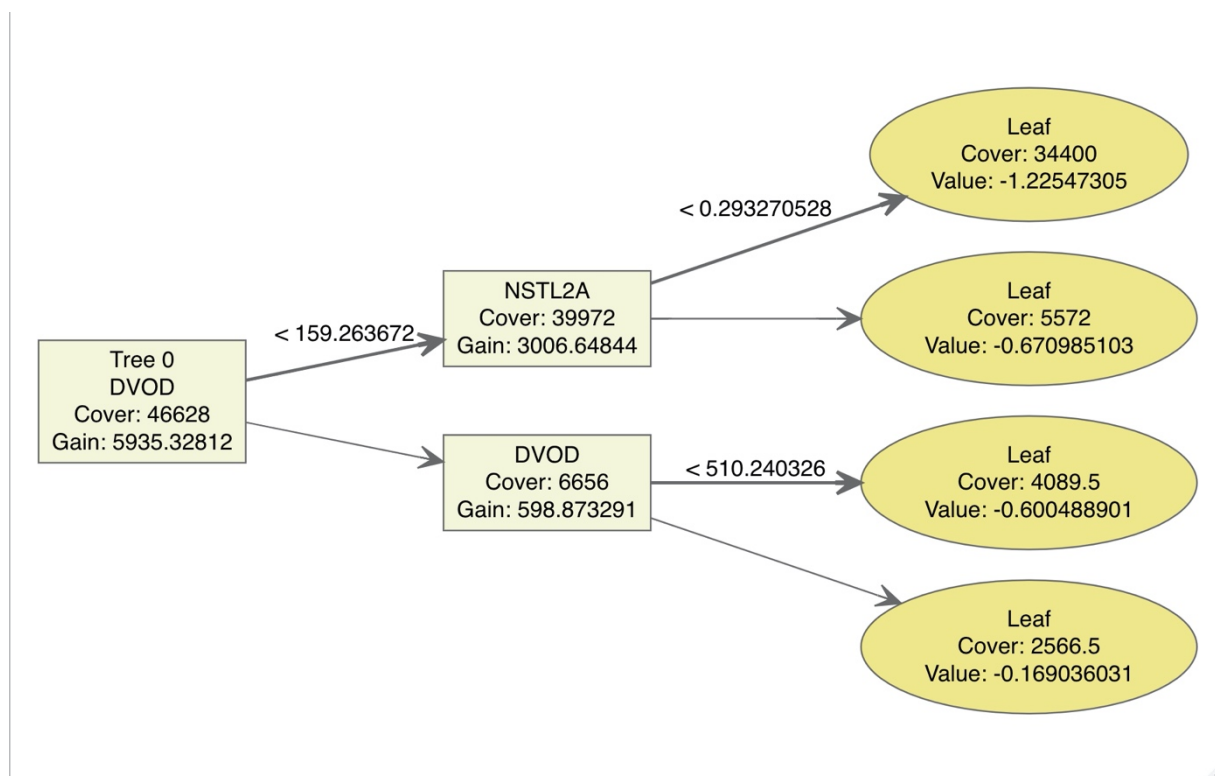
gdje je γ minimalni stupanj smanjenja gubitka čije povećanje doprinosi konzervativnosti modela. XGBoost koristi algoritam postupnog opadanja (eng. *gradient descent*) prilikom minimizacije ciljne funkcije i grananja stabala pri čemu se koristi predviđena vrijednost iz prethodnog koraka, pojednostavljeno zapisano:

$$y^{(t)} = y^{(t-1)} + \epsilon f_t(x_i) \quad (10)$$

gdje je ϵ koeficijent umanjenja (eng. *shrinkage*) koji smanjuje utjecaj svakog novog stabla u iteraciji, a time i prekomjernu prilagodbu modela.

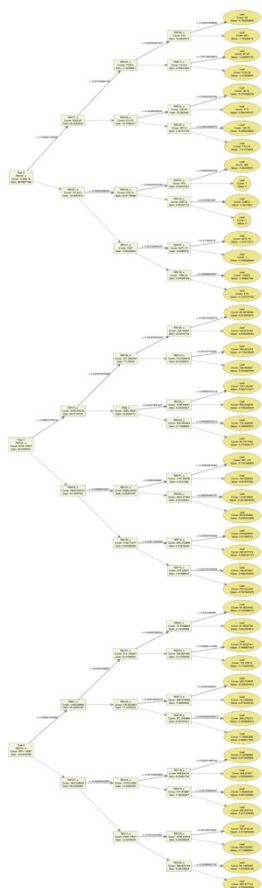
Stablo, grane, čvorovi i listovi prikazani su na slici ispod. U čvorovima se donose odluke i određuje smjer prema konačnom listu koji sadrži skor za dotično stablo i ulazne nezavisne varijable.

Slika 1



Ansambl stabala predstavlja veliki broj stabala koja nisu povezana, ali zajedno čine ansambl koji je naučen da klasificira ulazne podatke s obzirom na zavisnu varijablu (nadzirano učenje).

Slika 2



Pomoću dobivenog ansambla stabala, izračunava se ML score i nekalibrirani PD poduzetnika i izračunava se pomoću sljedećih formula:

$$MLScore_i = \sum value_{leaf_i} \quad (11)$$

$$PD_{i\ nekalib.} = \frac{1}{1 + e^{-MLScore_i}} \quad (12)$$


$PD_{i\ nekalib.}$ je nekalibrirana vjerojatnost nastanka defaulta (statusa neispunjavanja obveza) za poduzetnika i . Nekalibrirana vrijednost odražava vjerojatnost nastanka defaulta s obzirom na uzorak na kojemu je napravljena procjena parametara modela (koeficijenata). Tako izračunatu vjerojatnost defaulta potrebno je kalibrirati prema centralnoj tendenciji stope defaulta u cijeloj populaciji.

3.2.1 Treniranje i testiranje modela te odabir modela najboljih diskriminativnih karakteristika

PD model za izračun kreditne procjene poduzeća učen je na trening uzorku, a provjeren pomoću testnog uzorka. Kako bi se izbjegla prekomjerna prilagodba modela trening uzorku (prenaučenos), korištena je iterativna metoda uzorkovanja iz osnovnog skupa podataka za oba uzorka: trening i test,

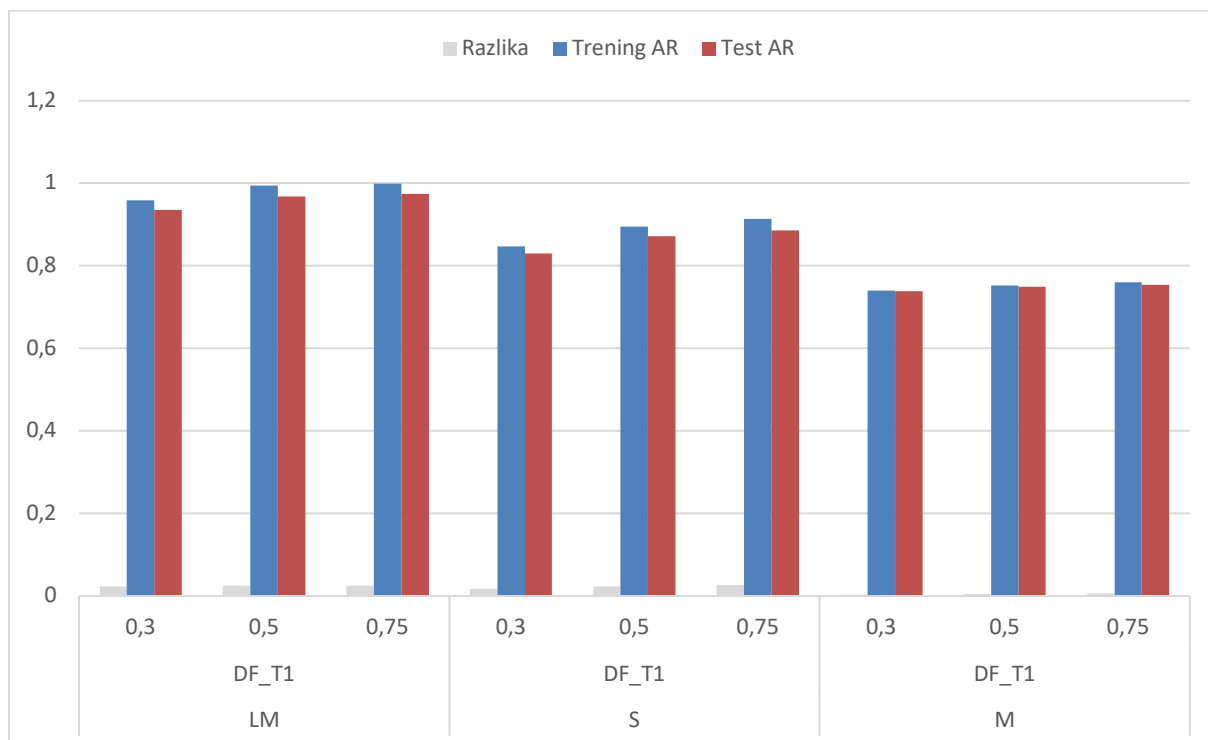
tzv. "boot-straping" metoda kojom se iz početnog uzorka slučajnim odabirom kreiraju različiti uzorci čime se ispituju performanse modela izvan uzorka (eng. *out-of-sample*). Postupak je ponavljan 10 puta mijenjajući pri tome poduzeća koja ulaze u uzorke slučajnim odabirom uz zadržavanje originalne distribucije uzorka za svaki segment. Budući da je udio defaulta u originalnom skupu podataka jako mali (3-5%), prilikom uzorkovanja u trening i test uzorak uključeno je 30% poduzetnika koji nisu u defaultu i 90% onih koji to jesu. Na jednak način korišteni su isti omjeri prilikom uzorkovanja u svakom segmentu.

Slika 3



XGBoost metodologija koristi nekoliko parametara u procjeni modela, kao što je to opisano u uvodnom dijelu. Korištena je binomna logistička ciljna funkcija (*objective = "binary:logistic"*), s obzirom na dihotonu zavisnu varijablu koja poprima samo dvije vrijednosti: 0 ili 1, a rezultat klasifikacije predstavlja vjerojatnost nastupanja financijskih nestabilnosti u opservacijskom periodu. Kao broj stabala odabrano je 8 (*nrounds=8*). Maksimalna dubina stabla je: 6 (*max.depth=6*), a maksimalni broj grana je 4 (*nthread=4*). Svaki par trening-test uzoraka korišten je za procjenu i provjeru diskriminatorne snage modela (AUC, (Area under receiver operatig curve) kod treniranja, *AR, Accuracy Ratio*, odnosno gini na performansama modela) i njene stabilnosti na promjenu uzorka za različite gama (γ ... minimalni stupanj smanjenja gubitka; vidi jednadžbu (9)) i eta (ϵ ... koeficijent umanjenja; vidi jednadžbu (10)) parametre XGBoost klasifikacije. Početni izbor za γ je 0, a ϵ se mijenja: 0,3, 0,5 i 0,75. Procjene modela ponovljene su za tri opisana segmenta.

Slika 4


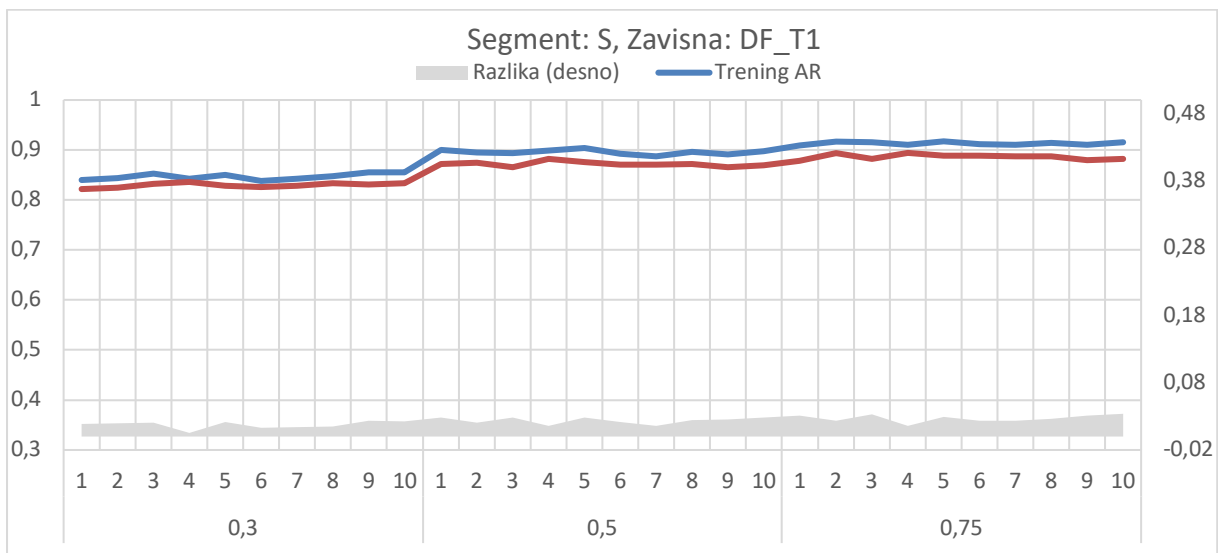



Kao opservacijski period odabran je horizont od 1 godine. Performanse modela na opservacijskom horizontu od 1 godine su izvrsne do iznimne. U modelskim performansama za segment LM zbog malog broja opservacija i događaja defaulta, lakše i brže dolazi do prenaučivosti. Stoga je za LM model u obzir uzet jedino niži faktor učenja $\eta=0,3$.

Dobiveni rezultati su prikazani tablično i grafički, pri čemu su kriteriji za odabir optimalnih parametara za procjenu modela maksimizacija diskriminatorne snage modela na oba uzorka: trening i test, mjerena omjerom preciznosti (*eng. Accuracy Ratio; AR ili GINI*) uz istovremeno minimiziranje njihove razlike. Dobivene prosječne vrijednosti gini koeficijenta za 10 iteracija uz zadane kombinacije eta parametara te pripadajuće standardne devijacije rangirane su prema optimizacijskim kriterijima. Prosječni gini koeficijenti rangirani su od najvećeg prema najmanjem (rang najvećeg=1), a razlika trening-test gini od najmanje prema najvećoj (rang najmanje=1). Ukupni rang modela je rang sume ta dva ranga, a najbolji (najmanji) rang predstavlja optimalni model i kombinaciju gama i eta parametara. Rezultirajući gini koeficijenti za trening i test uzorak uz odabrane $\gamma=0$ i eta parametre u 10 provedenih iteracija prikazani su grafički po segmentima, gdje je vidljivo kretanje gini koeficijenta i razlike između trening i test gini koeficijenata.

Za segment LM napravljeno je dodatnih 10 iteracija (11 - 20) sa promijenjenim parametrima uzorkovanja. Manji broj opservacija u segmentu rezultirao je znatnom prenaučivošću kod 30:90 omjera stratifikacije i slabljenjem modelskih performansi na OOT podacima. Dodatnih 10 iteracija je napravljeno uz stratifikaciju 40:80.

Slika 5



Najbolje ukupne performanse na trening i test uzorcima imali su sljedeći modeli radnih naziva:

- **M-DF_T1-1.3**
- **LM-DF_T1-6.2**
- **S-DF_T1-4.3**

3.2.2 Inicijalna Kalibracija

Budući da je uzorak na kojemu su modeli trenirani stratificiran asimetrično, pa je pristran prema poduzetnicima u defaultu, modele je potrebno kalibrirati na stvarne očekivane stope defaulta u pojedinim segmentima. Kalibracija PD modela radi se prema centralnoj tendenciji ostvarenih stopa nastanka statusa neispunjavanja obveza poduzetnika. Inicijalna kalibracija za potrebe In-Time testiranja provodi se za razdoblje 2012. – 2017.

Kalibracija je napravljena prilagodbom modelskog PD-a poduzetnika na centralnu tendenciju korištenjem Bayesove tehnike prema prikazanoj formuli:

$$PD_i^{CT} = \frac{PD_i \cdot (1 - DR^S) \cdot DR^{CT}}{(1 - PD_i) \cdot DR^S \cdot (1 - DR^{CT}) + PD_i \cdot (1 - DR^S) \cdot DR^{CT}} \quad (13)$$

pri čemu je:

PD_i^{CT} ... kalibrirani PD poduzetnika i

PD_i ... nekalibrirana modelska procjena PD-a poduzetnika i

DR^{CT} ... izračunata centralna tendencija iz stopa defaulta za definirano kalibracijsko razdoblje

DR^S ... prosječna stopa defaulta uzorka za procjenu parametara modela

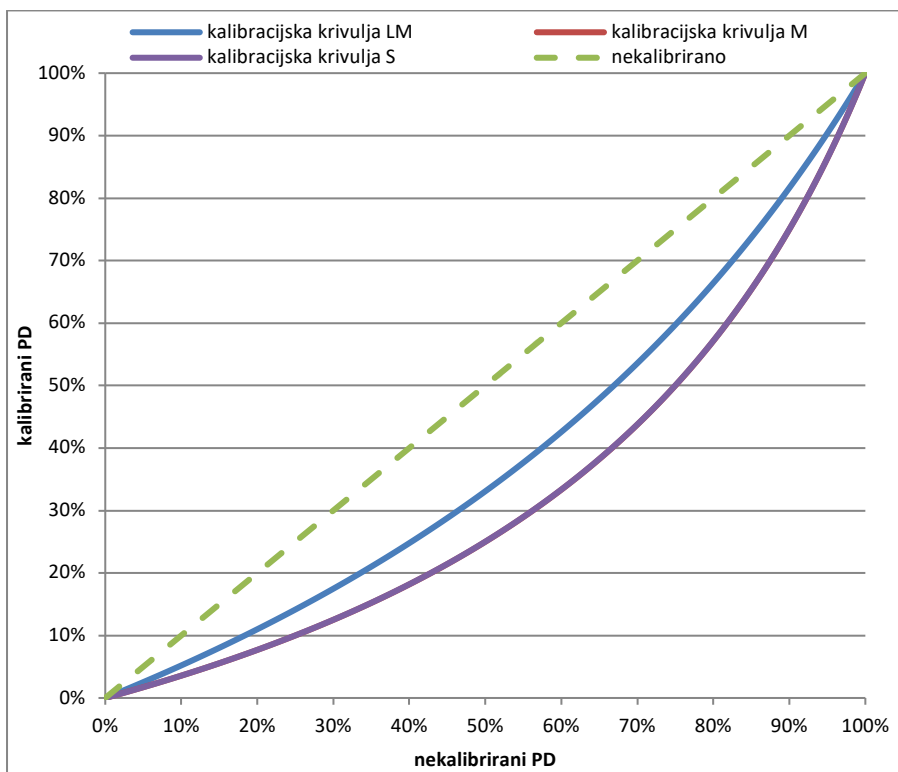
Tablica 3

SEGMENT	DR	TYPE	DATE_FROM	DATE_TO	GODINA	SCENARIJ	SCENARIJ_OZN	VER
LM	2,70%	S	06/03/2021	06/03/2022		Kalibracija	A	Uzorak
M	11,91%	S	05/03/2021	05/03/2022		Kalibracija	A	Uzorak
S	6,27%	S	05/03/2021	05/03/2022		Kalibracija	A	Uzorak
LM	1,35%	CT	05/03/2021	05/03/2022	2017	Kalibracija	A	TTC (InTime)
M	4,31%	CT	05/03/2021	05/03/2022	2017	Kalibracija	A	TTC (InTime)
S	2,18%	CT	05/03/2021	05/03/2022	2017	Kalibracija	A	TTC (InTime)

Tablica prikazuje ostvarene stope defaulta razvojnog uzorka za procjenu modela dubokog strojnog učenja PD-a za razdoblje GFI-POD 2012.-2017. i centralne tendencije ostvarenih stopa defaulta populacije na In-Time uzorku za segmente srednje velikih i velikih poduzetnika, za segment malih poduzetnika i za segment mikro poduzetnika u razdoblju 2012.-2017.

Primjenom kalibracijske funkcije dobije se kalibracijska krivulja za modele koja je prikazana na slikama ispod:

Slika 6




3.3 Dizajn modela

3.3.1 Dizajn modela za segment M: PD_M_v1

Temeljem provedenih iteracija na različitim uzorcima, najbolju diskriminatornu snagu za segment M ima model M-DF_T1-1.3.

Varijable koje imaju najviši ukupni prirast informacije u modelu su prikazane na grafikonu ispod:

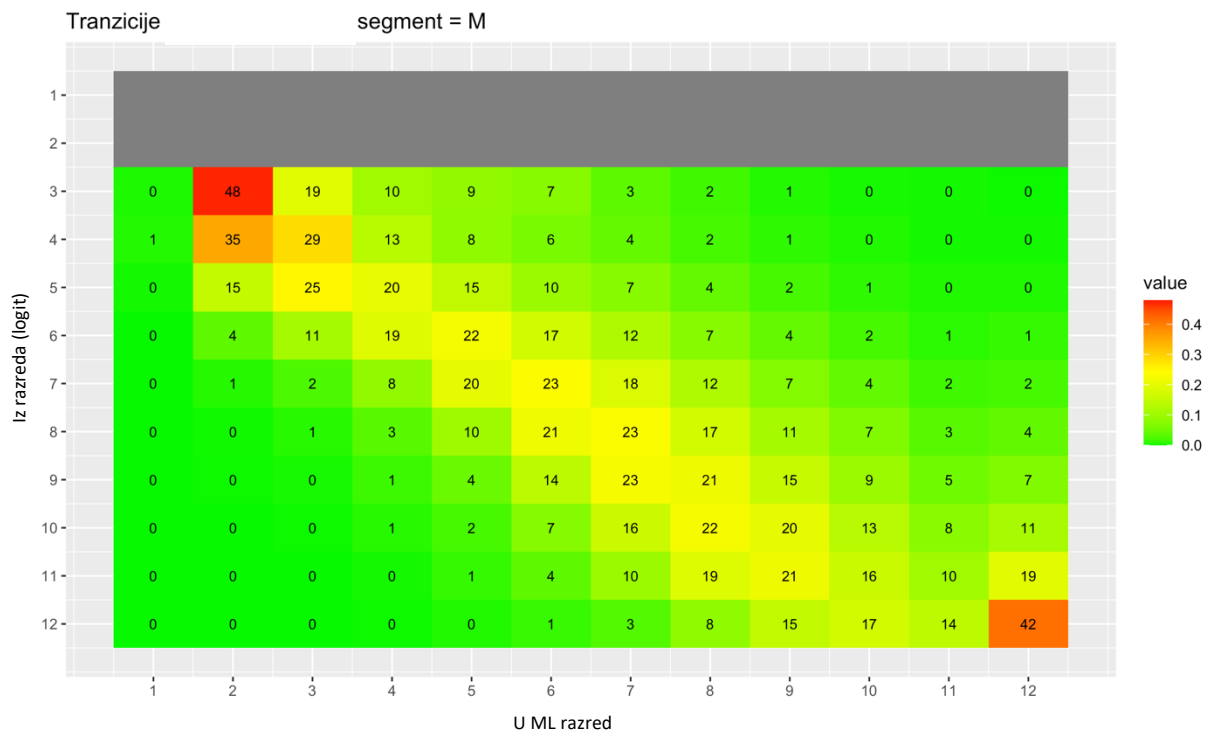
Slika 7



Usporedba sa logit modelom

Uspoređujući sa logit modelom, vidljivo je da je više poduzetnika raspoređeno u razrede 1 i 2, što ranije nije bio slučaj. Većina slučajeva je koncentrirana oko dijagonale matrice, s time da su bolji poduzetnici blago raspoređeni u jedan do dva bolja razreda, a kod lošijih razreda se znatni dio svrstava u 12. razred.

Slika 8




3.3.2 Dizajn modela za segment LM: PD_LM_v1

Temeljem provedenih iteracija na različitim uzorcima, najbolja svojstva za segment LM ima model LM-DF_T1-6.2.

Varijable koje imaju najviši ukupni prirast informacije u modelu su prikazane na grafikonu ispod:

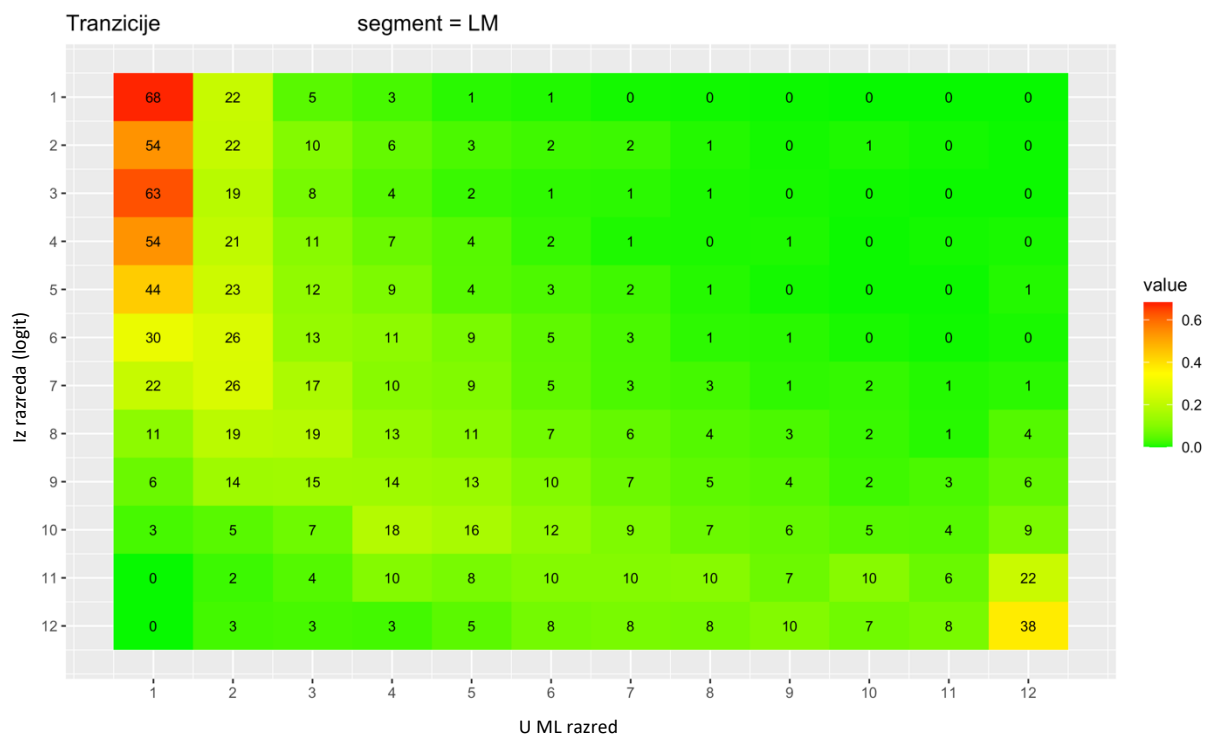
Slika 9



Usporedba sa logit modelom

Uspoređujući sa logit modelom, vidljivo je da je više poduzetnika raspoređeno u razrede 1 i 2.

Slika 10




3.3.3 Dizajn modela za segment S: PD_S_v1

Temeljem provedenih iteracija na različitim uzorcima, najbolju diskriminatorsnu snagu za segment S ima model S-DF_T1-4.3.

Varijable koje imaju najviši ukupni prirast informacije u modelu su prikazane na grafikonu ispod:

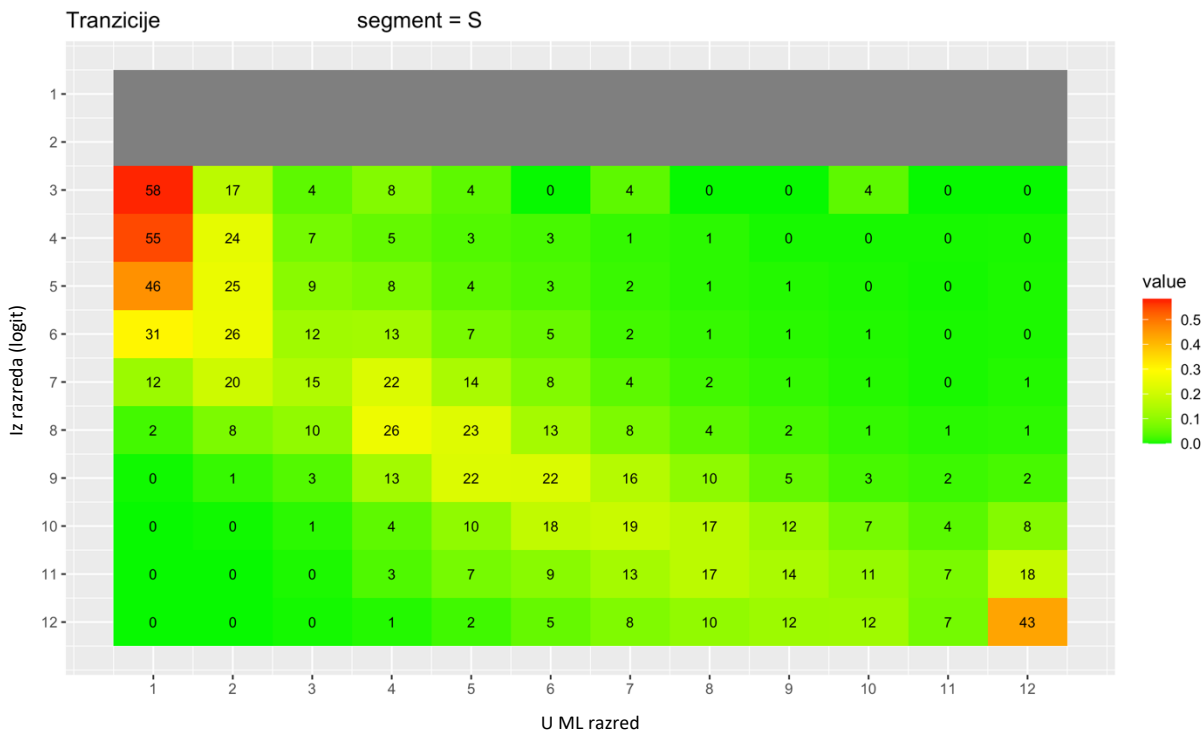
Slika 11



Usporedba sa logit modelom

Uspoređujući sa logit modelom, vidljivo je da je više poduzetnika raspoređeno u razrede 1 i 2, što ranije nije bio slučaj. Većina slučajeva je koncentrirana oko dijagonale matrice, s time da su bolji poduzetnici blago raspoređeni u jedan do dva bolja razreda, a kod lošijih razreda se znatniji dio svrstava u 12. razred.

Slika 12



3.3.4 Preciznost modela na „neviđenim“ podacima (OOT)

Testovi preciznosti, diskriminatorne snage i distribucije po klasama kreditne procjene napravljeni su na "neviđenim" podacima izvan vremena: Out-of-Time (OOT). Podaci izvan vremena su temeljeni na GFI-POD 2018. i 2019. sa ostvarenjima u godinama koje slijede: 2019. i 2020. Zbog epidemioloških mjera i mjera za pomoć gospodarstvu od posljedica pandemije, 2020. godina ne može se smatrati "uobičajenom" godinom, već je to godina koja zahtjeva primjenu stres scenarija. Budući da se ovdje radi o inicijalnoj validaciji koja služi za procjenu primjenjivosti modela, odziv na podacima ostvarenim tijekom 2020. godine je orijentacijskog karaktera, pa modeli nisu kalibrirani na stresne uvjete, što rezultira nešto slabijim performansama modela.

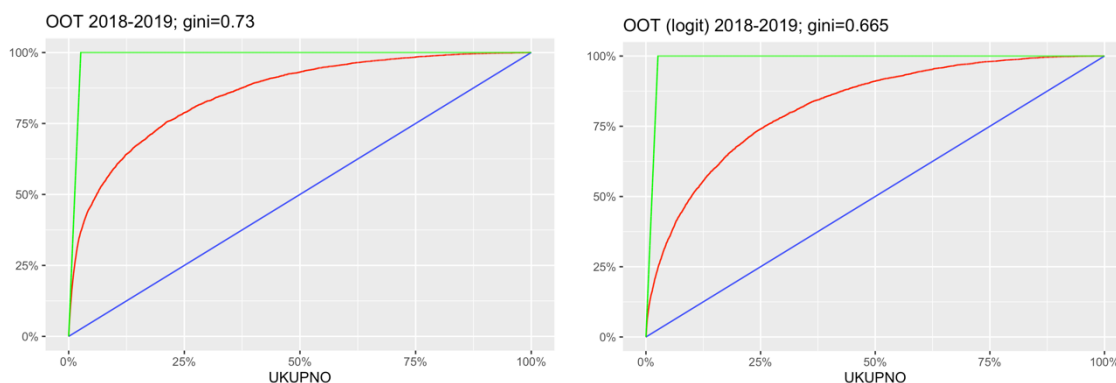
Iz tog razloga, validacije na OOT podacima napravljene su uzevši u obzir 2019. i 2020. zajedno (GFI-POD 2018.-2019.), te 2019. i 2020. ponaosob.

Ukupna preciznost PD modela na OOT 2018.-2019. podacima je izuzetno visoka i iznosi 96,2%, specifičnost je 97,8%, a osjetljivost 39,9%. Drugim riječima, model je ispravno klasificirao 96,2% poduzetnika, pri čemu je ispravno prepoznao 97,8% stabilnih poduzetnika i 39,9% defaulta.

Diskriminatorna snaga modela (OOT)

Diskriminatorna snaga svih PD modela pomoću strojnog učenja je izvrsna i znatno bolja od diskriminatorne snage logit PD modela. Na ukupnim podacima 2018. i 2019. ukupni gini PD modela strojnog učenja je 0,730, dok je na istim podacima gini logističkog modela 0.665.


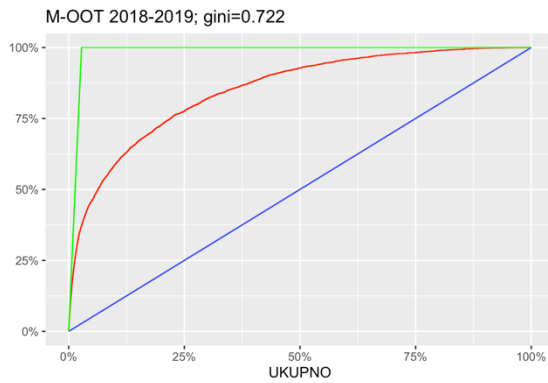
Slika 13



Također, u svim segmentima diskriminatorna snaga PD modela pomoću strojnog učenja je izvrsna (iznad 70%) i bolja od logističkih modela.



M segment

Slika 14





S segment

Slika 15



LM segment


Slika 16



Distribucije kreditne procjene (OOT)


Distribucija poduzetnika po razredima kreditne procjene nema izraženiju koncentraciju, a udio defaulta je rastući prema većim razredima.

Slika 17. Distribucije po razredima kreditne procjene



Uspoređujući sa logit modelom, vidljivo je da je više poduzetnika raspoređeno u razrede 1 i 2. Većina slučajeva je koncentrirana oko dijagonale matrice, s time da su poduzetnici blago pomaknuti za jedan do dva razreda na bolje, a kod lošijih razreda se dio svrstava u 12. razred.


Slika 18



4 Centralna tendencija (kalibracija)

Kalibracija ML.PD modela radi se prema centralnoj tendenciji ostvarenih stopa nastanka statusa neispunjavanja obveza poduzetnika za razdoblje 2017. – 2023. PD model je prethodno kalibriran na razdoblje 2017.-2022. te da bi se model mogao kalibrirati na cijeli gospodarski ciklus ili barem na njegov veći dio, potrebno je izračunati centralnu tendenciju frekvencija defaulta u maksimalno dostupnom razdoblju od 2017.-2023. godine (Default Frequency, Default Rate). Što je veći dio ekonomskog ciklusa obuhvaćen, modelske procjene kalibriranog PD-a biti će bliže TTC (Through the Cycle) stopi defaulta, a protivno će biti bliže PIT (Point in Time) stopama defaulta. Kalibracijom modelskog PD-a prema recesijskim stopama defaulta, rezultirajući model precjenjuje PD tako da su stope modelskog kalibriranog PD-a nešto više od realno očekivanih. Kalibracija prema stopama defaulta iz razdoblja ekonomskog rasta shodno tome podcjenjivala bi PD. Stoga se u praksi najčešće PD modeli kalibriraju na razdoblje koje obuhvaća glavninu ekonomskog ciklusa pri čemu prosječna stopa defaulta daje vrijednost centralne tendencije. Modeli koji su kalibrirani prema TTC prikladniji su za izračun kapitalnog zahtjeva od PIT modela, jer daju stabilniji i o ekonomskom ciklusu neovisan, točnije, slabo ovisan rezultat koji se koristi u izračunu potrebnog kapitala kreditne institucije. Međutim, za potrebe MSFI 9, PD vrijednosti se trebaju kalibrirati na PIT i to prema očekivanim stopama defaulta za naredno razdoblje, što se procijenjuje pomoću satelitskih makroekonomskih modela i makroekonomskim očekivanjima (scenarijima).

Slika 19



Za izračun centralne tendencije koriste se podaci GFI-POD za razdoblje od 2016. – 2022. te događaj defaulta prema baselskoj definiciji za sljedeću godinu (za 2017. – 2023.). U uzorak su uzeti samo

poduzetnici koji su predali financijski izvještaj s vrstom izvještaja 10 ili 11 (što znači da nisu u stečaju ili likvidaciji u toj godini). Po definiciji default nastupa ako je iznos blokade veći od 250,00 EUR te ako je poduzetnik u neprekinutoj blokadi 90 ili više dana. Segment veličine preuzet je iz oznake veličine u godišnjem financijskom izvještaju, 'M' za mikro, 'S' za male, 'LM' za srednje i velike, a koji je određen prema pravilima veličine ZOR-a u toj godini.

Kalibracija je napravljena prilagodbom modelskog PD-a poduzetnika na centralnu tendenciju korištenjem Bayesove tehnike prema formuli (13).

Tablica 4 prikazuje stope defaulta za svaki segment prema centralnoj tendenciji za TTC za razdoblje 2017.-2023. Sukladno novim podacima uključenim u analizirano razdoblje, izračunata je nova centralna tendencija za kalibraciju modela u koju je dodana i marža konzervativnosti kako bi se izbjegle previsoke koncentracije poduzetnika u najboljim razredima (razredima 1 i 2) te se kalibracija izračunava sa vrijednostima centralnih tendencija koje uključuju i spomenute marže konzervativnosti (Tablica 4, kolona DR^{*CT}).

Tablica 4

<i>Segment</i>	DR^S	DR^{CT}	Marža konzervativnosti	DR^{*CT}
<i>Veliki i srednji (LM)</i>	2,70%	0,62%	0,5%	1,12%
<i>Mali (S)</i>	6,27%	1,33%	1%	2,33%
<i>Mikro (M)</i>	11,91%	2,83%	0%	2,83%

Izvor: FINA; CT prema stopama defaulta ostvarenim u razdoblju 2012. – 2021.

5 Kalibracija skale kreditne procjene (master skala)

Korištena skala kreditne procjene ima 12 kategorija za poduzetnike koji nisu u statusu neispunjavanja obveza, odnosno u defaultu, te 3 kategorije za poduzetnike koji su u statusu neispunjavanja obveza. Poduzetnici koji nisu u statusu neispunjavanja obveza su poduzetnici koji nisu u blokadi, odnosno nisu u blokadi dužoj od 90 dana, niti su u njoj bili u periodu od 6 mjeseci prije datuma izračuna kreditne procjene. Poduzetnici u statusu neispunjavanja obveza (razred 13) su poduzetnici koji su u blokadi dužoj od 90 dana, poduzetnici koji nisu u blokadi, a koji su izašli iz blokade duže od 90 dana u periodu od 6 mjeseci prije datuma izračuna kreditnog, poduzetnici nad kojima je pokrenut stečajni ili slični postupak (razred 14) te poduzetnici u likvidaciji (razred 15).

Skala kreditne procjene je jedinstvena za sve segmente poduzetnika (male, srednje i velike) radi lakše usporedivosti dodijeljenih kreditnih procjena. Skala kreditne procjene je podložna promjenama i uskladbama definiranih PD raspona za kategorije kreditne procjene u slučaju značajnijeg odstupanja ostvarenih stopa defaulta od predviđenih, neovisno jesu li odstupanja pozitivna (PD podcjenjen) ili negativna (PD precjenjen). Time se definirana skala kreditne procjene može prilagođavati određenim fazama ekonomskog ciklusa, kako bi se postigla veća stabilnost kreditne procjene i njezina što veća neovisnost o ekonomskom ciklusu (TTC kreditne procjene).

Skala kreditne procjene prikazana je u sljedećoj tablici:

Tablica 5

RAZRED	KLASA	PD_MIN	PD_MEAN	PD_MAX	OPIS
1	A1	0,00%	0,03%	0,05%	Poduzetnici sa zanemarivom vjerojatnošću zastoja u plaćanju
2	A2	0,05%	0,06%	0,15%	Poduzetnici s najnižom vjerojatnošću zastoja u plaćanju
3	A3	0,15%	0,16%	0,31%	Poduzetnici s vrlo niskom vjerojatnošću zastoja u plaćanju
4	B1	0,31%	0,32%	0,51%	Poduzetnici s niskom vjerojatnošću zastoja u plaćanju
5	B2	0,51%	0,55%	0,82%	Poduzetnici sa srednje niskom vjerojatnošću zastoja u plaćanju
6	B3	0,82%	0,98%	1,33%	Poduzetnici s blago povišenom vjerojatnošću zastoja u plaćanju
7	B4	1,33%	1,68%	2,14%	Poduzetnici s povišenom vjerojatnošću zastoja u plaćanju
8	B5	2,14%	2,81%	3,46%	Poduzetnici s ispod prosječnom vjerojatnošću zastoja u plaćanju
9	B6	3,46%	4,45%	5,59%	Poduzetnici sa prosječnom vjerojatnošću zastoja u plaćanju
10	C1	5,59%	7,01%	9,04%	Poduzetnici sa blago iznad prosječnom vjerojatnošću zastoja u plaćanju
11	C2	9,04%	10,88%	14,60%	Poduzetnici sa visokom vjerojatnošću zastoja u plaćanju
12	C3	14,60%	37,29%	99,99%	Poduzetnici sa vrlo visokom vjerojatnošću zastoja u plaćanju
13	D1	100,00%	100,00%	100,00%	Poduzetnici u blokadi više od 90 dana ili bili u blokadi više od 90 dana u periodu od 6 mjeseci prije trenutka izračuna kreditne procjene
14	D2	100,00%	100,00%	100,00%	Poduzetnici nad kojima je pokrenut stečajni ili slični postupak
15	D3	100,00%	100,00%	100,00%	Poduzetnici u postupku likvidacije

Korištenjem kumulativnih stopa defaulta zadovoljava se i Basel III preporuka da razred kreditne procjene odražava višegodišnji rizik poduzetnika.


6 Kvantitativna validacija PD modela

6.1 Preciznost klasifikacije modela

6.1.1 Distribucija frekvencije dobrih i loših s obzirom na klasu kreditne procjene

Na grafičkim prikazima distribucija frekvencija poduzetnika po razredima Master skale za sva tri segmenta za cijeli uzorak (sve godine 2017.-2023., odnosno prema GFI-POD 2016.-2022.) vidljivo je da nema povećanih koncentracija poduzetnika niti u jednom razredu (Slika 20). Koncentracije su u svim razredima ispod 25% i ne prelaze niti 15% poduzetnika unutar istog razreda. Budući da se skala kreditne procjene primjenjuje na sve segmente kroz puni ciklus (TTC) i predstavlja glavnu skalu sustava kreditne procjene, sustavno promatrano ne postoje značajno povišene koncentracije kreditne procjene.

Slika 20



Funkcija prosječnog PD-a je monotono rastuća za sva tri segmenta, kao i funkcija ostvarenog PD-a (default rate DR). Promatrano na ukupnom uzorku za razdoblje 2017.-2023. godinu, može se reći da TTC model zadovoljava pretpostavke monotonog rasta funkcije rizičnosti i zahtjeva za niskom koncentriranošću poduzetnika unutar kategorija kreditne procjene.

6.1.2 Tablica kontigencije (Confusion matrix)

Tablica kontigencije uspoređuje predviđanja sa ostvarenjima statusa neispunjavanja obveza. Pri tome je ključno određivanje kriterija za kategoriju kreditne procjene koja podrazumijeva „lošu“ kreditne procjene, odnosno kategoriju predviđenog statusa neispunjavanja obveza. Vrijednost isključivanja (cut-off value) može se definirati kao kategorija kreditne procjene koja, zajedno sa svim lošijim kategorijama predstavljaju visoku vjerojatnost nastajanja statusa neispunjavanja obveza, ili kao PD vrijednost iznad koje vrijedi ista pretpostavka. Ta vrijednost ovisi o sklonosti preuzimanja rizika kreditne institucije (risk appetite) i u kreditnom poslovanju u odobravanju kreditnog rizika uzima se kao prag odbijanja kreditnog zahtjeva (non-investment grade).

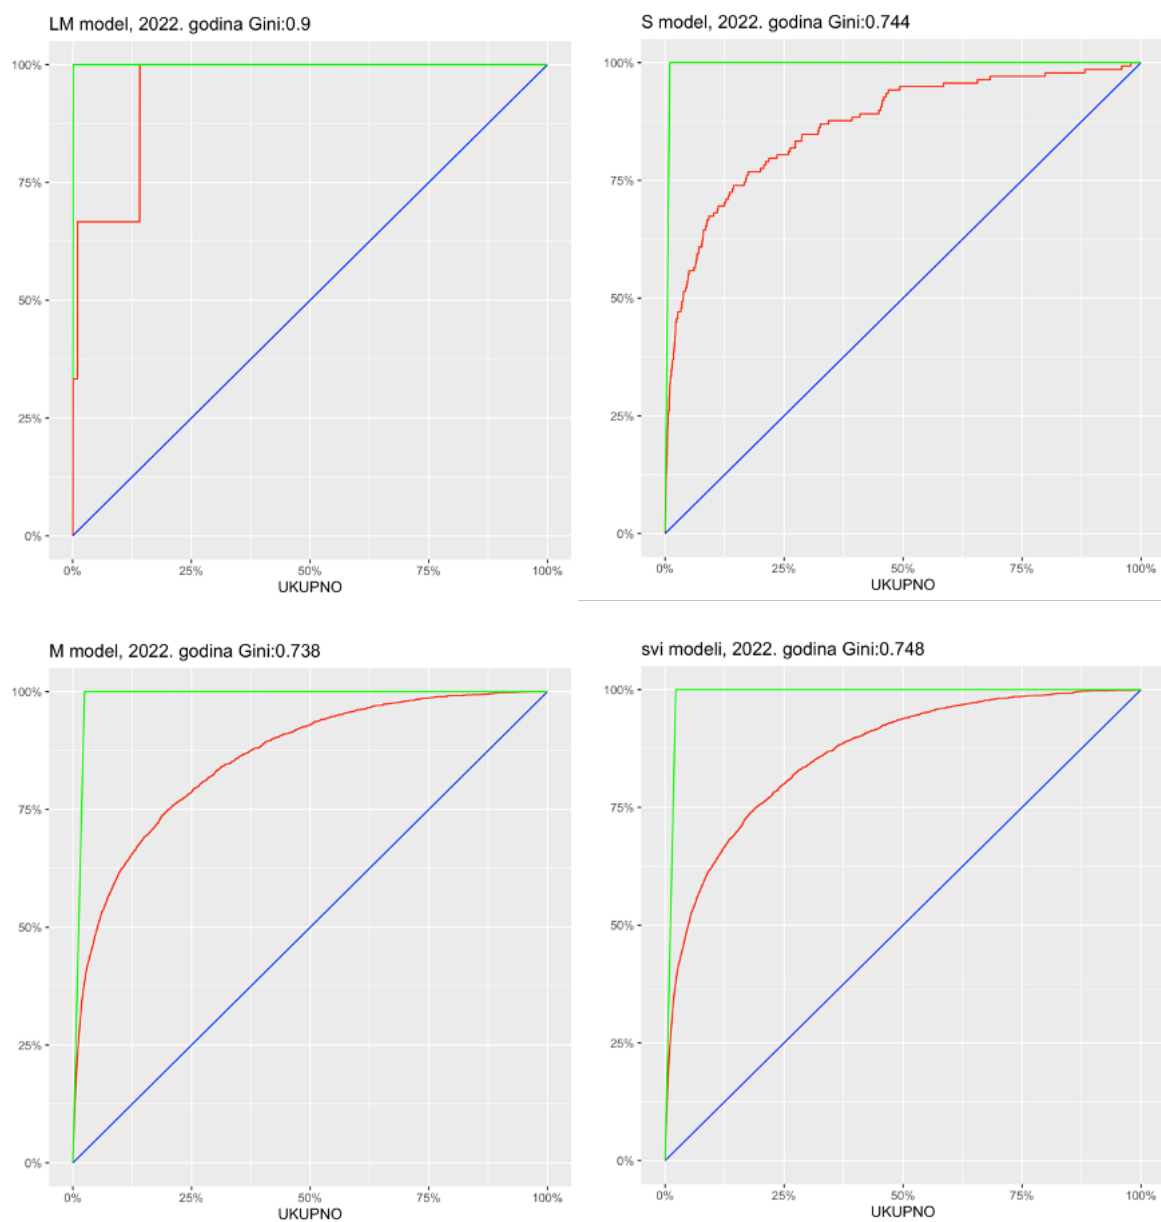
Za potrebe ove validacije korištena je kategorija 12 kao vrijednost isključivanja što odgovara donjoj PD granici za kategoriju 12: $PD_{cut-off}=14,60\%$. Preciznost klasifikacije prema tablici kontigencije je vrlo dobra, na ukupnoj razini visokih 97,3% točno klasificiranih poduzetnika. Osjetljivost modela u razdoblju 2017.-2023. je oko 98%. Postotak uspješne klasifikacije loših je oko 34%, što znači da je model prepoznao oko 1/3 poduzetnika koji su doista tijekom godine blokirani više od 90 dana po materijalno značajnom iznosu duga (default), što je dobar rezultat budući da 12. razred kreditne procjene ima prosječni PD oko 37%, a model je pouzdano prepoznao gotovo 35% loših poduzetnika. Postotak uspješne klasifikacije dobrih poduzetnika oko 99% što znači da je model pogrešno predvidio za tek 1% poduzetnika da će defaultirati, a što se nije dogodilo. Istovremeno, Greška tipa I je 1,7% što znači da je model predvidio da će ti poduzetnici uredno poslovati, a u konačnici su ipak završili u defaultu. Greška tipa II je oko 54%, što znači da model konzervativno procjenjuje potencijalno loše poduzetnike (dodjeljuje im razred 12), pri čemu oko polovine poduzetnika ipak ne završi u defaultu.

6.1.3 Krivulja snage (CAP)

Diskriminatorna snaga modela je sposobnost modela da razluči poduzetnike koji su u statusu neispunjavanja obveza od ostalih poduzetnike, odnosno dužnika. Vizualni prikaz diskriminatorne snage modela jesu CAP i ROC krivulja, a kvantifikatori diskriminatorne snage su AR (Accuracy Ratio, gini) koeficijent i AUC (Area Under ROC Curve).

CAP krivulja predstavlja grafički prikaz diskriminatorne snage modela prikazujući kumulativnu distribuciju poduzetnika koji su u statusu neispunjavanja obveza (defaultirani poduzetnici) u odnosu na kumulativnu distribuciju svih dužnika (rangirani poduzetnici). Sljedeći grafikoni prikazuju CAP krivulje modela za sva tri segmenta za GFI-POD 2022. godinu, po pojedinim segmentima i objedinjeno na razini sustava kreditne procjene prema ostvarenim defaultima tijekom 2023. godine.

Slika 21



6.1.4 Omjer točnosti (Accuracy ratio AR, gini)

Uz CAP krivulju prikazuju se i krivulja idealnog modela i krivulja random modela. Te tri krivulje određuju površine iz kojih se računa AR koeficijent, mjera diskriminatorne snage modela: $AR=B/(A+B)$. Površina ispod ROC krivulje predstavlja AUC, mjeru diskriminatorne snage modela. AUC i AR su međusobno povezani sljedećom relacijom:

$$AR=2*AUC-1 \quad (14)$$

Tablica 6

Segment / godina	Gini koef.	Promjena
LM		
2020	0,8689	
2021	0,9629	↑ 0,0940
2022	0,8996	↓ -0,0632
S		
2020	0,9372	
2021	0,9238	↓ -0,0134
2022	0,7439	↓ -0,1798
M		
2020	0,7362	
2021	0,7376	↑ 0,0013
2022	0,7377	↑ 0,0002
svi		
2021	0,7630	
2022	0,7475	↓ -0,0155

Gini koeficijenti modela za sve segmente, te za segment malih i mikro poduzetnika prema GFI-POD za 2022. godinu i ostvarenim stopama defaulta u 2023. godini imaju izvrsnu diskriminatornu snagu, dok za segment srednjih i velikih ima iznimnu diskriminatornu snagu.

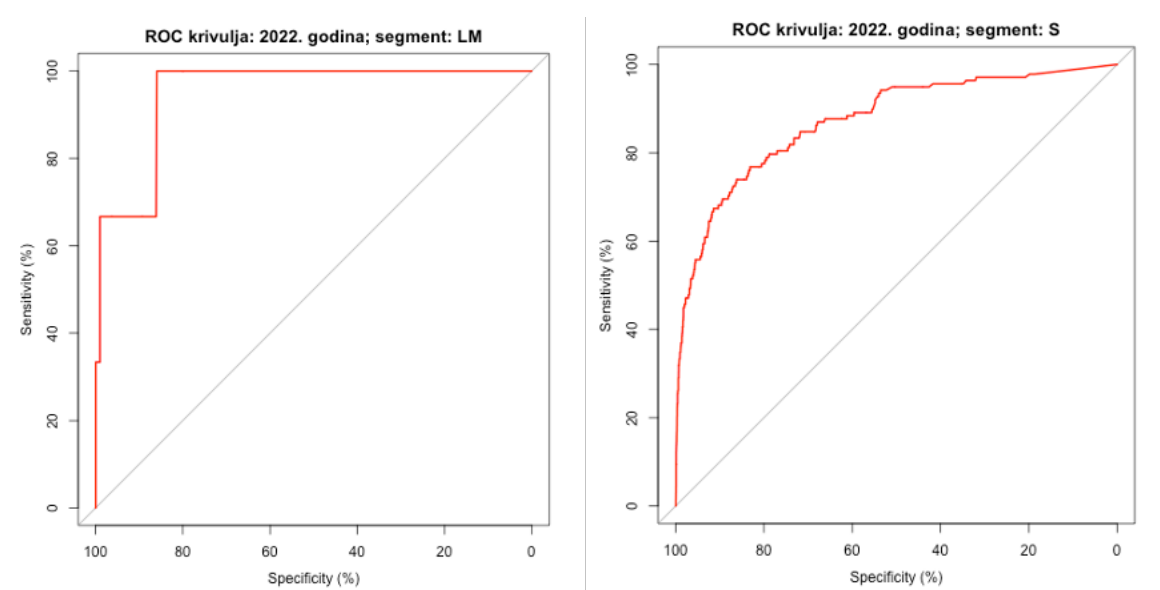
6.1.5 ROC krivulja (Receiver Operating Characteristic)

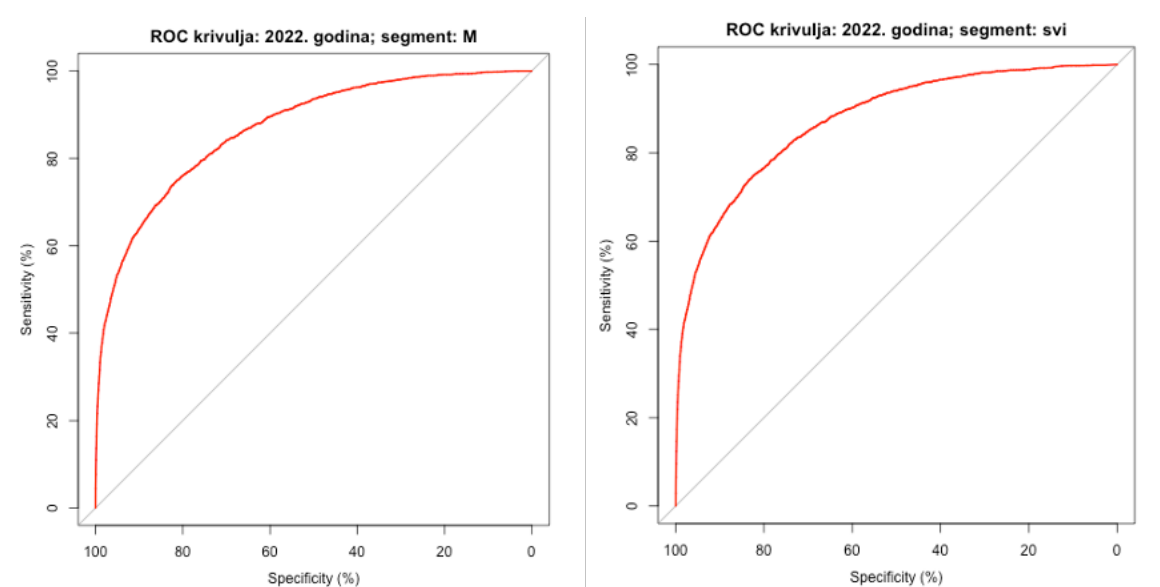
ROC karakteristika je drugi način grafičke prezentacije diskriminatorne snage modela. ROC krivulja prikazuje osjetljivost modela, tj. prikazom udjela dužnika u statusu neispunjavanja obveza (sensitivity, Hit Rate) u odnosu na udio dužnika koji nisu u statusu neispunjavanja obveza ocijenjenih sa S ili lošije (stopa pogrešnog upozorenja, False Alarm Rate) za svaku kategoriju kreditne procjene R_i .

Da bi se diskriminatorna snaga sustava kreditne procjene mogla ocijeniti, potrebno je najprije odrediti razred kreditne procjene koji predstavlja prognozirani status neispunjavanja obveza. Jednako kao i u matrici konfuzije, korišten je razred 12 kao prognoza defaulta poduzetnika.

Na sljedećim su grafikonima (Slika 22) prikazane ROC krivulje modela za sve segmente poduzetnika za godišta GFI-POD 2022. godine (novi podaci).

Slika 22





Na grafikonima je vidljivo da se ROC krivulje, jednako kao i CAP krivulje, modela za sve segmente i ukupno nalaze na izvrsnoj i iznimnoj razini diskriminatorne snage.

6.1.6 Površina ispod ROC krivulje (Area Under Receiver Operating Characteristic AUC)

Površina AUC ispod ROC krivulje uz 95%-tnu pouzdanost ukazuje na visoku prihvatljivu diskriminatornu snagu modela za male poduzetnike.

Tablica 7

Segment / Godina	Area under curve AUROC		Confidence interval CI=95%		
	AUROC	Promjena	AUROC conf. int. low	AUROC conf. int. high	
LM					
2020	0,9344		0,8789	0,9900	
2021	0,9814	↑ 0,0470	0,9540	1,0000	
2022	0,9500	↓ -0,0315	0,8616	1,0000	
S					
2020	0,9686		0,9550	0,9822	
2021	0,9624	↓ -0,0062	0,9428	0,9819	
2022	0,8728	↓ -0,0896	0,8393	0,9062	
M					
2020	0,8681		0,8614	0,8749	
2021	0,8688	↑ 0,0007	0,8617	0,8759	
2022	0,8689	↑ 0,0001	0,8616	0,8761	
svi					
2021	0,8815		0,8751	0,8879	
2022	0,8738	↓ -0,0077	0,8668	0,8807	

6.1.7 Brier score (MSE)

Brierov score predstavlja relativnu mjeru diskriminatorne snage modela, a po svojoj prirodi predstavlja srednju kvadratnu pogrešku (Mean Square Error MSE), tj. kvadrat razlike indikatora nastanka statusa

neispunjavanja obveza ($\theta_i = 1$ za default, 0 u suprotnom slučaju), te odgovarajućih pojedinačnih predviđanja PD-a PD_i , uprosječno za sve poduzetnike N (N ... broj poduzetnika):

$$BS = 1/N * \sum_{i=1}^N (PD_i - \theta_i)^2 \quad (15)$$

Brierov score je unutar raspona 0 i 1 (0%-100%), a niže vrijednosti predstavljaju bolju diskriminatornu sposobnost modela. U praksi se najčešće koriste 10% kao gornja granica prihvatljivosti modela, no usporedba Brierovog scorea s nekom referentnom vrijednošću ukazuje na bolji model: bolji je model sa manjom vrijednošću Brierovog scorea.

Tablica 8

GODINA_TO	MODEL_ID	BS=1/N* $\sum_{i=1}^N (PD_i - \theta_i)^2$	SEMAFOR
2021	LM	0,49%	●
2022	LM	0,39%	●
2021	M	2,43%	●
2022	M	2,15%	●
2021	S	0,88%	●
2022	S	1,08%	●
2021	svi	2,24%	●
2022	svi	2,00%	●

Kalibracija modela temeljem Brierovog scorea za sve segmente je dobra te njegova vrijednost je u svim slučajevima značajno manja od 10%.

6.2 Testovi kalibracije PD modela

6.2.1 Test pojedinačnog razreda (Binomial test)

Pod pretpostavkom neovisnosti događaja nastanka statusa neispunjavanja obveza, binomni test se koristi za ocjenu korektnosti predviđenih PD-eva za pojedinačne kategorije kreditne procjene u jednom vremenskom razdoblju.

U testu je korištena razina pouzdanosti $\alpha=95\%$. Za svaku kategoriju kreditne procjene i modela izračunate su kritične vrijednosti za odabranu razinu pouzdanosti: Inf_i – donja razina i Sup_i – gornja granica testa za ostvarene stope defaulta:

$$Inf_i = \overline{PD}_i - \Phi^{-1}(\alpha) \cdot \sqrt{\frac{\overline{PD}_i \cdot (1 - \overline{PD}_i)}{N_i}} \quad (16)$$

$$Sup_i = \overline{PD}_i + \Phi^{-1}(\alpha) \cdot \sqrt{\frac{\overline{PD}_i \cdot (1 - \overline{PD}_i)}{N_i}} \quad (17)$$

gdje je \overline{PD}_i prosječna procijenjena vrijednost PD-a kategorije i , N_i je ukupan broj poduzetnika u kategoriji i , a Φ^{-1} je inverzna funkcija normalne distribucije za razinu pouzdanosti α , srednju vrijednost 0 i standardnu devijaciju 1. Ako je opažena stopa defaulta manja od kritične vrijednosti Inf_i za $\alpha=95\%$ rezultat testa je žuto, ako je opažena stopa defaulta između kritičnih vrijednosti Inf_i i Sup_i za $\alpha=95\%$,

rezultat testa je zeleno, te ako je opažena stopa defaulta iznad kritične vrijednosti Sup_i za $\alpha=95\%$, test je crveno.

Tablica 9

		Distribucija kreditnih procjena (model: svi, za god.: sve, kalibracija: TTC 2017.-2023.)							Skala kreditnih procjena		PD skala			Binomni test	
Razred	Nmin	Total	Bad	Good	%Total	% Bad	% Good	DR	razred	PD raspor	PD min	PD mean	PDmax	p-value	
1	✗ 20.174	17.612	6	17.606	2,42%	0,00%	2,42%	0,03%	1	0,09%	0,00%	0,03%	0,055%	✓	68,2%
2	✓ 8.887	73.598	57	73.541	10,10%	0,01%	10,09%	0,08%	2	0,10%	0,055%	0,06%	0,15%	✓	95,8%
3	✓ 4.044	95.675	187	95.488	13,13%	0,03%	13,10%	0,20%	3	0,12%	0,15%	0,16%	0,31%	✓	99,6%
4	✓ 2.232	85.530	359	85.171	11,74%	0,05%	11,69%	0,42%	4	0,19%	0,31%	0,32%	0,51%	✓	100,0%
5	✓ 1.373	100.094	689	99.405	13,73%	0,09%	13,64%	0,69%	5	0,31%	0,51%	0,55%	0,82%	✓	100,0%
6	✓ 865	109.369	1.376	107.993	15,01%	0,19%	14,82%	1,26%	6	0,51%	0,82%	0,98%	1,33%	✓	100,0%
7	✓ 544	90.262	1.881	88.381	12,39%	0,26%	12,13%	2,08%	7	0,82%	1,33%	1,68%	2,14%	✓	100,0%
8	✓ 342	65.720	2.130	63.590	9,02%	0,29%	8,73%	3,24%	8	1,32%	2,14%	2,81%	3,46%	✓	100,0%
9	✓ 216	42.590	2.234	40.356	5,84%	0,31%	5,54%	5,25%	9	2,13%	3,46%	4,45%	5,59%	✓	100,0%
10	✓ 138	22.867	1.957	20.910	3,14%	0,27%	2,87%	8,56%	10	3,44%	5,59%	7,01%	9,04%	✓	100,0%
11	✓ 89	9.184	1.480	7.704	1,26%	0,20%	1,06%	16,11%	11	5,56%	9,04%	10,88%	14,60%	✓	100,0%
12	✓ 41	16.255	6.828	9.427	2,23%	0,94%	1,29%	42,01%	12	85,39%	14,60%	37,29%	99,99%	✓	100,0%
Ukupno:		728.756	19.184	709.572	100,00%	2,63%	97,37%	2,63%							

✗ ... p < 1% ! ... p < 5% ✓ ... p ≥ 5%

Temeljem rezultata binomnog testa može se ustvrditi da je sustav kreditne procjene dobro kalibriran.

6.2.2 Test većeg broja razreda

6.2.2.1 Spiegelhalter test

Ako je PD poduzetnika individualno procijenjen, binomni test i Hosmer-Lemeshow test koriste procijenjene srednje vrijednosti kategorija kreditne procjene kao PD koji je dodijeljen svim poduzetnicima u toj kategoriji. Ovi testovi mogu dovesti do određene pristanosti pri izračunu teorijske varijance broja statusa neispunjavanja obveza. Spiegelhalter test zaobilazi taj problem. Jadnako kao prethodna dva testa, Spiegelhalter test pretpostavlja neovisnost statusa neispunjavanja obveza. Spiegelhalter test počiva na Brierovom scoreu, koji se još naziva i Mean Square Error (MSE). Null hipoteza testa H_0 : svi predviđeni PD-evi odgovaraju opaženim bezuvjetnim PD-evima. Očekivana vrijednost MSE uz navedenu hipotezu iznosi:

$$E[MSE] = \frac{1}{N} \sum_{i=1}^N PD_i(1 - PD_i) \quad (18)$$

a njena varijanca:

$$Var[MSE] = \frac{1}{N^2} \sum_{i=1}^N PD_i(1 - PD_i)(1 - 2PD_i)^2 \quad (19)$$

Prema centralnom graničnom teoremu i danim pretpostavkama neovisnosti defaulta, distribucija standardne srednje kvadratne pogreške

$$Z = \frac{MSE - E[MSE]}{\sqrt{Var[MSE]}} \quad (20)$$

je aproksimacija standardne normalne distribucije. Odluka o prihvaćanju/odbacivanju null hipoteze temelji se na p-vrijednosti: što je p-vrijednost bliže 0, null hipoteza se odbacuje.

Model dobro procjenjuje individualne PD-e u prema rezultatima Spiegelhalterova testa kao i HL testa za segmente malih i mikro poduzetnika.

Tablica 10

GODINA_TO	MODEL_ID	Hosmer-Lemeshow		Spiegelhalter test	
		test	p-value	z	p-value
2021	LM	7,45186067	17,4%	-0,51549782	69,7%
2022	LM	10,5280787	43,0%	-0,64362476	74,0%
2021	M	497,11528	100,0%	-44,2012959	100,0%
2022	M	392,403496	100,0%	-44,0491155	100,0%
2021	S	16,5195134	83,1%	-4,54064682	100,0%
2022	S	87,6864176	100,0%	0,091870435	46,3%
2021	svi	492,682633	100,0%	-44,2708938	100,0%
2022	svi	424,511725	100,0%	-43,2131228	100,0%

Model dobro procjenjuje individualne PD-e u prema rezultatima Spiegelhalterova testa kao i HL testa za segmente malih, mikro kao i srednjih i velikih poduzetnika. Gledano u cjelini kao TTC sustav kreditne procjene i njegovu kalibraciju kroz višegodišnje razdoblje (test je proveden na podacima GFI-POD 2016.-2022. i korigiranim stopama defaulta kroz 2017.-2023.), prema rezultatima Hosmer-Lemeshow testa i Spiegelhalterova testa sustav kreditne procjene je dobro kalibriran.

6.3 Testiranje stabilnosti modela

6.3.1 Vremenska stabilnost

System Stability Index (SSI)

Vremenska stabilnost modela najčešće se u praksi testira pomoću SSI indeksa (System Stability Index).

SSI testira u kojoj se mjeri populacija za koju je razvijan sustav kreditne procjene slična trenutnoj populaciji na koju se sustav primjenjuje. Testovi se provode iz godine u godinu. SSI je definiran kao

$$SSI = \sum_{i=1}^n (A - T) * \ln \left(\frac{A}{T} \right) \quad (21)$$

gdje je A distribucija udjela broja poduzetnika po kategorijama kreditne procjene od 1 do n u aktualnoj populaciji, a T je distribucija udjela broja poduzetnika po kategorijama kreditne procjene od 1 do n u testnoj populaciji.

Tablica 11

GODINA	MODEL	SSI
2022	svi	0,0196
2022	LM	0,0322
2022	S	0,0142
2022	M	0,0223

S obzirom na SSI ocijene, modeli za sva tri segmenta i ukupno su stabilni u vremenu (nema značajnih promjena u populaciji).

6.3.2 Stabilnost razreda kreditne procjene (migracijske matrice)


Stabilnost sustava kreditne procjene po razredima kreditne procjene može se ocijeniti pomoću migracijskih matrica. Migracijske matrice je moguće konstruirati nakon što je sustav kreditne procjene u upotrebi minimalno 2 godine, odnosno ako postoje podaci o kreditnim procjenama za najmanje 2 godine. Analiza je temeljena na godišnjim migracijskim matricama. Poželjna svojstva migracijskih matrica su:

- stope migracija u status neispunjavanja obveza trebaju biti u rastućem redosljedu prema lošijim kategorijama kreditne procjene
- visoke stope moraju biti na dijagonali, a niske izvan dijagonale što upućuje da su kreditne procjene stabilne u vremenu.
- stope migracija trebale bi biti u padajućem redosljedu s većom udaljenošću od dijagonale.

Ova svojstva trebala bi biti stabilna i za migracije u većim vremenskim razdobljima od jednogodišnjih, što znači da se kreditne procjene mijenjaju kroz vrijeme, ali bez velikih skokova kroz kategorije. U slučajevima kada dodjela kreditne procjene dominantno ovisi o karakteristikama poduzetnika, kreditne procjene se sporo mijenjaju jer nisu osjetljive na kreditne cikluse. Stoga je stabilnost tranzicijskih matrica indikator analitičkog procesa koji je usmjeren na karakteristike poduzetnika i time je prediktivan za poduzetnika.

Test stabilnosti razreda kreditne procjene najčešće se u praksi provodi pomoću jednogodišnjih migracijskih matrica razreda kreditne procjene. Migracijske matrice (stope) kreditnih procjena (migracije prema GFI-POD od 2017./2018. do 2021./2022. godine) su prikazane na sljedećem prikazu.

Slika 23



Tablica 12

godina	-11	-10	-9	-8	-7	-6	-5	-4	-3	-2	-1	0	+1	+2	+3	+4	+5	+6	+7	+8	+9	+10	+11	+12
2019	0,0%	0,0%	0,0%	0,1%	0,2%	0,5%	1,1%	2,6%	5,2%	9,9%	17,6%	28,8%	16,3%	7,6%	4,2%	2,3%	1,4%	1,0%	0,7%	0,3%	0,2%	0,1%	0,0%	0,0%
2020	0,0%	0,0%	0,0%	0,1%	0,2%	0,4%	1,0%	2,3%	4,9%	9,2%	16,8%	28,0%	17,2%	8,7%	4,8%	2,5%	1,6%	1,1%	0,6%	0,3%	0,2%	0,1%	0,0%	0,0%
2021	0,0%	0,0%	0,0%	0,1%	0,2%	0,5%	1,2%	2,7%	5,9%	10,6%	18,8%	28,0%	15,5%	7,0%	3,9%	2,1%	1,4%	1,0%	0,6%	0,3%	0,2%	0,1%	0,0%	0,0%
2022	0,0%	0,0%	0,0%	0,1%	0,2%	0,5%	1,2%	2,8%	5,8%	11,1%	20,1%	28,7%	14,6%	6,2%	3,3%	1,8%	1,2%	0,9%	0,7%	0,3%	0,2%	0,1%	0,0%	0,0%
LM Avg	0,0%	0,0%	0,0%	0,1%	0,2%	0,5%	1,1%	2,7%	5,4%	10,2%	18,2%	28,4%	15,9%	7,4%	4,0%	2,2%	1,4%	1,0%	0,6%	0,3%	0,2%	0,1%	0,0%	0,0%
α=95%	0,5%	0,5%	0,5%	0,5%	0,7%	1,0%	1,6%	3,1%	5,9%	10,6%	18,6%	28,8%	16,3%	7,9%	4,5%	2,7%	1,9%	1,4%	1,1%	0,8%	0,6%	0,6%	0,5%	0,5%
ΔR	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●

Sva tri modela pokazuju dobru stabilnost razreda kreditne procjene. Stabilnost unutar ± 1 razreda zadržava oko 62% poduzetnika.

7 Rekapitulacija kvantitativnih validacijskih testova

Transformacije varijabli u kombinaciji sa biheviornim varijablama te ponovna procjena parametara PD modela poduzetnika rezultirala je značajnim poboljšanjem karakteristika modela. Rekapitulacija rezultata provedenih kvantitativnih testova prikazana je na sljedećoj tablici:

Tablica 13

Kvantitativna validacija (TTC)	LM	S	M	Ukupno
Preciznost klasifikacije modela	●	●	●	●
Distribucija frekvencije dobrih i loših s obzirom na klasu kreditne procjene	●	●	●	●
Tablica kontigencije (Confusion matrix)	●	●	●	●
Diskriminatorna snaga sustava kreditne procjene	●	●	●	●
Krivulja snage (CAP)	●	●	●	●
Omjer točnosti (Accuracy ratio AR, gini)	●	●	●	●
ROC krivulja (Receiver Operating Characteristic)	●	●	●	●
Površina ispod ROC krivulje (Area Under Receiver Operating Characteristic AUC)	●	●	●	●
Kalibracija PD modela	●	●	●	●
Test pojedinačnog razreda (Binomial test)	●	●	●	●
Test većeg broja razreda	●	●	●	●
Brier score (MSE)	●	●	●	●
Hosmer-Lemeshow test	●	●	●	●
Spiegelhalter test	●	●	●	●
Testiranje stabilnosti modela	●	●	●	●
Stabilnost razreda kreditne procjene (migracijske matrice)	●	●	●	●
Vremenska stabilnost	●	●	●	●
SSI	●	●	●	●
Promjene razreda kreditne procjene	●	●	●	●
Ukupno	●	●	●	●

Skala kreditne procjene tijekom validacije provedene u 2024. godini nije mijenjana jer su kalibracijski testovi pokazali adekvatnost postojeće skale kreditne procjene. Povećane koncentracije poduzetnika u razredima 1 i 2 ublažene su dodavanjem marže konzervativnosti pri rekalkibraciji PD-a. Postignuti su izvrsni rezultati binomnih testova po kategorijama kreditne procjene nakon rekalkibracije. Rekalkibracija PD-a poboljšava rezultate binomnih testova u 2023. godini (za GFI-POD 2022.) za TTC, a za PIT kalibraciju prema procijenjenim stopama DR za 2024., te nema očiglednih zapreka da se PIT model koristi za 2024./2025. godinu temeljem modelskih procjena očekivanih stopa defaulta za kalibraciju PIT PD-a prema temeljnom i šok scenariju. Testovi preciznosti klasifikacije i testovi stabilnosti sustava kreditne procjene daju izvrsne rezultate.

Testovi kalibracije pokazuju da je model dobro kalibriran za sve segmente. Ostali testovi, preciznost klasifikacije i stabilnost modela i dalje su zadržani na visokoj razini, uz nešto niže ocijene u dijelu stabilnosti LM segmenta, no zadovoljavajuće na razini cijelog sustava.

8 Kvalitativna validacija sustava kreditne procjene

Prva sveobuhvatna kvalitativna validacija sustava kreditne procjene napravljena je 2015. godine. Revizija u sklopu kvalitativne validacije scoring modela bila je usmjerena na reviziju razvoja scoring modela i dokumentiranosti razvoja, pregleda korištenih metoda, teorijskih razmatranja i kriterija za odabir metode, korištenih pretpostavki i provedenih testova učinkovitosti. Cilj revizije bio je potvrda usklađenosti metodologije i procesa razvoja sustava kreditne procjene sa Basel III smjernicama. Preduvjet za provedbu revizije je isporuka i uvid u razvojni uzorak (development sample), testne i validacijske uzorke (out-of sample i out-of time) na kojima je provedeno testiranje modela u fazi razvoja i produkcijske podatke (production data) koji su rezultat primjene sustava kreditne procjene u poslovanju sa poznatim ishodom statusa neispunjavanja obveza unutar vremenskog horizonta na koji se odnosi kreditna procjena, te pripadajuća dokumentacija kao i rezultati provedenih testova i primjenjenih kriterija za prihvaćanje/odbacivanje rezultata testova.

U dijelu kvalitativne validacije provela se i revizija informatičke tehnologije procesa izračuna kreditne procjene, korištenja, kontrole kvalitete podataka, korporativnog upravljanja, validacije internih procjena i stresno testiranje. Preduvjet za provedbu revizije bio je uvid u funkcioniranje i organizaciju IT sustava i sustava ovlaštenja u dijelu sustava kreditne procjene, proces prikupljanja i kontrole podataka, izvještaje temeljene na izračunatim kreditnim procjenama i sustav kontrole procesa dodjele kreditne procjene i kvalitete podataka, poznavanje filozofije kreditne procjene (know-how) te uvid u pripadajuću dokumentaciju sustava kreditne procjene i dijelove programskog koda za izračun kreditne procjene.

Područja revizije kvalitativne validacije bila su:

- Kvalitativna validacija sustava kreditne procjene
 - (1) Revizija dokumentacije sustava kreditne procjene
 - (2) Definicija statusa neispunjavanja obveza (defaulta) i usklađenost sa Basel III smjernicama
 - (3) Revizija razvoja scoring modela
 - Struktura sustava kreditne procjene
 - Egzogene varijable modela
 - Vremenski horizont
 - Karakteristike PD modela
 - (4) IT i kontrola kvalitete podataka
 - (5) Revizija procesa dodjele kreditne procjene
 - (6) Upotreba modela i izvještavanje
 - (7) Revizija procesa upravljanja podacima

Posljednja kvalitativna validacija sustava kreditne procjene napravljena je 2023. godine. U sklopu kvalitativne validacije sustava kreditne procjene, napravljena je opsežna kontrola kvalitete podataka, IT sustava i procesa dodjele kreditne procjene te cjelovitosti dokumentacije sustava kreditne procjene.

Tablica 14

Kvalitativna validacija	LM	S	M	Ukupno
Revizija IT sustava i procesa dodjele kreditne procjene				●
Kontrola kvalitete podataka	●	●	●	●
Kontrola cjelovitosti dokumentacije sustava				●
Ukupno				●

Rezultati kvalitativne revizije sustava kreditne procjene za 2021./2022. godinu potvrđuju da je sustav kreditne procjene (logit) usklađen s Basel III smjernicama.

FINA kontinuirano nadgleda učinkovitost i robusnost PD modela i sustava kreditne procjene u cjelini kroz redovite godišnje kvantitativne validacije sustava te minimalno jednom u dvije godine kvalitativnim provjerama funkcioniranja sustava i procesa dodjele kreditne procjene. Svaki nalaz revizije otklanja se u najkraćim mogućim rokovima prema određenoj hitnosti i mogućim učincima na funkcioniranje i kvalitetu sustava kreditne procjene. Parametri PD modela redovito se provjeravaju, a pouzdanost procjena osigurava se redovitom jednogodišnjom kalibracijom sustava. Izvorni podaci za određivanje kreditne procjene prikupljeni direktno od poslovnih subjekata jamstvo su kvalitete podataka i njihove pouzdanosti što omogućava kvalitetnije procjene svih faktora rizika koji proizlaze iz financijskih i bihevioralnih podataka poduzetnika.

Prva kvalitativna validacija ML.PD sustava kreditne procjene je napravljena tijekom 2023. godine.

9 Pravila za korekciju modelski izračunate kreditne procjene

Izračunati podaci o TTC PD-u i kreditnoj procjeni temeljeni su na statističkoj (modelskoj) procjeni vjerojatnosti defaulta poduzetnika. Iako statistički model uključuje i podatak o maksimalnom broju dana u blokadi poduzetnika tijekom proteklih 6 mjeseci, statistički gledano, njihov je marginalni doprinos na povećanje vjerojatnosti defaulta malen, osobito kada je broj dana u blokadi mali. Ipak, takvi poduzetnici imaju povećani rizik da ostanu u blokadi dovoljno dugo da dođu u status defaulta (u blokadi iznad 90 dana za iznose iznad praga materijalne značajnosti).

Zbog poželjne konzervativnosti sustava kreditne procjene i percepcije korisnika kreditne procjene, u sustav su uvedena određena pravila prema kojima se, primjerice, poduzetnicima koji uđu u status blokade automatski korigira razred kreditne procjene za jedan razred niže od statistički izračunatog razreda (izuzev razreda 12 i lošijih, odnosno C3, D1, D2 i D3 koji se ne korigiraju temeljem statusa o blokadi, već samo temeljem stupanja u default, odnosno izlaska iz defaulta). Kreditna procjena se također automatski korigira i u slučajevima pokretanja predstečajnog, stečajnog ili likvidacijskog postupka te u slučaju kontinuirane blokade duže od 90 dana za materijalno značajni iznos (događaji stupanja u default).

Automatska korekcija kreditne procjene provodi se za sve poduzetnike u slučaju nastanka događaja koji pokreću korekciju temeljem unaprijed definiranih pravila (poput događaja promjenestatusa blokade, pokretanja predstečajnog, stečajnog ili likvidacijskog postupka). U slučaju nastupanja blokade, korigira se razred kreditne procjene za jedan razred niže od statistički izračunatog razreda (izuzev razreda 12 i lošijih, odnosno C3, D1, D2 i D3 koji se ne korigiraju), npr. iz A2 u A3, iz A3 u B1... itd.

Korekcija je jednokratna i izvršava se automatizmom drugog dana blokade neovisno o materijalnoj značajnosti iznosa zbog kojega je blokiran i vrijedi sve dok je poduzetnik u blokadi. U slučaju da se blokada produži dulje od 90 dana u kontinuitetu po materijalno značajnoj obvezi, poduzetniku se dodjeljuje razred kreditne procjene 13 (D1) koji označava default i primjenjuju se pravila za izlazak iz defaulta (vidi 2.1.). U slučaju da nakon 90 dana iznos zbog kojega je poduzetnik blokiran ne premašuje prag materijalne značajnosti, poduzetniku se ne dodjeljuje razred kreditne procjene D1, već se nastavlja pravilo za korekciju kreditne procjene za poduzetnike u blokadi.

Ako je za vrijeme trajanja blokade kraćem od 90 dana u kontinuitetu ili tijekom urednog poslovanja (što obično nije slučaj), pokrenut postupak predstečajne nagodbe, ili stečajni ili slični postupak, poduzetniku se automatizmom dodjeljuje razred kreditne procjene 14 (D2), a pokretanjem likvidacijskog postupka, poduzetniku se dodjeljuje razred 15 (D3). Vrijede ranije navedena pravila za izlazak iz defaulta (vidi 2.1.).

Korekcija kreditne procjene ekspertnom procjenom i upotrebom pravila je usklađena i preporučena Basel III smjernicama.