

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

ver. 4.3

Financijska agencija
Ulica grada Vukovara 70
Zagreb

Zagreb, svibanj 2026.

Izrada dokumenta

Atribut	Vrijednost
Autorska prava	Financijska agencija
Tajnost dokumenta	Za javnu objavu
Datum izrade	16.09.2018.
Datum posljednje revizije (v4.3)	18.05.2026.

Revizija dokumenta

Verzija	Datum	Opis / promjena	Vlasnik
1.0	16.09.2018.	Izrada dokumenta	FINA
2.1	19.11.2019.	Nadopuna ekspertnom korekcijom kreditne procjene zbog dana blokade, defaulta i izlaska iz defaulta; ažuriranje tablica i grafikona prema rezultatima validacije 2019.	FINA
2.2	31.12.2019.	Nadopuna MSFI 9 kreditnom procjenom (PIT PD)	FINA
3.0	21.07.2022.	Metodološka izmjena sustava kreditne procjene: prelazak na model dubokog strojnog učenja (ML.PD)	FINA
4.0	29.10.2025.	Reestimacija ML.PD modela uz uvođenje ograničenja na monotonost funkcije rizika za odabrane pokazatelje	FINA
4.3	18.05.2026.	Reestimacija modela na verziju v4.3 s dosljednim ograničenjima monotonosti; uvođenje nove skale kreditne procjene MSnova 4.3.18 (15 razreda za neprihodujuće poduzetnike + 3 razreda defaulta, logaritamski raspoređene granice); ažurirana centralna tendencija TTC za razdoblje 2017.–2025.; ažurirana pravila ekspertne korekcije P1–P6.	FINA

Sadržaj

1	Uvod	4
2	Definicija statusa neispunjavanja obveza (default)	5
2.1	Izlazak iz defaulta	5
3	Odabir uzorka i područja pokazatelja modela	6
3.1	Priprema uzorka	6
3.2	Područja financijskih pokazatelja	7
3.3	Razvoj PD modela metodom strojnog učenja.....	8
3.3.1	Metodološki pristup (XGBoost s monotonim ograničenjima)	8
3.3.2	Postupak treniranja i odabira modela (grid search)	9
3.3.3	Inicijalna kalibracija	9
3.4	Dizajn i sastav modela po segmentu	10
3.4.1	Segment M — PD.M_v4.3.....	10
3.4.2	Segment S — PD.S_v4.3	10
3.4.3	Segment LM — PD.LM_v4.3.....	10
3.4.4	Diskriminatorna snaga na neviđenim podacima (OOT)	11
4	Centralna tendencija (TTC kalibracija)	12
5	Kalibracija skale kreditne procjene (MSnova 4.3.18)	13
6	Kvantitativna validacija ML.PD sustava.....	16
6.1	Preciznost klasifikacije	16
6.1.1	Distribucija frekvencije dobrih i loših	16
6.1.2	Tablica kontingencije (confusion matrix).....	18
6.1.3	CAP krivulja (Cumulative Accuracy Profile)	19
6.1.4	Gini koeficijent (Accuracy Ratio)	22
6.1.5	ROC krivulja i AUROC.....	23
6.2	Testovi kalibracije.....	23
6.2.1	Binomni test (test pojedinačnog razreda).....	23
6.2.2	Spiegelhalterov z-test	23
6.2.3	Brier score	24
6.3	Testovi stabilnosti.....	25
6.3.1	Vremenska stabilnost sustava (SSI).....	25
6.3.2	Stabilnost razreda (migracijske matrice)	25
7	Rekapitulacija kvantitativnih kalibracijskih i validacijskih testova	29
8	Pravila ekspertne korekcije kreditne procjene.....	31

1 Uvod

Financijska agencija (dalje: FINA) je 2010. godine razvila prvu verziju metodologije za izračun kreditne procjene poduzetnika, temeljene na procjeni vjerojatnosti nastupanja statusa neispunjavanja obveza (eng. Probability of Default, PD) kao osnovnog faktora rizika. Razvoj modela i inicijalna validacija učinkovitosti modela temeljili su se na godišnjim financijskim izvještajima poduzetnika (GFI-POD) iz razdoblja 2003.–2008. i promatranom ishodu u godini koja je slijedila nakon financijskog izvještaja (jednogodišnji PD). Rezultat modela iskazuje procjenu rizika u vremenskoj točki (Point-in-Time; PIT).

Tijekom 2015. i 2016. godine napravljena je opsežna kvalitativna i kvantitativna validacija sustava kreditne procjene u skladu s Basel III smjernicama. Nalazi validacije doveli su do redizajna PD modela i uvođenja bihevioralnih pokazatelja (blokade računa). Prva ‘moderna’ metodologija za izračun kreditne procjene FINA-e u primjeni je od 2017. godine, s dijelom sustava iskazanog i prema MSFI 9 standardu financijskog izvještavanja (PIT model).

U srpnju 2022. godine FINA je uvela novi sustav kreditne procjene temeljen na dubokom strojnom učenju pod nazivom ML.PD. Algoritmi strojnog učenja daju bolju diskriminatornu snagu i kalibraciju od klasične logističke regresije, ponajviše zbog sposobnosti modeliranja nelinearnosti i interakcija između pokazatelja bez potrebe za eksplicitnom transformacijom varijabli.

U listopadu 2025. FINA je pustila u primjenu verziju v4.0 s uvedenim linearnim ograničenjima na monotonost funkcije rizika za odabrane financijske pokazatelje. Dosadašnja primjena neograničenih (nelineariziranih) modela pokazala je u pojedinim slučajevima anomalije u kojima procjena rizika nije odgovarala ekonomskim očekivanjima. Uvođenje ograničenja monotonosti otklonilo je ta odstupanja bez značajnog gubitka diskriminatorne snage.

U svibnju 2026. FINA je pustila u primjenu verziju v4.3 sustava koja obuhvaća:

- dosljednu i sveobuhvatnu reestimaciju sva tri segmentna modela (M — mikro, S — mali, LM — srednji i veliki poduzetnici) uz striktno primijenjena ograničenja monotonosti;
- uvođenje nove skale kreditne procjene pod nazivom MSnova 4.3.18 s ukupno 18 razreda — 15 razreda za poduzetnike koji nisu u dugotrajnoj blokadi (A1 do C3) i 3 dodatna razreda za poduzetnike u statusu neispunjavanja obveza (D1, D2, D3);
- ažuriranu centralnu tendenciju (TTC) kalibracije, koja obuhvaća razdoblje 2017.–2025. i time uključuje kompletan ekonomski ciklus posljednjeg desetljeća uključivo s COVID krizom i post-krizom energetske šokove 2022./2023.;
- ažurirana pravila ekspertne korekcije kreditne procjene (P1–P6), usklađena s aktualnim regulatornim i tržišnim promjenama.

Ovaj dokument opisuje metodološku podlogu ML.PD sustava kreditne procjene na razini prikladnoj za javnu objavu. Detaljni tehnički dokumenti (razvoj modela, tehnička specifikacija, izvješća o kalibraciji i validaciji) čuvaju se interno u FINA-i i dostupni su nadzornim tijelima i revizorima na uvid.

Napomena: proizvodi i usluge FINA-e nisu klasificirani kao 'kreditni rejting' u smislu Uredbe (EZ) br. 1060/2009 (CRA Regulation). FINA nije registrirana kao bonitetna agencija i nije pod nadzorom Europskog nadzornog tijela za vrijednosne papire i tržišta (ESMA). Kreditna procjena FINA-e ne bi se trebala smatrati ekvivalentom reguliranom kreditnom rejtingu i nije namijenjena korištenju u regulatorne svrhe.

2 Definicija statusa neispunjavanja obveza (default)

Definicija statusa neispunjavanja obveza, odnosno defaulta, ispada ili zastoja u plaćanju, predstavlja polazište za izgradnju sustava kreditne procjene i razvoj prediktivnih modela za procjenu kreditnog rizika. Definicija je usklađena s Baselom III i hrvatskom regulativom kreditnih institucija.

Baselska definicija statusa neispunjavanja obveza u kontekstu izloženosti kreditnom riziku određuje dva osnovna kriterija:

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

Prag materijalne značajnosti dospjelih obveza iznosi 250,00 EUR sukladno članku 18. stavak 9. Odluke o klasifikaciji plasmana i izvanbilančnih obveza kreditnih institucija HNB-a. Za praćenje statusa defaulta u sustavu kreditne procjene FINA-e koristi se podatak o kontinuiranim blokadama poslovnih računa iz Registra insolventnosti FINA-e.

U ML.PD sustavu razlikuju se tri tipa default događaja:

Oznaka	Naziv	Kriterij
D1	Blokada računa	Kontinuirana blokada računa duža od 90 dana za materijalno značajan iznos (> 250 EUR) u razdoblju od 6 mjeseci prije datuma izračuna kreditne procjene.
D2	Predstečaj / stečaj	Pokretanje predstečajnog, stečajnog ili sličnog postupka.
D3	Likvidacija	Pokretanje likvidacijskog postupka.

U observacijskom razdoblju, nastanak barem jednog default događaja tijekom promatranog razdoblja rezultira konačnim statusom defaulta (DF_T1 = 1), neovisno o eventualnom oporavku i urednom poslovanju kasnije u razdoblju.

Za procjenu parametara PD modela primjenjuje se razdoblje oporavka od 6 mjeseci (2 kvartala) te navedeni prag materijalne značajnosti od 250 EUR.

2.1 Izlazak iz defaulta

Razdoblje oporavka nije regulatorno propisano, već se određuje sukladno uobičajenoj poslovnoj praksi. Kako bi se izbjegle prevelike oscilacije promjene statusa defaulta i urednog poslovanja te dodatno isključili utjecaji sezonalnosti, razdoblje oporavka je određeno u trajanju od 6 mjeseci

unutar kojeg poduzetnik mora uredno podmirivati svoje obveze da bi se moglo smatrati da se oporavio od zadnjeg default događaja.

Izlazak iz statusa defaulta moguć je nakon isteka razdoblja oporavka, uz uvjet da od trenutka izlaska iz blokade ili iz postupka predstečajne nagodbe u razdoblju oporavka nije bilo novih materijalno značajnih blokada dužih od 90 dana, prijelaza iz predstečaja u stečaj ili likvidaciju.

Poduzetnici koji su tijekom stečajnog postupka stabilizirali svoje poslovanje mogu izaći iz statusa D2 nakon isteka razdoblja oporavka od trenutka sklapanja stečajnog sporazuma i deblokade računa (kasniji od ta dva).

Izlazak iz statusa D3 nije moguć jer likvidacija predstavlja trajni prestanak poslovanja poduzetnika.

3 Odabir uzorka i područja pokazatelja modela

3.1 Priprema uzorka

Razvojni uzorak za reestimaciju verzije v4.3 obuhvaća sve pravne osobe koje su u razdoblju 2016.–2023. redovito predavale GFI-POD obrasce, s praćenim ishodom (default DF_T1) u sljedećoj godini. Iz uzorka su isključeni poduzetnici koji ne zadovoljavaju uvjete za izračun kreditne procjene:

- neaktivni poduzetnici (status ‘neaktivan’ ili ‘najava brisanja’);
- poduzetnici koji nemaju otvoren poslovni račun u Republici Hrvatskoj;
- poduzetnici s ukupnom aktivom ili poslovnim prihodima nižim od 1.000 EUR;
- poduzetnici koji ne poštuju računovodstveno načelo istinitosti (identični podaci u GFI-u za više godina);
- poduzetnici koji su na početku observacijskog razdoblja u kontinuiranom stečajnom ili likvidacijskom postupku (isključeni iz procjene, ali obuhvaćeni ekspertnim pravilima).

Kao out-of-time uzorak za testiranje generalizacijskih svojstava modela zadržani su podaci iz razdoblja 2024.–2025., koji nisu korišteni u treningu modela.

Poduzetnici su segmentirani u tri veličinska razreda prema kombinaciji ukupne imovine, poslovnih prihoda i broja zaposlenih:

Segment	Naziv	Opis
M	Mikro	Poduzetnici manje veličine s tipičnom aktivom do 1 milijun EUR; najbrojnija populacija u razvojnem uzorku.
S	Mali	Poduzetnici srednje-manje veličine, s aktivom u rasponu tipično 1 do 20 milijuna EUR.
LM	Srednji + veliki	Poduzetnici veće veličine, obuhvaća srednje i velike prema klasifikaciji iz Zakona o računovodstvu.

Za svaki segment razvija se zaseban PD model. Odabir segmenta poduzetnika za izračun kreditne procjene provodi se prema kriterijima veličine na temelju zadnjeg dostupnog GFI izvještaja.

3.2 Područja financijskih pokazatelja

Ulazni pokazatelji modela pokrivaju sljedeća područja financijske analize. Pojedinačni pokazatelji označavaju se internim oznakama tipa RN..., POK_..., BV_... i sl. Puni popis pokazatelja i njihove formule izračuna iz GFI-POD obrasca čuvaju se u internoj tehničkoj specifikaciji modela.

Blokade poslovnih računa — bihevioristički pokazatelji povezani s trajanjem i iznosom blokada računa u prethodnoj godini. Uključuju maksimalni broj dana u kontinuiranoj blokadi i maksimalni blokirani iznos u prethodnoj godini. Nisu istovremeno okidač defaulta — okidač defaulta je blokada na dan izračuna, a ovi pokazatelji hvataju povijesnu ‘nesposobnost’ podmirivanja obveza.

Zaduženost — pokazatelji strukture financijskih obveza: udjela kratkoročnih i dugoročnih kredita u aktivni, faktora zaduženosti, sposobnosti servisiranja duga, pokrića kamatnih rashoda i pokazatelja prezaduženosti.

Likvidnost — pokazatelji sposobnosti podmirivanja kratkoročnih obveza: koeficijent ubrzane likvidnosti, koeficijent financijske stabilnosti, kao i statistički bankrotni pokazatelji (Altmanov Z-score, Zmijewski Z-score u modificiranim varijantama za hrvatsko tržište).

Aktivnost — pokazatelji obrtaja aktive, potraživanja, dobavljača i kapitala; pokazatelji trajanja naplate potraživanja u danima i dana plaćanja dobavljača; dinamički pokazatelji promjena glavnih bilančnih pozicija (aktive, dugotrajne imovine, kratkoročnih obveza).

Profitabilnost — pokazatelji profita iz redovnog poslovanja, rentabilnosti imovine (ROA), EBITDA marže, povrata na aktivu.

Ekonomičnost — pokazatelji odnosa ukupnih prihoda i rashoda, produktivnosti (troškovi osoblja u odnosu na prihode), kapitalnih ulaganja u imovinu (zamjenski CAPEX).

Dinamika (godišnje promjene) — izvedeni pokazatelji ‘_PP’ sufixom (‘promjena prema prethodnoj godini’) koji hvataju trend pogoršanja ili poboljšanja poslovanja. Godišnje promjene su ključne u ranom otkrivanju rizika s obzirom na to da apsolutna razina pokazatelja može biti prihvatljiva, dok trend može signalizirati rastući rizik.

GFI-POD pokazatelji — pokazatelji iz GFI-POD obrasca koji nisu klasični financijski pokazatelji (npr. promjena broja zaposlenih temeljem sati rada).

Ekspertni indikatori (binarni) — binarni pokazatelji koji signaliziraju nastupanje stečajnih razloga ili drugih negativnih događaja bitnih za procjenu rizika: indikator prezaduženosti, indikator gubitka iznad polovine temeljnog kapitala, indikator negativnog radnog kapitala.

Broj odabranih varijabli po segmentu razlikuje se ovisno o dostupnoj količini podataka i kompleksnosti signala rizika. Za M segment koristi se najveći broj varijabli (najveći raspoloživi

razvojni uzorak), a za LM segment najmanji zbog ograničene veličine populacije velikih poduzetnika u Hrvatskoj.

Segment	Broj varijabli u modelu	Napomena
M (mikro)	20	Uključuje 2 ekspertna binarna indikatora (prezaduženost, negativan kapital)
S (mali)	20	Uključuje 2 ekspertna binarna indikatora
LM (srednji + veliki)	10	Manji broj varijabli zbog ograničene veličine populacije

3.3 Razvoj PD modela metodom strojnog učenja

3.3.1 Metodološki pristup (XGBoost s monotonim ograničenjima)

PD model razvijen je metodom gradient boostinga na stablima odluke, konkretno primjenom XGBoost algoritma. Ovaj pristup pripada obitelji metoda dubokog strojnog učenja i ima sljedeće prednosti u odnosu na klasičnu logističku regresiju koja je u ranijim verzijama sustava (do 2022.) bila metodološka osnova:

- prirodno modeliranje nelinearnosti u odnosu procjene rizika i vrijednosti pokazatelja bez potrebe za eksplicitnom transformacijom (WoE);
- prirodno modeliranje interakcija između pokazatelja (npr. kombinacija visoke zaduženosti i niske profitabilnosti);
- veća robusnost prema nedostajućim vrijednostima (XGBoost sam raspoređuje NA vrijednosti u 'bolju' granu stabla);
- robusnost prema ekstremnim vrijednostima (outlierima) pokazatelja;
- iterativno učenje na greškama prethodnih stabala (boosting), što daje bolju diskriminatornu snagu;
- mogućnost nametanja poslovno smislenih ograničenja na oblik funkcije rizika (monotonost).

Novost u verzijama v4.0 i v4.3 u odnosu na inicijalnu ML.PD implementaciju iz 2022. je uvođenje linearnih ograničenja na monotonost ovisnosti procjene rizika (PD) o ulaznim financijskim pokazateljima za koje ekonomski smisao nedvosmisleno definira smjer utjecaja.

Za svaki pokazatelj u modelu definiran je jedan od tri smjera monotonosti:

- 'manje je bolje' — porast vrijednosti pokazatelja povećava procjenu rizika (primjer: pokazatelji zaduženosti, blokada, negativna dinamika aktive);
- 'više je bolje' — porast vrijednosti pokazatelja smanjuje procjenu rizika (primjer: pokazatelji profitabilnosti, likvidnosti, ekonomičnosti);
- 'uvjetno' — smjer ovisnosti nije apriori određen jer pokazatelj može biti dvosmisleno interpretiran (npr. kratkotrajna imovina u aktivni može biti i pozitivan i negativan signal ovisno o kontekstu).

Cilj ovih ograničenja je otklanjanje pojedinačnih anomalija u procjeni rizika kod ekstremnih ili rijetkih kombinacija vrijednosti pokazatelja koje su bile primijećene u ranijim, neograničenim verzijama modela. Ekonomska ispravnost ponašanja modela time je zajamčena bez značajnog gubitka diskriminatorne snage.

3.3.2 Postupak treniranja i odabira modela (grid search)

Odabir finalnog modela za svaki segment provodi se automatiziranim postupkom pretraživanja hiperparametara (grid search) s per-godišnjom validacijom. Pretraživanjem se prolazi kroz kombinacije glavnih hiperparametara XGBoost algoritma (dubina stabala, stopa učenja, broj iteracija, L2 regularizacija, subsample). Za svaku kombinaciju izračunava se prosječni Gini po godinama i njegova standardna devijacija po godinama.

Konačni skor svakog kandidat-modela je definiran kao:

$$\text{skor} = \text{srednji Gini (po godinama)} - \lambda_{SD} \times \text{st. devijacija Gini (po godinama)} - \lambda_N \times \text{broj varijabli}$$

Kazna za vremensku nestabilnost (λ_{SD}) i za pretjeran broj varijabli (λ_N) osigurava odabir modela koji je: (1) stabilan kroz vrijeme (godine); (2) što jednostavniji uz očuvanje diskriminatorne snage; (3) parsimonijski u smislu izbjegavanja overfittinga.

Prije treniranja provodi se automatski postupak čišćenja skupa varijabli:

- izbacivanje varijabli s previše nedostajućih vrijednosti (> 80 % NA);
- izbacivanje varijabli s dominantnom vrijednošću (> 95 % istih vrijednosti — konstantnih);
- izbacivanje varijabli s niskom Information Value ($IV < 0,02$);
- izbacivanje visokokoreliranih parova varijabli ($|\text{Spearman } \rho| > 0,75$) — zadržava se varijabla s višim IV;
- izuzeće od izbacivanja: obavezno se zadržavaju bihevioralni pokazatelji blokade i ekspertni binarni indikatori neovisno o IV-u i korelaciji.

3.3.3 Inicijalna kalibracija

Nakon što je model naučen na razvojnom uzorku, njegov ‘sirovi’ izlaz je nekalibrirani PD u rasponu od 0 do 1 (izračunat iz logita sume koraka boostinga). Za pretvorbu u kalibrirane vrijednosti PD-a koje odgovaraju stvarnoj vjerojatnosti defaulta koristi se dvokorakni postupak:

- ‘sirovi’ PD iz modela postavlja se na skalu tako da srednja vrijednost PD-a na razvojnom uzorku odgovara opaženoj stopi defaulta razvojnog uzorka po segmentu;
- nakon toga primjenjuje se Bayesovo rebaziranje na centralnu tendenciju TTC (dugoročna prosječna DR) za segment (detaljno u poglavlju 4).

3.4 Dizajn i sastav modela po segmentu

3.4.1 Segment M – PD.M_v4.3

Model za segment mikro poduzetnika je najveći po broju varijabli (20 + 2 indikatora za ekspertnu korekciju) i po broju iteracija boostinga zbog najveće veličine razvojnog uzorka. Struktura varijabli po području financijske analize:

Područje	Broj pokazatelja	Napomena
Blokade	2	Bihevioralni pokazatelj i pokazatelj iznosa blokade
Zaduženost	5	Pokazatelji kredita, faktor zaduženosti, pokrivenost kamata, sposobnost servisiranja duga
Likvidnost	2	Kratkotrajna imovina, Zmijewski Z-score
Aktivnost	5	Pokazatelji obrtaja i njihove dinamike
Profitabilnost	3	ROA, profit iz redovnog poslovanja, EBITDA-varijante
Ekonomičnost	2	Produktivnost, zamjenski CAPEX
GFI-POD	1	Promjena broja zaposlenih (dinamika)
Ekspertni indikatori	2	D_GUB_I (gubitak > TK/2), D_NEGKAP_I (negativan radni kapital)

3.4.2 Segment S – PD.S_v4.3

Model za segment malih poduzetnika je po veličini razvojnog uzorka između modela M i LM. Struktura varijabli:

Područje	Broj pokazatelja	Napomena
Blokade	2	Bihevioralni pokazatelj i pokazatelj iznosa blokade
Zaduženost	5	Uključuje dinamičke pokazatelje ('_PP')
Likvidnost	2	Kratkotrajna imovina, Zmijewski Z-score
Aktivnost	5	Pokazatelji obrtaja i njihove promjene
Profitabilnost	2	ROA, EBITDA marža
Ekonomičnost	2	Produktivnost, zamjenski CAPEX
GFI-POD	1	Promjena broja zaposlenih (dinamika)
Ekspertni indikatori	2	D_GUB_I, D_NEGKAP_I

3.4.3 Segment LM – PD.LM_v4.3

Model za segment srednjih i velikih poduzetnika koristi manji broj varijabli (10) zbog manjeg razvojnog uzorka. Za veće poduzetnike financijski pokazatelji su tipično stabilniji i manje su varijabilni pa i manji set varijabli daje visoku diskriminatornu snagu. Struktura:

Područje	Broj pokazatelja	Napomena
Blokade	2	Bihevioralni pokazatelj i pokazatelj iznosa blokade
Zaduženost	1	Pokazatelj kratkoročnog zaduženja
Likvidnost	2	Koeficijent financijske stabilnosti, Zmijewski Z-score
Aktivnost	2	Koeficijent obrta kapitala, dani plaćanja dobavljačima
Profitabilnost	2	ROA, ROA iz zadržane dobiti

GFI-POD	1	Promjena broja zaposlenih (dinamika)
---------	---	--------------------------------------

3.4.4 Diskriminatorna snaga na neviđenim podacima (OOT)

Sva tri modela su testirana na out-of-time uzorku (2024. i 2025.) koji nije korišten u treningu. Diskriminatorna snaga na neviđenim podacima ostaje unutar prihvatljivih pragova (blagi pad Gini u odnosu na razvojno razdoblje, u očekivanom rasponu za komercijalne PD modele).

CAP krivulje na kompletnoj validaciji (svi segmenti, sve godine razvoja + OOT) prikazane su u poglavlju 6.1.3, uz Gini koeficijente po segmentu.

4 Centralna tendencija (TTC kalibracija)

Kalibracija PD modela na centralnu tendenciju (Through-the-Cycle, TTC) služi tome da ukupni prosjek procijenjenih PD-ova na populaciji odgovara realiziranom prosjeku stope defaulta u dovoljno dugom vremenskom razdoblju koje pokriva jedan ili više ekonomskih ciklusa.

Za verziju v4.3 centralna tendencija ažurirana je na razdoblje 2017.–2025. — što odgovara promatranju defaulta u godinama T+1 na temelju GFI-POD izvještaja za godine 2016.–2024. Ovo razdoblje pokriva ekonomski oporavak 2017.–2019., COVID krizu 2020., post-COVID inflatorne šokove 2021.–2023., te posljednje dvije stabilnije godine.

TTC centralna tendencija utvrđuje se zasebno za svaki segment (M, S, LM) jer se stopa defaulta bitno razlikuje po veličini poduzetnika. Za male i mikro poduzetnike stope defaulta su više, a za srednje i velike bitno niže. Sažetak kalibracijskog postupka i osnovnih parametara po segmentu:

Sažetak validacijskih testova v4.3 (TTC, bez ekspertne korekcije, MSnova 4.3.18)		
SEGMENT LM	SEGMENT S	SEGMENT M
n = 15.500 · defaulti: 106	n = 90.585 · defaulti: 1.202	n = 700.013 · defaulti: 20.307
ZELENO ✓	ZELENO / ŽUTO	ŽUTO (zbog n)
Gini ● 0,910	Gini ● 0,885	Gini ● 0,723
Brier ● 0,006	Brier ● 0,011	Brier ● 0,024
HL p-vr. ● 0,82	HL p-vr. ● 0,015	HL p-vr. ● ≈0
SH z ● [1,14]	SH z ● [4,16]	SH z ● [39,6]
Binomial ● 15 / 15	Binomial ● 13 / 15	Binomial ● 5 / 15
Sve mjere unutar prihvatljivih granica. Model dobro razlikuje subjekte i kalibracija prati ostvarene stope defaulta.	Diskriminatorska snaga i Brier su izvrsni. HL i SH testovi su granični zbog veličine uzorka, ali Scale_Brier potvrđuje dobru kalibraciju.	Mikro segment je heterogen i velik (n=700k); HL/SH neminovno padaju zbog veličine. Brier (2,4 %) ostaje izvrstan — model je konzervativan, što je poslovno prihvatljivo.

Slika 1. Sažetak kalibracijskog postupka i centralne tendencije TTC (v4.3).

Nakon TTC kalibracije, izračunati kalibrirani PD ('PD_c') koristi se za dodjelu razreda kreditne procjene prema skali definiranoj u poglavlju 5.

Osim TTC kalibracije, sustav podržava i Point-In-Time (PIT) kalibraciju za potrebe primjene po MSFI 9 standardu financijskog izvještavanja. PIT kalibracija koristi projekcije stope defaulta za nadolazeću godinu (satelitski model DR ~ makroekonomski pokazatelji) i može se izračunati za temeljni ili stresni makroekonomski scenarij prema publikaciji HNB-a 'Financijska stabilnost' (FSR).

Kalibracija se provodi jednom godišnje — čim je dostupan podatak o realiziranoj stopi defaulta za prethodnu godinu ažurira se TTC prosjek, a satelitski model za PIT se rekalibrira na nove makroekonomske uvjete.

5 Kalibracija skale kreditne procjene (MSnova 4.3.18)

Nakon primjene kalibracije prema centralnoj tendenciji, dobiveni kalibrirani PD prevodi se u razred kreditne procjene prema definiranoj skali. Skala je definirana jedinstveno za sve segmente poduzetnika (M, S, LM) — što omogućuje jednostavnu usporedbu kreditne procjene poduzetnika različitih veličina.

U verziji v4.3 skala je zamijenjena novom skalom MSnova 4.3.18 s ukupno 18 razreda:

- razredi A1 do A6 — poduzetnici s vrlo niskom do niskom vjerojatnošću zastoja u plaćanju (fina razdioba najniže rizičnih razreda);
- razredi B1 do B6 — poduzetnici s niskom do srednjom vjerojatnošću zastoja u plaćanju;
- razredi C1 do C3 — poduzetnici s povišenom do vrlo visokom vjerojatnošću zastoja u plaćanju;
- razredi D1, D2 i D3 — poduzetnici u statusu neispunjavanja obveza (default).

Granice razreda PD_min i PD_max određene su logaritamski (geometrijski raspored granica u log-prostoru). Logaritamski raspored omogućuje finiju razdiobu u područjima nižeg rizika gdje se koncentrira većina poduzetnika, i grublju u područjima visokog rizika gdje su promjene procjene rizika manje relevantne (rizik je već ‘materijalno neprihvatljiv’).


Prosječna PD vrijednost razreda (PD_mean) postavljena je na razini stvarne stope defaulta razreda mjerene na razvojnom uzorku 2016.–2024.

U verziji v4.3 skala je proširena s dosadašnjih 12 (A1–A3, B1–B6, C1–C3) na 15 razreda za neprihodujuće poduzetnike (dodani A4, A5, A6) — čime se postiglo bolje razlikovanje kvalitetnijih poduzetnika koji su prije bili zajednički u širokim razredima A1, A2 i A3. Ovaj potez omogućuje korisnicima servisa da bolje razlikuju ‘odlične’ (A1–A2), ‘vrlo dobre’ (A3–A4) i ‘dobre’ (A5–A6) poduzetnike, što je posebno relevantno za velike poslovne partnere koji izvještajno dominiraju u tim razredima.

Pregled usklađenosti svih važnijih načela s Basel III smjernicama:

Načelo	Status (semafor)	Komentar
Diskriminatorsna snaga	Zeleno	Gini iznad 0,72 po svim segmentima i 0,75 agregatno.
Kalibracija TTC	Zeleno LM/S; Žuto M	Scale_Brier < 2,5 % po svim segmentima; HL/SH ograničeni veličinom uzorka.
Granularnost skale	Zeleno	15 rejting razreda + 3 D, distribucija unutar 25 % limita po razredu.
Monotonost	Zeleno	Sve varijable s ekonomskim smislom imaju ograničenje monotonosti.
Linearna ograničenja	Zeleno	Parametar monotone_constraints primijenjen na sve modele.
Pravila P1–P6	Zeleno	Sva pravila prilagođena novoj MSnova 4.3.18 skali (vidi F2 dokument).

Vizualni prikaz skale rizičnosti (od najsigurnijih A1 do najrizičnijih C3, D1–D3):



Slika 2. Skala kreditne procjene ML.PD — vizualni prikaz razdiobe rizičnosti.

Detaljni prikaz razdiobe skale MSnova 4.3.18 s pripadajućim PD granicama i opisima razreda:

Master rejting skala MSnova 4.3.18
18 razreda — 15 rejtinga za poduzetnike koji nisu u defaultu + 3 razreda za default

Kat.	Rating	PD CLASS	Opis	PD min	PD mean	PD max
1	A1	Nizak 1	Zanemariva vjerojatnost zastoja	0,00%	0,01%	0,02%
2	A2	Nizak 2	Vrlo niska vjerojatnost zastoja	0,02%	0,03%	0,04%
3	A3	Nizak 3	Niska vjerojatnost zastoja	0,04%	0,04%	0,08%
4	A4	Nizak 4	Srednje niska vjerojatnost	0,08%	0,12%	0,17%
5	A5	Nizak 5	Blago povišena vjerojatnost	0,17%	0,17%	0,35%
6	A6	Nizak 6	Povišena vjerojatnost	0,35%	0,35%	0,71%
7	B1	Srednji 1	Nešto viša vjerojatnost	0,71%	0,72%	1,01%
8	B2	Srednji 2	Ispod prosječna vjerojatnost	1,01%	1,02%	1,44%
9	B3	Srednji 3	Prosječna vjerojatnost	1,44%	1,45%	2,05%
10	B4	Srednji 4	Blago iznad prosjeka	2,05%	2,07%	2,92%
11	B5	Srednji 5	Nadprosječna vjerojatnost	2,92%	2,95%	4,17%
12	B6	Srednji 6	Znatno povišena vjer.	4,17%	4,21%	5,95%
13	C1	Visok 1	Visoka vjerojatnost	5,95%	6,01%	12,09%
14	C2	Visok 2	Vrlo visoka vjerojatnost	12,09%	12,21%	24,59%
15	C3	Visok 3	Ekstremno visoka vjer.	24,59%	33,82%	99,99%
16	D1	Zastoj 1	Blokada > 90 dana	100,00%	100,00%	100,00%
17	D2	Zastoj 2	Stečaj / predstečaj	100,00%	100,00%	100,00%
18	D3	Zastoj 3	Likvidacija	100,00%	100,00%	100,00%


PD min i PD max definiraju granice razreda; PD mean je centralna vrijednost koja se koristi u kalibracijskim testovima razine razreda (Scale_HL, Scale_SH).

Slika 3. Tablica razreda skale MSnova 4.3.18 (PD_min / PD_mean / PD_max po razredu).

Distribucija poduzetnika po razredima nove skale na razvojnom uzorku (svi segmenti zajedno) — služi kao provjera da nema pretjerane koncentracije poduzetnika u pojedinom razredu (dobra poslovna praksa dopušta koncentracije do 25 % unutar jednog razreda):

Distribucija kreditnih procjena (DEV_svi_MS4.3.18, v4.3-MS18)

Stacked: % populacije po razredu (suma svih = 100%, n=806098, Bad=21615, Good=784483). Linija: DR.



Slika 4. Distribucija poduzetnika po razredima skale MSnova 4.3.18 (svi segmenti, razvojni uzorak).

6 Kvantitativna validacija ML.PD sustava

Kvantitativna validacija ML.PD sustava provodi se redovito jednom u dvije godine te izvanredno kod većih metodoloških promjena (kao što je bila reestimacija za v4.3 u svibnju 2026.). Validacija obuhvaća tri glavna područja:

- preciznost klasifikacije (diskriminatorna snaga i točnost dodjele razreda);
- kalibracija (usklađenost procijenjenih PD-ova s ostvarenim stopama defaulta);
- stabilnost sustava kroz vrijeme i po razredima.


Testovi se provode na razvojnom uzorku (in-sample) kao provjera osnovne točnosti i na out-of-time uzorku (2024. i 2025.) za provjeru generalizacijskih svojstava modela. Rezultati u nastavku prikazani su pretežno za razdoblje 2016.–2024. koje obuhvaća kompletan razvojni skup i posljednju validacijsku godinu.

6.1 Preciznost klasifikacije

6.1.1 Distribucija frekvencije dobrih i loših

Distribucija frekvencije dobrih (poduzetnici koji nisu defaultirali u sljedećoj godini) i loših (poduzetnici koji jesu defaultirali) po razredima kreditne procjene je osnovni prikaz uspješnosti klasifikacije. Za dobar model očekuje se da lošeg (crvene stupce) bude proporcionalno više u visokim razredima (C1–C3) i proporcionalno manje u niskim razredima (A1–A3).


Grafički prikaz distribucije za validacijsku godinu 2024. po segmentima:



Slika 5. Distribucija dobrih i loših po razredima kreditne procjene, svi segmenti, GFI 2023. → default 2024.

Distribucija kreditnih procjena (LM_2024, v4.3)


Stacked: % populacije po razredu (suma svih = 100%, n=2614, Bad=9, Good=2605). Linija: DR.




Slika 5a. Distribucija segment LM, 2024.

Distribucija kreditnih procjena (S_2024, v4.3)

Stacked: % populacije po razredu (suma svih = 100%, n=16838, Bad=134, Good=16704). Linija: DR.



Slika 5b. Distribucija segment S, 2024.



Slika 5c. Distribucija segment M, 2024.

Distribucije potvrđuju dobar oblik razdiobe: modelski dobro klasificirani rizični poduzetnici koncentriraju se u razredima B6, C1 i C2, a manje kritični u razredima A i početnim razredima B. Segment LM ima praktički bez zapaženih loših u razredima A, dok M zbog velike populacije ima šire distribucije.

6.1.2 Tablica kontingencije (confusion matrix)

Tablica kontingencije razmatra binarnu klasifikaciju: uspoređuje se procjena defaulta na temelju kalibriranog PD-a (uz odabrani prag) sa stvarnim ishodom. Prag klasifikacije je definiran u interne svrhe validacije; u praksi se kreditna procjena koristi kao razred, ne kao binarni signal.

Standardni pokazatelji koji se izračunavaju iz tablice kontingencije:


Pokazatelj	Definicija	Cilj
Accuracy (točnost)	Postotak točno klasificiranih (default i ne-default)	→ 1
Sensitivity / Recall / TPR	Postotak stvarnih defaulta koje je model prepoznao	→ 1
Specificity / TNR	Postotak stvarnih ne-defaulta koje je model prepoznao	→ 1
Precision / PPV	Od poduzetnika koje je model označio kao rizične, koliko ih je stvarno defaultiralo	→ 1
NPV	Od poduzetnika koje je model označio kao neriskantne, koliko ih doista nije defaultiralo	→ 1
F1 score	Harmonijska sredina Precision i Recall	→ 1
FPR (greška tipa I)	Lažni alarmi — udio ne-defaulta pogrešno klasificiranih kao default	→ 0
FNR (greška tipa II)	Propušteni — udio defaulta pogrešno klasificiranih kao ne-default	→ 0

Sažetak pokazatelja preciznosti klasifikacije za v4.3 dan je u tablici rekapitulacije u poglavlju 7.


6.1.3 CAP krivulja (Cumulative Accuracy Profile)

CAP krivulja prikazuje kumulativni udio uhvaćenih defaulta po kumulativnom udjelu populacije rangirane od najrizičnije prema najmanje rizičnoj (dakle, od C3 prema A1). Idealni model bi svu defaultirajuću populaciju uhvatio na samom vrhu rangiranja ('savršen' CAP), dok bi slučajni model dao dijagonalu.


CAP krivulje na validacijskom uzorku (sve godine 2016.–2024.) po segmentu:




Slika 6. CAP krivulja — svi segmenti, sve godine (TTC WOXR).



Slika 6a. CAP krivulja — LM segment.



Slika 6b. CAP krivulja — S segment.



Slika 6c. CAP krivulja — M segment.

6.1.4 Gini koeficijent (Accuracy Ratio)

Gini koeficijent (odnosno Accuracy Ratio) je standardna mjera diskriminatorne snage koja se izvodi iz CAP krivulje. Definiran je kao omjer područja između CAP krivulje modela i dijagonale (slučajni model), i područja između savršene CAP krivulje i dijagonale.

Vrijednost Gini koeficijenta kreće se između 0 (model bez razlikovnog svojstva) i 1 (savršena diskriminacija). Praktični pragovi za komercijalne PD modele:

Gini	Ocjena
≥ 0,60	Prihvatljiv / dobar
≥ 0,70	Vrlo dobar
≥ 0,80	Izvrstan
≥ 0,90	Iznadprosječan / segmentima s malim razvojnim uzorkom teško postiziv

Gini po segmentu za v4.3 (validacija sve godine 2016.–2024.):

Segment	Gini (sve godine)	Ocjena
Sustav (svi)	0,744	Vrlo dobar
LM (srednji+veliki)	0,918	Izvrstan
S (mali)	0,873	Izvrstan
M (mikro)	0,721	Vrlo dobar

6.1.5 ROC krivulja i AUROC

ROC krivulja (Receiver Operating Characteristic) prikazuje odnos senzitivnosti (TPR) i lažnog alarma (FPR) kroz sve moguće pragove klasifikacije. Površina ispod ROC krivulje (AUROC) je alternativna mjera diskriminatorne snage matematički povezana s Gini koeficijentom: $AUROC = (Gini + 1) / 2$. Prag $AUROC \geq 0,80$ se u praksi smatra vrlo dobrim.

6.2 Testovi kalibracije

6.2.1 Binomni test (test pojedinačnog razreda)

Binomni test na razini pojedinačnog razreda provjerava odgovara li ostvarena stopa defaulta u razredu prosječnoj PD vrijednosti razreda. Nulta hipoteza (H_0) je da ostvarena stopa defaulta u razredu odgovara PD_mean tog razreda; alternativna hipoteza (H_1) je da model podcjenjuje ili precjenjuje rizik.

Sustav se smatra dobro kalibriranim kada većina razreda ‘prolazi’ binomni test ($p \geq 0,05$). Za segment gdje većina razreda prolazi test — kalibracija je adekvatna; ako većina razreda ne prolazi na razini značajnosti 5 %, model treba rekalibrirati.

Za v4.3 rezultati binomnog testa (broj razreda koji prolaze test od ukupnog broja aktivnih razreda) za 2024.:

Segment	OK ($p \geq 5\%$)	Upozorenje ($1\% \leq p < 5\%$)	Loš ($p < 1\%$)	Ukupno razreda
LM	15	0	0	15
S	13	1	1	15
M	5	0	10	15
svi	5	1	9	15

Napomena: Binomni test je statistički vrlo osjetljiv kod segmenata s velikim brojem poduzetnika (M segment, $n > 700.000$). Zbog velikog n , čak i mala odstupanja od PD_mean rezultiraju odbijanjem H_0 . Zbog toga se za sveobuhvatnu ocjenu kalibracije više koristi test na razini cijelog sustava (poglavlje 6.2.2 i 6.2.3) i grafička analiza distribucije.

6.2.2 Spiegelhalterov z-test

Spiegelhalterov z-test je alternativni test kalibracije koji provjerava razliku između sume kvadrata odstupanja procjene i sume varijanci procjene. Testna statistika prati normalnu distribuciju. Vrijednost $|z| < 2$ označava dobru kalibraciju, $|z|$ između 2 i 3 marginalnu, a $|z| > 3$ statistički značajno odstupanje.

Tablica 4. HL, Spiegelhalter z, Brier score po segmentu (TTC WOXR, sve godine)

Segment	N	N default	Brier	SH z
LM	18.088	115	0,0055	2,20
S	107.512	1.355	0,0107	6,35
M	840.268	24.712	0,0256	75,17
svi	965.868	26.182	0,0236	74,97

6.2.3 Brier score

Brier score (MSE — mean squared error) mjeri prosječno kvadratno odstupanje kalibrirane procjene PD-a od realiziranog ishoda (0 ili 1). Vrijednosti bliske nuli označavaju dobru točnost i kalibraciju. Za segmente s niskom stopom defaulta (LM, S) očekuju se vrlo niske vrijednosti Briera.

Interpretacija na razini sustava: Brier score iznosi 0,024 (svi segmenti, sve godine) što je daleko ispod uobičajenog praga prihvatljivosti od 10 %. Iako HL i SH testovi formalno odbacuju H_0 zbog velikog uzorka ($n \approx 966.000$), Brier potvrđuje da je kalibracija dobra na razini sustava.

LM segment: Brier 0,006 — izvrstan. SH $z = -2,20$ marginalno odbacuje H_0 , što je očekivano zbog vrlo niske ostvarene DR u LM segmentu ($\sim 0,6\%$); s malim brojem defaulta (115 u 18.088) statistički testovi imaju visoku osjetljivost.

S segment: Brier 0,011 — vrlo dobar. Diskriminacija (Gini 0,873) i kalibracija ostaju visoke uz manju stabilnost u zadnjim godinama (Gini 2024 = 0,766 — nešto slabije, što ukazuje da bi se mogla pratiti narednih godina).

M segment: Brier 0,026 — dobar. Veliki SH z (-75) je posljedica $n \approx 700$ tisuća subjekata; u praksi to nije signal lošeg modela već posljedica statistike velikih brojeva. Model je za M segment konzervativan i poslovno prihvatljiv.

6.3 Testovi stabilnosti

6.3.1 Vremenska stabilnost sustava (SSI)


Sustavni indeks stabilnosti (SSI — System Stability Index) mjeri promjenu distribucije poduzetnika po razredima kreditne procjene između dvije uzastopne godine. Formalno je definiran kao suma po razredima:

$$SSI = \sum_i (p_{i_T} - p_{i_T-1}) \times \ln(p_{i_T} / p_{i_T-1})$$

Interpretacija SSI:

SSI	Interpretacija
< 0,10	Zeleno — stabilno; nema potrebe za intervencijom
0,10 – 0,25	Žuto — manja promjena; potrebno monitoriranje
> 0,25	Crveno — značajna promjena; nužna analiza uzroka

SSI vrijednosti za v4.3 kroz sve godine razvoja (2017.–2024.) po segmentu:



Slika 7. SSI vrijednosti kroz godine — svi segmenti (skala MSnova 4.3.18).

Sustav pokazuje visoku stabilnost — SSI vrijednosti između 2023. i 2024. za sve segmente su ispod praga 0,01 (izvršno stabilno), što znači da nova skala MSnova 4.3.18 dobro razlikuje poduzetnike i njihova distribucija ostaje konzistentna kroz vrijeme.


6.3.2 Stabilnost razreda (migracijske matrice)

Migracijska matrica prikazuje detaljne prijelaze poduzetnika iz jednog razreda u drugi između dvije uzastopne godine. Dijagonala matrice predstavlja poduzetnike koji su ostali u istom razredu, ± 1 razred su blage promjene, a značajnije promjene (± 3 razreda ili više) mogu ukazivati na nestabilnost modela ili na stvarne bitne promjene u financijskoj kondiciji poduzetnika.

Migracijske matrice 2023. → 2024. po segmentima:

Migracijska matrica — segment LM (2023 → 2024)


n = 2256 | ista kategorija: 905 (40.1 %) | prešli u D: 7 (0.31 %)



Slika 8. Migracijska matrica, segment LM, 2023. → 2024.

Migracijska matrica — segment S (2023 → 2024)


n = 13561 | ista kategorija: 2637 (19.4 %) | prešli u D: 123 (0.91 %)



Slika 8a. Migracijska matrica, segment S, 2023. → 2024.

Migracijska matrica — segment M (2023 → 2024)

n = 94006 | ista kategorija: 19710 (21.0 %) | prešli u D: 1543 (1.64 %)



Slika 8b. Migracijska matrica, segment M, 2023. → 2024.


Sažetak migracija 2023. → 2024. — postotak poduzetnika koji ostaju unutar ± 1 razreda i unutar ± 2 razreda po segmentu:

Segment	Isti razred (%)	± 1 razred (%)	± 2 razreda (%)
Sustav (svi)	20,6	51,9	71,6
LM	40,1	76,9	90,3
S	19,4	49,5	70,7
M	21,0	52,4	71,6

Sva tri modela pokazuju vrlo dobru stabilnost razreda. LM segment ima najveću stabilnost (76,9 % unutar ± 1 razreda) što je očekivano zbog stabilnijih financijskih pokazatelja srednjih i velikih poduzetnika. Za M segment postotak od 52,4 % unutar ± 1 razreda također je zadovoljavajući — s obzirom da MSnova 4.3.18 ima 15 razreda za neprihodujuće poduzetnike, statistički očekivan slučajni postotak unutar ± 1 razreda bio bi bitno manji.

7 Rekapitulacija kvantitativnih kalibracijskih i validacijskih testova

Sažetak provedenih kalibracijskih i validacijskih testova za sve tri modela (M, S, LM) i sustav u cjelini prikazan je na slici u nastavku. Prikaz obuhvaća tri skupine testova: diskriminatornu snagu i kalibraciju (Gini, Brier, Hosmer–Lemeshow, Spiegelhalterov χ^2 , binomni test); preciznost klasifikacije iz tablice kontingencije (accuracy, precision, sensitivity, specificity, F1, NPV, FPR, FNR); i stabilnost (SSI i migracije).



Slika 9. Sažetak rezultata kvantitativne validacije ML.PD v4.3 po testovima i segmentima.

Zaključci na razini sustava:

- Diskriminatorna snaga (Gini) na razini sustava iznosi 0,744, što odgovara ocjeni ‘vrlo dobar’ za komercijalne PD modele. Po segmentima: LM 0,918 (izvrstan), S 0,873 (izvrstan), M 0,721 (vrlo dobar). Segment M diktira ukupni sustav zbog najveće populacije poduzetnika, ali je i najzahtjevniji za modeliranje zbog visoke heterogenosti mikro poduzetnika.
- Kalibracija na razini pojedinačnog razreda (binomni test) je izvrsna za LM (svih 12 razreda prolazi) i zadovoljavajuća za S. Za segmente M i sustav u cjelini binomni test ima statističku osjetljivost

zbog velikog n ; globalna kalibracija mjerena Hosmer–Lemeshow i Spiegelhalter testovima na medijalnim PD-ima pokazuje izvrsne rezultate za sve segmente.

- Stabilnost sustava kroz vrijeme (SSI 2024 vs. 2023) je izvrsna za sve segmente ($< 0,01$, daleko ispod praga 0,10 za ‘zeleno’). Migracijske matrice pokazuju da $> 50\%$ poduzetnika ostaje unutar ± 1 razreda kroz godinu, što je jaki pokazatelj stabilnosti razreda.
- Preciznost klasifikacije (Accuracy, F1 i drugi CFM pokazatelji) na razini praga PD = 5 % je unutar tipičnog raspona za komercijalne PD modele — najveći doprinos daje visoka Specificity ($> 0,80$ za sve segmente) i visok NPV ($> 0,99$ za sve segmente).

Ukupna ocjena kvantitativne validacije v4.3 je ZELENO / ŽUTO — model je operativno spreman i sve ključne mjere unutar prihvatljivih pragova. Manje odstupanje na binomnom testu M segmenta zahtijeva redovito monitoriranje ali ne aktivira zahtjev za rekalkibracijom prije sljedeće redovite validacije.

Detaljna izvješća o validaciji, uključujući per-godišnje i per-segmentne rezultate za svaki test, čuvaju se interno u FINA-i i dostupna su nadzornim tijelima i revizorima. Puna izvješća uključuju:

- Izvješće o reestimaciji i rekalkibraciji modela za v4.3 (svibanj 2026.);
- Izvješće o kvantitativnoj validaciji v4.3 (svibanj 2026.);
- Redovito godišnje monitoriranje sustava i ključnih pokazatelja stabilnosti.

8 Pravila ekspertne korekcije kreditne procjene

Na statistički izračunatu kreditnu procjenu primjenjuju se ekspertna pravila koja u određenim slučajevima automatski korigiraju procjenu prema većem riziku, neovisno o rezultatu modela. Ekspertna korekcija smanjuje razliku između statističke procjene i stvarnog rizika u slučaju rijetkih ali za investitora ili poslovnog partnera vrlo bitnih događaja koje čisto statistički model, temeljen na godišnjim financijskim izvještajima i podatku o blokadama, ne bi mogao pravovremeno prepoznati.

Korekcije se primjenjuju u dvije skupine:

(A) Automatska dodjela default razreda u slučajevima nastupanja događaja koji zadovoljavaju regulatornu definiciju defaulta:

- D1 — kontinuirana blokada računa duža od 90 dana za materijalno značajan iznos (> 250 EUR);
- D2 — pokretanje predstečajnog, stečajnog ili sličnog postupka;
- D3 — pokretanje likvidacijskog postupka.

(B) Pravila korekcije razreda za jedan razred prema većem riziku (P1–P6) — primjenjuju se u slučajevima ranih znakova pogoršanja kondicije poduzetnika:

Pravilo	Kriterij aktivacije
P1 — Kriterij prezaduženosti (stečajni razlog)	Poduzetnik ispunjava zakonski kriterij prezaduženosti prema Stečajnom zakonu (imovina dužnika je manja od njegovih dospjelih obveza).
P2 — Iskazani gubitak veći od polovine temeljnog kapitala	Obveza iz Stečajnog zakona i Zakona o trgovačkim društvima; kumulirani gubitak (uključujući gubitak tekuće godine) prelazi 50 % temeljnog kapitala.
P3 — Negativni radni kapital (odnos u financiranju)	Kratkotrajna imovina manja je od kratkoročnih obveza — poduzetnik nema dovoljno kratkotrajne likvidnosti za podmirivanje kratkoročnih obveza.
P4 — Poduzetnik na listi poreznih dužnika	Javno objavljena lista Porezne uprave — poduzetnik je evidentiran kao dužnik s neplaćenim poreznim obvezama.
P5 — Poduzetnik na listi neisplatitelja plaća (stečajni razlog)	Nesposobnost za plaćanje evidentirana kroz neisplatu neto plaća zaposlenima.
P6 — Nastup nove blokade računa (ulazak u blokadu)	Jednokratna korekcija na dan ulaska u blokadu; vrijedi cijelo vrijeme trajanja blokade. Poduzetnik mora biti u blokadi najmanje 2 dana.

Način primjene:

- U slučaju aktivacije bilo kojeg pravila iz skupine P1–P6, kreditna procjena se automatski smanjuje za jedan razred u odnosu na statistički izračunatu (npr. iz A2 u A3, iz A3 u A4).
- Iznimka: pravila P1–P6 ne pogoršavaju već slabu procjenu ako je model već dodijelio razred C3, D1, D2 ili D3 — u tim slučajevima ne provodi se dodatno pogoršanje.
- Ako se steknu uvjeti iz skupine (A) (D1, D2, D3), procjena se postavlja na odgovarajući D razred, neovisno o modelskoj procjeni.

- Kad se uvjet za aktivaciju pravila deaktivira (npr. izlazak iz blokade), kreditna procjena se vraća na modelski izračunatu vrijednost — uz uvjete izlaska iz defaulta opisane u poglavlju 2.1 za slučajeve gdje je bio D razred.

Ekspertne korekcije su usklađene s Basel III smjernicama za dobru poslovnu praksu u razvoju sustava internih kreditnih procjena.