

VIŠJA STROKOVNA ŠOLA ACADEMIA

MARIBOR

IZZIVI PRI RAZVOJU MODELOV TVEGANJA ZA CROWDLENDING PLATFORME

Kandidatka: Iuliia Kravchenkova

Vrsta študija: študentka izrednega študija

Študijski program: Ekonomist

Mentor – predavatelj: doc. dr. MBA Dušan Mežnar, univ. dipl. inž. el.

Mentorica v podjetju: mag. Olga Kuznetsova

Lektorica: Jasmina Vajda Vrhunec, prof. slov.

Maribor, 2025

IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Podpisana Iuliia Kravchenkova sem avtorica diplomskega dela z naslovom Izzivi pri razvoju modelov tveganja za crowdlending platforme, ki sem ga napisala pod mentorstvom doc. dr. MBA Dušana Mežnarja, univ. dipl. inž. el.

S svojim podpisom zagotavljam, da:

- je predloženo delo izključno rezultat mojega dela,
- sem poskrbela, da so dela in mnenja drugih avtorjev, ki jih uporabljam v predloženi nalogi, navedena oz. citirana skladno s pravili Višje strokovne šole Academia Maribor,
- se zavedam, da je plagiatorstvo – predstavljanje tujih del oz. misli kot moje lastne – kaznivo po Zakonu o avtorski in sorodnih pravicah (Uradni list RS, št. 16/07 – uradno prečiščeno besedilo, 68/08, 110/13, 56/15 in 63/16 – ZKUASP); prekršek pa podleže tudi ukrepom Višje strokovne šole Academia Maribor skladno z njenimi pravili,
- skladno z 32.a členom ZASP dovoljujem Višji strokovni šoli Academia Maribor objavo diplomskega dela na spletnem portalu šole.

Maribor, november 2025

Podpis študenta:

ZAHVALA

Zahvaljujem se mentorju doc. dr. MBA Dušanu Mežnarju za strokovne nasvete, konstruktivno kritiko in podporo med pisanjem diplomskega dela.

Posebno zahvalo namenjam Guzel za neprecenljiv prispevek k mojemu strokovnemu razvoju na začetku moje kariere.

POVZETEK

V digitalnem finančnem okolju množično posojanje (crowdlending) postaja ena ključnih oblik alternativnega financiranja, saj omogoča neposredno povezavo med vlagatelji in posojilojemalci ter spodbuja demokratizacijo dostopa do kapitala. Diplomsko delo »Izzivi pri razvoju modelov tveganja za crowdlending platforme« obravnava problem učinkovitosti tradicionalnih modelov ocenjevanja kreditnega tveganja za mala in zagonska podjetja ter raziskuje možnosti njihove posodobitve z vključitvijo nefinančnih kazalnikov in s tem povezanih izzivov.

V teoretičnem delu raziskave je analiziran razvoj množičnega posojanja kot sestavnega dela digitalnih tehnologij in predstavljeni so tradicionalni pristopi k merjenju kreditnega tveganja (Altmanov Z-rezultat, modeli PD/LGD/EAD), pri čemer je dodatno prikazana njihova omejena uporabnost za podjetja brez obsežne finančne zgodovine. Empirični del vključuje analizo, ki preverja natančnost modelov na podatkih množične posojilne platforme. Rezultati kažejo, da klasični modeli pogosto napačno razvrstijo zanesljive posojilojemalce med tvegane.

Za odpravo neučinkovitosti je bil v Altmanov Z-rezultat vključen nabor sedmih kazalnikov »mehkih informacij«, s pojasnilom njihove povezanosti z verjetnostjo neplačila ter z obravnavo izzivov pri zbiranju in interpretaciji teh podatkov. Za izračune sta bili uporabljeni metoda linearne diskriminantne analize in logistična regresija. Kombinacija finančnih in nefinančnih informacij je povečala napovedno moč modela. Raziskava potrjuje, da je raznolikost v ekipi tesno povezana z večjo inovativnostjo, boljšimi finančnimi kazalniki in dostopnostjo kapitala, kar določa dolgoročni uspeh zagonskih podjetij in vpliva na oceno mladih podjetij.

V zaključku je mogoče poudariti, da ima združevanje kvantitativnih in kvalitativnih informacij ključen pomen za nadaljnji razvoj modelov ocenjevanja tveganj v množičnem posojanju. Takšen pristop povečuje učinkovitost kreditnih odločitev, zmanjšuje stopnjo neplačil in krepi stabilnost platform.

Ključne besede: *množično posojanje, kreditno tveganje, mehke informacije, upravljanje talentov.*

ABSTRACT

Challenges in Developing Risk Models for Crowdlending Platforms

In the digital financial environment, crowdlending has become one of the key forms of alternative financing, enabling direct interaction between investors and borrowers and promoting the democratization of access to capital. The thesis “Challenges in Developing Risk Models for Crowdlending Platforms” addresses the issue of the effectiveness of traditional credit risk assessment models for small enterprises and startups, and explores the possibilities of their modernization through the use of non-financial indicators, along with the challenges associated with their application.

The theoretical part analyzes the development of crowdlending as an integral component of digital technologies, as well as traditional methods of measuring credit risk (Altman’s Z-score, PD/LGD/EAD models), highlighting their limited applicability for companies without extensive financial histories. The empirical part includes an analysis that evaluates the accuracy of models based on data from a crowdlending platform. The findings indicate that classical models often misclassify financially sound borrowers as high risk.

To address these inefficiencies, seven “soft information” indicators were incorporated into Altman’s Z-score model, accompanied by a justification of their relevance to default risk and a discussion of the methodological challenges related to data collection and interpretation. Linear discriminant analysis and logistic regression were applied to evaluate predictive performance. The integration of financial and non-financial information increased the predictive power of the model. The research confirms that team diversity is closely linked to greater innovativeness, stronger financial performance, and improved access to capital, which shapes the long-term success of startups and influences the valuation of young companies.

In conclusion, it can be stated that the integration of quantitative and qualitative information is crucial for the further development of risk assessment models in crowdlending. Such an approach enhances the effectiveness of credit decision-making, reduces default rates, and strengthens the stability of lending platforms.

Keywords: *crowdlending, credit risk, soft information, talent management*

KAZALO VSEBINE

1	UVOD	8
1.1	OPREDELITEV PROBLEMA	8
1.2	NAMEN, CILJI IN OSNOVNE TRDITVE	8
1.3	PREDPOSTAVKE IN OMEJITVE	9
1.4	UPORABLJENE RAZISKOVALNE METODE	10
1.5	PRAKTIČNA UPORABA	10
2	TEORETIČNE OSNOVE IN POSEBNOSTI PLATFORM ZA MNOŽIČNO POSOJANJE.....	12
2.1	KONCEPT IN VRSTE MNOŽIČNEGA POSOJANJA	12
2.2	TVEGANJA PRI MNOŽIČNEM POSOJANJU	15
2.3	PROFILI POSOJIOJEMALCEV: MALA IN SREDNJE VELIKA TER ZAGONSKA PODJETJA – OVIRE ZA TRADICIONALNI DOSTOP DO KREDITOV ZA MALA IN SREDNJE VELIKA TER ZAGONSKA PODJETJA.....	17
3	MODELI ZA OCENO TVEGANJA	22
3.1	PREGLED OBSTOJEČIH PRISTOPOV K MODELIRANJU TVEGANJ V FINANČNEM SEKTORJU (ALTMANOV Z-REZULTAT, MODELI PD/LGD/EAD)	22
3.2	PROBLEM KAKOVOSTI FINANČNIH INFORMACIJ V MALIH IN ZAGONSKIH PODJETJIH	26
4	ANALIZA IZZIVOV PRI RAZVOJU MODELOV TVEGANJA ZA POSOJIOJEMALCE MNOŽIČNEGA POSOJANJA	30
4.1	KOMBINIRANI PRISTOP K OCENJEVANJU TVEGANJA Z »MEHKIMI INFORMACIJAMI« (KAZALNIKA, SPECIFIČNA ZA USTANOVITELJA: SPLETNA PRISOTNOST IN ZGODOVINA ZBIRANJA KAPITALA)	30
4.2	IZZIVI PRI STANDARDIZACIJI IN SKALIRANJU MODELOV NA PODLAGI KOMBINIRANIH PODATKOV	36
5	VLOGA USTANOVITELJA IN EKIPE PRI DOLGOROČNEM USPEHU	40
5.1	POMEN PROFESIONALNE IN RAZNOLIKE EKIPE ZA USPEH MALIH IN ZAGONSKIH PODJETIJ	40
5.2	MOŽNOSTI VKLJUČEVANJA STROKOVNE RAZNOLIKOSTI EKIP V MODELE OCENJEVANJA TVEGANJA	45
6	SKLEP	47
7	SEZNAM LITERATURE.....	51
8	PRILOGE.....	55

KAZALO SLIK

SLIKA 1: STATISTIKA EU ZA LETO 2023: PONUDNIKI IN VLAGANJE PO VRSTI FINANCIRANJA	14
SLIKA 2: EVROPSKI TRG MNOŽIČNEGA POSOJANJA – TRŽNI DELEŽ PO POSLOVNIH SEGMENTIH (2024)	18

SLIKA 3: ROC ZA ALTMANOV Z-REZULTAT.....	29
SLIKA 4: ROC ZA 12-FAKTORSKI MODEL	35
SLIKA 5: RAZNOLIKOST EKIPE IN UČINKOVITOST ODLOČANJA	41
SLIKA 6: RAZNOLIKOST EKIPE IN FINANČNI REZULTATI	42
SLIKA 7: SPOLNA RAZNOLIKOST EKIPE IN KREDITNA OCENA.....	42
SLIKA 8: RAZNOLIKOST EKIPE IN UČINKOVITOST ODLOČANJA	43
SLIKA 9: ROC ZA 14-FAKTORSKI MODEL	44

KAZALO TABEL

TABELA 1: AUC PO ALTMANOVEM Z-REZULTATNEM MODELU	28
TABELA 2: KAZALNIKI »MEHKIH INFORMACIJ« ZA OCENO KREDITNEGA TVEGANJA	32

1 UVOD

V zadnjem desetletju je finančna industrija doživela temeljite spremembe, ki jih poganjata digitalizacija in razvoj finančnih tehnologij. Eden najhitreje rastočih segmentov tega razvoja je množično posojanje (crowdlending), ki je postalo pomembna alternativa tradicionalnemu bančnemu financiranju. Platforme za množično posojanje omogočajo neposredno povezavo med vlagatelji in posojilojemalci ter tako prispevajo k demokratizaciji dostopa do kapitala.

1.1 *Opredelitev problema*

Tradicionalni bančni modeli ocenjevanja kreditnega tveganja temeljijo predvsem na kvantitativnih finančnih kazalnikih, kot so prihodki, dobiček ter razmerje med dolgom in kapitalom. Ti modeli so zanesljivi pri ocenjevanju velikih in uveljavljenih podjetij, vendar se izkažejo za neučinkovite, kadar gre za mala in srednje velika podjetja (MSP) ter zagonska podjetja. Posledica je sistematična napačna razvrstitev teh podjetij kot visoko tveganih. Zaradi tega se ta podjetja pogosto soočajo z ovirami pri pridobivanju tradicionalnih bančnih posojil, kar jih prisili, da iščejo financiranje prek alternativnih mehanizmov, kot je crowdlending.

Kljub temu ostaja eden največjih izzivov teh platform natančna ocena kreditnega tveganja, zlasti pri MSP-jih in zagonskih podjetjih, ki pogosto nimajo popolne finančne zgodovine. Ta raziskava se osredotoča na razumevanje teh izzivov in na iskanje načinov za izboljšanje ocenjevanja tveganj v okolju množičnega posojanja.

V diplomskem delu bo opredeljeno, zakaj so tradicionalni kreditni modeli, ki temeljijo na finančnih kazalnikih, kot so prihodki, dobiček in kazalniki zadolženosti, neučinkoviti ter kateri alternativni pristopi lahko izboljšajo natančnost napovedovanja kreditnega tveganja.

1.2 *Namen, cilji in osnovne trditve*

Osrednji fokus raziskave je integracija »mehkih informacij« – značilnosti, ki niso zajete v finančnih izkazih, vendar so lahko ključne za ocenjevanje tveganj – kot so vedenje ustanoviteljev, zgodovina pridobivanja kapitala, struktura ekipe in opis projekta. Posebna pozornost bo namenjena vlogi ustanovitelja pri oblikovanju ekipe in upravljanju talentov, vključno z njegovo sposobnostjo privabljanja raznolikih strokovnjakov.

Cilj raziskave je analizirati vpliv »mehkih informacij« na izboljšanje tradicionalnih modelov ocenjevanja kreditnega tveganja in izzive, ki se pojavljajo pri vključevanju teh informacij v

dejanske procese kreditnega ocenjevanja. Končni cilj je oblikovati utemeljena priporočila za platforme, ki si prizadevajo izboljšati upravljanje tveganj pri financiranju netradicionalnih posojilojemalcev.

Za dosego zastavljenega cilja so določene naslednje naloge:

1. proučiti razloge, zaradi katerih se zagonska podjetja in MSP-ji odločajo za množične posojilne platforme kot vir financiranja;
2. analizirati ustreznost tradicionalnih modelov ocenjevanja tveganj glede na značilnosti poslovanja zagonskih podjetij in MSP-jev;
3. oceniti vpliv vključitve »mehkih informacij« v modele ocenjevanja tveganj na njihovo napovedno moč;
4. proučiti korelacijo med raznolikostjo strokovnih izkušenj v ekipi zagonskega podjetja in verjetnostjo njegovega dolgoročnega uspeha.

Hipoteze diplomskega dela:

H1: Če je podjetje zagonsko podjetje ali MSP, je verjetnost uporabe crowdlending platform za financiranje večja kot pridobitev sredstev prek tradicionalnih bank.

H2: Če se zagonska podjetja in MSP-ji ocenjujejo z uporabo tradicionalnih modelov finančnega ocenjevanja tveganja (npr. donosnost, dinamika prihodkov, razmerje dolga), je večja verjetnost njihove napačne razvrstitve kot visoko tvegani kreditojemalci.

H3: Če se v modele ocenjevanja tveganja vključijo kvalitativni dejavniki, kot so prisotnost ustanovitelja na družbenih omrežjih, zgodovina zbiranja kapitala in struktura ekipe, bo model pokazal višji rezultat AUC pri napovedovanju kreditnega tveganja na crowdlending platformah v primerjavi z modeli, ki temeljijo izključno na tradicionalnih finančnih kazalnikih.

H4: Če ekipa zagonskega podjetja izkazuje raznolikost strokovnih ozadij, kot je razvidno iz javno dostopnih kanalov podjetja, je verjetnost dolgoročnega poslovnega uspeha večja.

1.3 Predpostavke in omejitve

Raziskava temelji na predpostavki, da uporaba tradicionalnih finančnih kazalnikov v kombinaciji z »mehkimi informacijami« omogoča večjo natančnost pri ocenjevanju kreditnega tveganja. Kljub temu ima raziskava določene omejitve, ki lahko vplivajo na obseg in globino analiziranih rezultatov:

- podatki o portfelju množične posojilne platforme so predstavljeni samo za en dan in zajemajo vzorec 64 podjetij;
- obdobje delovanja platforme je krajše od petih let, kar pomeni, da ni na voljo podatkov o neplačilih skozi celotne gospodarske cikle, ki običajno trajajo 7–11 oziroma 15–20 let;
- finančni podatki podjetij – posojilojemalcev so zaupni in zaokroženi na tisočice;
- za analizo je bilo izbranih le devet kvalitativnih kazalnikov;
- zbiranje podatkov o raznolikosti ekip je bilo izvedeno ročno, zato lahko vsebuje netočnosti in elemente subjektivne presoje;
- dostopna literatura o tej temi je omejena predvsem na znanstvene raziskave, ki obravnavajo uporabo omejenega nabora »mehkih informacij« v modelih za ocenjevanje tveganj.

1.4 Uporabljene raziskovalne metode

V raziskavi je uporabljena kombinacija kvantitativnih in kvalitativnih metod. Kvantitativni del vključuje uporabo Altmanovega Z-rezultata in testiranje njegove učinkovitosti na empiričnem naboru podatkov množične posojilne platforme. Kombinirani model, ki poleg tradicionalnih finančnih kazalnikov vključuje tudi kakovostne podatke iz virov, kot so gov.uk, LinkedIn, Crunchbase, spletne strani podjetij in družbena omrežja, je analiziran z uporabo linearne diskriminantne analize.

Kvalitativni del raziskave temelji na pregledu znanstvenih študij o množičnem posojanju in tematskih raziskav platform v Evropski uniji (EU) in Združenem kraljestvu. Na podlagi teh podatkov so v delu osvetljeni skriti vzorci, povezani s tveganjem, za devet kazalnikov »mehkih informacij«.

Uporaba mešane metodologije omogoča celovito proučitev raziskovalnega problema: kvalitativna analiza služi kot temelj za oblikovanje teoretičnega okvira, medtem ko kvantitativni podatki omogočajo preverjanje teh izhodišč na dejanskih podatkih in identifikacijo konkretnih praktičnih izzivov.

1.5 Praktična uporaba

Praktična vrednost te raziskave je v razvoju in preverjanju modela za ocenjevanje kreditnega tveganja, ki upošteva posebnosti zagonskih podjetij in MSP-jev. V delu je predlaganih devet kazalnikov kvalitativnih informacij, namenjenih vključitvi v model, skupaj z utemeljitvijo povezave vsakega kazalnika s tveganjem neplačila. Poleg tega je izvedena analiza izzivov

integracije »mehkih informacij« v model, od zbiranja podatkov do njihove končne interpretacije glede na značilnosti posameznega posojilojemalca.

Izboljšanje modelov za ocenjevanje kreditnega tveganja na razvijajočem se trgu množičnega posojanja je izjemno pomembno, saj vodi k izboru manj tveganih posojilojemalcev, zmanjšuje stopnjo neplačil in omogoča stabilen razvoj platform. Razvoj alternativnih oblik financiranja prispeva k večji dostopnosti kapitala za podjetja in omogoča pravičnejšo oceno tveganja, kar je ključno za njihovo rast.

Tako lahko rezultati te raziskave služijo kot osnova za razvoj učinkovitih algoritmov odločanja na področju alternativnega financiranja.

2 TEORETIČNE OSNOVE IN POSEBNOSTI PLATFORM ZA MNOŽIČNO POSOJANJE

2.1 *Koncept in vrste množičnega posojanja*

Množično posojanje (bolj poznano pod angleškim izrazom »crowdlending«) je sodoben način zbiranja denarja, pri katerem veliko ljudi (»množica«) vlaga majhne zneske denarja, običajno prek spletnih platform. Te digitalne platforme delujejo kot posredniki, ki povezujejo podjetja, ki potrebujejo sredstva, s potencialnimi posojilodajalci.

Ključna razlika med množičnim in tradicionalnim bančnim posojanjem je v tem, da ustvarja neposredno povezavo med tistimi, ki dajejo denar, in tistimi, ki ga prejemajo. Naložbe so lahko v obliki posojil ali nakupa dolžniških obveznic. Ta pristop je še posebej dragocen za podjetja na manjših trgih, kjer je dostop do bančnega kapitala pogosto omejen (European Securities and Markets Authority, 2025).

Platforme za množično posojanje, ki delujejo kot ponudniki storitev, ponujajo javni spletni prostor, kjer se lahko vlagatelji seznani z različnimi projekti, ki so prestali predhodni izbor platforme, in se odločijo, ali bodo investirali. Za MSP-je, ki se pogosto soočajo s težavami pri pridobivanju financiranja od bank, je množično posojanje postalo pomemben alternativni vir kapitala.

Pojav množičnega posojanja (crowdlendinga), ključnega elementa sodobne finančne tehnologije (fintech), je neposredna posledica transformacijskih procesov, ki sta jih sprožila razvoj interneta in pojav digitalnih trgov (Shneor in drugi, 2020). Da bi razumeli nastanek tega pojava, se je treba ozreti v prazgodovino tržnega gospodarstva pred pojavom interneta v devetdesetih letih prejšnjega stoletja.

Zgodovinsko gledano, je bila prevlada na trgu skoncentrirana v rokah velikih korporacij (Coca-Cola, Nestlé itd.), ki so imele potrebno infrastrukturo za uspeh: privilegiran dostop do maloprodajnih kanalov, znatne marketinške proračune ter tesne odnose z bankami in finančnimi institucijami. Ta podjetja so imela koristi od ekonomije obsega in tolerance do tveganja, kar jim je omogočilo hitro rast, medtem ko so se mala in zagonska podjetja pogosto soočala z ovirami za vstop zaradi visokih operativnih stroškov in omejenega dostopa do kreditov s strani konservativnih bančnih struktur, osredotočenih na zavarovanje in dokazano kreditno zgodovino, kar je znatno oviralo njihov razvoj.

Pojav interneta je sprožil radikalen premik v ekonomski paradigmi, demokratiziral dostop do informacij, komunikacije in tržnih priložnosti.

1. Nižje ovire za vstop: internet je odpravil potrebo po znatnih kapitalskih izdatkih za izgradnjo fizične infrastrukture, kar omogoča ustvarjanje virtualnih poslovnih modelov z minimalnimi začetnimi naložbami.
2. Globalizacija trgov: geografske omejitve so bile odpravljene, kar malim podjetjem omogoča dostop do globalnega potrošniškega občinstva.
3. Pojav elektronskih tržnic: internet je omogočil nastanek platform, kot so Amazon in eBay ter kasneje še Shopify. Te platforme delujejo kot digitalni ekosistemi, ki združujejo ponudbo in povpraševanje. Omogočile so malim blagovnim znamkam in neodvisnim proizvajalcem, da neposredno dosežejo potrošnike, mimo tradicionalnih maloprodajnih vratarjev, kar je bilo prej nedosegljivo.
4. Vzpon družbenih medijev, kot so Facebook, Instagram in LinkedIn, je podjetnikom omogočil, da si zgradijo občinstvo, tržijo svoje izdelke in si ustvarijo ugled po bistveno nižjih stroških.


Internet torej ni zgolj poenostavil trgovinskih procesov, temveč je temeljito spremenil strukturo konkurence in odprl pot novim, fleksibilnim subjektom (zagonskim podjetjem in MSP-jem) do neposrednega dostopa do potrošnika. Kljub dostopu do potrošnika prek interneta so nove blagovne znamke in podjetja še naprej doživljala akutno pomanjkanje financiranja, saj je tradicionalni bančni sektor ostal konservativen glede inovativnih ali premalo zrelih poslovnih modelov. To je deloma posledica regulativnih zahtev in birokratskih težav pri prilagajanju konservativnih modelov tveganja, deloma pa neskladja ciljev glede tveganja in donosa, zaradi česar je posojanje tej niši za tradicionalne banke ekonomsko nerentabilno, o čemer bomo podrobneje razpravljali v nadaljevanju (Coakley & Lazos, 2021).

V tem kontekstu se je množično posojanje pojavilo kot rešitev, namenjena premostitvi finančne vrzeli. Z izkoriščanjem digitalnih platform in odpravljanjem posrednikov bank je množično posojanje omogočilo vlagateljem, tako institucionalnim kot malim, da neposredno financirajo posojilojemalce. Platforme, kot so Funding Circle (VB), Iwoca (VB) in Mintos (EU), so razvile robustne sisteme točkovanja in avtomatizirane postopke odobritve za ocenjevanje vlog za posojila (Funding Circle, 2025), kar je omogočilo hitrejša in prilagodljivejša odločitve o posojanju na podlagi alternativnih virov podatkov (Iwoca, 2018).

Podobno kot se družbeni mediji uporabljajo za trženje, platforme za množično posojanje uporabljajo digitalne tehnologije za predstavitev projektov, izvajanje skrbnega pregleda in upravljanje finančnih transakcij. Množično posojanje torej ni le nova finančna storitev, temveč nujna posledica digitalne revolucije. Demokratiziralo je dostop do kapitala za subjekte, ki so bili prej izključeni iz tradicionalnega finančnega sistema, in postalo pomembna povezava, ki je malim podjetjem, ki so že imela dostop do potrošnikov prek interneta, omogočila dostop tudi do kritičnega financiranja.

Zato množičnega posojanja ne smemo razumeti zgolj kot alternativno obliko kredita, temveč kot sestavni del razvijajočega se digitalnega gospodarstva – gospodarstva, ki odraža strukturno preobrazbo načina izmenjave blaga, storitev in kapitala v internetni dobi.

V EU množično posojanje ureja Uredba 2020/1503 o evropskih ponudnikih storitev množičnega financiranja. Ta uredba določa enotna pravila za množično financiranje, ki temelji na naložbah in posojilih.



Slika 1: Statistika EU za leto 2023: ponudniki in vlaganje po vrsti financiranja

Vir: (https://www.esma.europa.eu/sites/default/files/2025-01/ESMA50-2085271018-4039_ESMA_Market_Report_-_Crowdfunding_in_the_EU_2024.pdf)

Financiranje na podlagi posojil v EU je razdeljeno na naslednje vrste (European Securities and Markets Authority, 2025):

- Množično financiranje na podlagi posojil je najpogostejša oblika financiranja v EU, ki predstavlja 65 % celotnega zneska zbranih sredstev v letu 2023 (slika 1). Leta 2023 je bilo predlaganih skoraj 5000 takšnih projektov, v katerih je sodelovalo več kot 1,7 milijona vlagateljev. Povprečni znesek zbranih sredstev je znašal približno 15.000 EUR, kar je bistveno manj kot pri projektih z dolžniškim in lastniškim kapitalom;

- množično financiranje na podlagi dolga je predstavljala 17 % vseh zbranih sredstev v letu 2023. Ključna značilnost te vrste financiranja je, da vključuje izdajo prenosljivih dolžniških vrednostnih papirjev. Vlagatelji v takšnih shemah lahko običajno prodajo svoj delež drugemu vlagatelju na platformi za plačilo. Povprečni znesek zbranih sredstev na projekt je bil okoli 53.000 evrov;
- množično financiranje na podlagi lastniškega kapitala je leta 2023 predstavljala 6 % vseh zbranih sredstev. Financiranje se izvaja z nakupom prenosljivih lastniških vrednostnih papirjev. Povprečni znesek zbranih sredstev na projekt je bil okoli 46.000 evrov;
- druge vrste financiranja.

2.2 Tveganja pri množičnem posojanju

Platforma za množično posojanje je del trga neposrednega posojanja. Zato so v razmerju tri stranke, ki oblikujejo svoja tveganja: tveganja vlagateljev, tveganja posojilojemalcev in tveganja platforme za množično posojanje.

Razumevanje teh tveganj je ključnega pomena za zagotavljanje trajnostne rasti in integritete trga.

Tveganja za posojilojemalce

Visoke obrestne mere: te zmanjšujejo finančno vzdržnost poslovnega modela. Ker se mora vsako podjetje v tržnem gospodarstvu osredotočiti na povprečno tržno ceno in konkurenco, je poslovna marža v ozkem koridorju. Ko se uresničijo operativna tveganja, visoka obremenitev z obrestnimi merami naredi poslovni model nestabilen glede na zunanje stresne dejavnike.

Togi pogoji odplačevanja: za razliko od revolving kreditov posojila za množično posojanje pogosto zahtevajo fiksne amortizacijske načrte. Posojilojemalci morajo odplačevati dolg ne glede na nestanovitnost prihodkov, kar povečuje tveganje za operativne težave.

Omejitev zneskov posojil: v praksi platforme za množično posojanje pogosto privabljajo le majhna posojila, s povprečnim zneskom posojila približno 15.000 evrov. Operativno je dražje nenehno zbirati denar na različnih platformah, kar ne omogoča osredotočanja na ključna vprašanja razvoja poslovanja.

Tveganja za vlagatelje (posojilodajalce)

Kreditno tveganje/tveganje neplačila: glavno tveganje za posojilodajalce je tveganje neplačila. Stečaj posojilojemalca vodi do izgube vloženih sredstev. Leta 2022 je bila povprečna stopnja

neplačila pri množičnem posojanju kreditov za MSP-je v EU približno 3,6 % (European Securities and Markets Authority, 2025). Vendar pa tako kot pri tradicionalnem bančništvu skupna stopnja neplačila morda ne odraža dejanskega deleža slabih posojil, ki zamujajo s plačili in imajo znatno tveganje neplačila v prihodnjih obdobjih.

Informacijska asimetrija: MSP-ji in zagonska podjetja pogosto zagotavljajo omejene podatke o kreditni zgodovini in finančnih podatkih. Zaradi tega vlagatelji težko natančno ocenijo tveganja, saj so lahko informacije, ki so na voljo za sprejemanje naložbene odločitve, nepopolne ali premalo pregledne.

Likvidnostno tveganje: večina posojil, financiranih z množičnim financiranjem, je nelikvidnih, ker ni sekundarnih trgov, ki bi posojilodajalcem omogočali prodajo delov posojil pred zapadlostjo. To pomeni, da so sredstva vlagateljev vezana, dokler posojilo ni odplačano.

Tveganje platforme: sama platforma za množično posojanje lahko bankrotira ali slabo upravlja posojila. Ker ni pod obsežno regulativno zaščito kot banke, to poveča tveganja za vlagatelje ob morebitnem propadu.

Tveganje kršitev podatkov vlagateljev: če je platforma napadena, bi lahko bili ukradeni občutljivi podatki vlagateljev, saj morajo vsi vlagatelji opraviti postopek KYC.

Tveganje koncentracije: posamezni posojilodajalci se lahko preveč izpostavijo eni sami platformi ali sektorju posojilojemalcev. Brez ustrezne diverzifikacije lahko skupina neplačil povzroči nesorazmerno izgubo.

Platforme za množično financiranje v EU morajo biti skladne z uredbo ECSPR (september 2023). Ta zahteva, da platforme vlagateljem in nadzornikom razkrijejo metode kreditnega ocenjevanja, oblikovanje cen in okvire za upravljanje tveganj. Pričakovano je ustrezno upravljanje, vendar je študija pokazala, da je povprečna transparentnost le 5/10, saj je skoraj 40 % platform ocenjenih kot »ogrožene« zaradi slabega razkritja. Vlagateljem se svetuje, da pred sklenitvijo pogodbe pregledajo zgodovinske stopnje neplačil in ugled platforme (Eurocrowd, 2025).

Tveganja platforme

Tveganje napačne cene: platforme določajo obrestne mere in provizije na podlagi tveganja, če modeli kreditnega točkovanja napačno izračunajo tveganje, so lahko posojila podcenjena – kar ogroža trajnost platforme – ali precenjena – kar odvrča posojilojemalce in zmanjšuje dostop do trga. Študija »Tveganja in donosi pri množičnem posojanju« (Adhami in drugi,

2019) je proučila 4130 posojilnih transakcij na 68 evropskih platformah med letoma 2012 in 2017 s skupnim obsegom financiranja v višini 931 milijonov EUR. Rezultati so pokazali pomembnost tveganja napačnega oblikovanja cen:

Inverzno razmerje med tveganjem in donosom: posojila z višjo stopnjo tveganja pogosto prinašajo nižje ponujene donose, kar je v nasprotju s tradicionalnimi trgi.

Neučinkovitost oblikovanja cen: prisotnost zavarovanja (70 % posojil je bilo prednostnih) ni vodila do nižjih obrestnih mer. To kaže, da na ceno bolj vplivajo trženjske strategije kot natančna ocena kreditnega tveganja.

Vedenje vlagateljev: analiza je potrdila vpliv vedenjske dinamike: 1-odstotno povečanje ponudbe poveča verjetnost dodatnih ponudb za 15 %.

Kreditno tveganje: nenatančna ocena tveganja lahko privede do povečanih neplačil in povečanja izgub.

Tveganje za ugled in upravljanje: napake pri upravljanju platforme, kot sta slabo vodenje evidenc ali navzkrižje interesov.

Likvidnostno tveganje za delovanje platform: medtem ko se posojilodajalci soočajo z nelikvidnostjo posojil, se platforme soočajo tudi z nestanovitnostjo denarnega toka – na primer neizterjava poplačil moti poslovanje in izplačila vlagateljem.


Regulativno/skladnostno tveganje: neupoštevanje standardov ECSPR lahko povzroči prekinitev poslovanja.

Nedvomno je zemljevid tveganj, tako kot pri vsakem poslu, obsežen, a ker je bistvo množičnega posojanja posojanje, je najpomembnejše tveganje kreditno tveganje. Čeprav je to tveganje dodeljeno vlagateljem, platforma vseeno nosi znatna tveganja za ugled, povezana z njenim preživetjem na trgu, upravljanje kreditnega tveganja pa je ključno področje, saj so prihodki platforme v bistvu storitve ocenjevanja in upravljanja tveganj.

2.3 Profili posojilojemalcev: mala in srednje velika ter zagonska podjetja – ovire za tradicionalni dostop do kreditov za mala in srednje velika ter zagonska podjetja

Poslovni segment ima prevladujoč položaj na evropskem trgu množičnega posojanja, saj je leta 2024 predstavljal približno 69 % celotnega tržnega deleža (slika 2). Ta segment se je

uveljavil kot glavno gonilo rasti, ki ga poganjata vse večje sprejemanje in uporaba spletnih platform za posojanje s strani MSP-jev po vsej Evropi.



Slika 2: Evropski trg množičnega posojanja – tržni delež po poslovnih segmentih (2024)

Vir: (<https://www.mordorintelligence.com/industry-reports/europe-crowd-lending-and-crowd-investing-market>)

Posojilojemalec platforme za množično posojanje je torej MSP ali zagonsko podjetje. Ključne značilnosti takšnih posojilojemalcev so odsotnost kreditne zgodovine, nizka kapitalizacija, izgube in odsotnost likvidnega zavarovanja.

V evropski in britanski praksi je zagonsko podjetje (startup) opredeljeno kot novo podjetje, osredotočeno na inovacije z visokim potencialom rasti. Zanj so značilni inovativen model, negotovost glede rezultatov in močna odvisnost od zunanjega financiranja, kot sta tvegani kapital ali množično financiranje.

MSP-ji so v evropski klasifikaciji opredeljeni kot:

- mala podjetja: do 50 zaposlenih, letni promet ali bilanca stanja do 10 milijonov evrov;
- srednje velika podjetja: do 250 zaposlenih, letni promet do 50 milijonov evrov ali bilančna vsota do 43 milijonov evrov.

V Združenem kraljestvu se uporablja podobna klasifikacija, kjer MSP-ji predstavljajo več kot 99 % vseh podjetij in so ključni dejavnik zaposlovanja in inovacij.

Združeno kraljestvo je vodilno na evropskem trgu množičnega posojanja, saj je leta 2024 predstavljalo približno 47 % celotnega tržnega deleža (Mordor Intelligence, 2025). K tej stalni rasti je prispeval zgodnji in relativno napreden pristop Združenega kraljestva k regulaciji finančne tehnologije, ki ga ponazarja akreditacija platform, kot je Funding Circle, s strani organa za finančno ravnanje (FCA) za vladno podprte sheme (kot je CBILS med pandemijo covida-19) (Shneor in drugi, 2020).

Glede na poročilo Odbora za finance Združenega kraljestva (Treasury Committee, 2024) se je stopnja uspešnosti vlog za bančna posojila MSP-jem zmanjšala s približno 80 % leta 2018 na

približno 50 % leta 2023, kar kaže na strmo zoženje dostopa do konvencionalnega financiranja. Številne vloge so zavrnjene ali od njih odvrača vse večja nenaklonjenost tveganju med posojilodajalci. Leta 2022 je bilo uspešnih le približno 40–45 % finančnih zahtevkov MSP-jev, medtem ko je bil ta delež pred pandemijo približno 65 %. Poleg tega so britanske gospodarske zbornice (British Chambers of Commerce, 2024) ugotovile, da je skoraj 70 % MSP-jev poročalo o poslabšanju dostopa do posojil v zadnjih treh letih, pri čemer jih je le 13 % v zadnjem času ugotovilo, da je ta lažji.

Raziskava Bank of England o MSP-jih iz leta 2024 dodatno poudarja, da se je polovica podjetij za naložbe zanašala izključno na notranja sredstva, pri čemer so kot glavne ovire navedli visoke stroške zadolževanja, omejitve zavarovanj in gospodarsko negotovost (HM Treasury, 2025).

Čeprav so podatki EU nekoliko starejši, so raziskave za obdobje 2020–2021 (European Commission, 2021) poročale o stalnem upadanju razpoložljivosti bančnih posojil za mikro in mala podjetja, zlasti v obliki lastniških in dolžniških instrumentov. Evropska komisija je prav tako označila dostop do financiranja kot najbolj perečo skrb za MSP-je v več državah članicah, zlasti tistih, ki so manjša, bolj inovativna ali mlajša.

Če podrobneje pogledamo delovanja bank, obstaja več razlogov, zakaj je segment malih podjetij za tradicionalne banke neprivlačen in drag:

1. Visoki administrativni in poslovni stroški: banke imajo obsežno fizično infrastrukturo (poslovnice), veliko število osebja, znatne stroške za varnost, skladnost in operativne procese, ki se bistveno ne spreminjajo glede na majhno velikost posojila. Ker so administrativni stroški bank fiksni, obdelava majhnih posojil zahteva enake vire kot velika. To zmanjšuje dobiček in dela servisiranje malih posojilojemalcev neučinkovito. Crowdlending pa, ravno nasprotno, te stroške zaradi popolne digitalizacije minimizira.

2. Prekomerna regulacija in kapitalske zahteve: banke delujejo pod strogimi regulativnimi zahtevami (na primer Basel III), ki jih zavezujejo k oblikovanju znatnih rezerv za kreditna tveganja. Posojila malim in zagonskim podjetjem porabijo več kapitala, saj imajo višjo stopnjo neplačil, kar zahteva znatne kapitalske izdatke za njihovo rezervacijo, kar posledično zmanjšuje dobičkonosnost. Platforme za množično posojanje ne prevzemajo kreditnega tveganja in ga prenašajo na vlagatelje, zato se ne soočajo s podobnimi regulativnimi bremenmi pri oblikovanju rezerv.

3. Pomanjkanje zanimanja za visoko tvegane projekte: banke se osredotočajo na posojilojemalce s stabilnimi kazalniki in dolgo zgodovino. Zagonska podjetja in MSP-ji ne izpolnjujejo teh meril ter predstavljajo visoko tvegan segment. Crowdlending to tveganje prenese na vlagatelje, ki so pripravljeni tvegati za potencialno višji dohodek.

Kombinacija nepreglednosti informacij, slabe kreditne zgodovine in visokih stroškov obdelave ustvarja sistemsko pomanjkljivost za MSP-je in zagonska podjetja znotraj tradicionalnega bančnega sistema, kjer vse zgoraj navedeno velja za »visoko tvegano«.

V tem okolju omejenega dostopa do bank se MSP-ji vse pogosteje obračajo na posojilodajalce s področja finančne tehnologije in tržnic. Na primer anketa v Združenem kraljestvu je pokazala, da 40 % MSP-jev meni, da je lažje pridobiti financiranje od posojilodajalcev s področja finančne tehnologije kot od tradicionalnih bank (Sonovate, 2023). Ista študija je ugotovila, da so posojila s področja finančne tehnologije mnogim MSP-jem pomagala preživeti krizo življenjskih stroškov leta 2023. Poročilo je prav tako poudarilo, da se je 65 % MSP-jev soočalo z vse večjimi ovirami pri bančnem financiranju, zaradi česar so se obrnila k alternativnim virom. Platforme, kot je Funding Circle, so do leta 2024 MSP-jem v Združenem kraljestvu zagotovile več kot 15 milijard funtov posojil (HM Treasury, 2025).

Raziskava Funding Circle je pokazala, da petina posojilojemalcev meni, da ne bi mogli pridobiti zunanjega financiranja brez platforme, tudi če bi bili kreditno sposobni (Shneor in drugi, 2020). Poleg tega 50 % MSP-jev običajno uporablja le enega posojilodajalca. Če je njihova vloga za posojilo zavrnjena, mnoga podjetja izgubijo navdušenje in zaradi negotovosti ne iščejo financiranja drugje. Ta pojav »obupanih posojilojemalcev« lahko privede do zamujenih priložnosti za financiranje, kar zavira inovacije in splošno gospodarsko rast (British Business Bank, 2024). To ponazarja, kako množično posojanje zagotavlja dostop tam, kjer tradicionalni kanali odpovejo, in spodbuja inovacije.

Hkrati platforme za množično posojanje kažejo visoko učinkovitost zaradi optimizacije procesov in uporabe digitalnih tehnologij, kar jim omogoča, da služijo tržnim segmentom, ki so za tradicionalne banke manj privlačni, in imajo pomembne prednosti:

1. Visoka učinkovitost in dostopnost: odločitev o financiranju je spletna in hitra (od 3 minut do 24 ur). Ni treba obiskati banke, dostop do storitev je 24 ur na dan, 7 dni v tednu. To se bistveno razlikuje od počasnih in birokratskih postopkov v tradicionalnih bankah.

2. Ekonomska korist:

- nizki obratovalni stroški: glavni stroški platform so povezani s trženjem in plačami. Digitalizacija vseh procesov omogoča zmanjšanje obratovalnih stroškov za 2–4-krat v primerjavi s povprečno banko;
- platforma deluje po provizijskem modelu in ne ustvarja rezerv za kreditno tveganje.

3. Prilagodljivost: avtomatizirani procesi omogočajo platformam hitro skaliranje brez sorazmernega povečanja stroškov.

4. Privlačnost za vlagatelje: ponujajo višje donose kot depoziti in omogočajo diverzifikacijo tveganj med številna podjetja.

Množično posojanje zapolnjuje geografske kreditne vrzeli, saj prodira na premalo bančna območja in območja z nizkimi dohodki, s čimer spodbuja finančno vključenost.

Čeprav ga pogosto izberejo podjetja, ki jih banke zavrnejo, postaja crowdlending strateška prednost tudi za kreditno sposobne MSP-je. Ključne prednosti so hitrost, udobje, nizki stroški in manjše zahteve glede zavarovanja. Hitrost postopka je pogosto ključna, zaradi česar MSP-ji raje izberejo crowdlending kot dolgotrajne postopke tradicionalnih bank.

Tradicionalne banke pogosto zavračajo vloge za posojila številnih MSP-jev in zagonskih podjetij, ker ne izpolnjujejo strogih meril kreditne sposobnosti. Podjetja, ki nimajo obsežne kreditne zgodovine ali zadostnega likvidnega zavarovanja, so pogosto razvrščena kot visoko tvegana. Stopnja odobritve vlog za posojila MSP-jem v Združenem kraljestvu se je v zadnjih letih znatno zmanjšala, kar kaže na vse večji konservativizem med bankami. Poleg tega tradicionalne banke ne servisirajo malih podjetij zaradi visokih stroškov in strogih predpisov.

Evropski MSP-ji, ki so hrbtenica gospodarstva regije, se vse bolj obračajo na platforme za množično financiranje podjetij, saj ponujajo hitrejši dostop do kapitala v primerjavi s tradicionalnimi bančnimi institucijami. Crowdlending platforme so hitrejše, enostavnejše in nudijo prilagodljivejši postopek pridobivanja sredstev. Z izkoriščanjem digitalizacije in decentraliziranega modela tveganja lahko oskrbujejo tržne segmente, ki jih tradicionalne finančne institucije pogosto ignorirajo. To jasno podpira hipotezo H1: Če je podjetje zagonsko podjetje ali MSP, je verjetnost uporabe platform za množično posojanje za financiranje večja kot pridobivanje financiranja prek tradicionalnih bank.

3 MODELI ZA OCENO TVEGANJA

3.1 *Pregled obstoječih pristopov k modeliranju tveganj v finančnem sektorju (Altmanov Z-rezultat, modeli PD/LGD/EAD)*

Tradicionalno modeliranje finančnih tveganj v bančnem sektorju se močno opira na kvantitativne podatke iz finančnih izkazov. Ti modeli so osnova za odločitve o posojilih in skladnost s predpisi.

Sredi 20. stoletja so se tradicionalne metode analize finančnega stanja podjetij zanašale na strokovne ocene in primerjalna razmerja, kar je pogosto vodilo do subjektivnih zaključkov. Vendar pa je bil Altmanov Z-rezultat leta 1968 predstavljen v delu ameriškega ekonomista Edwarda Altmana z naslovom »Finančna razmerja, diskriminantna analiza in napovedovanje stečaja podjetij«. Njegov cilj je bil ustvariti statistični model za napovedovanje verjetnosti stečaja industrijskega podjetja v dveh letih (Altman, 1968). Altman je izhajal iz hipoteze, da kombinacija finančnih kazalnikov omogoča kvantitativno oceno tveganja finančne nestabilnosti.

Altmanov Z-rezultat temelji na Fisherjevi diskriminantni analizi. Ta metoda omogoča identifikacijo linearne kombinacije spremenljivk, ki maksimizira razliko med dvema skupinama: podjetji, ki so bankrotirala, in podjetji, ki so ostala finančno stabilna. Za izgradnjo modela je Altman uporabil vzorec 66 ameriških industrijskih podjetij, od katerih jih je 33 pozneje bankrotiralo, 33 pa je ostalo finančno stabilnih. Obdobje opazovanja je zajemalo pet let pred stečajem za problematična podjetja in podobno obdobje za »zdrava« podjetja.

Altman je predpostavil, da imajo največji vpliv na finančno stabilnost kazalniki likvidnosti, finančne strukture, dobičkonosnosti in obrata sredstev. Kot rezultat analize je bilo izbranih pet razmerij:

$$X_1 = \text{obratni kapital} / \text{skupna sredstva} \quad (3.1);$$

$$X_2 = \text{zadržani dobiček} / \text{skupna sredstva} \quad (3.2);$$

$$X_3 = \text{dobiček pred obrestmi in davki (EBIT)} / \text{skupna sredstva} \quad (3.3);$$

$$X_4 = \text{tržna vrednost lastniškega kapitala} / \text{skupne obveznosti} \quad (3.4);$$

$$X_5 = \text{prihodki} / \text{skupna sredstva} \quad (3.5).$$

Altman je na podlagi diskriminantne analize dobil naslednjo formulo za industrijska podjetja:

$$Z = 1,2 \times X_1 + 1,4 \times X_2 + 3,3 \times X_3 + 0,6 \times X_4 + 1,0 \times X_5 \quad (3.6)$$

Z-rezultat razvršča podjetja v tri cone: vrednost pod 1,8 kaže na resne finančne težave in veliko verjetnost stečaja, vrednost od 1,8 do 3,0 predstavlja »sivo cono« z zmernim tveganjem, vrednost 3,0 in več pa pomeni »varno cono« z nizko verjetnostjo stečaja. Altman je model preizkusil na vzorcu podjetij in pokazal, da je bila natančnost napovedi stečaja približno 95 % eno leto pred stečajem in 72 % dve leti pred stečajem (Altman, 1968). Te številke so bile bistveno boljše od rezultatov tradicionalne analize, ki temelji na posameznih finančnih kazalnikih.

Prvotna zasnova modela je bila razvita posebej za javno kotirana proizvodna podjetja s premoženjem, ki presega 1 milijon dolarjev. Od objave prvotnega modela je Altmanov Z-rezultat doživel več sprememb:

Z'-rezultat (1983): prilagoditev za zasebna podjetja, kjer tržna vrednost kapitala ni dostopna.

Z''-rezultat (1993): razširitev za mednarodno uporabo, ki upošteva valutne in panožne razlike.

Sodobne metode: od devetdesetih let se Z-rezultat pogosto kombinira z logistično regresijo in strojnim učenjem za napovedovanje neplačil.

Altmanov Z-rezultat se še vedno uporablja kot eno osnovnih orodij za analizo kreditnega tveganja. Sodobne raziskave ga združujejo z naprednimi tehnikami analize podatkov, vključno s strojnim učenjem in modeli za napovedovanje neplačil. Sodobna formula za Altmanov Z-rezultat je (Altman, 1983):

$$Z' = 0,717 \times X_1 + 0,847 \times X_2 + 3,107 \times X_3 + 0,420 \times X_4 + 0,998 \times X_5 \quad (3.7)$$

Modeli PD (Probability of Default), LGD (Loss Given Default) in EAD (Exposure at Default) so temeljne metodologije za merjenje kreditnega tveganja, ki so v zadnjih štirih desetletjih prevladovali v finančnem sektorju, zlasti od uvedbe sporazuma Basel II leta 2004 (Bank for International Settlements, 2020):

- **PD:** verjetnost, da posojilojemalec v določenem obdobju (običajno eno leto) preneha izpolnjevati obveznosti. Je osnova za določanje kreditnega tveganja in regulatornega kapitala. Za podjetniška, državna in bančna posojila je verjetnost neplačila povezana z interno bonitetno oceno posojilojemalca. Verjetnost neplačila v višini 100 % se dodeli posojilojemalcem, ki so že v neplačilu;

- **LGD:** delež izpostavljenosti, ki bi bil izgubljen v primeru neplačila, izražen kot odstotek EAD;
- **EAD:** to predstavlja skupno vrednost, ki ji je banka izpostavljena, ko posojilojemalec ne izpolni svojih obveznosti.

Ti parametri so ključni za izračun pričakovane izgube za vsako izpostavljenost in pričakovane izgube za portfelj kot celoto ter so vhodni podatki za opredelitev tveganju prilagojene aktive (RWA). Ta okvir je robusten in prevladujoč, deloma zaradi regulativne inercije in globoke integracije teh komponent v sisteme upravljanja tveganj bank.

Formula za pričakovano izgubo je (Corporate Finance Institute, brez datuma):

$$EL = PD \times LGD \times EAD \quad (3.8)$$

Vsaka kreditna institucija razvije svoje lastne modele PD/LGD/EAD, vendar deluje v skladu s strogimi regulativnimi pravili.

Banka najprej opredeli obseg modeliranja (produkt, segment, jurisdikcija) in portfelj razdeli na homogene »skupine« (npr. posojila na drobno/MSP, denominirana/zavarovana), v skladu z zahtevami Basla in smernicami EBA, kjer morajo parametri tveganja odražati »dolgoročno povprečje« homogenih skupin in biti skladni z definicijo neplačila.

Kakovost in reprezentativnost podatkov sta ključna pogoja za izgradnjo zanesljivih modelov. Banke uporabljajo obsežne nabore podatkov, ki jih lahko razdelimo v naslednje kategorije:

Interni zgodovinski podatki:

- datum in razlogi za neplačilo, vrsta neplačila, podatki o prestrukturiranju;
- finančni kazalniki posojilojemalca: dobiček, dolg, likvidnost;
- vedenjski podatki: zgodovina plačil, pogostost uporabe kreditnega limita, spremembe vzorcev aktivnosti na računu;
- podatki o izterjavi (za LGD): podrobni zapisi o stroških, povezanih z izterjavo (pravni stroški, stroški cenitve zavarovanja), kot tudi zneski, izterjani s prodajo zavarovanja ali pogajanja.

Zunanji podatki:

- podatki kreditne agencije: informacije o kreditni zgodovini posojilojemalca;
- makroekonomski kazalniki: BDP, stopnja brezposelnosti, inflacija, obrestne mere, indeks cen nepremičnin;

- kazalniki finančnega zdravja in tveganj posameznih gospodarskih sektorjev.

Podatki so temeljito očiščeni, standardizirani in preverjeni. Posledično se za izračun ocen uporabljajo trije razredi podatkov: kvalitativni kazalniki, kvantitativni kazalniki, podatki o kreditni zgodovini.

Pri kvantitativnih kazalnikih ima klasična ocena največji vpliv:

1. likvidnost bilance stanja;
2. stopnja rasti prihodkov;
3. dolgovna obremenitev, vključno z razmerjem med kazalniki in dobičkom ter prihodki;
4. dinamika dobičkonosnosti;
5. razlika med čistim denarnim tokom iz poslovanja in EBITDA.

Pri kvalitativnih kazalnikih imajo največjo težo obdobje delovanja, koncentracija tveganj pri dobaviteljih in kupcih ter panoga dejavnosti.

Vsi modeli upoštevajo makroekonomske cikle in dajejo privzeto napoved za celotno dolžino gospodarskega cikla. Poleg tega so za različne panoge značilne različne hitrosti odzivanja na makroekonomijo, zaradi česar so številne panoge bolj dinamične.

Modeli PD, LGD in EAD so zgrajeni z uporabo različnih statističnih metod in pristopov (European Banking Authority, 2017):

- modeli PD: najpogostejša metoda je logistična regresija (za binarni izid: neplačilo/brez neplačila). Uporabljajo se tudi linearna diskriminantna analiza in modeli preživetja. Metode strojnega učenja (Random Forest, Gradient Boosting) se uporabljajo manj pogosto zaradi zapletene interpretacije in zahtevne regulativne validacije;
- modeli LGD: ocenjuje se z beta regresijo ali dvostopenjskimi pristopi, kjer prva faza napoveduje izterjavo sredstev, druga pa časovno strukturo denarnih tokov. Model LGD upošteva ključne dejavnike, kot so vrsta posojilojemalca, produkt in kakovost zavarovanja. Zaradi različnih stečajnih režimov se LGD med državami močno razlikuje, kar zahteva lokalno kalibracijo;
- model EAD: za neizkoriščene kreditne limite se uporabljajo konverzijski faktorji, ki odražajo zgodovinski delež limita, ki ga bo posojilojemalec verjetno uporabil pred neplačilom. Modeliranje vključuje tudi analizo vedenjskih podatkov za napovedovanje uporabe limitov.

Validacija modelov je dolgotrajen proces, ki pogosto zahteva veliko časa in se ne more hitro odzvati na spremembe. Zato se kreditiranje podjetij ne more zanašati le na kreditne modele, temveč vključuje analizo skupine kreditnih analitikov in strukturiranje (zaveze, individualni parametri posojil, spremenljive omejitve). V primeru mladih podjetij se temu doda še kompleksnost ocenjevanja njihovega tržnega potenciala, za kar metodologija ocenjevanja trenutno ne obstaja. Oblikovanje takšne metodologije bo preboj v finančni analizi, primerljiv z Altmanovim modelom ocenjevanja.

3.2 Problem kakovosti finančnih informacij v malih in zagonskih podjetjih

Eden temeljnih izzivov pri ocenjevanju kreditnega tveganja za zagonska in mala podjetja je odsotnost ali nizka kakovost finančnih podatkov, kar ustvarja informacijsko asimetrijo v primerjavi z uveljavljenimi korporacijami. K temu pojavu prispeva več medsebojno povezanih dejavnikov.

V mnogih jurisdikcijah, vključno z EU in Združenim kraljestvom, so mikro in mala podjetja oproščena obveznosti zakonske revizije. Kombinacija dveh dejavnikov, pomanjkanja revizijskih zahtev in ohlapnih računovodskih standardov za mala podjetja, pomeni, da podjetja morda ne poročajo dosledno o prodaji ali dobičku, neopredmetena sredstva (intelektualna lastnina, blagovne znamke) se ne odražajo v bilanci stanja, nekateri tokovi (lastniške subvencije, menjava) pa se ne odražajo v uradnem poročanju. Čeprav to zmanjšuje upravna in finančna bremena, hkrati ustvarja informacijsko asimetrijo: vlagatelji in upniki ne morejo biti prepričani o točnosti ali popolnosti poročenih podatkov.

Zagonska podjetja nimajo virov za namenske računovodske oddelke, zato knjigovodstvo avtomatizirajo ali oddajo zunanjim izvajalcem. Čeprav so takšne rešitve učinkovite, pogosto vodijo do napak zaradi generičnih predlog ali pomanjkanja človeškega nadzora. Zanašanje na avtomatizacijo povečuje verjetnost napačnih razvrstitev in nepopolne dokumentacije. Zaloge niso redno preverjene, zato razlike med zabeleženim in dejanskim stanjem ostanejo neopažene. To onemogoča izračun zanesljivih stroškov in ocenjevanje likvidnosti podjetja.

Upravljavsko računovodstvo se v MSP-jih in zagonskih podjetjih redko razvija, saj je poudarek na kratkoročnem preživetju in hitrem vstopu na trg. Ustanovitelji se osredotočajo izključno na računovodstvo denarnega toka zaradi zagotavljanja likvidnosti. Nedenarni kazalniki, kot so amortizacija ali rezervacije, so pogosto zanemarjeni. Ker ti ne vplivajo na takojšnje denarne tokove, jih imajo ustanovitelji za nepomembne, kar zmanjšuje kakovost finančnih podatkov.

Podjetja, ki iščejo hitro financiranje prek množičnega posojanja, imajo lahko malo ali nič preteklih prihodkov, saj v zgodnji fazi prevladujejo stroški. Vendar pa morda že imajo delujoč izdelek, podpisane naročilnice ali začetne pogodbe, ki bi lahko kazale na prihodnjo sposobnost preživetja, vendar v tradicionalnih finančnih izkazih ostanejo nevidne. To časovno neskladje med stroški in prihodki zmanjšuje uporabnost preteklih finančnih kazalnikov pri ocenjevanju kreditne sposobnosti.

Posledično so finančne informacije, ki so na voljo pri zagonskih podjetjih, pogosto nepopolne, nedosledne in jim manjka globina, potrebna za tradicionalne modele ocenjevanja kreditnega tveganja. Zato klasični modeli ne morejo učinkovito ločiti med preživetja sposobnimi in nesposobnimi podjetji v tem segmentu, kar predstavlja metodološki izziv za platforme za množično posojanje.

Izzivi pridobivanja visokokakovostnih finančnih informacij za zagonska podjetja in MSP-je neposredno vodijo do njihove napačne razvrstitve kot posojilojemalcev z visokim tveganjem v tradicionalnih finančnih modelih. Altmanov Z-rezultat se na primer opira na finančna razmerja, pridobljena iz poročil, zaradi česar je v veliki meri neprimeren za zagonska podjetja in številne MSP-je, kot bo prikazano v nadaljevanju.

Podobno se modeli PD/LGD/EAD, čeprav robustni za uveljavljena podjetja, spopadajo z omejeno finančno zgodovino in pomanjkanjem preverljivih finančnih podatkov, kar je običajno pri mladih in malih podjetjih. Tradicionalni model predpostavlja določeno raven popolnosti podatkov, ki preprosto ni na voljo mnogim zagonskim podjetjem. Pri izračunu PD kvalitativna značilnost »slaba kakovost poročanja« znatno poslabša končno oceno. Pomanjkanje zavarovanja in visoke pričakovane stopnje neplačil bodo na koncu privedli do visokih pričakovanih izgub v modelih PD/LGD/EAD, zaradi česar bo bankam nepraktično posojati takim strankam. Zato MSP-ji poročajo o strožjih zahtevah glede zavarovanja in manj ugodnih pogojih kot večja podjetja.

Zaradi te sistematične napačne klasifikacije se številni MSP-ji in zagonska podjetja bodisi odpovedo zunanjemu financiranju bodisi se zanešajo na dražje alternativne vire.

Vendar pa pomanjkanje natančnega, pravočasnega in natančnega finančnega poročanja ne odraža nujno inherentnega tveganja poslovnega modela ali ekipe podjetnikov, temveč je omejitev samega orodja za ocenjevanje. Slabost vseh modelov je namreč v tem, da ocenjujejo le pretekle podatke (vključno s kreditno zgodovino), solventnost pa je odvisna od prihodnjih razmer in sposobnosti podjetja, da se pravočasno odzove na spremembe na trgu.

Za dokaz hipoteze 2 bosta uporabljena Altmanov Z-rezultat in nabor podatkov ene izmed evropskih platform za množično posojanje, ki izdaja posojila pretežno podjetjem, delujočim na trgu Združenega kraljestva (priloga 1).

Glede na podatkovno zbirko platforme so bila posojila izdana 64 podjetjem, vključno s tistimi, ki niso vložila finančnih izkazov. V zadnjih treh letih je bilo v tej podatkovni zbirki deset dejanskih neplačil. Na podlagi izračunov z uporabo Altmanovega Z-rezultata so bili pridobljeni spodnji rezultati modela.

Tabela 1: AUC po Altmanovem Z-rezultatnem modelu

Metrika	Vrednost
Neplačila (Defaults)	10
Posojila brez neplačila (Non-defaults)	54
Vsota rangov neplačil (Sum of default ranks)	368
AUC (Area Under Curve)	0,58

Vir: (Lastni vir)

AUC je široko uporabljena metrika pri ocenjevanju kreditnega tveganja, ki ocenjuje diskriminatorno sposobnost modela kreditnega točkovanja – kako natančno loči zanesljive posojilojemalce od tistih, ki so nagnjeni k neplačilu. AUC se giblje od 0,5 (naključna napoved) do 1,0 (popolna napoved), pri čemer višje vrednosti kažejo na večjo napovedno moč (Google, brez datuma).

AUC, ki temelji na Altmanovem Z-rezultatnem modelu, je bil izračunan z uporabo Mann-Whitneyjeve formule za rang (3.9). Ker je AUC odvisen le od vrstnega reda objektov, specifične vrednosti ne vplivajo na končni rezultat (tabela 1).


$$AUC = (vsota\ rangov\ neplačil - (neplačila \times (neplačila + 1)) / 2) / (neplačila \times posojila\ brez\ neplačila) \quad (3.9)$$

Krivulja Receiver Operating Characteristic (ROC) je bila zgrajena s pomočjo skripta v programskem jeziku Python, AUC pa je bil med gradnjo preračunan z uporabo knjižnice scikit-learn in njenih funkcij `roc_auc_score` (Google, brez datuma).

Na podlagi rezultatov izračuna je ugotovljeno, da je model nekoliko boljši od naključnega ugibanja (slika 3), vendar je njegova diskriminatorna sposobnost zelo šibka in ni primeren za mlada in pogosto nedonosna podjetja.

V resničnem testu Altmanovega Z-rezultata je bilo ugotovljeno, da 41 posojilojemalcev spada v območje visokega tveganja, medtem ko jih le osem dejansko ne izpolnjuje pogojev za plačilo. 41 posojilojemalcev predstavlja 64 % vseh podatkov, medtem ko 80 %

posojilojemalcev, ki jih je Altmanov Z-rezultat razvrstil kot tiste z visoko verjetnostjo stečaja, pravočasno odplača svoj dolg. Če bi se torej platforma pri odločanju o posojilu zanašala le na finančne kazalnike, bi izgubila 51,6 % vseh svojih trenutnih posojilojemalcev.



Slika 3: ROC za Altmanov Z-rezultat

Vir: (Lastni vir)

Praktični preizkus je pokazal, da Altmanov Z-rezultat napačno razvršča več kot polovico posojilojemalcev, ki redno odplačujejo posojila kot »visoko tvegana«. Zato so tradicionalni modeli slabo uporabni za mlada in mala podjetja. Ti modeli se namreč zanašajo na kvantitativne finančne metrike, ki pogosto ne odražajo resničnega potenciala, kakovost poročanja MSP-jev je pogosto nizka zaradi pomanjkanja revizije, virov in zrelih sistemov upravljanja. To potrjuje hipotezo H2: Če se zagonska podjetja in MSP-ji ocenjujejo z uporabo tradicionalnih modelov finančnega tveganja (npr. dobičkonosnost, dinamika prihodkov, razmerje med dolgom in kapitalom), potem obstaja večja verjetnost njihove napačne razvrstitve med posojilojemalce z visokim tveganjem. Omejitev tradicionalnih modelov le na natančna poročila poudarja nujno potrebo po bolj prilagodljivih in vključujočih metodologijah ocenjevanja tveganj za segmente malih in zagonskih podjetij, ki lahko uporabljajo širši nabor informacij.

4 ANALIZA IZZIVOV PRI RAZVOJU MODELOV TVEGANJA ZA POSOJILJEMALCE MNOŽIČNEGA POSOJANJA

4.1 Kombinirani pristop k ocenjevanju tveganja z »mehkimi informacijami« (kazalnika, specifična za ustanovitelja: spletna prisotnost in zgodovina zbiranja kapitala)

Ker klasični modeli ocenjevanja tveganja za zagonska podjetja izkrivljajo dejansko sliko tveganja, modeli za ocenjevanje teh podjetij zahtevajo vključitev dodatnih metrik »mehkih informacij«. Mehke informacije v modelih ocenjevanja kreditnega tveganja so kvalitativni, težko formalizirani podatki o posojiljemalcu, ki niso predstavljeni v standardnih finančnih izkazih in jih ni mogoče preprosto kvantificirati. Za razliko od finančnih metrik se mehke informacije oblikujejo z opazovanjem, izkušnjami interakcije in ocenami strokovnjakov.

Primeri mehkih informacij vključujejo ugled in izkušnje podjetnika, značilnosti poslovnega modela in tržne niše ter informacije o ekipi.

Več študij kaže, da vključitev »mehkih informacij« izboljša natančnost kreditnega ocenjevanja, še posebej pri informacijsko nepreglednih posojiljemalcih. Model strojnega učenja, ki uporablja alternativne digitalne podatke o transakcijah iz aplikacije za dostavo, se je izkazal za učinkovitega pri napovedovanju kreditne sposobnosti posojiljemalcev brez kreditne zgodovine in je dosegel AUC 0,796. Ta vrednost presega priporočene pragove 0,6 za pomanjkljive podatke in 0,7 za podatkovno bogata okolja. Druga študija je pokazala, da so modeli, ki uporabljajo samo podatke kreditnih agencij, dosegli AUC 0,683, modeli, ki temeljijo izključno na netradicionalnih podatkih, so dosegli AUC 0,7, medtem ko so kombinirani modeli dosegli najvišjo natančnost 0,73 (Chioda in drugi, 2024).

Dokazano je, da so digitalni odtisi (informacije, ki jih uporabniki pustijo na spletu, ko dostopajo do spletnega mesta ali se registrirajo) enako dobri ali boljši od tradicionalnih ocen. Model, ki je uporabljal samo digitalne odtise, je dosegel AUC 0,696, kar je preseglo natančnost modela, ki je uporabljal le ocene kreditnih agencij AUC 0,683 (Berg in drugi, 2018).

Študija podatkov platforme Prosper je pokazala, da posojilodajalci na trgih P2P ocenjujejo kreditno sposobnost posojiljemalcev z uporabo nepreverjenih informacij, ki napovedujejo

neplačilo za 45 % natančneje kot kreditne ocene, pridobljene izključno iz podatkov kreditnih agencij (Shneor in drugi, 2020). Druga študija majhnih posojil francoske socialne banke je poudarila pomen vključitve nepreverjenih informacij (zlasti o kakovosti upravljanja) za izboljšanje napovedovanja neplačila posojil, pri čemer je bilo ugotovljeno, da manj pregleden, kot je posojilojemalec, višja je napovedna vrednost nepreverjenih informacij (Cornée, 2015).

Študija platforme AngelList, namenjene množičnemu financiranju prek družbenih omrežij, je pokazala, da je angažiranost na družbenih omrežjih (npr. število tvitov, objav, novih sledilcev) močno povezana z uspehom množičnega financiranja, metode strojnega učenja pa lahko na podlagi teh podatkov in drugih metrik napovejo uspeh s 84-odstotno natančnostjo (Zhang in drugi, 2017).

Ti rezultati kažejo, da lahko alternativni podatki sami po sebi prekašajo tradicionalne podatke, medtem ko se kombinirani pristop izkaže kot optimalen.

Regulativni okviri v EU in Združenem kraljestvu dovoljujejo uporabo alternativnih podatkov, ob upoštevanju načel pravičnosti in kakovosti modela (European Banking Authority, 2020). Evropski bančni organ zahteva ustrezno upravljanje podatkov pri sklepanju zavarovanj. Poleg tega Splošna uredba EU o varstvu podatkov nalaga omejitve za odločitve, ki temeljijo izključno na avtomatizirani obdelavi, in zahteva mehanizme »človeškega vključevanja« (Information Commissioner's Office, 2023).

To opredeljuje splošno arhitekturo za oblikovanje modelov tveganja za množično posojanje: standardne finančne podatke, razločljive »mehke« funkcije in nadzor s strani zavarovalnice.

Za testiranje »mehkih« značilnosti na prejšnjem naboru podatkov bo implementiranih sedem dodatnih kazalnikov, skupaj z njihovo interpretacijo v okviru kreditnega modela (tabela 2).

Teorija informacijske asimetrije pojasnjuje vključitev kazalnikov X6, X7 in X11, saj družbena vidnost zmanjšuje informacijski razkorak glede javne prepoznavnosti in učinkovitosti trženja, profesionalna omrežja signalizirajo dostop do virov in strokovnjakov, struktura kapitala pa vpliva na kompleksnost odločanja in potencialni konflikt interesov. Skupaj ti kazalniki delujejo kot signali zaupanja in pomagajo premagati pomanjkanje zanesljivih revidiranih finančnih informacij.

Teorija človeškega kapitala trdi, da so znanje, spretnosti in izkušnje oblika kapitala ter da naložbe v ta vir, na primer v izobraževanje, povečujejo produktivnost ter s tem prihodnje dohodke posameznika in družbe kot celote. Kazalnik X8 je utemeljen, ker pretekle

podjetniške izkušnje povečujejo sposobnost učenja in sprejemanja kakovostnih odločitev, medtem ko X9 (zgodovina stečajev) odraža akumulacijo izkušenj skozi neuspehe.

Tabela 2: Kazalniki »mehkih informacij« za oceno kreditnega tveganja

Koda	Kazalnik	Teoretična utemeljenost	Omejitve in tveganja	Interpretacija in uporaba v modelu
X6	Število sledilcev na družbenih omrežjih	Kazalnik tržne prepoznavnosti in moči blagovne znamke. Število sledilcev odraža potencial povpraševanja in tržni doseg. Velikost spletnega občinstva pomembno povečuje verjetnost uspešnega pridobivanja sredstev.	Visoka možnost manipulacije (boti, kupljeni sledilci). Različna struktura občinstva po platformah (LinkedIn, Instagram, TikTok). Šibka korelacija s prihodki brez upoštevanja vključenosti uporabnikov.	Priporočljivo ga je normalizirati po panogi in dopolniti z metrikami aktivnosti (všečki, komentarji, rast).
X7	Velikost in struktura profesionalnega omrežja ustanovitelja	Odraža socialni kapital in ugled podjetnika. Velika mreža stikov (npr. LinkedIn, Facebook) je povezana z manjšim tveganjem neplačil (Ramadhani in drugi, 2022).	Možnost manipulacije (kupljeni stiki). Nehomogena kakovost povezav (tesni stiki proti pasivnim sledilcem). Zahteva normalizacijo glede na panogo in velikost podjetja.	Faktor zaupanja in odpornosti. Priporočljivo je uporabiti utežene kazalnike kakovosti omrežja (glede na ustreznost, položaj, panogo).
X8	Predhodne podjetniške izkušnje ustanovitelja	Pridobljeno znanje in izkušnje izboljšujejo kakovost odločitev. Serijski podjetniki pogosteje dosegajo uspeh. Predhodni neuspehi lahko povečajo prilagodljivost.	Možna precenitev zaradi pristranskosti preživelih (survivor bias). Uspeh v eni panogi ne zagotavlja uspeha v drugi.	Kategorialna spremenljivka prisotnosti/odsotnosti izkušenj z upoštevanjem konteksta panoge in trajanja izkušenj.
X9	Zgodovina stečajev ustanovitelja	Močan negativen signal kreditne sposobnosti. Stečaj pogosto poslabša dostop do financiranja, vendar raziskave kažejo na »feniksov učinek« – pridobivanje izkušenj in večja odpornost po neuspehu (Van Kesteren in drugi, 2017).	Možni napačni negativni signali: vsi stečaji ne pomenijo nesposobnosti.	Kategorialna spremenljivka prisotnosti/odsotnosti. Razlikovati med destruktivnimi in učnimi primeri.
X10	Lastniški delež ustanoviteljev	Visok osebni kapital zmanjšuje tveganje oportunističnega vedenja. Srednje visoka udeležba je povezana z optimalnim ravnovesjem med tveganjem in nadzorom.	Nelinearni vpliv: pri nizkih ravneh – šibka vključenost; pri 100 % – pomanjkanje zunanjega nadzora. Odvisno od strukture financiranja..	Odstotek lastniškega deleža ustanovitelja ali diskretna spremenljivka (nizek, srednji, visok). Interpretirati je treba v kontekstu preteklih finančnih odločitev.
X11	Število delničarjev in ustanoviteljev	Povezano s kakovostjo korporativnega upravljanja in porazdelitvijo odgovornosti. Timi z dvema ali več ustanovitelji izkazujejo večjo odpornost in višjo verjetnost uspeha (Honoré, 2022).	Preveliko število udeležencev lahko oteži sprejemanje odločitev in povzroči konflikte. Učinek je odvisen od faze razvoja zagonskega podjetja.	Obravnavati v kontekstu razvojne faze. Optimum – 2–3 ustanovitelji; v zreli fazi diverzifikacija vlagateljev povečuje stabilnost.
X12	Razmerje med 12-mesečnimi naložbami na tekočem računu in povprečnimi prihodki	Kaže odvisnost od zunanjega financiranja. Visoka vrednost lahko odraža bodisi zaupanje vlagateljev (v fazi rasti) ali pa tveganje likvidnosti (v obdobju stagnacije prihodkov).	Potrebna je natančna klasifikacija prilivov. Možna izkrivljanja zaradi sezonskosti ali cikličnosti panoge.	Visok delež naložb je sprejemljiv v fazi rasti, a tvegan ob upadu prodaje. Priporočljiva je normalizacija glede na fazo življenjskega cikla.

Vir: (Lastni vir)

Izbrani kazalniki (X6–X12) so tesno povezani s premagovanjem informacijske asimetrije, vedenjskimi financami in teorijo človeškega kapitala.

Koncepti vedenjskih financ se odražajo v X10 in X12: lastniški delež ustanoviteljev vpliva na usklajenost interesov in preprečuje oportunistično vedenje, razmerje med naložbami in prihodki pa kaže na optimizem vlagateljev. Skupaj ti kazalniki pretvarjajo ključne vidike informacijskega, človeškega in vedenjskega kapitala v specifične, merljive metrike, ki vplivajo na verjetnost neplačila in uspešnost podjetja.

Zbiranje kazalnikov za model se izvaja na avtomatiziran način, potem ko podjetje izpolni spletno vlogo za pridobitev posojila. Spletni vprašalnik vključuje registracijske podatke podjetja, osebne podatke ustanovitelja in njegovih soustanoviteljev, ime spletne strani, povezave do osebnih družbenih omrežij ustanoviteljev ter povezavo z bančnimi računi.

Podatki o številu sledilcev ustanoviteljev se zbirajo iz omrežja LinkedIn prek uradnega LinkedIn API. Če ustanovitelj v spletni vlogi navede povezavo do drugega družbenega omrežja, se podatki zberejo ročno.

Podatki o številu sledilcev podjetja se pridobijo z algoritmi za prepoznavanje vzorcev naslovov URL na spletni strani podjetja, nakar klici API-ja do platform, kot so X, Facebook in Instagram, vrnejo število sledilcev.

Prejšnja podjetja ustanovitelja se identificirajo z ujemanjem imen iz LinkedIna in javnega registra prek API-ja Companies House. To omogoča potrditev preteklih podjetniških izkušenj in zbiranje podatkov o zgodovini stečajev.

Podatki o kapitalski strukturi in lastniških deležih se prav tako zbirajo prek API-ja Companies House iz razdelkov Persons with Significant Control in Confirmation Statement z rednim posodabljanjem.

Samodejno pridobljeni izpiski se obdelajo za namen izračuna zneska investicij v zadnjih 12 mesecih.

Tak pristop zagotavlja visoko ponovljivost, minimalno človeško posredovanje in možnost sprotnega posodabljanja kazalnikov ob spoštovanju standardov zaupnosti.

Za oceno napovedne sposobnosti modela z zgoraj navedenimi spremenljivkami je bil uporabljen skript v programskem jeziku Python, ki izvaja metodo linearne diskriminantne analize (LDA) in logistično regresijo, izračunano prek spletnega orodja (StatsCalculators Team, 2025).

V skript in na spletno mesto so naloženi izvorni podatki iz priloge 1. Stolpec »Neplačila« vsebuje binarno ciljno spremenljivko, stolpci X1–X12 pa prediktorje.


Model LDA išče linearno kombinacijo značilnosti, ki optimalno loči razrede: neplačilo in brez neplačila. Logistična regresija ocenjuje verjetnost, da podjetje spada v razred »neplačilo«, na podlagi uteženih prispevkov posameznih napovednih spremenljivk X1–X12.

Za oceno napovedne moči modela LDA sta bila uporabljena dva pristopa:

- izračun In-Sample AUC je služil za prikaz maksimalne sposobnosti modela razložiti podatke, vendar pogosto daje optimistično oceno;
- stratificirana 5-blokovna navzkrižna validacija (CV) je bila uporabljena za zanesljivejšo oceno. Izvorni podatki so bili razdeljeni na pet enakih, neprekrivajočih se blokov, pri čemer je stratifikacija ohranila enak delež ciljnega razreda. Postopek se je ponovil petkrat: en blok je bil testni, štirje so bili učni. Izračunana sta bila aritmetična sredina petih AUC in standardni odklon ($\pm\sigma$), kar zagotavlja bolj realistično oceno delovanja modela na novih podatkih.

Rezultati modela LDA: izvedena analiza je pokazala visoko napovedno sposobnost izbranega nabora dejavnikov. Vrednost In-Sample AUC kaže, da je model sposoben z 90,9-odstotno natančnostjo rangirati posojilojemalce, ki so v neplačilu (slika 4). To je bistveno preseglo Altmanov model z AUC 0,580. Po ponovnem izračunu končne vrednosti s koeficienti (priloga 2) je vseh deset posojilojemalcev v neplačilu imelo oceno manj kot –4 (priloga 1). Rezultati navzkrižne validacije so pokazali CV AUC $0,853 \pm 0,031$, kar predstavlja zanesljivo oceno delovanja modela na novih podatkih. Vrednost 0,853 potrjuje, da ima model visoko napovedno moč, opazovana zmerina razlika med In-Sample AUC in CV AUC v višini 0,056 pa kaže, da je model stabilen in učinkovit za praktično uporabo.

Rezultati logistične regresije: izračun je pokazal (priloga 3) visoko statistično značilnost modela (likelihood ratio test = 47,10, verjetnost napake $p < 0,001$) in močno pojasnjevalno sposobnost (McFaddenov $R^2 = 0,85$). To kaže, da vključeni prediktorji – tako finančni kot nefinančni – skupaj dobro opisujejo verjetnost nastopa neplačila.



Slika 4: ROC za 12-faktorski model

Vir: (Lastni vir)

Logistična regresija je pravilno razvrstila 96,9 % opazovanj, $AUC = 0,993$, kar kaže na visoko napovedno natančnost. Modelna enačba:

$$P(d = 1) = 1 / (1 + \exp(- (14,1090 - 3,6502 \times X_1 - 6,5237 \times X_2 - 13,3917 \times X_3 + 27,2710 \times X_4 - 1,6258 \times X_5 - 0,0006 \times X_6 - 0,0081 \times X_7 - 220,2579 \times X_8 - 202,5971 \times X_9 - 0,0451 \times X_{10} - 2,7139 \times X_{11} - 113,9159 \times X_{12}))) \quad (4.1)$$

Kljub visokim vrednostim AUC je treba opozoriti na naslednje omejitve, ki vplivajo na reprezentativnost rezultatov:

- zelo majhen vzorec (64 podjetij), ki predstavlja celoten razpoložljiv nabor podatkov platforme za množično posojanje; zato lahko spremembe v podatkih, kot sta dodajanje ali odstranitev nekaj posojiljemalcev, pomembno vplivajo na rezultate modela;
- podjetja, ki so dosegla fazo pridobivanja posojil, so že opravila začetno oceno skladnosti z minimalnimi poslovnimi zahtevami platforme (dejavnost, obseg poslovanja) in zato odražajo skupino posojiljemalcev, značilnih za to platformo, ne pa celotnega trga;
- podatki so bili zbrani v kratkem obdobju delovanja platforme in ne zajemajo makroekonomskih ciklov srednje dolžine.

Model je zato treba v trenutni obliki obravnavati kot pilotsko različico. Z večjim številom podatkov se bo vrednost AUC verjetno zmanjšala, zato bo potrebno ponovno usposabljanje modela, kar je običajen pristop. Ob upoštevanju teh omejitev je v začetni fazi delovanja platforme glavna priporočena praksa za nadzor kreditnega tveganja vključitev dodatnega strokovnega mnenja kreditnega analitika.

Kljub temu pridobljeni rezultati potrjujejo pomen »mehkih« dejavnikov pri oceni kreditnega tveganja zagonskih podjetij in MSP-jev. Mehke informacije povečujejo napovedno moč modelov za oceno tveganja zagonskih podjetij in MSP-jev, ker:

- nadomeščajo pomanjkanje zgodovinskih finančnih podatkov;
- odražajo nematerialne dejavnike stabilnosti (kakovost upravljanja, mrežo povezav, ugled);
- zajemajo vedenjska in institucionalna tveganja;
- povečujejo diskriminacijsko sposobnost modela pri omejenih vzorcih;
- zmanjšujejo sistematična izkrivljanja z diverzifikacijo virov podatkov.

Logistična regresija je pokazala visoko statistično značilnost in 85-odstotno pojasnjevalno sposobnost predlaganega kombiniranega modela, kar dokazuje, da »mehke« informacije izboljšujejo modele ocenjevanja kreditnega tveganja, zlasti pri informacijsko nepreglednih in zgodnjih podjetjih. Primerjava z Altmanovim modelom kaže opazno izboljšanje kakovosti napovedi – povečanje natančnosti klasifikacije za 27,3 odstotne točke (z 0,58 na 0,853). Ti rezultati so skladni z empiričnimi ugotovitvami prejšnjih raziskav, predstavljenih na začetku poglavja, ki kažejo, da alternativni podatki, kot so digitalni odtisi ali aktivnost na družbenih omrežjih, dosegajo enako ali celo višjo napovedno natančnost kot tradicionalni finančni kazalniki. To potrjuje hipotezo, da vključitev kvalitativnih dejavnikov v modele tveganja vodi do višjih rezultatov AUC pri napovedovanju kreditnega tveganja na crowdlending platformah v primerjavi z modeli, ki temeljijo izključno na tradicionalnih finančnih kazalnikih.

4.2 Izzivi pri standardizaciji in skaliranju modelov na podlagi kombiniranih podatkov

Kljub očitnim prednostim vključevanje alternativnih podatkov v modele kreditnega tveganja predstavlja številne pomembne izzive, povezane s kakovostjo, standardizacijo in regulacijo.

Glavne težave alternativnih podatkov so njihova nepopolnost, nestrukturirana narava in morebitna pristranskost. Za razliko od tradicionalnih finančnih izkazov prihajajo iz različnih virov – družbenih medijev, javnih registrov in podatkovnih baz – ter zahtevajo precejšen trud za združevanje, normalizacijo in preverjanje njihove točnosti. Obdelava takšnih podatkov z metodami umetne inteligence zahteva znatne naložbe v analitiko. Uporaba neakovostnih ali pristranskih informacij lahko vodi do netočnih bonitetnih ocen. Poleg tega subjektivna narava

nekaterih podatkov, kot je medijska pokritost, zahteva razvoj enotnih standardov za njihovo numerično predstavitev v modelih.

Za zbiranje »mehkih informacij« se uporabljajo tako avtomatizirana orodja (API-ji, spletno strganje) kot ročno zbiranje podatkov. API-ji, kot je dostop do Crunchbasea, omogočajo relativno čiste in strukturirane podatke, vendar so omejeni po obsegu in vsebini. Spletno strganje zagotavlja širok nabor informacij (družbeni mediji, novice), vendar prinaša tveganja glede kakovosti ter pravne in etične pomisleke. Kombinacija teh dveh strategij velja za optimalno strategijo: prednost imajo profesionalni, preverljivi viri, javno spletno strganje pa se uporablja le v okviru strogih pravnih in etičnih smernic.

Ključni viri podatkov o zagonskih ekipah vključujejo profile na LinkedInu, informacije iz Crunchbasea, medijske objave ter strani podjetij in ustanoviteljev na družbenih omrežjih. LinkedIn je dragocen, ker vsebuje podrobne življenjepise, znanja in omrežne povezave. Ti podatki se aktivno uporabljajo pri raziskavah in ocenjevanju: analiza besedila profila pomaga oceniti osebnostne lastnosti in poklicno ozadje. Crunchbase združuje podatke o krogih financiranja in ekipah, ki zajemajo milijone organizacij in več sto tisoč ustanoviteljev, ter se pogosto uporablja tako v akademskih kot v tržnih raziskavah.

Vendar pa je avtomatizacija analize alternativnih podatkov zapletena. Prvič, podatki družbenih medijev so heterogeni in prenasičeni z nepomembno vsebino, kar zahteva predhodno filtriranje (npr. izbiranje samo objav iz profesionalnih omrežij) in prepoznavanje ustreznih značilnosti, kot so lokacije, nazivi delovnih mest in panoge (Ramadhani in drugi, 2022). Drugič, opredelitev konteksta je prav tako dvoumna: katere informacije so strokovne, kaj predstavlja avtorsko vsebino in kaj predstavlja profesionalni marketing? Avtomatizirana analiza profilov z uporabo NLP in strojnega učenja zahteva pripravo velikih učnih naborov za razvrščanje besedilnih podatkov za namene kreditne ocene, zaradi česar je naloga netrivialna in zahteva veliko virov.

Poleg tega so viri podatkov pogosto nepopolni ali zastareli. Vsi ustanovitelji niso navedeni na LinkedInu in Crunchbaseu; za določene panoge, kot so tehnološka zagonska podjetja, obstajajo specializirane baze podatkov, javni registri pa lahko vsebujejo napake. Natančna identifikacija je bistvenega pomena: obstaja tveganje zbiranja podatkov o drugi osebi z istim imenom. Biografski podatki so lahko tudi olepšani. Ključnega pomena je primerjati podatke iz različnih virov.

Zato je vključevanje alternativnih podatkov v kvantitativne modele zapleteno zaradi vprašanj interpretacije in standardizacije. Obstaja tudi tveganje manipulacije: posojilojemalci lahko umetno napihnejo javno dostopne metrike, kar zmanjša zanesljivost podatkov.

Za reševanje teh težav je potreben »hibridni pristop«, ki združuje avtomatizirano zbiranje podatkov z ročnim »strokovnim pregledom«. Človeški pregled preverja informacije, jih primerja med več viri (npr. profili na LinkedInu, Crunchbase in uradnimi registri) ter prepoznava morebitne pristranskosti. Čeprav ročno preverjanje zmanjšuje tveganje napak, povečuje stroške dela in lahko v oceno vnese subjektivnost.

Uporaba alternativnih podatkov sproža resne etične pomisleke v zvezi z zasebnostjo in tveganjem diskriminacije (neenaka obravnava določenih kategorij). Obdelava osebnih podatkov, zlasti podatkov o družbenih medijih in geolokaciji, zahteva strogo upoštevanje predpisov, kot je Splošna uredba EU o varstvu osebnih podatkov, ki je ključnega pomena za ohranjanje zaupanja in izogibanje pravni odgovornosti. Potencialni regulatorji so lahko skeptični do modelov z velikim številom vhodnih spremenljivk, zlasti do alternativnih podatkov, ki niso neposredno povezani s financami, zaradi težav pri zajemanju posrednih dokazov o prepovedanih pristranskostih (Furletti in drugi, 2025).

Tu je tudi vprašanje regulacije, saj gre za mladi trg, stroga regulacija in standardizacija v začetnih fazah pa bi lahko le škodovali panogi, ki bi teoretično lahko postala novo gonilo gospodarske rasti.

Izvajanje standardizacije zahteva zanesljiv nabor podatkov, na katerega se je mogoče zanašati. Kljub hitri rasti trga množičnega posojanja je za platforme bistveno, da zberejo dovolj informacij o uspešnosti portfelja v različnih fazah finančnega cikla, kar jim omogoča, da prepoznajo ključne vidike za regulativno izvajanje.

Trenutno platforme za množično posojanje javno ne razkrivajo informacij o svojih modelih za ocenjevanje tveganj, kar sledi praksi tradicionalnih bank, ki te modele obravnavajo kot zaupna notranja orodja. To politiko nerazkritja vodi več strateških razlogov. Modeli tveganja so ključni element konkurenčne prednosti, saj omogočajo učinkovito prepoznavanje zanesljivih posojilojemalcev in ponujanje privlačnih donosov vlagateljem.

Ohranjanje zaupnosti služi kot zaščita pred strateškimi manipulacijami brezvestnih posojilojemalcev. Poleg tega modeli tveganja v fintechu niso statični: nenehno se prilagajajo spreminjajočim se tržnim razmeram in vedenju posojilojemalcev. Razkritje nenehno razvijajočih se metodologij bi lahko povzročilo zmedo med deležniki.

Na splošno, čeprav kombinacija trdih in mehkih podatkov znatno izboljša napovedno moč in je koristna za finančno vključenost, je pot do standardiziranih in prilagodljivih modelov polna izzivov, povezanih z upravljanjem podatkov, skladnostjo s predpisi, etičnimi vidiki in inherentno naravo kvalitativnih informacij.

5 VLOGA USTANOVITELJA IN EKIPE PRI DOLGOROČNEM USPEHU

5.1 Pomen profesionalne in raznolike ekipe za uspeh malih in zagonskih podjetij

Človeški kapital predstavlja temelj delovanja vsakega podjetja, vendar sam po sebi ne zagotavlja uspeha. Ključno vlogo ima raznolikost ekipe – kombinacija različnih pogledov, izkušenj in kompetenc, ki omogoča boljše reševanje problemov in večjo inovativnost. Strateška zavezanost raznolikosti postaja vse prepoznavnejša kot odločilni dejavnik dolgoročne uspešnosti (Dixon-Fyle in drugi, 2020).

Raznolikost ekipe vključuje demografske, poklicne, kognitivne in kulturne dimenzije. Vsaka od teh prinaša specifične koristi, ki skupaj povečujejo odpornost in inovativnost podjetja. Kognitivna raznolikost je močnejši gonilni dejavnik inovacij, saj se nanaša na različne načine, kako ljudje razmišljajo, obdelujejo informacije in rešujejo probleme. Demografska raznolikost (spol, rasa, etnična pripadnost) je lahko tudi vir kognitivne raznolikosti, saj različne življenjske izkušnje in kulturna ozadja vplivajo na to, kako posamezniki razmišljajo.

Razlikovati moramo med raznolikostjo ekipe in raznolikostjo med ustanovitelji. Čeprav sta oba vidika povezana, imata različen vpliv na uspešnost podjetja. Širša ekipa ustvarja operativno raznolikost – različne spretnosti, izobrazbo in izkušnje, ki spodbujajo kreativnost in učinkovite procese. Po drugi strani pa raznolikost med ustanovitelji vpliva na vizijo podjetja, način odločanja in dolgoročno strategijo.

Ustanovitelji, ki prihajajo iz različnih kulturnih, strokovnih ali demografskih okolij, pogosto oblikujejo prilagodljivejše poslovne modele in razvijajo širšo mrežo partnerstev. Takšna raznolikost povečuje verjetnost preživetja podjetja v zgodnjih fazah, saj zmanjšuje tveganje ozkega pogleda in odvisnosti od enega tržnega segmenta. McKinsey (Dixon-Fyle in drugi, 2020) poudarja, da raznolike vodstvene ekipe učinkoviteje zaznavajo spremembe v okolju in hitreje sprejemajo odločitve, ki so usklajene z dolgoročnimi cilji.


V praksi to pomeni, da morajo ustanovitelji zavestno graditi raznolike ekipe, tudi če to pomeni preseganje osebnih omrežij. Homofilija – naravna težnja k sodelovanju z osebami, ki so nam podobne – lahko omejuje dostop do novih perspektiv in talentov. Raznolikost tako postane ključni del vodstvene strategije, ne le kadrovske politike.

Vpliv raznolikosti ekipe na uspešnost podjetja. Empirični podatki potrjujejo, da je raznolikost povezana z boljšimi poslovnimi rezultati (Brown, 2025):

- Boston Consulting Group: podjetja z nadpovprečno raznolikostjo ustvarijo 19 % višje prihodke od inovacij;
- Harvard Business Review: raznolika podjetja imajo 70 % večjo verjetnost, da osvojijo nove trge;
- Journal of Innovation Management: raznolike ekipe med brainstormingom ustvarijo 30 % več idej kot homogene ekipe.

Večji prihodki od inovacij in večja verjetnost vstopa na nove trge neposredno povezujejo raznolikost z rastjo prihodkov in donosnosti, s čimer se dolgoročno krepi finančna stabilnost podjetja.


Raznolike ekipe ne le ustvarijo več idej, temveč v 87 % primerov sprejemajo tudi učinkovitejše poslovne odločitve (slika 5), pri čemer učinkovitost odločanja v 95 % primerov korelira s finančnimi kazalniki.



Slika 5: Raznolikost ekipe in učinkovitost odločanja

Vir: (<https://www.forbes.com/sites/eriklarson/2017/09/21/new-research-diversity-inclusion-better-decision-making-at-work/>)

Vpliv raznolikosti v vodstveni ekipi na uspešnost podjetja: McKinsey (Dixon-Fyle in drugi, 2020) je v treh globalnih analizah več kot 1000 podjetij pokazal, da obstaja jasna korelacija med raznolikostjo in finančnim uspehom. McKinsey ugotavlja, da podjetja z najvišjo stopnjo spolne raznolikosti v izvršnih ekipah dosegajo 25 % večjo verjetnost nadpovprečne profitabilnosti, podjetja z visoko etnično raznolikostjo pa kar 36 % (slika 6).




Slika 6: Raznolikost ekipe in finančni rezultati

Vir: (<https://www.mckinsey.com/featured-insights/diversity-and-inclusion/diversity-wins-how-inclusion-matters>)

Po podatkih bonitetne agencije Moody's višji delež žensk v upravnih odborih pozitivno korelira z izboljšanjem kreditne ocene (slika 7), kar omogoča cenejši dostop do kapitala ter neposredno prispeva k večji dobičkonosnosti in finančni stabilnosti podjetja.

Board-level gender diversity is correlated with high credit ratings¹




Slika 7: Spolna raznolikost ekipe in kreditna ocena

Vir: (https://www.moody's.com/web/en/us/hosted-assets/BX13199_DE_I%20infographic_FINAL.pdf)

Tudi McKinsey (Dixon-Fyle in drugi, 2020) opozarja, da organizacije, ki povezujejo raznolikost z vključevanjem, razvijajo »kolektivno inteligenco«, kar omogoča višjo stopnjo inovativnosti in daljšo življenjsko dobo podjetij. Zato je raznolikost vodstvene ekipe pomemben dejavnik kreditne sposobnosti in poslovne zanesljivosti.

Raznolikost ustanoviteljev kot dejavnik uspeha in dostopa do kapitala: število ustanoviteljev v zagonskem podjetju korelira s pogostostjo doseganja uspeha. Po raziskavi imajo podjetja z več ustanovitelji večje možnosti za uspeh; kot je prikazano na sliki 8, imajo podjetja s tremi ali več ustanovitelji več kot dvakrat večjo verjetnost uspeha kot zagonska podjetja, ki jih je ustanovil posameznik (McCarthy in drugi, 2023).



Slika 8: Raznolikost ekipe in učinkovitost odločanja

Vir: (<https://www.nature.com/articles/s41598-023-41980-y/figures/2>)

Eden od ključnih dejavnikov, ki vplivajo na dolgoročno stabilnost, je tudi dostop do financiranja. Podatki potrjujejo, da vlagatelji dajejo prednost zagonskim podjetjem z dvema ali več ustanovitelji. Na primer leta 2024 je imelo 35 % zagonskih podjetij samostojne ustanovitelje, vendar so ti predstavljali le 17 % tistih, ki so zbrali krog tveganega kapitala. Hkrati je bilo 37 % zagonskih podjetij z dvema ustanoviteljema in 16 % s tremi ustanovitelji, ki so pritegnila 34 % oziroma 25 % vseh naložb tveganega kapitala (Barriviera, 2025).

Sklepno lahko ugotovimo, da raznolikost vpliva na več ključnih dimenzij uspeha podjetja:


- inovacijsko sposobnost – s spodbujanjem različnih pogledov in rešitev;
- finančno uspešnost – z neposredno povezavo z rastjo prihodkov in donosnosti;
- kreditno sposobnost – z večjo zanesljivostjo in zaupanjem finančnih institucij;
- organizacijsko odpornost – z večjo prilagodljivostjo in kolektivno inteligenco;
- dostop do kapitala – s pozitivno percepcijo vlagateljev do raznolikih ustanoviteljskih ekip.

Tako raznolikost prispeva k rasti prihodkov in povečanju donosnosti, s čimer dolgoročno krepi finančno stabilnost podjetja, kar potrjuje četrto hipotezo.

V model za oceno kreditnega tveganja je mogoče predlagati dva dodatna kazalnika, povezana z ekipo (priloga 2).

Velikost ekipe (število zaposlenih (X13)) je povezana s širšo bazo virov in raznolikostjo; poleg tega omogoča učinkovito delegiranje nalog, institucionalizacijo znanja in nadomeščanje odhodov posameznih zaposlenih, kar povečuje organizacijsko odpornost.

Število določenih področij kompetenc v ekipi (X14) prikazuje širino strokovnega znanja, prisotnega v timu. Ta metrika hkrati pomeni manjšo odvisnost od zunanjih svetovalcev. Kot je bilo že omenjeno, je funkcionalna raznolikost povezana z nadpovprečnimi kazalniki inovativne dejavnosti in večjo prilagodljivostjo na trgih.



Slika 9: ROC za 14-faktorski model

Vir: (Lastni vir)

Primerjava ključnih kazalnikov 14-faktorskega modela z 12-faktorskim modelom (podpoglavje 4.1):

- In-Sample AUC (slika 9): povečanje z 0,909 na 0,931 (+0,022), kar kaže na nekoliko večjo sposobnost modela pojasnjevati vzorce v učnih podatkih;
- CV AUC: rahlo znižanje z 0,853 na 0,844, razlika je minimalna (−0,009), kar pomeni, da model ohranja zelo podobno splošno napovedno moč tudi na novih podatkih;
- standardno odstopanje (σ): povečanje z 0,031 na 0,066, kar kaže na nekoliko večjo variabilnost rezultatov med validacijskimi ponovitvami, vendar ta ostaja v sprejemljivih mejah za modele z omejenim številom opazovanj.

Dodajanje dveh novih dejavnikov je zmerno izboljšalo kakovost modela. Rahlo povečanje vrednosti In-Sample AUC ob stabilnem CV AUC kaže, da model zajema dodatne informacije, ne da bi pri tem izgubil svojo sposobnost posploševanja. To potrjuje teoretično utemeljeno hipotezo, da struktura in velikost ekipe vplivata na kreditno sposobnost podjetij. V prihodnje

bi bilo smiselno preveriti pomembnost teh dejavnikov na večjem vzorcu, da bi potrdili njihovo splošno veljavnost in kvantitativno ocenili njun neodvisni prispevek k napovedni moči modela.

5.2 Možnosti vključevanja strokovne raznolikosti ekip v modele ocenjevanja tveganja

Za vključitev strokovne raznolikosti v model tveganja jo je treba digitalizirati. Kot smo že omenili, je to zapletena naloga, ki zahteva pretvorbo nestrukturiranih besedilnih informacij (npr. iz profilov LinkedIna) v strukturirano obliko z uporabo različnih kvantitativnih metrik. To nalogo je mogoče doseči tako z avtomatizacijo kot z ročno obdelavo, vendar obe metodi predstavljata znatne izzive:

1. **izbira vira podatkov:** prvi izziv je izbira zanesljivega vira podatkov. LinkedIn in Crunchbase sta najpogostejše uporabljena vira, vendar imata omejitve, vključno s tehničnimi (npr. omejitve API-ja) in pravnimi (kršitev pogojev storitve). Zbiranje podatkov iz »celotnega interneta« je nepraktično zaradi velike količine podatkov, pomanjkanja standardizacije in znatnih pravnih tveganj;
2. **opredelitev in interpretacija strokovnih kompetenc:** to je najtežji konceptualni izziv. Kaj pomeni izraz kompetenca? Ali gre le za najnovejšo zaposlitev? Ali je treba upoštevati vse prejšnje izkušnje? Ali je treba vključiti diplome z drugih področij ali publikacije/delovna mesta? Uteži, upadi, nedavnost? Na ta vprašanja ni univerzalno pravih odgovorov. Algoritem je treba usposobiti za interpretacijo teh odtenkov, kar zahteva znatne naložbe v razvoj in usposabljanje nevronske mreže;
3. **problem »črne škatle« ali človeške pristranskosti:** avtomatizacija z uporabo algoritmov strojnega učenja in obdelave naravnega jezika (NLP) ustvarja tveganja »črne škatle« – rezultate, ki jih je težko razložiti in preveriti. Algoritmi so lahko podvrženi skritim pristranskostim, interpretacija besedilnih informacij pa zahteva niansirano razumevanje konteksta. Kljub potencialu avtomatizacije je človeški nadzor še vedno potreben za zagotovitev zanesljivosti in razločljivosti ocen tveganja. Zato avtomatizacija ocenjevanja profesionalne raznolikosti v ekipi ni le tehnični izziv, temveč tudi strateški, ki zahteva skrbno načrtovanje in stalno potrjevanje.

Pri avtomatizaciji algoritem zahteva model učenja: model je treba »naučiti« pravilnega ujemanja besedilnih podatkov s klasifikacijami panog, kar je zahtevno. Poleg tega sta pri širitvi podjetja v drugo državo ali regijo potrebna dodatno usposabljanje in nov preizkus

validacije. Poleg tega lahko viri zagotovijo nasprotujoče si informacije (na primer oseba ima lahko več karier), kar zahteva strokovni pregled. Kot je bilo omenjeno, so v eni študiji fintech posojilodajalci uporabili strokovno znanje analitikov za validacijo modela na podatkih LinkedIna (Ramadhani in drugi, 2022), kar je bilo v tej študiji tudi ročno izvedeno.

Vendar pa lahko ročna ocenjevanja vodijo do sistematičnih napak, saj človeška presoja ponavadi preveč poudarja površinske lastnosti, kot so prestižna izobrazba ali izkušnje v uglednih podjetjih, hkrati pa ignorira resnično globino in relevantnost strokovnega znanja. Poleg tega lahko ocenjevalci nezavedno iščejo pristranskost potrditve in podcenjujejo tveganja, povezana z nezadostnim usklajevanjem in upravljanjem raznolikosti. To vodi do poenostavljenega dojemanja, v katerem se »večja raznolikost« samodejno enači z »boljšimi rezultati«, ne da bi se upoštevala nelinearna narava tega odnosa. Ročno ocenjevanje je zamudno in vključuje visoke stroške skaliranja.

To pomeni, da vključevanje raznolikosti v model tveganja zahteva bodisi znatne tehnološke naložbe (usposabljanje nevronske mreže na označenih podatkih) bodisi vključitev analitikov, kar poveča stroške in trajanje procesa.

Na splošno so možnosti za vključitev mehkih dejavnikov v ocenjevanje MSP-jev jasne: izboljšujejo filtriranje kreditnega tveganja in širijo dostop do kreditov za manj kot idealne posojilojemalce. Vendar pa vsak nov vir informacij prinaša izzive pri potrjevanju in interpretaciji ter dodatne stroške.

6 SKLEP

Glavna raziskovalna problematika diplomskega dela »Izzivi pri razvoju modelov tveganja za crowdlending platforme« je bila proučitev, kako lahko kombinacija tradicionalnih finančnih kazalnikov in »mehkih informacij« izboljša oceno dejanske bonitete malih in zagonskih podjetij, financiranih prek platform za množično posojanje.

V teoretičnem delu je bilo analizirano množično posojanje kot pojav, ki izhaja iz digitalizacije finančnega sektorja, prav tako so bili predstavljeni glavni modeli ocenjevanja tveganj (Altmanov Z-rezultat, PD/LGD/EAD). Analiza je pokazala, da so ti pristopi zanesljivi za uveljavljena podjetja z dolgo finančno zgodovino, vendar ne omogočajo natančne napovedi za mala in mlada podjetja. Empirični del je potrdil, da se več kot polovica posojilojemalcev, ki redno odplačujejo obveznosti, po klasičnih modelih napačno razvrsti kot visoko tvegana. To potrjuje omejitve tradicionalnih modelov v razmerah, kjer kakovost finančnih informacij ni visoka in kjer se poslovni potencial odraža predvsem v človeškem kapitalu in tržnih inovacijah.

Nato je bilo za vključitev v model predlaganih sedem indikatorjev »mehkih informacij«, povezanih z vedenjskimi in tržnimi značilnostmi podjetij, kot so prisotnost ustanovitelja na spletu, zgodovina pridobivanja sredstev in aktivnost na družbenih omrežjih. Ugotovljeno je bilo, da kombinacija teh kazalnikov s finančnimi metrikami znatno poveča napovedno moč modela in omogoča natančnejše razvrščanje posojilojemalcev.

Poleg tega diplomsko delo poudarja pomen strateškega upravljanja s talenti kot ključnega dejavnika uspešnosti zagonskih podjetij. Vlaganje v razvoj kompetenc ustanoviteljev in ekip prispeva k višji kredibilnosti podjetja ter povečuje njegovo bonitetno vrednost v očeh vlagateljev.

H1: *Če je podjetje zagonsko podjetje ali MSP, je verjetnost uporabe crowdlending platform za financiranje večja kot pridobitev sredstev prek tradicionalnih bank.*

Leta 2024 je poslovni segment predstavljal 69 % celotnega evropskega trga storitev množičnega posojanja. Združeno kraljestvo je vodilno na evropskem trgu crowdlending storitev s 47-odstotnim deležem, kjer so platforme, kot sta Funding Circle in Iwoca, do leta 2024 odobrile posojila za MSP-je v skupni vrednosti več kot 15 milijard funtov šterlingov.

Takšen obseg crowdlendinga je posledica postopnega zmanjševanja dostopa do bančnih kreditov: delež uspešnih vlog se je zmanjšal z 80 % leta 2018 na 50 % leta 2023. Raziskave

kažejo, da 40 % podjetij meni, da je lažje pridobiti financiranje pri fintech posojilodajalcih, medtem ko jih je 65 % izbralo alternativne oblike financiranja zaradi ovir pri bančnih kreditih.

Tradicionalne banke se soočajo z visokimi fiksnimi stroški, zahtevami Basel III in potrebo po oblikovanju rezerv za tveganja, kar naredi kreditiranje malih podjetij nedonosno. Crowdlending pa ponuja hitrejša (3–24 ur), popolnoma digitalizirane postopke in 2–4-krat nižje operativne stroške. Podatki kažejo, da zagonska podjetja in MSP-ji pogosteje izberejo množično posojanje kot banke zaradi hitrosti, prilagodljivosti in lažjega dostopa do kapitala.

Hipoteza je potrjena.

H2: *Če se zagonska podjetja in MSP-ji ocenjujejo z uporabo tradicionalnih modelov finančnega ocenjevanja tveganja (npr. donosnost, dinamika prihodkov, razmerje dolga), je večja verjetnost njihove napačne razvrstitve kot visoko tvegani kreditojemalci.*

Zaradi specifične narave poslovanja mladih podjetij – kratke zgodovine, negotovih prihodkov in osredotočenosti na rast – njihovi finančni izkazi ne odražajo dejanskega potenciala ali tveganja poslovnega modela.

Empirični rezultati kažejo, da ima Altmanov model nizko diskriminatorno sposobnost ($AUC = 0,58$), kar pomeni, da komaj presega raven naključnega ugibanja. V resničnem testu modela je bilo ugotovljeno, da 41 posojilojemalcev (kar predstavlja 64 % vseh podatkov) spada v območje visokega tveganja, medtem ko jih je dejansko le 8 resnično nesposobnih za plačilo. Poleg tega 80 % posojilojemalcev, ki jih je Altmanov Z-rezultat razvrstil kot tvegane, svoje obveznosti redno poravnava. Takšna napačna klasifikacija v praksi kaže, da model bistveno precenjuje tveganje, kar bi neupravičeno izključilo solventne posojilojemalce iz procesa financiranja, omejilo dostop do kapitala in zaviralo podjetniško rast.

Ta ugotovitev potrjuje, da tradicionalni kvantitativni pristopi, utemeljeni na zgodovinskih podatkih, ne zajamejo dejanske kreditne sposobnosti zagonskih podjetij.

Hipoteza je potrjena.

H3: *Če se v modele ocenjevanja tveganja vključijo kvalitativni dejavniki, kot so prisotnost ustanovitelja na družbenih omrežjih, zgodovina zbiranja kapitala in struktura ekipe, bo model pokazal višji rezultat AUC pri napovedovanju kreditnega tveganja na crowdlending platformah v primerjavi z modeli, ki temeljijo izključno na tradicionalnih finančnih kazalnikih.*

Empirične raziskave dosledno potrjujejo, da vključitev mehkih informacij bistveno poveča napovedno natančnost kreditnih modelov. Modeli, ki uporabljajo samo alternativne podatke, imajo boljšo napovedno moč (AUC 0,7) kot modeli, ki temeljijo na podatkih kreditnih agencij (AUC 0,683); kombinirani pristop dosega AUC 0,73.

Izvedeni izračuni v okviru te raziskave dodatno potrjujejo večjo napovedno vrednost vključitve mehkih informacij. Novi 12-faktorski model, ki vključuje sedem kvalitativnih spremenljivk, je dosegel In-Sample AUC 0,909 in CV AUC $0,853 \pm 0,031$, kar predstavlja 47-odstotno izboljšanje natančnosti v primerjavi z Altmanovim modelom (AUC 0,580). Vseh deset posojilojemalcev v neplačilu je bilo pravilno razvrščenih, kar potrjuje stabilnost in praktično uporabnost razširjenega modela pri ocenjevanju tveganja v okolju množičnega posojanja.

Hipoteza je potrjena.

H4: *Če ekipa zagonskega podjetja izkazuje raznolikost strokovnih ozadij, kot je razvidno iz javno dostopnih kanalov podjetja, je verjetnost dolgoročnega poslovnega uspeha večja.*

Podjetja z višjo stopnjo raznolikosti v ekipi ustvarijo 19 % več prihodkov iz inovacij in imajo 70 % večjo verjetnost za vstop na nove trge, kar je neposredno povezano z rastjo prihodkov in dobičkonosnosti. Raznolike ekipe v povprečju ustvarijo 30 % več idej med možganskimi nevihtami in sprejemajo odločitve bolje v 87 % primerov, pri čemer učinkovitost odločanja v 95 % korelira z rastjo prihodkov.

Podjetja z visoko stopnjo spolne raznolikosti v vodstvu imajo 25 % večjo verjetnost, da bodo dosegla nadpovprečno dobičkonosnost, medtem ko podjetja z visoko etnično raznolikostjo dosegajo ta rezultat v 36 % primerov. Po podatkih Moody's obstaja pozitivna korelacija med deležem žensk v upravnih odborih in izboljšanjem kreditne ocene, saj podjetjem omogoča cenejši dostop do kapitala ter povečuje njihovo dobičkonosnost in finančno stabilnost.

Sklepno je mogoče ugotoviti, da raznolikost v ekipi spodbuja inovacije in rast prihodkov, izboljšuje kakovost odločanja, olajšuje dostop do financiranja ter s tem pomembno prispeva k dolgoročni stabilnosti in rasti podjetij.

Hipoteza je potrjena.

V zaključku lahko ugotovimo, da kombinacija tradicionalnih finančnih kazalnikov in mehkih informacij predstavlja učinkovit pristop k ocenjevanju tveganja zagonskih podjetij in MSP-jev na crowdlending platformah. Raziskava je potrdila, da klasični modeli, kot je Altmanov Z-

rezultat, precenjujejo tveganje, medtem ko razširjeni model z vključitvijo kvalitativnih kazalnikov dosega bistveno višjo napovedno moč. Platformam za množično posojanje priporočamo uvedbo tovrstnih hibridnih modelov. Takšen pristop omogoča natančnejšo selekcijo posojilojemalcev, znižanje stopnje neplačil in posledično večjo finančno stabilnost trga crowdlendinga, ki se je že uveljavil kot nepogrešljiv vir financiranja. Poleg tega je pomembno, da platforme pri ocenjevanju kreditne sposobnosti podjetja posebno pozornost namenijo raznolikosti ekipe.

7 SEZNAM LITERATURE

- Adhami, S., Gianfrate, G., & Johan, S. (3. marec 2019). *Risks and returns in crowdlending*. <https://ssrn.com/abstract=3345874>
- Altman, E. I. (september 1968). *Financial ratios, discriminant analysis and the prediction of corporate bankruptcy*. <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
- Altman, E. I. (1983). *Corporate financial distress*. New York: John Wiley.
- Bank for International Settlements. (27. marec 2020). *Basel Framework: CRE32 – IRB approach: risk components*. https://www.bis.org/basel_framework/chapter/CRE/32.htm
- Barriviera, G. (21. marec 2025). *Solo-founder startups double but face funding challenges*. Funds Society. <https://www.fundssociety.com/en/news/alternatives/las-startups-dirigidas-por-un-fundador-individual-se-han-mas-que-duplicado-pero-tienen-menos-exito-a-la-hora-de-conseguir-capital-riesgo/>
- Berg, T., Burg, V., Gombovi, A., & Puri, M. (april 2018). (2018). *On the rise of FinTechs - Credit scoring using digital footprints*. National Bureau of Economic Research. <https://www.fdic.gov/rise-fintechs-credit-scoring-using-digital-footprints.pdf>
- British Business Bank. (marec 2024). *SME Finance Survey*. <https://www.british-business-bank.co.uk/sites/g/files/sovrnj166/files/2024-03/ipsos-sme-finance-survey-2023.pdf>
- British Chambers of Commerce. (4. april 2024). *Access to Finance Challenge for SMEs*. <https://www.britishchambers.org.uk/news/2024/04/access-to-finance-challenge-for-smes/>
- Brown, G. (13. marec 2025). *Diversity and innovation statistics: How diverse teams drive workplace innovation*. Niagara Institute. <https://www.niagarainstitute.com/blog/how-diverse-teams-drive-innovation-in-the-workplace-statistics>
- Chioda, L., Gertler, P., Higgins, S., & Medina, P. C. (november 2024). *FinTech lending to borrowers with no credit history*. National Bureau of Economic Research. https://www.nber.org/system/files/working_papers/w33208/w33208.pdf
- Coakley, J., & Lazos, A. (2021). New developments in equity crowdfunding: A review. *Review of Corporate Finance Vol. 1: No. 3-4*, 341–405.

- Cornée, S. (oktober 2015). *The relevance of soft information for predicting small business credit default: Evidence from a social bank*. <https://scispace.com/pdf/the-relevance-of-soft-information-for-predicting-small-4uvhxlcl4g.pdf>
- Corporate Finance Institute. (brez datuma). *Expected loss (EL): Definition, calculation, & importance*. <https://corporatefinanceinstitute.com/resources/career-map/sell-side/risk-management/expected-loss-definition-calculation-importance/>
- Dixon-Fyle, S., Dolan, K., Vivian Hunt, D., & Prince, S. (19. maj 2020). *Diversity wins: How inclusion matters*. McKinsey & Company. <https://www.mckinsey.com/featured-insights/diversity-and-inclusion/diversity-wins-how-inclusion-matters>
- Eurocrowd. (2025). *ECSPR Compliance: Uneven Ground*. <https://eurocrowd.org/ecspr-compliance-uneven-ground/>
- European Banking Authority. (20. november 2017). *Guidelines on PD estimation, LGD estimation and the treatment of defaulted exposures*. <https://www.eba.europa.eu/activities/single-rulebook/regulatory-activities/model-validation/guidelines-pd-estimation-lgd>
- European Banking Authority. (29. maj 2020). *Final report: Guidelines on loan origination and monitoring*. https://www.eba.europa.eu/sites/default/files/document_library/Publications/Guidelines/2020/Guidelines%20on%20loan%20origination%20and%20monitoring/884283/EB_A%20GL%202020%2006%20Final%20Report%20on%20GL%20on%20loan%20origination%20and%20monitoring.pdf
- European Commission. (november 2021). *Analytical report 2021. European Union*. <https://single-market-economy.ec.europa.eu/system/files/2021-11/Analytical%20report%202021.pdf>
- European Securities and Markets Authority. (8. januar 2025). *Market Report on Crowdfunding in the EU 2024*. European Securities and Markets Authority. https://www.esma.europa.eu/sites/default/files/2025-01/ESMA50-2085271018-4039_ESMA_Market_Report_-_Crowdfunding_in_the_EU_2024.pdf
- Funding Circle. (20. maj 2025). *Funding Circle Facilitates Ninth UK Public Securitisation, Cementing Position as a Leading SME ABS Issuer*. Funding Circle.

- <https://corporate.fundingcircle.com/media/press-releases/funding-circle-facilitates-ninth-uk-public-securitisation-cementing-position-leading-sme-abs-issuer/>
- Furletti, M., Sommerfield, L., Willis, C., Page, L., & Anthony, D. N. (21. januar 2025). *CFPB highlights fair lending risks in advanced credit scoring models*. <https://www.consumerfinancialserviceslawmonitor.com/2025/01/cfpb-highlights-fair-lending-risks-in-advanced-credit-scoring-models/>
- Google. (brez datuma). *ROC and AUC. Google for Developers*. <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc>
- HM Treasury. (8. maj 2025). *Small Business Access to Finance*. <https://www.gov.uk/government/calls-for-evidence/small-business-access-to-finance/small-business-access-to-finance>
- Honoré, F. (16. februar 2022). *Joining forces: How can founding members' prior experience variety and shared experience increase startup survival?*. <https://doi.org/10.5465/amj.2018.1386>
- Information Commissioner's Office. (15. marec 2023). *How do we ensure fairness in AI?* <https://ico.org.uk/for-organisations/uk-gdpr-guidance-and-resources/artificial-intelligence/guidance-on-ai-and-data-protection/how-do-we-ensure-fairness-in-ai/>
- Iwoca. (2018). *'Faster than Farah': iwoca takes over 12% of all UK small business overdraft approvals*. <https://www.iwoca.co.uk/news/twelve-percent-overdraft-approvals>
- McCarthy, P. X., Gong, X., Braesemann, F., Stephany, F., Rizoiu, M.-A., & Kern, M. L. (17. oktober 2023). *The impact of founder personalities on startup success*. Scientific Reports. <https://www.nature.com/articles/s41598-023-41980-y>
- Mordor Intelligence. (2025). *Europe Crowdlending and Crowd Investing Market - Size, Share & Industry Analysis*. <https://www.mordorintelligence.com/industry-reports/europe-crowd-lending-and-crowd-investing-market>
- Ramadhani, D. P., Wijaya, P. M., & Alamsyah, A. (26. julij 2022). *Credit scoring model construction based on LinkedIn social media data*. <https://ieomsociety.org/proceedings/2022rome/379.pdf>
- Shneor, R., Zhao, L., & Flåten, B.-T. (2020). *Advances in Crowdfunding*. Palgrave Macmillan. <https://doi.org/10.1007/978-3-030-46309-0>

- Sonovate. (16. avgust 2023). *40% of SMEs prefer fintech lenders over mainstream banks*.
<https://www.sonovate.com/media-coverage/40-smes-prefer-fintech-lenders-over-mainstream-banks/>
- StatsCalculators Team. (8. november 2025). *Logistic Regression Calculator*. StatsCalculators.
<https://www.statscalculators.com/calculators/regression-analysis/logistic-regression-calculator>
- Treasury Committee. (8. maj 2024). *SME Finance*. House of Commons.
<https://committees.parliament.uk/publications/44604/documents/221576/default/>
- Van Kesteren, J., Adriaanse, J., & Van der Rest, J.-P. (22. september 2017). *The story behind bankruptcy: When business gets personal*. <https://doi.org/10.5204/qutlr.v17i1.706>
- Zhang, Q., Ye, T., Essaidi, M., Agarwal, S., Liu, V., & Thau, B. (6. november 2017). *Predicting startup crowdfunding success through longitudinal social engagement analysis*. <https://doi.org/10.1145/3132847.3132908>

8 PRILOGE

Priloga 1: Izračunani in vhodni podatki za model tveganja

Nepl ačla	Obrato valni kapital, tisoč €	Skupna sredstva tisoč €	Zadržani dobiček, tisoč €	EBIT, tisoč €	Kapital, tisoč €	Skupne obveznos ti, tisoč €	Prihodki , tisoč €	X1	X2	X3	X4	X5	Z- rezultat tveganje	Z- rezultat, tveganje	X6	X7	X8	X9	X10	X11	X12	Rezultat 12- faktorski modela	X13	X14
0	3.430	3.589	2.000	912	2.000	1.589	7.540	0,96	0,56	0,25	1,26	2,1	4,57	Nizko	1.000	2	1	0	100	2	-	0,3	55	10
0	1.527	1.589	-6.713	-364	-161	1.750	3.927	0,96	-4,22	-0,23	-0,09	2,47	-1,17	Visoko	150	3	1	0	40	15	3,2	-0,67	30	8
0	63	166	-2.982	-533	-1.268	1.434	814	0,38	-17,96	-3,21	-0,88	4,9	-20,4	Visoko	85	0,8	0	0	70	3	0,7	5,38	5	2
0	283	1.407	-3.066	-55	157	1.250	1.463	0,2	-2,18	-0,04	0,13	1,04	-0,73	Visoko	300	1,5	1	0	30	12	1,3	-1,37	15	5
0	892	1.567	298	-116	298	1.269	3.250	0,57	0,19	-0,07	0,23	2,07	2,51	Srednje	500	5	1	0	100	3	-	0,61	40	5
0	466	480	-795	-75	-384	864	1.275	0,97	-1,66	-0,16	-0,44	2,66	1,27	Srednje	300	0,35	1	0	100	2	-	2,34	8	5
0	118	203	-395	-13	-395	598	775	0,58	-1,95	-0,06	-0,66	3,82	2,1	Srednje	15	0,15	1	0	80	20	3,4	2,01	9	3
0	0	0	0	596	-850	850	4.124	0	0	0	-1	0	-0,42	Visoko	400	0	1	0	100	1	-	1,91	20	5
1	58	58	-716	-118	-405	463	192	1	-12,34	-2,03	-0,87	3,31	-13,12	Visoko	10	0,1	0	0	100	2	-	6,31	3	2
0	518	593	-1.861	-704	225	368	905	0,87	-3,14	-1,19	0,61	1,53	-3,94	Visoko	70	0,6	1	0	60	45	11,4	0,3	15	5
0	310	417	70	90	70	347	603	0,74	0,17	0,22	0,2	1,45	2,87	Srednje	15	0,07	1	1	100	2	-	1,39	2	1
0	1.045	1.082	-1.829	-941	732	350	911	0,97	-1,69	-0,87	2,09	0,84	-1,72	Visoko	30	5	0	0	51	68	12,1	0,56	2	1
0	1.370	1.430	-765	610	-358	1.788	10.661	0,96	-0,53	0,43	-0,2	7,46	8,92	Nizko	60	10	1	1	80	2	-	-1,2	48	10
1	174	204	-1.848	-232	-186	390	672	0,85	-9,06	-1,14	-0,48	3,29	-7,51	Visoko	25	0,2	0	0	60	2	-	4,05	2	1
0	132	200	-450	-477	-217	417	768	0,66	-2,25	-2,39	-0,52	3,84	-5,23	Visoko	45	3	0	0	86	3	8,6	3,59	18	4
1	636	784	-75	-49	13	771	542	0,81	-0,1	-0,06	0,02	0,69	1	Visoko	3	0	0	0	100	2	-	4,71	15	2
1	134	205	-200	24	17	188	597	0,65	-0,98	0,12	0,09	2,91	2,95	Nizko	3	0	0	0	100	2	-	5,08	2	1
0	106	106	35	52	35	71	259	1	0,33	0,49	0,49	2,44	5,17	Nizko	15	0,05	0	0	40	7	4,6	1,93	5	3
1	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	3	0	0	0	100	1	-	4,72	2	1
0	120	171	-817	-148	0	171	11	0,7	-4,78	-0,87	0	0,06	-6,17	Visoko	13	1,5	1	1	70	28	150,5	-0,38	1	1
0	78	85	-477	-29	-434	519	193	0,92	-5,61	-0,34	-0,84	2,27	-3,24	Visoko	40	0,25	0	0	100	2	-	5,47	1	1
0	190	249	-747	9	12	237	276	0,76	-3	0,04	0,05	1,11	-0,75	Visoko	25	0,4	1	0	90	3	4	2,38	6	3
0	249	262	88	264	88	174	421	0,95	0,34	1,01	0,51	1,61	5,91	Nizko	-	0	0	0	100	1	-	4,86	4	1
1	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	7	0,12	0	0	100	2	-	4,68	2	1
0	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	11	0,3	1	0	90	3	-	2	1	1
0	205	212	27	-6	32	180	619	0,97	0,13	-0,03	0,18	2,92	3,7	Nizko	55	0,9	0	0	100	2	-	4,58	11	2
0	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	40	0,7	1	0	80	15	-	1,27	4	3
0	35	36	-91	-68	-91	127	113	0,97	-2,53	-1,89	-0,72	3,14	-4,48	Visoko	25	0,15	0	0	100	3	-	4,97	4	2
0	90	96	-587	-168	-587	683	6	0,94	-6,11	-1,75	-0,86	0,06	-10,24	Visoko	3	0,3	0	0	60	2	66	3,21	2	1
1	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	1	0	0	0	100	2	-	4,72	1	1
0	193	193	-77	0	-77	270	55	1	-0,4	0	-0,29	0,28	0,54	Visoko	13	1,1	1	1	100	3	-	1,08	3	2
0	176	177	-9	46	-9	185	235	0,99	-0,05	0,26	-0,05	1,33	2,78	Srednje	12	2	1	0	80	5	7,7	1,18	7	3

0	206	245	-1.307	-140	-194	439	231	0,84	-5,33	-0,57	-0,44	0,94	-4,94	Visoko	40	1,3	1	1	70	10	10,5	0,15	4	3
1	404	404	83	81	173	231	183	1	0,21	0,2	0,75	0,45	2,28	Srednje	2	0,3	0	0	100	2	-	4,55	3	1
0	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	12	0	0	0	100	2	-	4,7	1	1
0	0	0	0	-30	-372	372	58	0	0	0	-1	0	-0,42	Visoko	11	0,3	0	1	100	2	-	3,48	2	2
0	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	8	0,55	0	0	100	1	-	4,59	2	1
0	37	35	-34	17	-34	69	95	1,06	-0,97	0,49	-0,49	2,71	3,95	Nizko	15	0,7	0	0	70	5	13,9	3,46	2	2
0	7	7	-93	-33	-43	51	23	1	-13,29	-4,71	-0,84	3,29	-22,26	Visoko	9	1,2	1	1	60	1	52,2	0,52	1	1
0	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	-	0	1	0	100	3	-	2,56	3	1
0	31	34	-9	-162	-9	43	140	0,91	-0,26	-4,76	-0,21	4,12	-10,35	Visoko	6	0,4	1	1	100	2	-	0,99	1	1
0	0	0	0	-2	0	0	0	0	0	0	0	0	-	Visoko	5	0,012	0	0	100	2	-	4,71	2	1
0	16	16	-54	0	-47	63	0	1	-3,38	0	-0,75	0	-2,45	Visoko	3	0,18	0	0	60	4	-	3,15	3	1
0	252	266	-112	9	-110	376	800	0,95	-0,42	0,03	-0,29	3,01	3,31	Nizko	20	5	1	1	100	1	-	0,47	8	5
0	55	55	-24	-27	-24	80	265	1	-0,44	-0,49	-0,3	4,82	3,5	Nizko	35	3,5	0	0	80	3	2,7	3,29	4	2
0	-18	120	-449	-33	-258	378	242	-0,15	-3,74	-0,28	-0,68	2,02	-2,41	Visoko	3	0,12	0	0	60	5	7,4	3,47	4	3
0	141	190	-1.349	-100	-71	261	476	0,74	-7,1	-0,53	-0,27	2,51	-4,73	Visoko	15	0,6	0	1	100	2	-	4,4	8	2
1	11	11	-70	-27	-70	81	101	1	-6,36	-2,45	-0,86	9,18	-3,5	Visoko	60	0,09	0	0	100	1	-	5,99	3	1
1	0	0	0	0	0	0	0	0	0	0	0	0	-	Visoko	2	0	0	0	100	1	-	4,72	1	1
0	242	267	146	18	146	121	572	0,91	0,55	0,07	1,21	2,14	3,97	Nizko	30	18	0	0	100	2	-	0,5	4	3
0	552	566	60	-24	60	506	274	0,98	0,11	-0,04	0,12	0,48	1,19	Visoko	37	3	1	1	100	2	6,6	0,52	2	2
0	109	119	-183	-38	-183	302	370	0,92	-1,54	-0,32	-0,61	3,11	1,21	Visoko	22	2,5	0	0	100	2	-	4,52	3	2
0	756	852	-215	157	177	675	3.105	0,89	-0,25	0,18	0,26	3,64	4,74	Nizko	150	0,7	1	0	100	3	-	2,45	12	4
0	1.448	2.166	-1.066	101	-695	2.861	5.150	0,67	-0,49	0,05	-0,24	2,38	2,48	Srednje	16	8	1	0	100	4	0,4	0,93	40	6
0	542	774	464	-172	45	729	1.899	0,7	0,6	-0,22	0,06	2,45	2,79	Srednje	400	10	0	0	100	2	0,5	1,75	12	3
0	871	1.007	-190	-170	-10	1.017	800	0,86	-0,19	-0,17	-0,01	0,79	0,72	Visoko	19	1,8	0	1	70	5	2,8	1,61	3	3
0	258	309	-41	-47	193	116	908	0,83	-0,13	-0,15	1,66	2,94	3,65	Nizko	27	0,2	1	0	100	1	-	2,6	3	2
0	2.912	3.234	-251	274	326	2.908	3.258	0,9	-0,08	0,08	0,11	1,01	1,9	Srednje	13	5	0	0	55	7	1,1	1,39	15	5
0	9	319	-85	-66	-85	404	193	0,03	-0,27	-0,21	-0,21	0,61	-0,33	Visoko	8	2,4	1	0	80	5	18,7	1,08	13	4
0	624	640	-770	-500	655	-15	150	0,98	-1,2	-0,78	-43,67	0,23	-20,85	Visoko	25	0,3	1	1	55	89	104	0,77	2	2
0	565	644	-24	130	381	263	1.464	0,88	-0,04	0,2	1,45	2,27	4,1	Nizko	65	0,2	1	1	80	20	1,2	0,18	25	5
0	1.055	1.059	-1.783	-857	160	899	707	1	-1,68	-0,81	0,18	0,67	-2,49	Visoko	16	0,8	0	0	70	58	17	2,64	2	2
0	200	207	-144	50	-130	337	700	0,97	-0,7	0,24	-0,39	3,38	4,07	Nizko	7	1,5	1	0	100	3	-	2,6	8	4
0	-359	645	-479	25	423	222	292	-0,56	-0,74	0,04	1,91	0,45	0,34	Visoko	12	0,05	0	0	100	5	4,1	4,74	3	3

Vir: (Lastni vir)

Priloga 2: Koeficienti modela LDA za 12- in 14-faktorske modele ter koeficienti logistične regresije

	β LDA (12-faktorski model)	β Logistična regresija (12-faktorski model)	β LDA (14-faktorski model)
X1	-0,095205192	-3,6502	-0,179215654
X2	-0,130940896	-6,5237	-0,142855486
X3	0,134686463	-13,3917	0,238941344
X4	-0,058818624	27,271	-0,067598151
X5	0,101404452	-1,6258	0,126395153
X6	-1,80934E-06	-0,0006	-2,78463E-06
X7	-0,000231055	-0,0081	-0,000229908
X8	-2,15088816	-220,2579	-1,954802251
X9	-1,206088544	-202,5971	-1,084974709
X10	0,047356951	-0,0451	0,036512987
X11	-0,008952207	-2,7139	-0,009916302
X12	-0,001129989	-113,9159	-0,006349129
Intercept	-	14,109	-
X13	-	-	0,123215765
X14	-	-	-0,681163379

Vir: (Lastni vir)

Priloga 3: Rezultati logistične regresije

2. Model Summary ⓘ				
McFadden's R ²	AIC	LR Chi ²	p-value	Observations
0.8491	34.37	47.102	4.4752e-06	64
4. Classification Metrics ⓘ				
Accuracy 96.9%		AUC 0.993		Log Loss 0.0718
Confusion Matrix		Detailed Metrics		
Predicted Positive	Actual Positive	Sensitivity (Recall)		
	Actual Negative	90.0%		
Predicted Negative	9	Specificity		
	1	98.2%		
		Precision		
		90.0%		
		F1 Score		
		0.9		

Vir: (<https://www.statscalculators.com/calculators/regression-analysis/logistic-regression-calculator>)