

VILNIAUS UNIVERSITETAS
EKONOMIKOS IR VERSLO ADMINISTRAVIMO FAKULTETAS

FINANSAI IR BANKININKYSTĖ

Almina Kafitulovaitė
MAGISTRO BAIGIAMASIS DARBAS

MAŽŲ IR LABAI MAŽŲ ĮMONIŲ PREKYBOS KREDITO RIZIKOS VERTINIMO MODELIS	TRADE CREDIT RISK ASSESSMENT MODEL FOR SMALL AND MICRO- ENTERPRISES
---	--

Darbo vadovė: Prof., Dr. (HP) Rasa Kanapickienė

Vilnius, 2026

TURINYS

PAVEIKSLŲ SĄRAŠAS	3
LENTELIŲ SĄRAŠAS	3
ĮVADAS	5
1. MAŽŲ IR LABAI MAŽŲ ĮMONIŲ PREKYBOS KREDITO RIZIKOS VERTINIMO TEORINIAI ASPEKTAI.....	9
1.1 Prekybos kredito samprata ir kylančios rizikos	9
1.2 Prekybos kredito rizikos vertinimo modeliai	17
1.3 Mažų ir labai mažų įmonių vertinimo metodų taikymas	23
2. PREKYBOS KREDITO RIZIKOS VERTINIMO MODELIO MAŽOMS IR LABAI MAŽOMS ĮMONĖMS TYRIMO METODIKA.....	28
2.1 Tyrimo tikslas ir planas.....	29
3. KREDITO RIZIKOS VERTINIMO MODELIO LIETUVOS MAŽOMS IR LABAI MAŽOMS ĮMONĖMS REZULTATAI IR JŲ INTERPRETACIJA.....	40
3.1 Kredito rizikos vertinimo modelio duomenų diagnostika	40
3.2 Logistinės regresijos modelio formavimas	45
3.3 Sprendimų medžio modelio formavimas	54
IŠVADOS IR PASIŪLYMAI.....	60
LITERATŪROS ŠALTINIAI	63
SANTRAUKA.....	68
SUMMARY	70

PAVEIKSLŲ SĄRAŠAS

1 PAV. KREDITO RIZIKOS RŪŠYS	11
2 PAV. ĮMONIŲ REITINGAVIMO PROCESAS	16
3 PAV. PREKYBOS KREDITO RIZIKOS VERTINIMO MODELIAI	19
4 PAV. PREKYBOS KREDITO RIZIKOS VERTINIMO MODELIŲ KLASIFIKACIJA	21
5 PAV. MAŽŲ IR LABAI MAŽŲ ĮMONIŲ CHARAKTERISTIKOS	24
6 PAV. TYRIMO PLANAS	30
7 PAV. KREDITO RIZIKOS VERTINIMO MODELIO MAŽOMS IR LABAI MAŽOMS ĮMONĖMS SPRENDIMO REZULTATAI (PROC.)	45
8 PAV. PRADINĖS IR RE-KALIBRACIJOS KREIVĖS	53
9 PAV. SPRENDIMŲ MEDIS (CART)	56
10 PAV. LOGISTINĖS REGRESIJOS IR CART MODELIŲ ROC KREIVĖS	59

LENTELIŲ SĄRAŠAS

1 LENTELĖ. PREKYBOS KREDITO APIBRĖŽIMO INTERPRETACIJOS MOKSLINIUOSE ŠALTINIUOSE	10
2 LENTELĖ. PREKYBOS KREDITO PAGRINDINIAI PRINCIPAI	14
3 LENTELĖ. PREKYBOS KREDITO MODELIŲ PRIVALUMAI IR TRŪKUMAI	22
4 LENTELĖ. PREKYBOS KREDITO MODELIŲ VEIKIMO PRINCIPAS MAŽOMS IR LABAI MAŽOMS ĮMONĖMS	26
5 LENTELĖ. NAUDOJAMŲ MODELIŲ PALYGINIMAS	33
6 LENTELĖ. KLASIFIKAVIMO RODIKLIAI	37
7 LENTELĖ. MODELIO KINTAMIEJI	39
8 LENTELĖ. RODIKLIŲ APRAŠOMOSIOS STATISTIKOS REZULTATAI	40
9 LENTELĖ. DUOMENŲ PARUOŠIMO REZULTATAI	41
10 LENTELĖ. TRŪKSTAMUMAS PAGAL BŪKLĘ	42
11 LENTELĖ. FINANSINIŲ RODIKLIŲ TARPUSAVIO KORELIACIJOS	43
12 LENTELĖ. FINANSINIŲ RODIKLIŲ PALYGINIMAS TARP MOKIŲ IR NEMOKIŲ ĮMONIŲ	44
13 LENTELĖ. 2X2 SUVESTINĖ	46

14 LENTELĖ. SKAITINIŲ KATEGORIJŲ SUVESTIS	47
15 LENTELĖ. BANKROTO STATUSO IR MODELIO KLASIFIKACIJOS PRIKLAUSOMUMO TESTŲ REZULTATAI	47
16 LENTELĖ. LOGISTINĖS REGRESIJOS REZULTATAI	48
17 LENTELĖ. MULTIKOLINEARUMO PATIKRA (VIF)	50
18 LENTELĖ. MODELIO KALIBRACIJA (HOSMER – LEMESHOW IR BRIER RODIKLIAI)	50
19 LENTELĖ. KALIBRACIJA DECILIAIS	51
20 LENTELĖ. MODELIO RE-KALIBRACIJOS KOEFICIENTAI	52
21 LENTELĖ. MODELIO RE-KALIBRACIJOS DIAGNOSTIKA	53

IVADAS

Darbo temos aktualumas

Mažos ir labai mažos įmonės yra vienas svarbiausių ekonomikos sektorių, reikšmingai prisidedantis prie darbo vietų kūrimo ir regioninės plėtros, tačiau šios įmonės dažnai susiduria su finansiniais apribojimais dėl ribotų vidinių išteklių ir sudėtingos prieigos prie tradicinių finansavimo šaltinių, tokių kaip bankų paskolos. Toks vertinimas yra svarbus ne tik šioms įmonėms, bet ir kitoms suinteresuotoms šalims – tiekėjams, finansų institucijoms, teikiančioms faktoringo paslaugas, ir kitoms įmonėms, kurios naudoja prekybos kreditus kaip finansavimo arba verslo santykių priemonę. Sukurtas modelis būtų naudingas įmonėms, siekiančioms įvertinti savo partnerių kreditingumą ir taip sumažinti veiklos riziką bei užtikrinti veiklos tęstinumą. Finansų institucijos, teikiančios faktoringo ar kitokias paslaugas, galėtų naudotis šiuo modeliu kaip papildomu įrankiu, padedančiu įvertinti prekybos kredito riziką ir priimti pagrįstus sprendimus dėl klientų finansavimo.

Prekybos kredito rizika yra ypatingai aktuali šioje įmonių grupėje dėl ribotų galimybių valdyti finansinę riziką. Mažų ir labai mažų įmonių pinigų srautai dažnai būna nepastovūs, o jų veikla itin jautri ekonominiams ir rinkos svyravimams. Dėl šių priežasčių, net ir nedideli įsipareigojimų nevykdymo atvejai gali turėti didelį poveikį tiek šių įmonių, tiek jų tiekėjų finansiniam stabilumui. Efektyvus prekybos kredito rizikos vertinimas ir valdymas yra būtinas siekiant sumažinti nuostolių riziką ir užtikrinti stabilumą tiek įmonių viduje, tiek visoje tiekimo grandinėje.

Darbo aktualumas kyla iš poreikio giliau analizuoti prekybos kredito rizikos valdymo strategijas mažose ir labai mažose įmonėse. Moksliniai tyrimai ir praktiniai sprendimai šioje srityje dažnai orientuojasi į didesnes organizacijas, todėl būtina sukurti specializuotus modelius ir metodikas, kurios būtų pritaikytos mažų ir labai mažų įmonių specifikai.

Analizuojamos temos ištirimo lygis

Mažų ir labai mažų įmonių prekybos kredito rizikos vertinimo modelių tyrimų lygis yra ribotas, nes mokslinėje literatūroje dažniausiai dėmesys yra skiriamas bendriesiems kredito rizikos modeliams, pritaikytiems vidutinėms ir didelėms įmonėms. Istoriniai modeliai, tokie kaip Altman (1968) Z-rezultatas, Ohlson (1980) logistinė regresija, buvo orientuoti į dideles ir vidutines

įmonės, neatsižvelgiant į mažųjų verslų finansinius ypatumus ir nepastovius pinigų srautus. Sabato (2007) atliktas tyrimas bandė pritaikyti kredito rizikos modelius mažesnėms įmonėms, tačiau vis dar trūko elgsenos ir makroekonominių veiksmų analizės. Naujausi tyrimai nagrinėja įvairius prekybos kredito aspektus, Palacin – Sanchez ir kt. (2019) analizuoja prekybos kredito ir bankinių paskolų santykį mažose ir vidutinėse įmonėse, atskleisdami, kad šie finansavimo šaltiniai gali būti tiek papildantys, tiek konkuruojantys tarpusavyje. Tingbani ir kt. (2022) nagrinėja, kaip prekybos kreditas veikia įmonių augimą, nustatydami, jog pernelyg didelis priklausomumas nuo šio finansavimo gali sukelti augimo apribojimus. Be to, skaitmeninės transformacijos poveikis prekybos kredito prieinamumui tampa vis aktualesnis - G. Liu ir Wang (2023) nustatė, kad įmonės, investuojančios į skaitmenines technologijas, gali sumažinti savo priklausomybę nuo prekybos kredito, optimizuodamos finansinius srautus. Gofman ir Wu (2022) atskleidė, kad tiekimo grandinių struktūra ir įmonės vieta joje daro reikšmingą įtaką prekybos kredito sąlygoms. Gu ir kt. (2024) bei Wang ir kt. (2020) tyrimai parodė, kad mašininio mokymosi algoritmai, tokie kaip neuroniniai tinklai ir sprendimų medžiai, gali tiksliau prognozuoti įmonių mokumo riziką, tačiau tie metodai dažniau taikomi didesnėms organizacijoms, nes mažos įmonės susiduria su ribotais duomenimis. T. Chen ir Wang (2023) analizavo mažų ir vidutinių įmonių (MSES) kredito nemokumo mechanizmą, remiantis neišsamios informacijos modeliu. Sukurtas kredito nemokumo tikimybės modelis, kuris leidžia bankams geriau valdyti su mažų ir labai mažų įmonių susijusią kredito riziką. Gu ir kt. (2024) sukūrė XGBoost pagrįstą kredito rizikos vertinimo modelį, kuris leidžia tiksliau įvertinti mažų ir labai mažų įmonių mokumo riziką. Kanapickiene ir Spicas, (2019) tyrime buvo pritaikytas statistinis prekybos kredito rizikos vertinimo modelis (ETCRA), sukurtas naudojant logistinę regresiją. Modelis buvo pritaikytas mažų ir labai mažų įmonių nemokumo tikimybei prognozuoti, remiantis tiek finansiniais, tiek nefinansiniais kintamaisiais. Hipotezė tokia, kad galima naudoti tiek tik finansinius, tiek mišrų modelį, kuris padidintų modelio tikslumą. Nors prekybos kreditai yra svarbus finansavimo šaltinis, dauguma tyrimų orientuojasi į bankinių kreditų riziką, ignoruodami mažų įmonių poreikius. Be to, trūksta aiškios metodologijos, kaip derinti finansinius, elgsenos ir makroekonominius duomenis prekybos kredito kontekste. Šis darbas siekia užpildyti šią spragą, pateikdamas modelį, kuris atitiktų mažų ir labai mažų įmonių specifinius poreikius ir padėtų efektyviau valdyti prekybos kredito riziką.

Darbo naujumas

Šiuo darbu siekiama išryškinti mažų ir labai mažų įmonių prekybos kredito rizikos vertinimo iššūkius bei pateikti teorinį pagrindą jų sprendimui. Akcentuojama, kaip specifinės šių įmonių veiklos sąlygos, riboti ištekliai ir prieigos prie finansavimo apribojimai reikalauja individualiai pritaikytų rizikos vertinimo metodų. Praktiniu požiūriu darbas siekia pateikti prekybos kredito rizikos modelį, kuris leistų tiekėjams priimti tikslius ir operatyvius sprendimus, sumažinant galimus finansinius nuostolius. Empiriniu tyrimu siekiama pademonstruoti, kaip toks modelis gali būti naudojamas realiame mažų įmonių kontekste, įvertinant tiek finansinius, tiek elgsenos rodiklius. Šio darbo naujovė slypi naujo požiūrio į rizikos vertinimą pateikime, orientuotame į smulkaus verslo kreditavimo procesų tobulinimą ir finansinio stabilumo užtikrinimą.

Darbo problema. Kaip sukurti prekybos kredito rizikos vertinimo modelį, kuris, esant ribotai informacijai apie klientus, būtų pritaikytas mažoms ir labai mažoms Lietuvos įmonėms?

Darbo tikslas. Sukurti praktinį modelį, kuris būtų skirtas mažų ir labai mažų įmonių prekybos kredito rizikos vertinimui bei sprendimų priėmimui.

Darbo uždaviniai

1. Išanalizuoti skirtingų mokslinės literatūros autorių nuomonę apie prekybos kredito rizikos sampratą, išskirti bendrus prekybos kredito rizikos bruožus ir įvertinti jos vertinimo ypatumus
2. Išnagrinėjus mokslinę literatūrą, susisteminti prekybos kredito rizikos vertinimo modelius, atskleisti jų pagrindines savybes ir galimus taikymo būdus.
3. Remiantis literatūra, apibrėžti mažų ir labai mažų įmonių sąvoką, pagrindinius bruožus.

Tyrimo metodai

Darbe taikomi mokslinės literatūros analizės ir sintezės metodai. Empirinėje dalyje naudojami kiekybiniai duomenų analizės metodai, aprašomoji statistinė analizė, logistinės regresijos ir sprendimų medžių (CART) metodai, leidžiantys palyginti skirtingų modelių tinkamumą mažų ir labai mažų įmonių prekybos kredito rizikos vertinimui.

Darbo struktūra

Magistro baigiamasis darbas sudarytas iš trijų tarpusavyje susijusių skyrių. Pirmajame skyriuje nagrinėjami teoriniai prekybos kredito rizikos aspektai, aptariama šios rizikos reikšmė smulkiojo verslo finansavimo kontekste, apžvelgiami pagrindiniai prekybos kredito rizikos vertinimo metodai bei išryškinami mažų ir labai mažų įmonių veiklos ir finansavimo ypatumai. Antrajame skyriuje pateikiama tyrimo metodologija, aprašomas pasirinktas tyrimo modelis, naudojami statistiniai ir sprendimų medžių metodai, pagrindžiama duomenų bazės sudarymo logika bei aptariami empirinio tyrimo apribojimai. Trečiajame skyriuje analizuojami tyrimo metu gauti rezultatai, vertinamas sukurto prekybos kredito rizikos vertinimo modelio tinkamumas ir prognozavimo galimybės, o darbo pabaigoje pateikiamos apibendrintos išvados ir praktinės rekomendacijos.

1. MAŽŲ IR LABAI MAŽŲ ĮMONIŲ PREKYBOS KREDITO RIZIKOS VERTINIMO TEORINIAI ASPEKTAI

1.1 Prekybos kredito samprata ir kylančios rizikos

Prekybos kreditas – tai versle dalyvaujančių subjektų tarpusavio finansinis susitarimas, kuris leidžia klientui įsigyti prekių ar paslaugų su atidėto mokėjimo sąlyga, paprastai nuo 30 iki 90 dienų. Tokia kredito forma yra išsigelbėjimas įmonėms, ypač mažoms ir labai mažoms įmonėms, kurioms dažnai sunku gauti tradicines bankų paskolas dėl riboto užstato arba griežtų skolinimo kriterijų. Kaip teigia Palacin - Sanchez ir kt. (2019) , ypač mažos ir labai mažos įmonės pasikliauja prekybos kreditais ne tik siekdamos valdyti likvidumą, bet ir užmegzti ryšius su tiekėjais bei didinti savo konkurencingumą rinkoje. Prekybos kreditų ekonominė reikšmė apima ne tik atskiras įmones, bet ir makroekonominį stabilumą. Finansinių krizių ar ekonomikos nuosmukių metu prekybos kreditas veikia kaip anticiklinė priemonė, leidžianti įmonėms užtikrinti likvidumą, kai bankai sugriežtina skolinimo politiką (Deari ir kt., 2020). Tiekėjai, naudodamiesi savo informaciniu pranašumu, įgytu dėl nuolatinio verslo bendravimo, dažnai teikia kreditus pirkėjams net tada, kai kiti finansavimo būdai tampa neprieinami. Prekybos kreditas tampa nepakeičiamas siekiant palaikyti veiklos tęstinumą bei valdyti grynųjų pinigų srautus ir palaikyti augimą (X. Chen ir kt., 2021). Skirtingai nei įprastinis finansavimas, prekybos kreditas grindžiamas pasitikėjimu ir glaudžiais verslo santykiais, todėl tiekėjai gali veiksmingai įvertinti ir stebėti pirkėjų kreditingumą.

Lietuvių autorių nuomone, prekybos kreditas – trumpalaikė paskola, kuri yra suteikiama pirkėjui, ir yra siejama su trumpalaike paskola iš banko ar kredito unijos. Tačiau skirtumas yra tas, kad prekybos kreditą suteikia ne finansų institucija, o pardavėjas, kuris finansuoja pirkėją, parduodamas savo prekes ar paslaugas (Pridotkienė, 2012). Nepaisant to, vienos nuomonės nėra, kai kurie autoriai teigia, kad prekybos kreditas yra tas pats, kas komercinis kreditas, kadangi jame dalyvauja verslo įmonės. Vadovaujantis finansinio raštingumo specialistų nuomone, komercinis kreditas yra natūralaus finansavimo šaltinis – trumpalaikis įsiskolinimas tiekėjams už prekes, žaliavas ar paslaugas. Kaip nurodo Pridotkienė (2012), esminis skirtumas tarp prekybos kredito ir banko paskolos yra tas, kad banko paskoloms būdinga materialinė nauda kredito tiekėjui, o nemateriali nauda būdinga kredito tiekėjams.

Išanalizavus užsienio autorių požiūrius mokslo darbuose, apie prekybos kreditą, matyti, kad visų jų mintys iš esmės yra panašios, nes visi pabrėžia prekybos kredito reikšmę kaip finansinio įrankio, kuris yra skirtas užtikrinti likvidumą ir palaikyti įmonių veiklos tęstinumą. Kiekvienas autorius pabrėžia skirtingus aspektus. Sąvokų apibrėžimai apibendrinti 1 lentelėje.

1 lentelė

Prekybos kredito apibrėžimo interpretacijos moksliniuose šaltiniuose

Autorius	Apibrėžimas
(Hasan ir kt., 2024)	Prekybos kreditas yra pagrindinis likvidumo šaltinis, leidžiantis įmonėms valdyti trumpalaikius veiklos poreikius atidedant mokėjimus už prekes ir paslaugas.
(Zhang ir kt., 2024)	Prekybos kreditas yra finansavimo priemonė, pagrįsta pasitikėjimu ir veiklos būtinumu, ypač naudinga stabilizuojant tiekimo grandines ir suteikiant įmonėms galimybę išlaikyti likvidumą.
(Gao ir kt., 2023)	Prekybos kreditas - tai trumpalaikis finansavimo mechanizmas, plačiai naudojamas B2B sandoriuose, palaikantis likvidumą ir skatinantis ekonominį stabilumą, ypač rinkose, kuriose yra didelė informacijos asimetrija.
(Hasan ir kt., 2024)	Prekybos kreditas yra oficialaus finansavimo alternatyva, suteikianti įmonėms lankstų būdą subalansuoti gryųjų pinigų srautus ir stiprinanti tiekėjų ir pirkėjų santykius.
(Xu & Dao, 2020)	Prekybos kreditas - tai priemonė finansiniams suvaržymams kompensuoti, leidžianti pirkėjams naudotis prekėmis ar paslaugomis atidedant mokėjimą, taip užpildant likvidumo spragas ekonominio neapibrėžtumo laikotarpiais.
(Hasan & Alam, 2022)	Prekybos kreditas yra svarbi bankų paskolų alternatyva, kuri yra finansinė strategija, padedanti sušvelninti pinigų srautų problemas ir didinti tiekimo grandinės operacijų atsparumą.

Šaltinis: sudarytas autorių, remiantis pateiktais autoriais

Lentelėje išvardyti autoriai pabrėžia prekybos kredito svarbą kaip trumpalaikę finansinę priemonę, padedančią įmonėms palaikyti likvidumą, valdyti pinigų srautus ir užtikrinti veiklos tęstinumą. Jie vieningai sutaria, kad prekybos kreditas yra svarbus stabilizuojant tiekimo grandines ir stiprinant santykius tarp tiekėjų bei pirkėjų. Be to, prekybos kreditas laikomas veiksmingu mechanizmu ekonominio neapibrėžtumo sąlygomis, padedančiu kompensuoti finansinius suvaržymus ir užpildyti likvidumo spragas. Kai kurie autoriai akcentuoja jo reikšmę rinkose su informacijos asimetrija, o kiti – pasitikėjimu grįsta jo pobūdį, leidžiantį efektyviai valdyti tiekimo grandines. Taigi, lentelėje aprašyti požiūriai rodo, kad prekybos kreditas vienu


metu vertinamas ir kaip praktinis finansinis įrankis, ir kaip strateginė priemonė ilgalaikiams verslo ryšiams kurti.

Prekybos kreditas yra svarbus įrankis, leidžiantis įmonėms užtikrinti veiklos tęstinumą, palaikyti likvidumą ir stiprinti santykius su tiekėjais, tačiau, kaip ir bet kuri kita kredito forma, jis taip pat yra susijęs su tam tikromis rizikomis. Prekybos kredito rizika dažnai kyla dėl nesugebėjimo laiku atlikti mokėjimus, likvidumo apribojimų, rinkos nepastovumo, ribotos informacijos apie prekybos partnerius, tiekimo grandinių trukdžių bei makroekonominio neapibrėžtumo. Papildomai riziką didina veiklos priklausomybė nuo nedidelio skaičiaus pirkėjų ar tiekėjų, valiutų kursų svyravimai bei politinės ar teisinės aplinkos pokyčiai, galintys paveikti sandorius. Šie veiksniai daro prekybos kreditą jautresnį operaciniams ir rinkos iššūkiams, palyginti su komercinio kredito rizika, su kuria susiduria finansinės institucijos. Tuo tarpu bankų kredito riziką didina panašūs veiksniai, įskaitant skolininkų mokėjimo vėlavimus, jų likvidumo trūkumą ir rinkos svyravimus, tačiau taip pat svarbūs sisteminiai rizikos elementai, tokie kaip makroekonominiai pokyčiai, prasta portfelio diversifikacija ar netikėtos krizės finansų rinkose. Nors kai kurie veiksniai yra bendri, prekybos kredito rizika labiau susijusi su operaciniu ir individualių partnerių veiklos kontekstu, o finansinių institucijų rizika dažniau veikiama makroekonominių ir sisteminių veiksnių.

Moksliniuose straipsniuose yra analizuojamos įvairiausios kredito rizikos rūšys, tačiau, remiantis naujausia užsienio literatūra, yra išryškintos pagrindinės keturios (1 paveikslas).

1 paveikslas

Kredito rizikos rūšys



Šaltinis: sudaryta autorės, remiantis Bhattacharya, Biswas ir Mandal, 2023.

Iš keturių skirtingų rizikos rūšių, daugiausiai dėmesio analizuojamame Bhattacharya, Biswas ir Mandal, (2023) straipsnyje yra skiriama kredito įsipareigojimų nevykdymo rizikai. Tai rizikos rūšis, kai bankas patiria nuostolių paskolos gavėjui nevykdant savo įsipareigojimų, susijusių su palūkanomis arba pagrindine paskolos suma. Tai gali paveikti visus kredito rizikos sandorius, pavyzdžiui, paskolas ir vertybinius popierius. Ši rizika yra tinkama prekybos kreditui, nes ši rizika yra tiesiogiai susijusi su galimybe, kad pirkėjas nevykdys savo įsipareigojimų sumokėti už prekes ar paslaugas. Koncentracijos rizika – rizika, susijusi su viena ar keliomis pozicijomis, kurios gali sukelti pakankamai didelius nuostolius, kad kiltų grėsmė pagrindinei banko veiklai arba jeigu tai yra prekybos kreditas, tai suteikiant kreditą ribotam skaičiui pirkėjų arba jei didelė įmonės pajamų dalis priklauso nuo kelių pagrindinių klientų, o priklausomybė nuo tam tikrų klientų gali kelti riziką, jeigu kuris nors iš jų taps nemokus. Šalies rizika – nuostolių rizika, atsirandanti dėl suverenios valstybės įšaldant mokėjimus užsienio valiuta arba nevykdant savo įsipareigojimų. Prekybos kreditui ši rizika yra aktuali tik tuo atveju, jei tiekėjas ir pirkėjas yra skirtingose šalyse. Tokiu atveju valiutų svyravimai, politiniai ir ekonominiai veiksniai gali turėti įtakos prekybos sandorių įgyvendinimui. Sandorio šalies kredito rizika – rizika, kad sandorio šalis gali nevykdyti įsipareigojimų prieš galutinį atsiskaitymą už sandorio pinigų srautus. Ši rizika svarbi prekybos kreditui, nes ji apima galimybę, kad pirkėjas nevykdys įsipareigojimų iki nustatyto termino.

Vienas iš pagrindinių prekybos kredito rizikos bruožų yra tiesioginis ryšys su tiekimo grandinės valdymu. Prekybos kreditas dažnai yra grindžiamas dvišaliais susitarimais, kai tiekėjai suteikia galimybę atidėti mokėjimus už prekes ar paslaugas, tikėdamiesi, kad pirkėjai atsiskaitys laiku. Tokie susitarimai dažnai yra grindžiami ribota finansine analize, nes įmonės, skirtingai nei bankai, neturi išsamios prieigos prie kredito istorijos ir kitu svarbių duomenų apie savo klientus (Xie ir kt., 2022). Ši rizika padidėja ekonominio nestabilumo laikotarpiais, COVID – 19 pandemijos metu, kai bendrovių mokumas gerokai sumažėja dėl sumažėjusios paklausos ar tiekimo grandinės sutrikimų (Yin ir kt., 2022). Pavyzdžiui, Serbijoje atliktas kredito rizikos cikliškumo rodo, kaip ekonominis nestabilumas tiesiogiai veikia prekybos kredito riziką, nes daugelis pirkėjų negali įvykdyti savo įsipareigojimų (Kanazir, 2023). Tokiais atvejais prekybos kreditus teikiančios bendrovės patiria ne tik tiesioginių nuostolių dėl neatsiskaitymo, bet ir

sisteminės rizikos poveikį, kai vieno pirkėjo finansiniai sunkumai gali sukelti grandininę reakciją (Xie ir kt., 2022).

Skirtingai nuo prekybos kredito, paprasto kredito rizika yra dažniau siejama su finansų įstaigų teikiamomis paskolomis ir kitais finansavimo produktais. Pavyzdžiui, bankai, siekdami sumažinti riziką, taiko sudėtingas kredito vertinimo priemones, tokias kaip kredito reitingų duomenys, finansinių ataskaitų analizė ir portfelio diversifikavimo strategijos. Finansų sektoriuje kredito rizika dažnai analizuojama kaip sisteminės rizikos dalis, o tai reiškia platesnes ekonomines pasekmes. Tuo tarpu prekybos kredito rizika dažniau siejama su mikro lygio įvykiais, pavyzdžiui, individualių klientų nesugebėjimu laiku atlikti mokėjimus, kas tiesiogiai veikia tiekėjo veiklos rezultatus (Bams ir kt., 2021).

Nuolat didėjanti konkurencinė aplinka versle daro reikšmingą įtaką prekybos kredito atsiradimui ir plėtrai. Prekybinės įmonės, kurios siekia didinti prekių ir paslaugų pardavimus ir pritraukti naujų klientų, turi ieškoti sprendimų, kaip klientams pasiūlyti priimtinesnes mokėjimo už prekes ar paslaugas sąlygas. Nebūtinai žemesnės kainos pritraukia pirkėjus, svarbu yra pasiūlyti konkurencingas sutarčių sąlygas. Didelėje konkurencijos aplinkoje pirkėjai gali rasti tą pačią prekę keliose skirtingose vietose, dažnai net to paties segmento internetinėse parduotuvėse. Tokiais atvejais sprendimą, kur įsigyti prekę, lemia įmonės patikimumas, žinomumas, kainos patrauklumas, siūlomų naudų įvairovė ir, žinoma, patogios atsiskaitymo sąlygos bei kreditavimo principai.

Literatūroje yra plačiai analizuojami ir apibrėžiami pagrindiniai prekybos kredito principai – tai taisyklių, procedūrų ir sąlygų visuma, apibrėžianti tiek prekybos kredito suteikimo mechanizmą, tiek jo priežiūros ir valdymo praktiką. Šie principai formuoja nuoseklų kredito teikimo pagrindą, padeda įmonėms valdyti likvidumo riziką, sumažinti galimų nuostolių tikimybę bei užtikrinti stabilų atsiskaitymo procesą tiek mikro, tiek makroekonominiu lygmeniu. Be to, jie sudaro esminę įmonių tarpusavio finansinių santykių architektūros dalį, prisidedant prie atsakingo kredito teikimo kultūros formavimo ir veiksmingo įsipareigojimų vykdymo užtikrinimo. Atsižvelgiant į tai, žemiau pateikiami svarbiausi prekybos kredito principai ir jų turinys (2 lentelė).

2 lentelė

Prekybos kredito pagrindiniai principai

Prekybos kredito principas	Aprašymas
Kredito atsiskaitymo terminas	Prekybos kreditas suteikiamas su aiškiai nustatytu atsiskaitymo terminu. Klientai privalo sumokėti už prekes ar paslaugas iki nustatytos datos.
Kredito limitas	Nustatomas maksimali suma, kurią klientas gali pasiskolinti iš tiekėjo. Šis limitas priklauso nuo kliento finansinio stabilumo ir mokumo istorijos.
Kredito laikotarpis	Apibrėžiamas laikotarpis, per kurį kreditas turi būti grąžintas. Tai užtikrina tiekėjo likvidumo valdymą ir skatina laiku vykdyti įsipareigojimus.
Kredito garantijos (draudimas)	Draudimo polisas ar užstatas apsaugo tiekėją nuo kliento nemokumo.
Tikslinis kredito pobūdis	Kreditas gali būti suteikiamas ne visoms prekėms ar paslaugoms, o tik tam tikrai jų grupei arba kategorijai
Sutarties sąlygos	Aiškiai apibrėžiamos atsiskaitymo taisyklės, sąlygos, taikomos sankcijos už vėlavimą ar sutarties pažeidimus

Šaltinis: sudaryta autorės, remiantis Petersen ir Rajan, 1997.

Prekybos kredito principai pabrėžia svarbiausius aspektus, užtikrinančius aiškią, saugią ir veiksmingą tiekėjo ir kliento bendradarbiavimo sistemą. Kredito atsiskaitymo terminas padeda išvengti vėlavimų atsiskaitymuose ir skatina abiejų šalių įsipareigojimų vykdymą, nustatydamas konkrečią datą, iki kurios turi būti atliktas mokėjimas. Tuo tarpu, kredito laikotarpis apima bendrą laikotarpį, per kurį klientas gali disponuoti prekėmis ar paslaugomis, nesuteikdamas mokėjimo. Nors abu principai yra susiję, jų tikslai ir funkcijos skiriasi. Kredito laikotarpis orientuojasi į pinigų srautų planavimą ir klientui suteikiamą lankstumą, o kredito atsiskaitymo terminas yra sutartinis įsipareigojimas, kuris nustato konkrečią mokėjimo datą. Kredito limitas apsaugo tiekėją nuo pernelyg didelio rizikos lygio ir užtikrina, kad klientas neperžengtų savo finansinių galimybių.

Kredito laikotarpis padeda planuoti pinigų srautus ir sumažina tikimybę, kad kredito grąžinimas bus atidėtas. Kredito garantijos mažina tiekėjo finansinę riziką ir leidžia lengviau suteikti kreditą rizikingesniems klientams. Tikslinis kredito pobūdis leidžia geriau valdyti kredito riziką, susitelkiant į tam tikras prekes ar paslaugas, kurios yra svarbios verslo veiklai. Sutarties sąlygos užtikrina kad tiekėjas ir klientas turėtų bendrą supratimą apie atsiskaitymo tvarką ir būtų mažinama ginčų tikimybė. Tokia prekybos kredito pagrindinių principų lentelė gali būti naudojama kaip gairės kredito politikai kurti arba klientų atsiskaitymo procesams tobulinti.

Norint, kad visas kredito procesas vyktų sklandžiai, yra reikalingas kredito reitingas. Kredito reitingai yra pagrindinė finansinių sprendimų priėmimo priemonė, daranti įtaką įmonių strategijoms, investuotojų elgsenai ir rinkos dinamikai. Šie reitingai daro tiesioginę įtaką tiek bankų, tiek verslo įmonių sprendimams, nors jų taikymo tikslai skiriasi. Verslo įmonėms kredito reitingai padeda formuoti strategijas, siekiant išvengti reitingų sumažinimo ar pasinaudoti geresnėmis finansavimo sąlygomis, o bankai juos naudoja vertindami skolininkų riziką ir mažindami nemokumo tikimybę. Šiuolaikinėje praktikoje tradiciniai ir skaitmeniniai kredito reitingai yra derinami, siekiant veiksmingai formuoti skolų grąžinimo elgesį ir tiksliau valdyti riziką (Aktas ir kt., 2021). Pavyzdžiui, duomenų integracija leidžia tiek bankams, tiek verslo įmonėms efektyviau vertinti skolininkų kreditingumą ir užtikrinti įsipareigojimų vykdymą (Li ir kt., 2024). Bankai kredito reitingus taiko finansiniam rizikos vertinimui ir paskolų portfelių valdymui, o verslo įmonės naudoja juos kaip strateginį įrankį kapitalo struktūros optimizavimui. Nors taikymo tikslai skiriasi, kredito reitingai abiem atvejais išlieka esminiu finansinių sprendimų ir rizikos valdymo pagrindu.

Naujausi tyrimai pabrėžia kredito reitingų metodikų tobulėjimą. Tradiciniai kiekybiniai tyrimai – pagrįsti tokiais finansiniais rodikliais kaip pelningumas, skolų ir nuosavo kapitalo santykiai, pinigų srautai – dabar vis dažniau papildomi kokybiniais veiksniais, tokiais kaip vadovybės kokybė, pramonės dinamika ir makroekonominės tendencijos. Pavyzdžiui, Donovan ir kt. (2021), pabrėžia „minkštųjų pataisymų“ svarbą tobulinant kredito reitingus per kokybinius atskleidimus, tokius kaip vadovų diskusijos ir pramonės perspektyvos, kurie pagerina reitingų prognozavimo tikslumą.

Kredito reitingai taip pat susiduria su kritika dėl jų vaidmens skatinant sisteminę riziką. Kladakis ir Skouralis (2023) parodė, kad pagrindinių institucijų reitingų sumažinimas didina


sisteminę riziką, ypač kai reitingai nukrenta nuo investicinio iki spekuliatyvaus lygio, sukeliančio didelių rinkos sutrikimų. Be to, bankų reitingai tampa vertingais tradicinių kredito reitingų agentūrų papildai, suteikdami unikalių įžvalgų, pagrįstų skolintojų glaudesniais ryšiais su skolininkais. Šios papildomos perspektyvos padidina kredito vertinimų patikimumą, ypač prognozuojant nemokumus (Lourie ir kt., 2024).

Bankų skolininkų rizikai vertinti naudojami įvairūs metodai – nuo kiekybinių iki kokybinių. Dažniausiai bankų reitingų sistemos remiasi šių dviejų metodų deriniu. Bazelio bankų priežiūros komitetas (BCBS, 2004) apibrėžia reitingų sistemą kaip visų metodų, kontrolės mechanizmų, duomenų rinkimo ir IT sistemų visumą, kuri leidžia įvertinti kredito riziką ir jos komponentus bei nustatyti vidaus reitingus. Atsižvelgdami į savo veiklos specifiką ir poreikius, bankai taiko skirtingas reitingavimo sistemas, tačiau visos jos privalo atitikti bendrus reikalavimus. Europos Sąjungos šalyse reitingų sistemos, naudojamos kapitalo poreikio skaičiavimui, turi atitikti Europos Parlamento ir Tarybos direktyvą 2006/48/ED.

Bankai reitingavimą naudoja tiek skolininko, tiek paskolos rizikai vertinti. 2 paveiksle pavaizduotas įmonių reitingavimo procesas.

2 paveikslas

Įmonių reitingavimo procesas



Šaltinis: sudaryta autorės, remiantis Savickaite ir Valvonis, 2007.

Bankai renka įvairius metodus įmonių reitingavimui. Statistinis modelis naudojamas gan retai – jis dažniau taikomas vertinant fizinių asmenų arba mažų ir vidutinių įmonių riziką. Stambių

įmonių paskolos paprastai būna labiau individualizuotos, todėl standartizuotas statistinis metodas negali tiksliai atskleisti visų skolininko savybių. Be to, bankai dažnai neturi pakankamai duomenų apie įmonių įsipareigojimų nevykdymo atvejus, todėl statistinių modelių taikymas tampa sudėtingas dėl empirinio pagrindimo trūkumo.

Modelio sudarymas – renkama informacija - kiekybiniai ir kokybiniai rodikliai, kuri vertinama nustatant reitingą, visa ši informacija perduodama eksperto ir statistiniam vertinimui, tai pagrindžia modelio logiką. Modelio pritaikymas – peržiūrimi reitingai, jie nustatomi ir tada įsipareigojimų nevykdymo tikimybė (PD) priskiriama reitingui. Paskutinis reitingavimo proceso žingsnis – rezultatų taikymas. Atliekamas praktinio taikymo testas, vertinami PD rodikliai, reitingai ir jie pritaikomi banko veikloje.

Apibendrinant galima teigti, kad prekybos kreditas yra itin svarbi trumpalaikio finansavimo priemonė, leidžianti įmonėms palaikyti likvidumą, užtikrinti veiklos tęstinumą ir stiprinti santykius su tiekėjais. Skirtingai nuo komercinio finansavimo prekybos kreditas grindžiamas pasitikėjimu ir glaudžiais verslo santykiais, o jo efektyvumas ypač akivaizdus mažoms ir labai mažoms įmonėms, kurios dažnai susiduria su ribota prieiga prie bankinių finansavimo šaltinių. Nors prekybos kreditas suteikia reikšmingą naudą įmonių veiklai, jis taip pat yra susijęs su įvairiomis rizikomis, tokiomis kaip mokėjimų vėlavimai, likvidumo trūkumas ir rinkos svyravimai, kurie reikalauja atitinkamų valdymo ir vertinimo priemonių. Kredito rizikos modeliai ir reitingavimo metodikos leidžia tiksliau įvertinti skolininkų gebėjimą vykdyti įsipareigojimus ir padeda užtikrinti tiek individualių įmonių, tiek visos ekonomikos stabilumą. Šių priemonių efektyvumas priklauso nuo tinkamos duomenų integracijos, veiksmingos kredito politikos ir nuolatinio rizikos valdymo strategijų tobulinimo.

1.2 Prekybos kredito rizikos vertinimo modeliai

Prekybos kredito rizikos vertinimo modeliai yra svarbi finansų analizės ir rizikos valdymo priemonė, leidžianti nustatyti kliento tikimybę nevykdyti įsipareigojimų bei įvertinti galimą nuostolių mastą. Smulkiojo ir labai smulkiojo verslo kontekste šių modelių reikšmė dar labiau išauga, nes mažos įmonės dažnai neturi pakankamų finansinių rezervų ar ilgalaikio kredito istorijos, o jų veikla pasižymi didesniu nepastovumu. Todėl prekybos kredito rizikos modeliai tampa esminiu informacijos šaltiniu tiek tiekėjams, tiek kredito valdytojams, padedant priimti

labiau pagrįstus ir riziką mažinančius sprendimus dėl kredito ribų nustatymo, atsiskaitymo terminų suteikimo ar papildomų garantijų reikalavimo.

Per pastaruosius dešimtmečius prekybos kredito rizikos vertinimo modelių raida atskleidė aiškia tendenciją – nuo paprastų, tik finansinių rodiklių pagrindu sudarytų vertinimų pereinama prie sudėtingesnių, kompleksinių sistemų, integruojančių tiek finansinius, tiek nefinansinius, elgsenos ir operacinius duomenis. Tai susiję su augančia duomenų prieiga, didėjančiu analitinių įrankių tikslumu ir pastangomis sumažinti informacijos asimetriją tarp kredito tiekėjo ir gavėjo. Modeliai padeda įmonėms ne tik įvertinti klientų mokumo riziką, bet ir sukurti labiau struktūruotą kredito politiką, išvengti pernelyg didelio rizikos prisiėmimo bei subalansuoti augimo ir finansinio stabilumo tikslus.

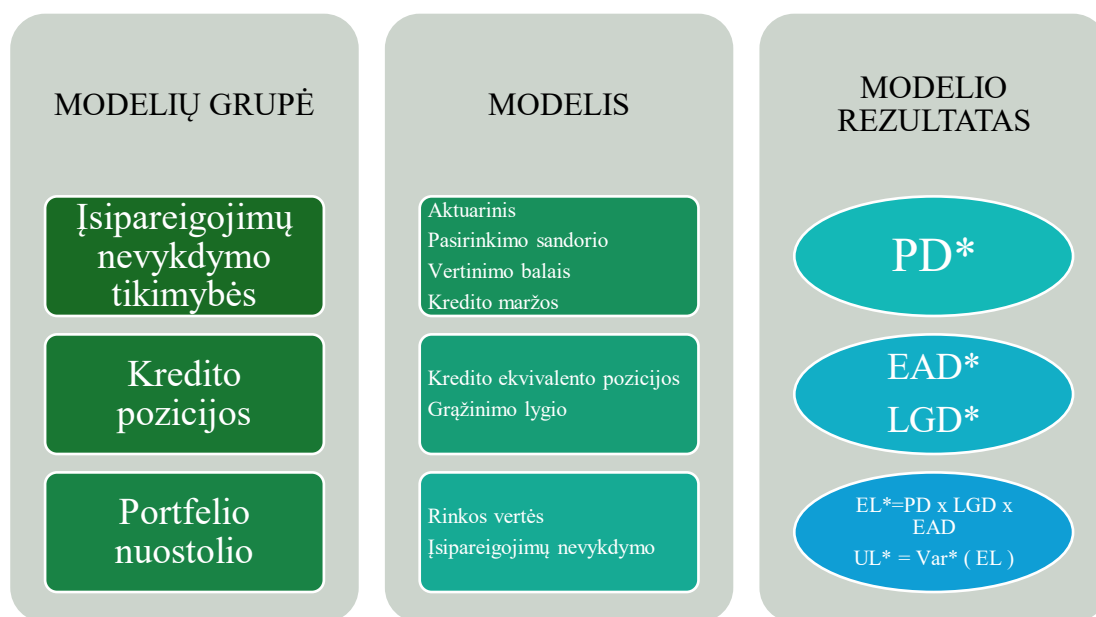
Remiantis Valvonio ir Kamieno (2004) įžvalgomis, kredito rizikos vertinimo modeliai apima keletą pagrindinių parametrų, kurie leidžia įvertinti skirtingus nuostolių komponentus: įsipareigojimų nevykdymo tikimybę (probability of default – PD), nuostolį nevykdymo atveju (loss given default – LGD), kredito pozicijos dydį nevykdymo momentu (exposure at default – EAD) ir kredito pozicijos trukmę (maturity – M). Nors iš pradžių šie modelio komponentai buvo sukurti bankų sektoriui, jų interpretacijos logika gali būti pritaikyta ir prekybos kredito analizei, tačiau būtina atsižvelgti į reikšmingus skirtumus tarp paskolų ir prekybos kreditų.

Prekybos kreditas yra trumpalaikis finansavimo instrumentas, todėl rizikos parametrai turi specifinį pritaikymą. PD vertinamas trumpesniajam laikotarpiui – dažnai 30–90 dienų apmokėjimo ciklui. LGD priklauso nuo užtikrinimo priemonių tipo ir apimties, tačiau prekybos kredite dažnai nėra formalių užstatų, todėl LGD gali būti aukštesnis nei bankų sektoriuje. EAD prekybos kredite atitinka suteiktą prekių ar paslaugų vertę, kuri paprastai neturi formalaus materialaus užtikrinimo. Kredito pozicijos trukmė (M) taip pat yra trumpesnė, vertinama pagal konkretų užsakymo ir atsiskaitymo ciklą.

Šių parametrų visuma leidžia įvertinti tikėtinus (EL) ir netikėtus (UL) nuostolius, kurie yra būtini tiek rizikos kainodarai, tiek kredito portfelio valdymui. Vis dėlto dėl prekybos kredito operacijų trumpalaikiškumo, mažesnio formalumo ir didesnio kliento elgsenos vaidmens, rizikos valdytojai privalo daugiau dėmesio skirti operaciniams ir elgsenos indikatoriams, kurie geriau atskleidžia mokėjimo drausmę ir tikimybę laiku atsiskaityti. Dėl šių priežasčių prekybos kredito rizikos vertinimo modeliai turi būti adaptuoti ir pritaikyti unikaliai prekybos kredito kontekstui, įtraukiant specifinius duomenų šaltinius ir vertinimo principus (3 paveikslas).

3 paveikslas

Prekybos kredito rizikos vertinimo modeliai



* PD (angl. probability of default) – įsipareigojimų neįvykdymo tikimybė

* EAD (angl. exposure at default) – kredito pozicijos dydis nevykdymo metu

*LGD (angl. loss given default) - nuostolis įsipareigojimų nevykdymo atveju

*EL (angl. expected loss) – tikėtinas nuostolis

*UL (angl. unexpected loss) – netikėtas nuostolis)

*Var (angl. value of risk) – rizikos vertinimas

Šaltinis: sudaryta autorės, remiantis Kamieniu ir Valvonių (2004)

Remiantis moksline literatūra, kredito rizikos vertinimo modeliai yra skirstomi į kelias pagrindines grupes pagal naudojamus metodus ir vertinimo tikslus. Pagrindiniai modeliai yra šie:

- **Statistiniai modeliai**
- **Elgsenos modeliai**
- **Struktūriniai modeliai**
- **Hibridiniai modeliai**
- **Makroekonominiai modeliai**
- **Dirbtinio intelekto ir mašininio mokymosi modeliai**

Statistiniai modeliai yra vieni seniausių ir labiausiai pripažintų metodų kredito rizikos vertinimui. Jie remiasi istorinių duomenų analize ir matematiniais metodais, tokiais kaip regresijos analizė ir diskriminantinė analizė. Vienas žymiausių statistinių modelių yra **Altman Z- score**

(Altman, 1968), kuris naudoja finansinius rodiklius, tokius kaip likvidumas, pelningumas ir įsipareigojimų santykis su turtu, siekiant prognozuoti įmonių bankrotą. Altman Z modelis nėra tinkamas mažoms ir labai mažoms įmonėms, nes daugelis tokių įmonių yra nelistinguojamos, įmonės akcijomis nėra viešai prekiaujama, todėl pagal Altman formulę, X_4 negali būti apskaičiuotas. Balanso rodikliai gali neatsispindėti tikrosios finansinės būklės dėl neapskaitytų neformalių įsipareigojimų, nes mažos įmonės labiau priklauso nuo pinigų srautų nei nuo balanso rodiklių. Kitas svarbus metodas – **logistinė regresija**, kurią pirmasis pasiūlė (Ohlson, 1980), siekiant įvertinti bankroto tikimybę. Skirtingai nuo Altman Z modelio, kuris remiasi tik balanso ir pelno (nuostolių) rodikliais, logistinė regresija leidžia įtraukti ir nefinansinius duomenis, todėl logistinė regresija gali būti taikoma mažoms ir labai mažoms įmonėms, jeigu yra pakankamai duomenų ir į modelį įtraukiami tinkami rodikliai. Geriausia logistinę regresiją taikyti kartu su alternatyviais metodais.

Elgsenos modeliai suteikia dėmesį į skolininkų elgesį, nagrinėjant jų mokėjimų istoriją, kontraktų laikymosi įpročius ir operacijų dažnumą. Šie modeliai ypač naudingi mažoms ir labai mažoms įmonėms, kurios dažnai neturi detalių finansinių duomenų. (Thomas ir kt., 2002), akcentavo elgsenos modelių svarbą mažmeniniam kreditui, o Altman, Sabato, Wilson (2010) ištyrė jų naudą sektoriuje. Šių modelių pranašumas – galimybė įvertinti klientų mokumo riziką pagal jų veiklos įpročius. Goel ir Rastogi (2023) tyrė elgsenos kredito vertinimo modelių taikymą, siekiant prognozuoti mažų ir vidutinių įmonių kredito riziką, įtraukiant psichologinius ir elgsenos veiksnius, tokius kaip verslumo savivertė ir sąžiningumas. Nors elgsenos modeliai gali būti naudingi mažoms ir labai mažoms įmonėms, kurios dažnai neturi išsamios finansinės istorijos, jų taikymas yra ribotas dėl subjektuvumo ir sunkumų kvantifikuojant skolininko „charakterį“, todėl jie turėtų būti derinami su kitais metodais.

Struktūriniai modeliai yra grindžiami įmonių kapitalo struktūros analize ir daugiausiai naudojami didelėms įmonėms. Merton (1974) modelis, pagrįstas pasirinkimo sandorių teorija, leidžia įvertinti įmonės turto ir įsipareigojimų santykį, nustatant galimybę vykdyti įsipareigojimus. Black ir Scholes (1973) darbai opcionų kainodaros srityje taip pat tapo pagrindu šiems modeliams, kurie yra ypač veiksmingi prognozuojant ilgalaikius įsipareigojimus. Matanga ir Holman (2024) atliktas tyrimas, pritaikant Altman Z- score modelį ankstyviems įspėjamiesiems

signalams, parodė, kad struktūrinių modelių adaptavimas gali pagerinti prognozavimo tikslumą tam tikrose sektoriuose.

Hibridiniai modeliai integruoja statistinius, elgsenos ir makroekonominis duomenis, siekdami užtikrinti išsamesnį ir lankstesnį kredito rizikos vertinimą. Kanapickiene ir Spicas (2019) pasiūlė tokį modelį, kuris apjungia finansinius rodiklius SME'ų rizikai vertinti Lietuvoje. Grunert, Norden ir Weber (2005) pabrėžė hibridinių modelių pranašumus, ypač kai vertinami tiek kiekybiniai, tiek kokybiniai rodikliai. Šie modeliai leidžia prisitaikyti prie skirtingų pramonės šakų ir dinamiškos aplinkos.


Makroekonominiai modeliai vertina kredito riziką platesniame ekonominiame kontekste, nagrinėjant tokius veiksnius kaip bendras vidaus produktas (BVP), infliacija ir sektoriaus augimas. Duffie ir Singleton (1999) bei Pasaran, Schuermann ir Treutler (2006) sukūrė modelius, kurie susieja kredito riziką su pasauliniais ekonominiais rodikliais, pabrėždami jų įtaką bankų sektoriaus stabilumui. 2021 m. Europos Centrinis Bankas pabrėžė kredito rizikos valdymo svarbą, atsižvelgiant į makroekonominis rodiklius ir jų įtaką bankų sektoriaus stabilumui.

Dirbtinio intelekto ir mašininio mokymosi modeliai yra naujausia kredito rizikos vertinimo kryptis. Khandani, Kim ir Lo (2010) pasiūlė naudoti sprendimų medžius ir neuroninius tinklus, leidžiančius analizuoti didelius duomenų kiekius ir prognozuoti riziką realiuoju laiku. Baesens ir kt. (2003) ištyrė įvairių mašininio mokymosi modelių, tokių kaip genetiniai algoritmai ir palaikymo vektorių mašinos, taikymą kredito rizikos vertinimui.

Daugybė mokslinių tyrimų ir publikacijų pabrėžia kredito rizikos vertinimo modelių svarbą bei reikalingumą, todėl šiuos modelius galima klasifikuoti į kelias grupes (4 paveikslas).

4 paveikslas

Prekybos kredito rizikos vertinimo modelių klasifikacija



Šaltinis: sudaryta autorės, remiantis Mackevičiumi ir Silvanavičiūte (2006)

Šioje klasifikacijoje pabrėžiama, kad kredito rizikos vertinimo modeliai gali būti skirstomi pagal taikomas metodologijas į dvi pagrindines grupes: tradicinius statistinius įrankius ir pažangius dirbtinio intelekto sprendimus. Šalia tradicinių statistinių modelių, sukurtų įmonių finansinės būklės ir bankroto prognozavimui, buvo sukurti pažangūs dirbtinio intelekto metodai, tokie kaip sprendimų medžiai ir neuronų tinklai. Sprendimų medžių modeliai, grindžiami hierarchiniu duomenų skaidymu pagal rizikos požymius, leidžia identifikuoti įmones, kurios turi didžiausią tikimybę nesugebėti laiku vykdyti įsipareigojimų. Tuo tarpu dirbtiniai neuroniniai tinklai pasižymi gebėjimu analizuoti sudėtingas netiesines priklausomybes tarp rodiklių ir nustatyti svarbiausius veiksnius, darančius įtaką įmonės rizikai (Mackevičius ir Silvanavičiūtė, 2006). Nors šie metodai iš pradžių buvo taikomi bankroto rizikos prognozavimui, jų taikymo galimybės puikiai tinka ir prekybos kredito rizikos vertinimui (Caldarelli ir kt., 2016). Dauguma analizuojamų rodiklių, tokių kaip mokėjimo istorija, finansinis stabilumas ar elgsenos veiksniai, yra bendri abiem sritims. Šių modelių universalumas leidžia juos sėkmingai naudoti prekybos kredito kontekste, užtikrinant tikslesnius sprendimus dėl kredito suteikimo ir efektyvų rizikos valdymą. Kiekviena grupė turi savo privalumų ir trūkumų, kurie detaliai apibendrinti 3 lentelėje.

3 lentelė

Prekybos kredito modelių privalumai ir trūkumai

MODELIS	PRIVALUMAI	TRŪKUMAI
TEISINĖ DISKRIMINANTINĖ ANALIZĖ	Aiški interpretacija, veiksmingumas mažose imtyse, plačios pritaikymo galimybės, istorinis patikimumas (Altman, 1968; Cındık ir kt., 2021; Đuričin ir kt., 2024; Trinh, 2024)	Priklausomybė nuo prielaidų, jautrumas duomenų kokybei, ribota taikymo sritis prekybos kredite (Cındık ir kt., 2021; Đuričin ir kt., 2024; Trinh, 2024)
LOGISTINĖ REGRESIJA	Paprastas taikymas, gebėjimas pateikti kiekybinius įverčius, pranašumas prieš diskriminantinę analizę. (Abid ir kt., 2018; El Khair Ghoujdam ir kt., 2024; J. Liu ir kt., 2024; Ohlson, 1980; Shen ir kt., 2019)	Ribotas gebėjimas modeliuoti sudėtingas priklausomybes, priklausomybė nuo duomenų kokybės. (Abid ir kt., 2018; El Khair Ghoujdam ir kt., 2024; J. Liu ir kt., 2024; Ohlson, 1980; Shen ir kt., 2019)
SPRENDIMŲ MEDŽIAI	Lankstumas, lengva interpretacija, funkcijų atranka, pritaikomumas kreditų rizikos vertinime. (J. Liu ir kt., 2024; Xia ir kt., 2022)	Perteklinis pritaikymas, jautrumas duomenų kokybei, sudėtingumas naudojant ansamblinius metodus. (J. Liu ir kt., 2024; Xia ir kt., 2022)
NEURONŲ TINKLŲ	Tikslūs rezultatai, universalumas, patikimumas su neišsamiais duomenimis. (Corazza ir kt., 2021; Naresh & Ayyappa, 2024; Ubarhande ir kt., 2024)	Dideli duomenų ir technologiniai reikalavimai, juodosios dėžės problema, priklausomybė nuo apmokymo. (Corazza ir kt., 2021; Naresh & Ayyappa, 2024; Ubarhande ir kt., 2024)

Šaltinis: sudaryta autorės, remiantis įvardintais autoriais

Lentelėje matyti, kad visi modeliai turi tiek privalumų, tiek trūkumų. Klasikiniai modeliai pasižymi aiškumu, paprastumu ir maža skaičiavimo našta, tačiau jų tikslumas ribotas dirbant su sudėtingais ar nestruktūrizuotais duomenimis, o dirbtinio intelekto modeliai yra tikslesnis ir lankstesni, tačiau sudėtingesni bei reikalaujantys daugiau resursų.


Apibendrinant galima teigti, kad prekybos kredito rizikos vertinimo modeliai yra esminis įrankis, padedantis nustatyti skolininkų įsipareigojimų nevykdymo tikimybę ir valdyti riziką. Modeliai, tokie kaip statistiniai, elgsenos, struktūriniai, hibridiniai, makroekonominiai bei dirbtinio intelekto sprendimai, atskleidžia skirtingus kredito rizikos vertinimo aspektus. Nors tradiciniai statistiniai modeliai pasižymi paprastumu ir aiškumu, jų taikymas ribotas su mažiau struktūrizuotais duomenimis, kas yra būdinga mažoms ir labai mažoms įmonėms. Tuo tarpu pažangūs elgsenos ir dirbtinio intelekto modeliai užtikrina didesnę tikslumą, tačiau reikalauja daugiau resursų bei techninių gebėjimų. Šių modelių pritaikymas prekybos kredito rizikos vertinime reikalauja specifinio požiūrio, nes prekybos kreditas, skirtingai nei bankinis finansavimas yra trumpesnio laikotarpio ir dažnai remiasi neformaliomis finansinėmis priemonėmis. Labai svarbu pasirinkti tinkamiausią modelį, atsižvelgiant į įmonės poreikius, duomenų prieinamumą ir sektoriaus specifiką, siekiant užtikrinti veiklos tęstinumą ir sumažinti galimą riziką.

1.3 Mažų ir labai mažų įmonių vertinimo metodų taikymas

Mažos ir labai mažos įmonės (MVI) yra esminė ekonomikos dalis, prisidedanti prie darbo vietų kūrimo, regioninės plėtros ir inovacijų skatinimo Europos Sąjungos šalyse MVI sudaro apie 99 % visų įmonių ir sukuria daugiau nei du trečdalius darbo vietų privačiame sektoriuje (Europos komisija, 2020). Nepaisant jų reikšmės, mažų ir labai mažų įmonių finansavimo prieinamumas išlieka viena iš didžiausių jų veiklos problemų. Šių įmonių svarba akivaizdi, tačiau jų analizė mokslinėje literatūroje dažniausiai apsiriboja teoriniu lygmeniu, o praktinių tyrimų yra mažai. Dažnai mažos ir labai mažos įmonės nagrinėjamos kartu su vidutinėmis įmonėmis, patenkant į bendrą smulkaus ir vidutinio verslo (SVV) analizės sritį. Pagal Lietuvos Respublikos smulkiojo ir vidutinio verslo plėtros įstatymą, 3 straipsnį, mažos ir labai mažos įmonės apibrėžiamos pagal tris pagrindinius kriterijus (5 paveikslas).

5 paveikslas

Mažų ir labai mažų įmonių charakteristikos



Šaltinis: sudaryta autorės, remiantis LR smulkiojo ir vidutinio verslo plėtros įstatymu.

Dėl šių bruožų MVĮ dažnai tampa ekonominio vystymosi pagrindu, tačiau jų finansavimo iššūkiai reikalauja nuodugnesnės analizės ir sprendimų paieškos. Remiantis Europos Komisija, mažos ir labai mažos ir vidutinės įmonės dažnai susiduria su rinkos trūkumais, kurie apsunkina jų veiklą ir mažina konkurencingumą rinkoje. Tokie trūkumai gali pasireikšti įvairiose srityse, pavyzdžiui, finansavime (ypač rizikos kapitalo), moksliniuose tyimuose, inovacijose ar aplinkosaugos reglamentų laikymesi. MVĮ dažnai stokoja galimybių gauti reikiamą finansavimą, investuoti į tyrimus ir naujoves arba laikytis aplinkosaugos standartų dėl ribotų išteklių. Be to, jos susiduria su struktūriniais iššūkiais, tokiais kaip valdymo ir techninių gebėjimų trūkumas, darbo rinkos apribojimai ar nepakankamas žinojimas apie tarptautinės plėtros galimybes. Šie veiksniai dar labiau apsunkina jų veiklą ir riboja augimo potencialą.

Prieš nagrinėjant prekybos kredito rizikos vertinimo modelius, svarbu išskirti pagrindinius mažų ir labai mažų įmonių ypatumus, kurie daro įtaką rizikos vertinimui. Remiantis Chen, Wang (2021), Gu ir kt. (2024), Altman ir kt. (2010), Kanapickiene, Spicu (2019), Thomas ir kt. (2002) moksliniais tyrimais, yra specifikuojami pagrindiniai mažų ir labai mažų įmonių ypatumai:

- 1. Ribota finansinė informacija.** Mažos įmonės dažnai nepateikia audituotų finansinių ataskaitų arba pateikia tik robotą duomenų kiekį.

2. **Didelė priklausomybė nuo savininko sprendimų.** Įmonės finansinė būklė ir veiklos sėkmė dažnai tiesiogiai priklauso nuo savininko ar valdymo komandos gebėjimų, sprendimų ir reputacijos. Savininko asmeninė kredito istorija neretai naudojama kaip papildomas rizikos vertinimo rodiklis.
3. **Nepastovūs pinigų srautai.** MVĮ pinigų srautai yra dažnai nepastovūs, o prekybos kreditai yra pagrindinis likvidumo šaltinis. Tai daro jų veiklą labiau pažeidžiamą nei didesnių įmonių.
4. **Jautrumas makroekonominiams pokyčiams.** MVĮ yra labiau pažeidžiamos dėl makroekonominių pokyčių, tokių kaip palūkanų normų ar žaliavų kainų svyravimų.
5. **Elgsenos rodiklių svarba vertinant riziką.** MVĮ elgsenos rodikliai, tokie kaip mokėjimų istorija, užsakymų vykdymo dažnumas ir kontraktų laikymasis, yra svarbūs, kai nėra pakankamai finansinių duomenų.

Išskyrus pagrindinius mažų ir labai mažų įmonių ypatumus, galima pastebėti, kad šie veiksniai daro tiesioginę įtaką prekybos kredito rizikos vertinimo modelių pasirinkimui ir pritaikymui. Atsižvelgiant į ribotus finansinius duomenis, elgsenos rodiklių svarbą bei didelį jautrumą išorės pokyčiams, tradiciniai modeliai ne visuomet yra tinkami mažoms ir labai mažoms įmonėms, todėl šių įmonių kredito rizikai vertinti dažnai taikomi būtent tokioms įmonėms pritaikyti arba pažangesni metodai, įskaitant hibridinius modelius, elgsenos rodiklius integruojančias sistemas ir mašininio mokymosi algoritmus. Be to, šio segmento įmonėms būdingas didesnis veiklos ciklo nepastovumas, neformalesnės valdymo struktūros ir ribotas kapitalo prieinamumas, todėl jų rizikos vertinimas reikalauja jautresnių ir adaptuojamų modelių.

Remiantis moksline literatūra, Altman ir kt. (2010), Altman (1968), Ohlson (1980), Mileris (2009), Thomas ir kt. (2002), Gut ir kt. (2024), Wang ir kt. (2020), Kanapickienė, Spicu (2019), Zhao ir kt. (2022) toliau aptariami pagrindiniai prekybos kredito rizikos vertinimo modeliai, jų veikimo principai ir pritaikomumas mažoms ir labai mažoms įmonėms, atsižvelgiant į jų specifiką ir poreikius. Šių modelių analizė leidžia įvertinti jų taikymo ribas ir praktinį tinkamumą, atsižvelgiant į duomenų prieinamumą ir įmonių veiklos ypatumus. Be to, skirtingų metodų sugretinimas suteikia galimybę identifikuoti, kurie modeliai efektyviausiai atspindi smulkaus verslo kredito rizikos struktūrą Lietuvoje. Tokia analizė taip pat padeda suprasti, kokie modeliai pasižymi didžiausiu prognozavimo tikslumu disbalansuotoje duomenų aplinkoje,

būdingoje smulkioms įmonėms, ir kurie metodai geriausiai prisitaiko prie riboto informacijos kiekio. Šis kontekstas yra būtinas vertinant 4 lentelėje pateikiamų modelių tinkamumą praktiniam taikymui.

4 lentelė

Prekybos kredito modelių veikimo principas mažoms ir labai mažoms įmonėms

Modelis	Veikimo principas
Altman Z – score modifikacija	Prognozuoja bankroto tikimybę, naudodamas supaprastintus finansinius rodiklius, tokius kaip pelningumas, likvidumas ir darbo kapitalo santykis su turtu. Pritaikytas mažoms įmonėms, kuriuose ribota finansinė informacija
Logistinė regresija	Naudoja tikimybinį požiūrį, vertinant kredito riziką pagal finansinius ir kokybinius rodiklius. Vertina tikimybę, ar įmonė įvykdys įsipareigojimus.
Sprendimų medžiai	Kuria hierarchines sprendimo taisykles, naudodamas tiek kiekybinius (pvz., finansinius rodiklius), tiek kokybinius (pvz., mokėjimų istorija) duomenis. Kiekvienas „mazgas“ sprendimų medyje reprezentuoja rizikos klasifikaciją.
Elgsenos modeliai	Analizuoja operacinius ir elgesio duomenis, tokius kaip mokėjimo istorija, kontraktų vykdymo dažnumas ir klientų elgsenos ypatybės. Leidžia įvertinti riziką, kai nėra pilnų finansinių ataskaitų.
Hibridiniai modeliai	Jungia finansinius, elgsenos ir makroekonominis rodiklius. Integruoja tradicinius modelius (pvz., logistinę regresiją) su pažangiais metodais (pvz., elgsenos duomenų analize), kad pateiktų išsamų rizikos vertinimą.
XGBoost su SMOTE	Pažangus mašininio mokymosi algoritmas, kuris apdoroja disbalansuotus duomenis (pvz., kaip „rizikingų“ įmonių pavyzdžių yra mažiau nei „nerizikingų“). SMOTE algoritmas subalansuoja duomenis, o XGBoost naudoja sprendimų medžių modelį rizikos prognozavimui.

Šaltinis: sudaryta autorės, remiantis minėtais autoriais

Įvairūs prekybos kredito rizikos vertinimo modeliai yra pritaikomi mažoms ir labai mažoms įmonėms, atsižvelgiant į jų unikalius poreikius ir ribotas finansines galimybes. Norint pritaikyti šiuos modelius Lietuvoje, vertėtų atsižvelgti į specifinius šalies mažų ir labai mažų įmonių sektoriaus ypatumus bei esamas galimybes. Vienas pagrindinių aspektų – duomenų prieinamumas ir kokybė. Lietuvoje veikiantys duomenų šaltiniai, tokie kaip „Registrų centras“, „Sodra“ ar „rekvizitai.lt“, suteikia vertingą informaciją, tačiau daugelis mažų įmonių neturi išsamių finansinių ataskaitų, todėl būtina integruoti alternatyvius duomenis, tokius kaip mokėjimų istorija. Pažangūs technologiniai sprendimai, tokie kaip Fintech sektoriaus siūlomos platformos, leidžia įmonėms efektyviai taikyti pažangius modelius net ir esant ribotiems resursams. Vis dėlto

tokių sprendimų diegimas reikalauja technologinių žinių ir investicijų, todėl svarbus bendradarbiavimas su išoriniais paslaugų tiekėjais. Siekiant didesnio skaidrumo ir modelių efektyvumo, būtina užtikrinti, kad jie atitiktų teisinius reikalavimus, ypač duomenų apsaugos srityje. Be to, mažoms įmonėms būtina didinti informuotumą apie rizikos valdymo procesus, organizuojant mokymus ir tiekiant prieinamas konsultacijas. Tokiu būdu galima ne tik efektyviai valdyti prekybos kredito riziką, bet ir užtikrinti įmonių stabilumą.

Apibendrinant galima teigti, kad mažos ir labai mažos įmonės yra svarbi ekonomikos dalis, tačiau jų veiklai būdingi iššūkiai, tokie kaip ribota finansinė informacija, nepastovūs pinigų srautai ir jautrumas makroekonominiams pokyčiams, apsunkina rizikos vertinimą ir finansavimo galimybes. Nors tradiciniai statistiniai modeliai dažnai taikomi prekybos kredito rizikai vertinti, je ne visuomet tinkami šiam įmonių segmentui. Šių įmonių vertinimui vis dažniau pasitelkiami pažangūs metodai, tokie kaip dirbtinio intelekto sprendimai, hibridiniai modeliai ir elgsenos rodikliais paremta analizė. Šių metodų pritaikymas padeda tiksliau vertinti prekybos kredito riziką ir prisideda prie mažų įmonių stabilumo bei konkurencingumo.

2. PREKYBOS KREDITO RIZIKOS VERTINIMO MODELIO MAŽOMS IR LABAI MAŽOMS ĮMONĖMS TYRIMO METODIKA

Prekybos kredito rizikos vertinimo modelių kūrimas ir taikymas kelia nemažai iššūkių, ypač dėl ribotos prieigos prie tikrų duomenų apie klientus. Dažnai informacija apie mažų ir labai mažų įmonių finansinę padėtį ar kreditingumą yra neišsami arba sunkiai pasiekama dėl privatumo bei konfidencialumo politikos. Lietuvos Respublikos finansų įstaigos įstatymas numato, kad finansų įstaigos privalo turėti rašytines taisykles, užtikrinančias rizikos valdymą. Remiantis įstatymu „finansų įstaiga, sudarydama sandorius dėl finansinių paslaugų tiekimo ir investuodama lėšas, turi veikti saugiai bei patikimai, laiku pastebėti kylančią riziką, ją tinkamai įvertinti ir valdyti“ (*IX-1068 Lietuvos Respublikos finansų įstaigų įstatymas*, s.a.). Šie principai gali būti pritaikomi ir prekybos kredito rizikos valdymui.

Prekybos kredito rizikos modeliai turi būti pritaikyti prie mažų ir labai mažų įmonių unikalių savybių, tokių kaip riboti finansiniai ištekliai ir priklausomybė nuo prekybos kreditų kaip pagrindinio finansavimo šaltinio. Tokio modelio tikslas – ne tik prognozuoti įsipareigojimų nevykdymo tikimybę (PD), bet ir optimizuoti sprendimų priėmimą, remiantis vidiniais ir išoriniais duomenimis apie klientus. Kuriant prekybos kredito rizikos modelius, ypatingas dėmesys turi būti skiriamas kokybinių ir kiekybinių duomenų integracijai. Tyrime planuojama naudoti šiuos kokybinius kintamuosius: bankroto statusą, kuris apibrėžia įmonės veiklos būklę (bankrutavusi ar veikianti); įmonės dydį, nustatomą pagal Europos Sąjungos kriterijus (maža arba labai maža įmonė); registracijos datą, leidžiančią įvertinti įmonės amžių, ir darbuotojų skaičių. Šie kokybiniai duomenys papildo kiekybinius rodiklius ir gali sustiprinti modelio prognozavimo gebą. Tyrime naudojami kiekybiniai duomenys, gauti iš pelno (nuostolių) ataskaitų ir balansų, kurie leidžia apskaičiuoti pagrindinius finansinius rodiklius – pelningumo, mokumo, likvidumo bei veiklos efektyvumo. Šie struktūruoti rodikliai sudaro pagrindą objektyviam įmonės kredito rizikos vertinimui. Šiame darbe siūlomas prekybos kredito rizikos vertinimo modelis yra orientuotas į Lietuvos mažų ir labai mažų įmonių poreikius. Modelio tikslas – padėti tiekėjams subalansuoti galimą riziką ir augimo galimybes, suteikiant pagrįstus sprendimus dėl prekybos kreditų suteikimo. Modelio pritaikymas grindžiamas įmonės vidaus duomenimis (finansiniais ir

nefinansiniais rodikliais), siekiant kuo tiksliau įvertinti kliento kredito riziką mažų ir labai mažų įmonių segmente. Automatiniai sprendimų priėmimo procesai, pagrįsti aiškiomis kredito politikos gairėmis, leidžia įmonėms veiksmingai reaguoti į rinkos pokyčius ir užtikrinti veiklos tęstinumą. Tokiu būdu, prekybos kredito rizikos vertinimo modeliai prisideda prie mažų ir labai mažų įmonių stabilumo ir ilgalaikės plėtros.

2.1 Tyrimo tikslas ir planas

Tyrimo tikslas

Magistro baigiamojo darbo tikslas yra sukurti ir įvertinti prekybos kredito rizikos vertinimo modelį, skirtą mažoms ir labai mažoms įmonėms, kuri leistų efektyviai prognozuoti įsipareigojimų nevykdymo tikimybę ir padėtų tiekėjams priimti pagrįstus sprendimus dėl kredito suteikimo. Tyrime naudojamas kiekybinių ir kokybinių duomenų integracijos metodas, siekiant užtikrinti modelio tikslumą ir pritaikomumą praktikoje. Duomenys bus atrenkami iš viešai prieinamų šaltinių, tokių kaip „Registrų centras“, ir prireikus papildomi kitais duomenų šaltiniais, įskaitant makroekonominis rodiklius bei sektoriaus augimo tendencijas. Tyrimo metodas detalizuotas atsižvelgiant į duomenų prieinamumą ir praktines modelio pritaikymo galimybes.

Šiuo tyrimu siekiama ne tik sukurti prekybos kredito rizikos vertinimo modelį mažoms ir labai mažoms įmonėms, bet ir išanalizuoti veiksnius, darančius įtaką sprendimų priėmimo procesui, bei pasirinktos duomenų struktūros tinkamumą, siekiant užtikrinti aiškų ir efektyvų modelio pritaikomumą praktikoje. Empirinis tyrimas orientuotas į mažų ir labai mažų įmonių prekybos kredito galimybių vertinimą, siekiant padėti tiekėjams priimti pagrįstus sprendimus dėl kredito suteikimo; tyrimo principai gali būti aktualūs ir kitoms kredito riziką vertinančioms institucijoms. Norint pasiekti šį tikslą, bus keliami šie uždaviniai:

1. Nustatyti reikšmingus mažų ir labai mažų įmonių kredito riziką lemiančius kintamuosius, remiantis hibridinio modelio (logistinės regresijos ir sprendimų medžių) taikymu.
2. Įvertinti modelio veiksmingumą atliekant modelio tikslumo ir patikimumo vertinimą.
3. Palyginti sprendimų medžių ir logistinės regresijos modelius, taip pat modelius, kuriuose naudojami tik finansiniai duomenys, ir tuos, kurie apima tiek finansinius, tiek nefinansinius kintamuosius.


4. Patikrinti modelio pritaikomumą praktikoje atliekant modelio taikymo analizę, vertinant jo naudą realiose verslo sąlygose, ir pateikti rekomendacijas, kaip šiuos modelius naudoti prekybos kredito suteikimo sprendimuose.

5. Sukurti klasių klasifikavimo sistemą – sukurti sistemą, kuri įmones klasifikuoja pagal jų kredito rizikos lygį, atsižvelgiant į sukurtus modelius.

Prieš pereinant prie modelių sudarymo plano, pirmiausia atlikta tiriamų duomenų aprašomoji statistinė analizė. Joje pateikiami pagrindiniai apibendrinantys statistiniai rodikliai – vidurkiai, medianos, standartiniai nuokrypiai, minimalios ir maksimalios reikšmės – kiekvienam iš pasirinktų kintamųjų. Ši analizė leidžia įvertinti duomenų pasiskirstymą, kintamųjų variaciją ir galimus išsiskyrimus, kurie gali turėti įtakos tolesniam modeliavimui.

6 paveikslas

Tyrimo planas



Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Pirmiausia, siekiant atlikti tyrimą, buvo nustatyta tiriamoji visuma, imties formavimas, nagrinėjamas laikotarpis, kontrolinis laikotarpis ir imties dydis.

Tyrimo duomenys buvo surinkti iš viešai prieinamų Registrų centro šaltinių, pasitelkiant įmonių pateiktas metines finansines ataskaitas, kadangi susiduriama su problema, kad mažos ir

labai mažos įmonės turi ribotą kiekį informacijos. Pagal Lietuvos Respublikos finansinės apskaitos įstatymą labai mažos įmonės turi teisę rengti sutrumpintas ataskaitas:

1. Nuosavas kapitalas pateikiamas bendra suma, be išskaidymo į sudėtinės dalis, todėl negalima įvertinti atskirų komponentų, tokių kaip įstatinis kapitalas ar sukauptas pelnas, bei apskaičiuoti su jais susijusių struktūrinių rodiklių.
2. Trumpalaikis turtas išskiriamas tik į atsargas ar kitą trumpalaikį turtą, todėl nėra atskiros informacijos apie pinigų likučius, gautinas sumas ir trumpalaikes investicijas.
3. Ilgalaikis turtas taip pat dažnai pateikiamas tik kaip materialusis ir kitas ilgalaikis turtas.

Dėl šių informacijos ribotumų kai kurie svarbūs finansiniai rodikliai negalėjo būti apskaičiuoti visoms įmonėms, o tai darė įtaką duomenų kokybei ir apribojo analizės galimybes.

Tiriamoji visuma apima Lietuvoje veikiančias mažas ir labai mažas įmones, kurios atitinka Lietuvos Respublikos smulkiojo ir vidutinio verslo plėtros įstatyme nustatytus kriterijus: mažose įmonėse dirba mažiau nei 50 darbuotojų, o labai mažose – mažiau nei 10 darbuotojų, ir jų metinės pajamos arba turto vertė neviršija atitinkamai 10 mln. ir 2 mln. eurų.

Analizei pasirinktos įmonės, kurios:

1. Veikė ne trumpiau kaip dvejus metus iki bankroto (nemokių įmonių atveju);
2. Buvo įsteigtos ir registruotos Lietuvoje;
3. Pateikė metines finansines ataskaitas į Registrų centrą;
4. Veikė 2019–2023 metų laikotarpiu, kuris laikomas pagrindiniu tyrimo laikotarpiu

veikiančioms įmonėms.

Tiriamoji visuma apima tiek bankrutavusias, tiek šiuo metu veikiančias įmones, sudarant prielaidas kredito rizikos veiksnių analizei ir prognoziniam modeliui taikyti praktiniu lygmeniu. Imtis buvo sudaryta iš 232 įmonių, iš kurių 39 – bankrutavusios, o 193 – veikiančios. Kiekvienai įmonei buvo priskirtas unikalus identifikatorius (Įmonės Nr.), leidžiantis atsekti laikinę duomenų struktūrą. Duomenys apėmė šiuos finansinius rodiklius:

- Ilgalaikis turtas
- Trumpalaikis turtas
- Nuosavas kapitalas
- Mokėtinos sumos ir kiti įsipareigojimai
- Grynasis pelnas (nuostoliai)
- Pardavimo pajamos

- Darbuotojų skaičius

Nagrinėjamas laikotarpis buvo pasirinktas 2019-2023 m., t.y praėjusių 5 metų finansiniai ir ne finansiniai duomenys. Duomenys buvo sugrupuoti taip, kad veikiantys subjektai būtų analizuojami visais penkeriais metais, o nemokios įmonės – paskutiniais dviem metais iki bankroto. Tokiu būdu buvo užtikrinta duomenų aktualumas ir tikslumas, siekiant kuo labiau atspindėti finansinių rodiklių pokyčius prieš bankrotą ir stabilios veiklos metu.

Siekiant užtikrinti modelių prognozavimo tikslumą ir interpretaciją, nepriklausomų kintamųjų atranka buvo atliekama keliais etapais.

Pirmiausia buvo suformuotas galimų kintamųjų rinkinys, remiantis ankstesniais moksliniais tyrimais ir praktiniais vertinimais. Į jį įtraukti santykiniai finansiniai rodikliai, apskaičiuoti iš pelno (nuostolių) ataskaitos ir balanso duomenų, atspindintys įvairius įmonės veiklos aspektus – pelningumą, kurį atspindi grynasis pelningumas, likvidumą, kurį įvertina likvidumo koeficientas, mokumą, kurį parodo skolos koeficientas ir veiklos efektyvumą, kurį atskleidžia turto apyvartumas. Taip pat įtraukti kokybiniai nefinansiniai kintamieji: registracijos metai (konvertuoti į įmonės amžių) ir įmonės mastą apibūdinantys rodikliai (darbuotojų skaičius ir įmonės dydžio klasė)

Antrame etape atlikta trūkstančių duomenų analizė. Tie rodikliai, kurių reikšmės negalėjo būti apskaičiuotos dėl informacijos stokos finansinėse ataskaitose, buvo pašalinti iš tolimesnės analizės.

Trečiame etape atlikta koreliacijos analizė, siekiant išvengti multikolinearumo. Kintamųjų poros, kurių koreliacijos koeficientas viršijo 0,8, buvo peržiūrėtos – paliktas tik vienas iš stipriai koreliuojančių rodiklių.

Siekiant užtikrinti duomenų patikimumą ir išvengti iškreipimų, susijusių su ekstremaliomis reikšmėmis ar trūkstamais duomenimis, prieš statistinius testus buvo taikytos duomenų paruošimo procedūros. Trūkstamos reikšmės (NA) buvo tvarkomos taikant porinį praleistų reikšmių tvarkymą ir winsorizaciją, kad koreliacijos bei regresijos rezultatai būtų stabilesni. Atsižvelgiant į tai, kad finansinių rodiklių pasiskirstymai dažnai yra nevienodi ir neatitinka normalumo prielaidų, tolesnėje analizėje buvo pasirinkti neparametriniai metodai. Faktinių rodiklių lygiai tarp mokius ir nemokius įmonių buvo lyginami naudojant medianas ir tarpketvirtinių režių (IQR) analizę, o skirtumų reikšmingumas vertintas Mann-Whitney testu. Be to, Cliff δ koeficientas buvo taikomas praktinio efekto dydžiui įvertinti (mažas, vidutinis, didelis),

leidžiant interpretuoti ne tik statistinius, bet ir praktinius grupių skirtumus. Tokia metodinė kombinacija užtikrina, kad gauti rezultatai būtų patikimi, net jei duomenys pažeidžia klasikinės statistikos prielaidas.

Galiausiai, kokybiniai kintamieji, tokie kaip įmonės dydis buvo transformuoti į žymimuosius (angl. dummy) kintamuosius, o darbuotojų skaičius ir įmonės amžius modeliuoti kaip skaitiniai rodikliai. Įmonės dydis duomenyse pateikiamas aprašomuoju terminu „maža“ arba „labai maža“, kuris buvo transformuotas į dvejetainį (0/1) formatą. Šiuo atveju labai mažoms įmonės buvo priskirta reikšmė 1, o mažoms įmonėms – reikšmė 0. Tokia konversija leidžia modeliams interpretuoti šį kintamąjį kaip nepriklausomą prediktorių. Galutinis atrinktų kintamųjų rinkinys buvo naudojamas tiek logistinės regresijos, tiek sprendimų medžio (CART) modeliui sudaryti. Modelių formavimo procese pasirinkti du pagrindiniai metodai:

- **Logistinė regresija**, kuri remiasi tikimybių modeliavimu ir leidžia prognozuoti dvinarį rezultatyvųjį kintamąjį (šiuo atveju – bankrotą, pažymėtą kaip 1, arba veikimą – 0). Šis modelis leidžia įvertinti kiekvieno rodiklio įtaką bankroto tikimybei ir pateikia lengvai interpretuojamus koeficientus.
- **Sprendimų medis (CART – Classification and Regression Tree)** – tai interpretuojamas klasifikavimo modelis, kuris duomenis dalina į grupes pagal finansinių rodiklių reikšmes ir formuoja sprendimų taisykles, leidžiančias identifikuoti rizikingas įmones. Šis metodas ypač tinkamas, kai norima identifikuoti aiškias taisykles, pagal kurias įmonė laikytina rizikinga.

Modelių palyginimas aprašomas 5 lentelėje.

5 lentelė

Naudojamų modelių palyginimas

Modelis	Tipas	Stiprybės	Silpnybės	Naudojimo tikslas
Logistinė regresija	Statistinis modelis	Aiški interpretacija, tinka mažam kintamųjų skaičiui, statistiniai testai	Prastai apdoroja sudėtingus, nelinijinius ryšius	Nustatyti, kurie finansiniai rodikliai labiausiai prognozuoja bankrotą
CART (sprendimų medis)	Mašininio mokymosi modelis	Gali apdoroti nelinijinius ryšius, automatiškai atrenka svarbius kintamuosius	Gali būti per jautrus (overfitting), mažesnė interpretacija nei regresijoje	Sukurti lengvai suprantamą klasifikavimo logiką

Šaltinis: sudaryta autorės, remiantis atliktu tyrimu

Logistinė regresija yra plačiai taikomas klasifikacinis metodas, ypač tinkamas, kai priklausomasis kintamasis yra dvejetainis – pavyzdžiui, įmonė bankrutavo arba ne (Hosmer ir kt., 2013). Ji leidžia įvertinti tikimybę, kad tam tikras įvykis įvyks, atsižvelgiant į nepriklausomų kintamųjų reikšmes. Pasak James ir kt. (2013), logistinės regresijos modelis yra interpretuojamas per šansų (angl. odds) logaritmą, todėl tinka finansinių rizikų modeliavimui, kai svarbu įvertinti ryšį tarp įvairių įmonės rodiklių ir galimo bankroto. Modelis kuriamas remiantis maksimaliojo tikėtimumo (maximum likelihood) metodu, kuris leidžia rasti koeficientus, geriausiai atitinkančius stebimus duomenis (Gujarati ir Porter, 2009).

Be to, logistinės regresijos modeliai yra gana atsparūs net ir mažesniame duomenų kiekiui, palyginti su kitais sudėtingesniais metodais, tokiais kaip neuroniniai tinklai ar „ensemble“ klasifikatoriai. Dėl šios priežasties jie yra dažnai taikomi mažų ir labai mažų įmonių segmentų tyrimuose, kur duomenys gali būti riboti ar neišsamūs (Altman ir Sabato, 2007).

Modelio sudarymo procese pirmiausia apskaičiuojami į modelį įtrauktų kintamųjų koeficientai, po to vertinamas jų statistinis reikšmingumas (naudojant p-reikšmes ir pasikliautinus intervalus). Modelio tinkamumas vertinamas naudojant ROC kreivę ir AUC rodiklį (Fawcett, 2006). Kaip pažymi Siddiqi (2006), šie vertinimo kriterijai leidžia įvertinti ne tik bendrą modelio tikslumą, bet ir gebėjimą atskirti rizikingas įmones nuo nerizikingų. Siekiant užtikrinti įverčių patikimumą, koeficientai vertinami taikant robustines (HC) standartines paklaidas, kurios leidžia kompensuoti galimą heteroskedastiškumą ir suteikia tikslesnius reikšmingumo įverčius.

Vertinant modelio praktinį pritaikomumą, tyrime taip pat buvo nustatyta kredito rizikos politikos sprendimų riba, pagal kurią įmonės klasifikuojamos į priimtinas ir nepriimtinas prekybos kredito požiūriu. Ribinė reikšmė parinkta pagal modelio diskriminacinę galią ir ekonominį pagrindumą – šiame tyrime taikyta reikšmė $p = 0,30$. Tai reiškia, kad jei modelio prognozuojama bankroto tikimybė viršija 30%, įmonė priskiriama prie padidintos rizikos subjektų, kuriems kredito suteikimas turėtų būti atsargiai vertinamas. Pasirinkimas taikyti žemesnę nei standartinę 0,50 sprendimo riba grindžiamas tuo, kad kredito rizikos kontekste I rūšies klaida (neidentifikuotas rizikingas (t.y. nemokus) klientas) įprastai yra gerokai brangesnė nei II rūšies klaida (nepagrįstai atmestas saugus klientas). Mokslinėje literatūroje pabrėžiama, jog optimalios ribos nustatymas turi būti siejamas su rizikos apetitu ir ekonominiais nuostoliais, o ne su statistiniu neutralumu (Thomas, Edelman ir Crook, 2002; Bahnsen ir kt., 2014). Dėl šios priežasties daugelyje kreditų rizikos tyrimų taikomos žemesnės ribos, dažniausiai 0,20–0,35 intervale,

siekiant sumažinti brangiai kainuojančias I rūšies klaidas ir užtikrinti konservatyvesnę rizikos vertinimą (Altman ir Sabato, 2007; Khandani ir kt., 2010). Atsižvelgiant į tai, pasirinkta PD = 30% riba leidžia subalansuoti praktinius kredito politikos tikslus – pakankamai anksti identifikuoti galimus nemokumo atvejus, kartu nepersistengiant riboti potencialių verslo galimybių.

Pasak Mackevičiaus ir Silvanavičiūtės (2006), dėl sparčiai kintančios ekonominės aplinkos bei verslo sąlygų, ryšys tarp finansinių rodiklių ir įmonės kredito rizikos dažnai nebūna nei tiesinis, nei vienareikšmis. Todėl vietoje paprastos tiesinės priklausomybės vertinimo naudojamas logistinės regresijos modelis, kuris leidžia prognozuoti tikimybę, kad įmonė taps nemoki, remiantis kelių rodiklių visuma.

Modelis apskaičiuojamas naudojant logistinę funkciją:

$$\Pr(Y=1)=\frac{1}{1+e^{-z}}, z=\beta_0+\beta_1X_1+\dots+\beta_kX_k,$$

Kur priklausomasis kintamasis logistinės regresijos modelyje (PD – nemokumo tikimybė) yra fiktyvus kintamasis. PD įgyja reikšmę 1 ($Y = 1$), jei skolininkas nagrinėjamu laikotarpiu tapo nemokus, ir 0 ($Y = 0$) – priešingu atveju. β_i – tai konkretus koeficientas, priklausantis nuo i -tojo nepriklausomo kintamojo ($i = 1, \dots, k$). Nepriklausomi kintamieji X_i – tai visi galimi parametrai, galintys turėti įtakos kredito rizikai (Behr ir Guettler, 2007), o e – natūrinis logaritmo pagrindas (~ 2.718).

Tokiu būdu modelis leidžia įvertinti, kiek tikėtina, jog įmonė taps nemoki, atsižvelgiant į jos finansinę būklę.

Remiantis šiame tyrime naudojamu požiūriu, logistinės regresijos modelio sudarymas prasidėjo nuo paprasto bazinio modelio – buvo įtrauktas tik konstantinis narys. Po to kintamieji buvo pridedami **žingsnis po žingsnio (forward selection)** metodu – vienas po kito į modelį įtraukiami tik tie rodikliai, kurie statistiškai reikšmingai prisideda prie įmonės bankroto tikimybės paaiškinimo. Tai buvo pagrįsta tiek koreliacijos analize, tiek ekonomine rodiklių prasme.

Empirinė analizė buvo atlikta naudojant R programavimo kalbą ir ją papildančias statistines bibliotekas („dplyr“, „rpart“, „rpart.plot“, „pROC“, „writexl“).

Pradiniame etape buvo suformuotas dinaminis principu paremtas duomenų rinkinys. Į analizę buvo įtrauktos įmonės, veikiančios laikotarpiu nuo 2019 iki 2023 metų. Nemokių įmonių duomenys buvo analizuojami dvejus metus prieš bankrotą, tuo tarpu mokios įmonės buvo vertinamos visais metais. Po duomenų sujungimo ir struktūrizavimo buvo suformuotas galutinis

duomenų rinkinys, kuriame buvo apdoroti pagrindiniai finansiniai rodikliai: likvidumo koeficientas, skolos koeficientas, ROE, ROA, grynasis pelningumas ir turto apyvartumas. Vėliau, įvertinus ekstremalias likvidumo koeficiento reikšmes, šis rodiklis buvo eliminuotas iš galutinio modeliavimo rinkinio.

Į modelį įtraukti tik tie finansiniai rodikliai, kurie turėjo logišką ryšį su mokumu, likvidumu, pelningumu ir veiklos efektyvumu. Be finansinių rodiklių, į analizę taip pat buvo įtraukti du nefinansiniai kintamieji: darbuotojų skaičius ir įmonės amžius. Darbuotojų skaičius buvo traktuojamas kaip tęstinis įmonės masto rodiklis, leidžiantis tiksliau įvertinti veiklos apimtį, o įmonės amžius (apskaičiuotas pagal registracijos metus) naudotas kaip struktūrinė įmonės stabilumo ir patirties dimensija. Tokia kintamųjų parinkimo schema leido atsisakyti dichotominio įmonės dydžio kodavimo (SME klasifikacijos), nes skaitiniai masto rodikliai suteikė tikslesnę ir informatyvesnę įmonių heterogeniškumo reprezentaciją regresijos modelyje. Modelio tinkamumas vertintas pagal šiuos kriterijus:

- **Chi kvadrato testo (χ^2)** p reikšmė turėjo būti mažesnė nei 0,05, kad modelis būtų laikomas statistiškai reikšmingu.
- **Pseudo R² rodikliai** (Cox, Snell ir Nagelkerke) turėjo būti bent 0,2, rodantys priimtina modelio paaiškinamąją galią.
- Vertinant atskirų kintamųjų indėlį, analizuojamos **Wald testo p reikšmės** ($p < 0,05$). Pirmenybė teikiama statistiškai reikšmingiems ir ekonomiškai prasmingiems rodikliams. Ekonomiškai motyvuoti prediktoriai gali būti paliekami modelyje ir esant ribiniam statistiniam reikšmingumui.

Modelio prognozavimo galimybės įvertintos naudojant **ROC (receiver operating characteristic) kreivę**. Ji leidžia įvertinti, kaip gerai modelis atskiria nemokias įmones nuo mokių. Kreivė rodo tikslumo santykį tarp teisingai ir neteisingai klasifikuotų atvejų. Apskaičiuotas **AUC (area under the curve)** – tai pagrindinis tikslumo rodiklis: AUC reikšmė virš 0,8 rodo gerą modelio klasifikavimo gebėjimą, virš 0,9 – išskirtinį. Siekiant papildomai patikrinti modelio sprendimų ir faktinių baigčių atitikimą, sudaroma 2x2 kontingencinė lentelė, pagal kurią skaičiuojami pagrindiniai klasifikavimo rodikliai (tikslumas, jautrumas, specifiškumas, F1. rodiklis).

6 lentelė

Klasifikavimo rodikliai

Rodiklis	Reikšmė
Tikslumas (Accuracy)	0,821
Jautrumas (Sensitivity, TPR)	0,095
Specifiškumas (Specificity, TNR)	0,977
Teigiamo prognozavimo vertė (Precision, PPV)	0,475
Neigiamo prognozavimo vertė (NPV)	0,834
F1 rodiklis	0,159

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

6 lentelėje pateikti klasifikavimo rodikliai, naudojami modelio prognozavimo kokybei įvertinti, remiantis 2×2 kontingencine lentele. Šie rodikliai leidžia kiekybiškai įvertinti modelio gebėjimą teisingai klasifikuoti mokias ir nemokias įmones, atsižvelgiant tiek į bendrą klasifikavimo tikslumą, tiek į atskirų klasių atpažinimą. Jautrumo ir specifiškumo rodikliai naudojami modelio diskriminacinei gebai įvertinti, o teigiamos ir neigiamos prognozės vertės – prognozių patikimumui nustatyti. F1 rodiklis taikomas kaip apibendrinantis matas, ypač aktualus esant disbalansuotai klasei. Ryšiui patikrinti taikomi Pearson χ^2 , Yates koreguotas χ^2 tikimybių santykio (G-test) ir Fisher tikslusis testas, leidžiantys nustatyti, ar modelio sprendimai yra statistiškai priklausomi nuo faktinio įmonės bankroto fakto.

Siekiant išsamiau įvertinti modelio pritaikomumą duomenimis, be diskriminancinės galios (ROC, AUC) vertinami ir tikimybių kalibracijos rodikliai. Šiam tikslui taikomas Hosmer – Lemeshow (HL) testas, kuriuo tikrinama, ar prognozuojamų bankroto tikimybių pasiskirstymas atitinka stebėtas baigtis. Papildomai apskaičiuojamas Brier balas, rodantis vidutinę kvadratinę prognozavimo paklaidą, bei ECE (Expected Calibration Error) – svorinis vidutinis kalibracijos nuokrypis. Mažesnės šių rodiklių reikšmės rodo geresnį modelio pritaikymą ir prognozuojamų tikimybių atitikimą empiriniams duomenims.

Nustačius kalibracijos netikslumus, taikoma re-kalibracija, remiantis dviem metodinėmis priemonėmis – poslinkio (intercept – only) ir logistine (Platt) korekcijomis, kurios leidžia atitinkamai reguliuoti bendrą tikimybių lygį ir nuolydį, siekiant pagerinti prognozuojamų ir empirinių baigčių atitikimą.

Sprendimų medžiai (CART – Classification and Regression Trees) yra universalus ir aiškiai interpretuojamas duomenų klasifikavimo metodas, kuris taikomas prognozuojant įmonės nemokumo riziką remiantis tiek finansiniais, tiek kokybiniais duomenimis. Pasak Breiman ir kt. (1984), CART modeliai remiasi binariniu skaidymu – kiekviename etape duomenys padalijami į dvi grupes pagal tokį kintamąjį, kuris geriausiai atskiria tikėtinas baigtis. Kiekvienas medis

prasideda nuo šaknies (visos imties) ir šakojasi iki lapinių mazgų – galutinių klasifikacijų. CART metodas kiekvienam mazgui priskiria vidurkį ir dispersiją, siekdamas sumažinti vaikinių mazgų dispersiją, kaip nurodo Terradez, Kizys ir kt. (2015). Šis principas leidžia pasiekti didesnę vidinę homogeniškumą ir tikslesnę klasifikavimą, ypač vertinant kredito riziką.

Sprendimų medis formuojamas remiantis Gini indeksu, kuris įvertina duomenų grynumą po skaidymo pagal formulę:

$$Gini(t) = 1 - \sum_{i=0}^c p_i^2$$

Kur p_i – tikimybė, kad stebėjimas priklauso klasei i .

Gini indeksas pasirenkamas dėl savo paprastumo, interpretavimo aiškumo ir efektyvumo – jis dažnai naudojamas klasifikavimo uždaviniuose, kadangi padeda maksimaliai sumažinti klasifikavimo neapibrėžtumą (Breiman ir kt., 1984).

Modelis augamas tol, kol pasiekiamas iš anksto nustatytas maksimalus gylis (pvz., 5 lygiai) arba mazge lieka mažiau nei minimalus stebinių skaičius (pvz., 10). Siekiant užtikrinti modelio patikimumą ir išvengti peradaptavimo (angl. *overfitting*), sprendimų medis buvo genimas taikant 10 kartų kryžminę validaciją, o optimalus modelio dydis pasirinktas pagal 1-SE taisyklę, kuri leidžia išlaikyti balansą tarp modelio paprastumo ir prognozavimo tikslumo.

Vertinant modelio tikslumą buvo naudojami šie vertinimo kriterijai: 10 kartų kryžminis patikrinimas (10-fold cross-validation), ROC kreivė, plotas po ROC kreive (AUC), jautrumas (sensitivity) ir specifiškumas (specificity). Šie rodikliai leidžia įvertinti modelio gebėjimą atskirti rizikingas nuo nerizikingų įmonių. ROC kreivė padeda vizualiai įvertinti klasifikavimo tikslumą – kuo labiau kreivė priartėja prie viršutinio kairiojo kampo, tuo tikslesnis modelis.

Taip pat sprendimų medžio struktūra suteikia galimybę vizualiai matyti, kokios reikšmės atskiria grupes, ir kokiomis sąlygomis galima klasifikuoti įmones kaip rizikingas. Žemiau pateikiama lentelė su kintamaisiais, dažniausiai pasitaikančiais sprendimų medžio modelio šakose:

7 lentelė

Modelio kintamieji

Kintamasis	Formulė / Paaiškinimas
Grynasis pelningumas	$\text{Grynasis pelningumas} = \frac{\text{Grynasis pelnas}}{\text{Pardavimų pajamos}}$
Skolos koeficientas	$\text{Skolos koeficientas} = \frac{\text{Visi įsipareigojimai}}{\text{Turtas}}$
Nuosavybės grąža (ROE)	$\text{ROE} = \frac{\text{Grynasis pelnas}}{\text{Nuosavas kapitalas}}$
Turto grąža (ROA)	$\text{ROA} = \frac{\text{Grynasis pelnas}}{\text{Turtas}}$
Turto apyvartumas	$\text{Turto apyvartumas} = \frac{\text{Pardavimų pajamos}}{\text{Turtas}}$
Įmonės amžius	Nuo įsteigimo praėję metai
Įmonės bankroto statusas (dummy)	Nemoki / moki

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Aptarus abiejų modelių – logistinės regresijos ir sprendimų medžio (CART) – sudarymo principus, metodinius skirtumus ir pasirinktus kintamuosius, tolesnėje tyrimo dalyje vertinamas šių modelių prognozavimo efektyvumas. Vertinimas atliekamas remiantis keliomis tarpusavyje papildančiomis dimensijomis: modelių gebėjimu atskirti rizikingas ir nerizikingas įmones, prognozuojamų tikimybių atitikimu faktinėms baigtims bei bendru klasifikavimo tikslumu. Analizė apima tiek diskriminacinę galią, tiek kalibraciją, todėl leidžia įvertinti modelius ne tik pagal jų tikslumą, bet ir pagal praktinį tinkamumą sprendimų priėmimui. Toks daugiamačis vertinimas sudaro prielaidas objektyviam modelių palyginimui ir padeda nustatyti, kuris iš jų geriau atliepia mažų ir labai mažų įmonių prekybos kredito rizikos vertinimo poreikius Lietuvos kontekste.

Taigi, formuojant modelį, buvo užtikrinta metodinė nuosekli analizė – nuo duomenų paruošimo, rodiklių skaičiavimo, modelių konstravimo, iki jų tikslumo vertinimo. Tokiu būdu gauti rezultatai leidžia pagrįsti tolimesnius tyrimo etapus ir pasirinkti, kurį iš metodų labiau tinka taikyti praktikoje kredito rizikos vertinimui.

3. KREDITO RIZIKOS VERTINIMO MODELIO LIETUVOS MAŽOMS IR LABAI MAŽOMS ĮMONĖMS REZULTATAI IR JŲ INTERPRETACIJA

3.1 Kredito rizikos vertinimo modelio duomenų diagnostika

Mažų ir labai mažų įmonių kredito rizikos vertinimas yra svarbi analizės sritis, leidžianti įvertinti tikimybę, kad įmonė gali susidurti su nemokumu ar bankrotu. Darbo tikslas – suformuoti kredito rizikos vertinimo modelį, paremtą finansiniais rodikliais, ir įvertinti jo veikimo tikslumą naudojant tiek statistinius, tiek mašininio mokymosi metodus. Tam buvo pasirinkti du pagrindiniai modeliai – logistinės regresijos ir sprendimų medžio (CART) modeliai.

Atlikus tiriamų duomenų aprašomąją statistinę analizę, nustatyta, kad mažų ir labai mažų įmonių finansiniai rodikliai pasižymi itin didele sklaida ir nevienodu pasiskirstymu. Tai rodo šių įmonių finansinio pajėgumo heterogeniškumą – dalis jų veikia stabiliai, o kitos susiduria su reišmingais pelningumo ar likvidumo svyravimais. Siekiant įvertinti rodiklių pasiskirstymo ypatumus, 8 lentelėje pateikiamos minimalių, maksimalių, medianų, vidutinių reikšmių ir standartinių nuokrypių suvestinės.

8 lentelė

Rodiklių aprašomosios statistikos rezultatai

Kintamasis	Min	Max	Mediana	Vidurkis	SD
Likvidumo koeficientas	-116.46	14750.4	1.7	31.05	465.44
Skolos koeficientas	-0.37	222.05	0.4	1.71	9.48
ROE	-148.71	1440.97	0.06	1.25	42.76
ROA	-378.86	10.8	0.02	-0.5	11.33
Grynasis pelningumas	-269.12	325.77	0.02	0.06	14.04
Turto apyvartumas	0.0	124.31	1.26	2.46	6.82

Šaltinis: sudaryta autorės

Lentelėje pateikta aprašomoji pasirinktų finansinių rodiklių statistika leidžia įvertinti jų pasiskirstymą bei tipines reikšmes imtyje. Kaip matyti, didžiausią dispersiją turi likvidumo koeficientas, kurio vidurkis siekia 31,05, tačiau standartinis nuokrypis net 465,44, o maksimali reikšmė – 14750,4, kas rodo ryškius išsiskyrimus duomenyse. Panaši situacija stebima

ir ROE (nuosavybės gražos) bei grynojo pelningumo atveju – abiejų rodiklių didelės maksimalios reikšmės ir standartiniai nuokrypiai liudija apie stiprius nuokrypius nuo vidurkio.

Neigiamas ROA (turto gražos) vidurkis ($-0,5$) rodo, kad bendrai įmonės generuoja nuostolį iš turto, o skolos koeficiento vidurkis ($1,71$) leidžia daryti prielaidą, kad įmonių įsipareigojimai vidutiniškai viršija jų nuosavą kapitalą. Tuo tarpu turto apyvartumo medianos reikšmė ($1,26$) rodo, kad daugiau nei pusė įmonių generuoja daugiau pajamų nei turi turto, tačiau didelis SD ($6,82$) rodo didelę dispersiją.

Šie duomenys leidžia spręsti, kad finansiniai rodikliai pasižymi nevienodu pasiskirstymu, todėl būtina atsižvelgti į galimus išsiskyrimus ir ekstremalias reikšmes, galinčias turėti įtakos modelio sudarymui ir prognozavimo tikslumui.

Atsižvelgiant į aprašomosios statistikos rezultatus, akivaizdu, kad dalis rodiklių pasižymi didelėmis reikšmių amplitudėmis. Tai būdinga mažų ir labai mažų įmonių duomenims, nes jų finansiniai rezultatai dažnai svyruoja dėl sezoniškumo, mažesnių apyvartų ir ribotų išteklių. Todėl prieš pereinant prie modelių sudarymo, vadovaujantis metodologijos skyriuje aprašyta tyrimo seka, buvo atliktas duomenų paruošimo procesas, apimantis trūkstamų reikšmių analizę, ekstremalių reikšmių identifikavimą ir jų apdorojimą bei galutinės tyrimo imties formavimą. Šie etapai sudarė prielaidas statistiškai patikimam modelių konstravimui.

9 lentelė

Duomenų paruošimo rezultatai

Kriterijus	Įmonių skaičius	Procentinė dalis (%)
Pradinė imtis	242	100,0
Pašalintos dėl trūkstamų ar netikslių duomenų	10	4,1
Galutinė imtis	232	95,9

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Atlikus duomenų patikrinimą, galutinėje imtyje liko 232 įmonės, iš kurių 193 – mokios, o 39 – nemokios (16,8 %). Toks nemokių įmonių santykis yra pakankamas kredito rizikos modeliui sudaryti. Mokslinėje literatūroje nurodoma, kad modelių stabilumui ir diskriminacinei galiai užtikrinti nemokių įmonių dalis imtyje turėtų sudaryti ne mažiau kaip 15–20 % (Siddiqi, 2006; Hand ir Henley, 1997). Todėl šiame tyrime gauta proporcija atitinka minimalius rekomenduojamus reikalavimus ir leidžia analizuoti tiek stabilių, tiek nemokių įmonių finansinio

elgesio skirtumus. Prieš vertinant tarpusavio ryšius ir grupinius skirtumus, pirmiausia įvertinta duomenų pilnuma.

Svarbu pažymėti, kad iš pradinių rodiklių rinkinio buvo pašalintas likvidumo koeficientas. Šio rodiklio reikšmės pasižymėjo itin dideliais kraštutinumais (nuo 116 iki 14750), o standartinis nuokrypis viršijo 400 kartų medianą. Tokia sklaida rodo, kad duomenis iškreipia vienetiniai išsiskiriantys stebėjimai (outliers), o rodiklis praranda analitinę vertę ir gali neproporcingai paveikti modelio įverčius. Be to, mažų ir labai mažų įmonių kontekste trumpalaikio likvidumo rodikliai dažnai yra nepatikimi dėl buhalterinių ypatumų. Todėl likvidumo rodiklis šiame tyrime nebuvo įtrauktas į galutinį modeliavimo rinkinį.

10 lentelė

Trūkstamumas pagal būklę

Rodiklis	n (Mokios)	n (Nemokios)	Trūkstama (%) veik.	Trūkstama (%) bankr.
Skolos koeficientas	943	212	0,2	0,0
Turto grąža (ROA)	943	212	0,2	0,0
Grynasis pelningumas (Margin)	929	199	1,7	6,1
Turto apyvartumas	942	212	0,3	0,0
ROE_cln	812	157	14,1	25,9

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Pateiktame trūkstamumo palyginime tarp mokių ir nemokių įmonių matyti, kad daugumos bazinių kintamųjų duomenys yra beveik pilni. Skolos koeficiento, ROA ir turto apyvartumo NA (*angl. not available*) dalis neviršija 0-0,3% abiejose grupėse, todėl šie rodikliai tinkami naudoti pagrindiniuose modeliuose. Grynasis pelningumas (Margin) trūkstamumas yra didesnis bankrutavusiose įmonėse (6,1%), kas tikėtina siejasi su nulinių pardavimo pajamų atvejais. Kadangi absoliutus mastas išlieka vidutinis, tad rodiklis gali būti įtraukiamas kaip papildomas. Ryškiausias signalas – ROE. Trūkstatų reikšmių dalis ypač didelė, ypač bankrutavusiose (25,9%), o priežastis struktūrinė ($\leq$ nuosavas kapitalas). Tai reiškia, kad ROE_cln trūkstamumas nėra atsitiktinis ir gali šališkai paveikti įverčius, todėl pagrindinei specifikacijai racionalu rinktis ROA kaip pelningumo rodiklį, o ROE_cln naudoti tik patikimumo patikroms.

Kad būtų galima nustatyti, ar tarp pasirinktų rodiklių nėra stiprių tarpusavio priklausomybių buvo atlikta koreliacijų analizė.

11 lentelė

Finansinių rodiklių tarpusavio koreliacijos

Rodiklis	Skolos koeficientas	Turto grąža (ROA)	Nuosavybės grąža (ROE)	Grynasis pelningumas	Turto apyvartumas
Skolos koeficientas	1.00	-0.45	-0.02	-0.11	0.35
Turto grąža (ROA)	-0.45	1.00	0.69	0.28	-0.18
Nuosavybės grąža (ROE)	-0.02	0.69	1.00	0.27	0.08
Grynasis pelningumas	-0.11	0.28	0.27	1.00	-0.01
Turto apyvartumas	0.35	-0.18	0.08	-0.01	1.00

Šaltinis: sudaryta autorės, remiantis Registrų centro duomenimis

Lentelėje matyti, kad stipriausias ryšys tarp pelningumo rodiklių yra ROA ir ROE ($r = 0,69$). Tai rodo, kad abu rodikliai matuoja panašią finansinę būklę. Norint išvengti multikolinearumo rizikos paliekamas ROA, o ROE naudojamas tik patikimumo patikrai. Skolos koeficientas vidutiniškai neigiamai koreliuoja su ROA ($r = -0,45$) ir silpnai su grynuoju pelningumu, o tai paaiškinama logiškai; didesnis įsiskolinimas paprastai siejasi su žemesne grąža ir marža. Nė vienas porinis ryšys neviršija 0,8, todėl kritinio multikolinearumo požymių nenustatyta. Būtina pabrėžti, jog daliai įrašų ROA ir grynojo pelningumo reikšmės yra NA dėl nulinių ar neigiamų vardiklių, todėl analizėje buvo taikytas porinis praleistų reikšmių tvarkymas ir winsorizacija, kad koreliacijos būtų stabilesnės.

Remiantis koreliacijų analizės įžvalgomis, tikrinama, ar šie tarpusavio ryšiai atsispindi faktiniuose rodiklių lygių skirtumuose tarp skirtingų įmonių būklių. Tam yra sudaromos palyginimo lentelės, kuriuose mokių ir nemokių įmonių rodikliai pateikiami kaip medianos ir tarpketvirčių rėžiai (IQR), nurodomi stebinių skaičiai (n), o skirtumų reikšmingumas vertinamas Mann-Whitney testu. Kadangi vienu metu lyginami keli rodikliai, p reikšmės pateikiamos kaip q, o Cliff δ koeficientas leidžia įvertinti praktinį efekto dydį (mažas/vidutinis/didelis). Toks palyginimas papildoma koreliacijų lentelę: vietoje „krypties“ tarp kintamųjų galime matyti kiek ir kuria kryptimi skiriasi rodiklių reikšmės dviejose grupėse, kas yra labai svarbu kredito sprendimams.

Siekiant patikrinti, ar koreliacijos matomos kryptys atspindi faktiniuose lygių skirtumuose tarp grupių, toliau pareikiamas medianų (IQR) palyginimas su neparametriniu testu.

12 lentelė

Finansinių rodiklių palyginimas tarp mokius ir nemokius įmonių

Rodiklis	n (Bankr.)	n (Veik.)	Mediana (Bankr.)	IQR (Bankr.)	Mediana (Veik.)	IQR (Veik.)	Kryptis	p (MW)	Cliff's δ	q (BH)
Skolos koeficientas	212	943	0,5375	0,8432	0,3789	0,5769	Nemokios Mokios >	0,0008	0,148	0,0012
Turto grąža (ROA)	212	943	-0,0122	0,4235	0,0274	0,1563	Mokios Nemokios >	0,0003	-0,159	0,0008
Grynasis pelningumas (Margin)	199	929	-0,0045	0,3825	0,0208	0,1361	Mokios Nemokios >	0,0017	-0,142	0,0017

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Apibendrinant 12 lentelės rodiklių palyginimą, nustatyta, kad tarp mokius ir nemokius įmonių statistiškai reikšmingai, pritaikius Benjamini-Hochberg (FDR) korekciją, skiriasi trys esminės finansų dimensijos: skolos koeficientas, turto grąža (ROA) ir grynasis pelningumas. Nemokius įmonių rodikliai rodo didesnę finansinę svertą ir prastesnę grąžą, Cliff'o δ įverčiai indikuoja nedidelį – vidutinį, tačiau praktiškai reikšmingą efektą. Tuo tarpu turto apyvartumas ir ROE patikimų skirtumų tarp grupių nedemonstruoja, todėl bus vertinami kaip pagalbiniai, o ne pagrindiniai skiriamieji požymiai. Naudotos medianų ir IQR aprašomosios charakteristikos, Mann-Whitney neparametrinis testas ir BH korekcija mažina kraštinių reikšmių įtaką, o Benjamini-Hochberg kontroliuoja daugybinių palyginimų klaidos riziką. Skirtingos imties apimtys (n) prie kiekvieno rodiklio atspinti nevienodą trūkstančių reikšmių mastą, būdingą mažų ir labai mažų įmonių ataskaitoms. Gauti rezultatai dera su koreliacijų analize ir pagrindžia tolimesnį modelių specifیکavimą: logistinėje regresijoje ir sprendimų medžiuose branduoliniais kintamaisiais pasirenkami: skolos koeficientas, ROA ir grynasis pelningumas, o turto apyvartumas ir ROE naudojami kontroliniams testams ir jautrumo analizėms, siekiant aiškesnės interpretacijos.

Apibendrinant galima teigti, kad atlikta mažų ir labai mažų įmonių finansinių duomenų diagnostika atskleidė ryškią šių subjektų finansinės būklės heterogeniškumo tendenciją. Aprašomosios statistikos rezultatai parodė didelę finansinių rodiklių sklaidą ir reikšmių ekstremumą poveikį, būdingą šiam įmonių segmentui. Atlikta duomenų valymo ir trūkstančių


analizė leido suformuoti patikimą galutinę imtį ($n=232$), užtikrinančią reprezentatyvumą ir duomenų kokybę. Pašalinus likvidumo rodiklį dėl itin išsiskiriančių reikšmių, o taip pat identifikavus struktūrinį ROE trūkstumą, pagrindiniais modelio prediktoriais pasirinkti skolos koeficientas, turto grąža (ROA) ir grynasis pelningumas, bei du nefinansiniai kintamieji: darbuotojų skaičius ir įmonės amžius. Šie kintamieji statistiškai reikšmingai skiria mokias ir nemokias įmones tiek pagal kryptį, tiek pagal efektų dydį, todėl sudaro pagrindą tolimesniam logistinės regresijos ir sprendimų medžio (CART) modelių specifیکavimui.

3.2 Logistinės regresijos modelio formavimas

Finansų sektoriuje kredito rizikos modeliai yra svarbiausias instrumentas, kuris leidžia sistemiškai įvertinti ir prognozuoti įmonių bankroto tikimybę (PD). Susikūrus tokį modelį ir jį suderinus su aiškiomis kredito rizikos politikos nuostatomis, jo rezultatai tampa pagrindiniu įrankiu priimant sprendimus dėl klientų kreditingumo ir rizikos valdymo. Be to, automatizuoto prekybos kredito rizikos vertinimo, skirto mažoms ir labai mažoms įmonėms, patikimumo analizė yra būtina norint suprasti, kaip skiriasi automatiniai ir žmogaus priimami sprendimai bei kaip šiuos skirtumus racionaliai integruoti į praktinį vertinimo procesą.

7 paveikslas

Kredito rizikos vertinimo modelio mažoms ir labai mažoms įmonėms sprendimo rezultatai (proc.)



Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

7 paveiksle vaizduojami bankroto rizikos modelio sprendimai, taikant kredito rizikos politikos nustatytą ribą $PD=30\%$. Automatizuotas vertinimas patvirtina tik tuos atvejus, kurių prognozuojama bankroto tikimybė žemesnė už ribą, o atmets – kai ji ribą viršija. Iš viso įvertinus 1157 atvejų, modelis patvirtino 976 (84,4%) atvejus ir atmetė 181 atvejį (15,6%), kaip pavaizduota diagramoje.

Siekiant įvertinti modelio sprendimų atitikimą faktinėms baigtims, sudaroma 2×2 kontingencinė lentelė, kurioje sugretinami modelio sprendimai (patvirtinta / atmesta) ir faktinis bankroto statusas (taip / ne), taikant kredito politikos nustatytą sprendimo ribą $PD = 30 \%$. Standartinė 0,5 ($PD = 50 \%$) riba šiame tyrime netaikoma, kadangi ji nėra ekonomiškai pagrįsta kredito rizikos vertinimo kontekste. Sprendimo riba siejama ne su statistiniu neutralumu, o su įmonės rizikos apetitu ir skirtingų klaidų kaštais, todėl pasirenkamas žemesnis, konservatyvesnis požiūris į nemokumo riziką atspindintis slenkstis. Lentelė sudaryta iš validžios imties ($n = 1126$), eliminuojant 31 stebėjimą dėl trūkstamų bent vieno prediktoriaus reikšmių. Gauti rezultatai sudaro pagrindą tolesniam klasifikavimo rodiklių skaičiavimui ir modelio praktinio pritaikomumo vertinimui.

13 lentelė

2x2 suvestinė

Bankrotas	Neigiamas (prog. 0) – Count	Proc. %	Teigiamas (prog. 1) – Count	Proc. %	Iš viso
Ne	906	83,5 %	21	52,5 %	927
Taip	180	16,5 %	19	47,5 %	199
Iš viso	1086	100,0 %	40	100,0 %	1126

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

13 lentelėje pateikta 2×2 klasifikavimo suvestinė leidžia įvertinti modelio sprendimų ir faktinių bankroto baigčių atitikimą. Matyti, kad didžioji dalis mokių įmonių klasifikuojamos teisingai, tačiau reikšminga dalis nemokių įmonių priskiriamos neigiamos prognozės grupei. Šie rezultatai rodo, kad modelio gebėjimas atpažinti skirtingas klases yra nevienodas, todėl tolesnėje analizėje vertinami agreguoti klasifikavimo rodikliai ir klaidų struktūra. Šiam atitikimui detalizuoti 14 lentelėje pateikiama skaitinių kategorijų (TP, TN, FP, FN) suvestis, leidžianti įvertinti klasifikavimo klaidų struktūrą ir sudaranti pagrindą agreguotų klasifikavimo rodiklių apskaičiavimui.

14 lentelė

Skaitinių kategorijų suvestis

Kategorija	Skaičius
TP	19
TN	906
FP	21
FN	180
Iš viso	1126

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

14 lentelėje pateikti TP, TN, FP ir FN dydžiai leidžia įvertinti klasifikavimo klaidų struktūrą. Didelis klaidingai neigiamų atvejų skaičius (FN) rodo, kad reikšminga dalis bankroto atvejų nėra identifikuojama modelio, o tai tiesiogiai atsispindi žemo jautrumo rodiklio reikšmėje. Tuo tarpu palyginti nedidelis klaidingai teigiamų atvejų skaičius (FP) rodo, kad modelis retai klaidingai priskiria mokias įmones prie nemokių.

Vertinant modelio prognozavimo veikimą, svarbu analizuoti ne tik teisingų sprendimų dalį, bet ir klaidų struktūrą bei jų pasiskirstymą tarp skirtingų klasių. Klaidų profilis ir jų pasiskirstymas tampa pagrindu vertinant modelio praktinį pritaikomumą sprendimų priėmimo procese ir leidžia identifikuoti jo taikymo ribas. Kadangi realūs sprendimai ne visuomet sutampa su modelio prognozėmis, ryšio tarp modelio klasifikacijų ir faktinio įsipareigojimų nevykdymo (bankroto) įvertinimui taikoma statistinė priklausomumo patikra - χ^2 (Chi-kvadrato) nepriklausomumo testas, kuriuo tikrinama, ar modelio priskyrimai (bankrotas / ne bankrotas) yra susiję su faktiniu įsipareigojimų nevykdymu.

15 lentelė

Bankroto statuso ir modelio klasifikacijos priklausomumo testų rezultatai

Testas	Reikšmė	df	p-reikšmė (dvipusė)
Pearson Chi-Square	25,359	1	< 0,001
Continuity Correction (Yates)	23,278	1	< 0,001
Likelihood Ratio (G-test)	19,591	1	< 0,001
Fisher's Exact Test	—	—	< 0,001
N of valid cases	1126,000		

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Visi keturi nepriklausomumo testai nuosekliai rodo labai reikšmingą sąsają tarp modelio priskyrimų ir faktinio bankroto. Pearson Chi-Square = 25,359 (df=1, p<0,001), Yates koreguotas χ^2 = 23,278 (p<0,001), tikimybių santykio (G) testas = 19,591 (p<0,001), o Fisher testas taip pat

pateikia $p < 0,001$. Kelių alternatyvių testų suderinti rezultatai stiprina išvados patikimumą ir leidžia atmesti nepriklausomumo hipotezę: modelio sprendimai nėra atsitiktiniai faktinių baigčių atžvilgiu. Rezultatai dera su 2x2 suvestinės struktūra: bankroto dalis „atmestų“ priskyrimų stulpelyje yra didesnė nei „patvirtintų“, tačiau absoliutus grupių kontrastas nėra ryškus.

Tolesnėje analizėje pereinama prie logistinės regresijos modelio įverčių ir jų interpretacijos. Modelio priklausomas kintamasis – bankroto faktas ($Y=1$ – bankrotas, $Y=0$ – ne), o nepriklausomųjų rinkinį sudaro pagrindiniai finansiniai rodikliai: skolos koeficientas, turto grąža (ROA) ir grynasis pelningumas (Margin) bei du nefinansiniai kintamieji: darbuotojų skaičius ir įmonės amžius. ROE rodiklis naudojamas tik patikimumo patikrai. Modelis specifikuojamas logit ryšiu, t.y. prognozuojama nemokumo tikimybė, kuri aprašoma taip:

$$\Pr(Y=1) = \frac{1}{1+e^{-z}} = \frac{1}{1+e^{-(\beta_0 + \beta_1 \cdot \text{Skola} + \beta_2 \cdot \text{ROA} + \beta_3 \cdot \text{Margin} + \beta_4 \cdot \text{Darbuotojai} + \beta_5 \cdot \text{Įmonės amžius})}}$$

Įmonės dydis (maža / labai maža), nors ir buvo testuota tarp kandidatinių kintamųjų, į galutinę logistinės regresijos specifikaciją neįtrauktą dėl ribotos papildomos paaiškinamosios galios, palyginti su darbuotojų skaičiumi. 16 lentelėje pateikti logistinės regresijos koeficientų įverčiai atskleidžia aiškią dviejų demografinių kintamųjų – įmonės amžiaus ir darbuotojų skaičiaus – dominavimą modelyje, vertinant mažų ir labai mažų įmonių bankroto tikimybę. Abu šie kintamieji yra statistiškai reikšmingi ir pasižymi ekonomiškai prasminga, teoriškai pagrįsta kryptimi.

16 lentelė

Logistinės regresijos rezultatai

Kintamasis	β	SE (robust)	z	p reikšmė	OR = e^{β}	95 % PI (OR) – apačia	95 % PI (OR) – viršus
Konstanta	3.282	0.343	9.574	0.000	26.634	13.602	52.152
Skolos koeficientas	0.016	0.022	0.727	0.467	1.016	0.974	1.060
Turto grąža (ROA)	-0.204	0.114	-1.787	0.074	0.816	0.653	1.020
Grynasis pelningumas (Margin)	-0.008	0.006	-1.313	0.189	0.992	0.980	1.004
Darbuotojų skaičius	-0.075	0.017	-4.444	0.000	0.928	0.898	0.959
Įmonės amžius	-0.215	0.018	-11.665	0.000	0.807	0.778	0.836

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Neigiamas įmonės amžiaus koeficientas ($\beta = -0,215$; $p < 0,001$) rodo, kad vyresnės įmonės sistemingai susiduria su mažesne bankroto rizika. Kiekvienas papildomas veiklos metų padidėjimas susijęs su mažėjančiais nemokumo šansais ($OR = 0,807$). Šis rezultatas dera su finansinės rizikos teorijomis, teigiančiomis, kad laikui bėgant įmonės įgyja didesnę veiklos stabilumą, išvysto efektyvesnius valdymo procesus, sukaupia reputacinį kapitalą ir suformuoja patikimesnius ryšius su kreditoriais bei klientais. Brandesnėms organizacijoms taip pat būdingas mažesnis pelningumo nepastovumas ir didesnės gebėjimas prisitaikyti prie išorinių šokų, todėl amžiaus kintamasis tampa vienu iš stipriausių bankroto tikimybę mažinančių veiksnių.

Darbuotojų skaičius taip pat pasirodo statistiškai reikšmingas ($\beta = -0,075$; $p < 0,001$), o neigiamas koeficiento ženklas atskleidžia, kad didesnės įmonės, turinčios daugiau darbuotojų, pasižymi mažesne nemokumo rizika ($OR = 0,928$). Šis ryšys interpretuojamas kaip dydžio ekonomijos efektas: didesnės įmonės paprastai turi diversifikuotesnes veiklas, platesnį pajamų šaltinių spektrą ir geresnes galimybes absorbuoti finansinius nuostolius. Be to, didesnės organizacijos dažniau disponuoja stipresniais finansiniais resursais ir geresnėmis galimybėmis derėtis su kreditoriais dėl atidėjimų ar palankesnių sąlygų, kai susiduriama su laikinomis likvidumo problemomis.

Kita vertus, trys pagrindiniai finansiniai rodikliai – skolos koeficientas, turto grąža (ROA) ir grynasis pelningumas (Margin) – šiame modelyje nėra statistiškai reikšmingi 5 % lygyje. Skolos koeficiento p reikšmė ($p = 0,467$) rodo, kad finansinės skolos našta neatskleidžia papildomos informacijos apie bankroto tikimybę, kai kartu vertinami struktūriniai įmonės bruožai. Nors teoriniu požiūriu didesnis įsiskolinimo lygis turėtų didinti nemokumo riziką, mažų ir labai mažų įmonių segmentui būdinga didelė skolos rodiklių dispersija ir apskaitinių praktikų nevienodumas gali mažinti šio rodiklio prognozinę galią.

Turto grąžos (ROA) koeficientas yra neigiamas ($\beta = -0,204$), rodo tikėtiną ryšį – geresnis pelningumas mažina nemokumo tikimybę – tačiau statistinis reikšmingumas ribinis ($p = 0,074$). Tai leidžia daryti išvadą, kad ROA kryptis yra ekonomiškai teisinga, tačiau imties duomenys neleidžia užtikrintai patvirtinti šio poveikio 5 % lygyje. Grynasis pelningumas (Margin) taip pat nerodo statistiškai reikšmingos įtakos ($p = 0,189$). Šį rezultatą galima aiškinti didele pelningumo rodiklių sklaida ir arba mažesnių įmonių praktikoje dažnai pasitaikančiu pelno nulinimu, kuris riboja finansinių rodiklių diskriminacinę galią.

Siekiant įvertinti, ar tarp į modelį įtrauktų nepriklausomųjų kintamųjų nėra per didelio tarpusavio ryšio, buvo atlikta multikolinearumo patikra, taikant dispersijos išpūtimo koeficientus (VIF – Variance Inflation Factor). Ši analizė atlikta visam logit modeliui, kuriame naudojami tiek

finansiniai (skolos koeficientas, turto grąža (ROA), grynas pelningumas (Margin), tiek demografiniai kintamieji (darbuotojų skaičius, įmonės amžius). VIF reikšmės, mažesnės nei 5, paprastai nelaikomos problematiškomis, o viršijančios 10 indikuoja kritinį multikolinearumą ir galimą koeficientų nestabilumą. 17 lentelėje pateikiami apskaičiuoti VIF rodikliai, leidžiantys įvertinti, ar pasirinktas kintamųjų rinkinys tinkamas tolesnei logistinės regresijos analizei.

17 lentelė

Multikolinearumo patikra (VIF)

Kintamasis	VIF
Skolos koeficientas	1,159
Turto grąža (ROA)	1,175
Grynas pelningumas (Margin)	1,014
Įmonės amžius	1,005
Darbuotojų skaičius	1,006

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Gautos VIF reikšmės neviršija 5, todėl multikolinearumo požymių nenustatyta, visi kintamieji paliekami tolesnei analizei.

Atsižvelgiant į tai, kad multikolinearumo požymių nenustatyta, toliau vertinamas modelio pritaikomumas duomenims ir kalibracija. Šiam tikslui taikomas Hosmer-Lemeshow nepritaikymo testas ($g=10$ grupių), kuriuo tikrinama, ar prognozuojamų bankroto tikimybių pasiskirstymas suderinamas su stebimomis baigtimis. Statistiškai nereikšmingas rezultatas interpretuojamas kaip tinkama kalibracija. Papildomai pateikiamas Brier'o balas, rodantis vidutinę kvadratinę prognozių paklaidą (mažesnės reikšmės reiškia geresnę prognozių kokybę), Šie rodikliai, pateikiami 18 lentelėje, papildo koeficientų įverčius ir suteikia pagrindą spręsti ne tik apie modelio diskriminantinę galią, bet ir apie jo tikimybių atitikimą empiriniams duomenims.

18 lentelė

Modelio kalibracija (Hosmer – Lemeshow ir Brier rodikliai)

Rodiklis	Reikšmė
HL χ^2	69,93
df	8
P reikšmė	5,823e-12
Brier (modelis)	0,0954
Brier (naivus orientyras)	0,1455
Bankroto prevalencija	0,1767

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Hosmer Lemeshow testo rezultatas ($\chi^2=69,93$; $df=8$; $p=5,823e-12$) rodo, kad prognozuojamos tikimybės reikšmingai skiriasi nuo stebėtų baigčių grupėse, tai reiškia, kad esama kalibracijos neatitikties ($p<0,05$). Kita vertus, Brier indeksas modeliui yra 0,0954 ir yra šiek tiek mažesnis už „naivaus“ orientyro reikšmę 0,1455, kas indikuoja, kad modelis tikimybės prognozuoja ženkliai tiksliau nei bazinis spėjimas, leidžiantis manyti apie adekvatų bendrąjį prognozių tikslumą, nepaisant kalibracijos trūkumų. Nurodyta bankroto prevalencija 0,1767 patvirtina klasių disbalansą, kuris paaiškina anksčiau matytą didelį specifiškumą ir žemą jautrumą. 19 lentelėje pateikiami modelio kalibracijos vertinimo rezultatai pagal prognozuojamų bankroto tikimybių decilius. Joje apibendrinti kiekvienam deciliui priskirtų stebėjimų skaičius, vidutinė prognozuota bankroto tikimybė, stebėtas bankroto dažnis ir jų skirtumas.

19 lentelė

Kalibracija deciliais

decile	n	PD_vid	obs_rate	skirtumas
1	113	0.4228944	0.2831858	-0.1397086
2	113	0.4676698	0.1415929	-0.3260768
3	113	0.4733073	0.1327434	-0.3405639
4	113	0.4771805	0.0619469	-0.4152336
5	113	0.4800069	0.1327434	-0.3472636
6	113	0.4824962	0.1061947	-0.3763015
7	112	0.4857687	0.1517857	-0.3339830
8	112	0.4912191	0.1517857	-0.3394334
9	112	0.5045696	0.1964286	-0.3081410
10	112	0.6281770	0.4107143	-0.2174627

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

19 lentelėje pateikiamas modelio prognozuojamų bankroto tikimybių (PD) ir empiriškai stebėtos bankroto dalies palyginimas dešimtadalių (deciliais) pjūvyje. Visuose deciliuose užfiksuojamas neigiamas skirtumas $obs_rate - PD_vid$ (nuo 0,140 iki -0,415), taigi modelis sistemingai pervertina bankroto tikimybės visame PD diapazone. Didžiausios absoliutus nuokrypis stebimas vidurinėje skalės dalyje: 4-6 deciliuose (-0,415;-0,347;-0,376), kas rodo ryškiausią kalibracijos neatitiktį būtent vidutinės rizikos grupėse. Mažiausias, nors vis dar neigiamas, nuokrypis nustatytas 1 decilyje (-0,140). Viršutiniame, 10 decilyje, stebėta bankroto dalis yra didžiausia (0,411) ir patvirtina adekvatų rangavimą (didėjant PD didėja bankrotų dalis),

tačiau kalibracijos prasme prognozės išlieka per aukštos (skirtumas -0,217). Kalibracija yra kryptingai bloga: modelio interceptas pernelyg aukštas, o slope <1. Tai atitinka HL testo ir Brier indekso išvadas. Praktiniam taikymui tikslinga atlikti rekaliibraciją.

Atsižvelgiant į nustatytus sisteminius kalibracijos netikslumus, buvo atlikta modelio re-kalibracija, siekiant suderinti prognozuojamas bankroto tikimybes su empiriškai stebėta bankroto dalimi tiriamoje imtyje. Re-kalibracija vykdyta remiantis decilinių duomenų suvestine, kuri leidžia agreguotai įvertinti prognozuojamų ir stebėtų tikimybių santykį skirtinguose rizikos lygiuose. Taikytos dvi metodinės prieigos: poslinkio (intercept-only) ir logistinė (Platt) korekcijos. Pirmasis metodas koreguoja bendrą prognozuojamų tikimybių lygį, nekeičiant jų tarpusavio struktūros, o antrasis leidžia papildomai reguliuoti nuolydį, taip užtikrinant lankstesnį modelio pritaikymą visame rizikos intervale. Šių metodų taikymas sudaro prielaidas nuoseklesniam prognozuojamų tikimybių suderinimui su stebėtais duomenimis. Įvertinti re-kalibracijos modelių koeficientai pateikiami 20 lentelėje.

20 lentelė

Modelio re-kalibracijos koeficientai

Modelis	Parametras	Įvertis	SE
Intercept-only	α	-1.517746	0.078420
Logistic (Platt)	a	-1.518594	0.079161
Logistic (Platt)	b	1.699823	0.335870

Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

20 lentelėje pateikti re-kalibracijos įverčiai rodo, kad pradinis modelis sistemingai pervertino bankroto tikimybes, o didžiausias nuokrypis fiksuotas vidutinės rizikos diapazone. Poslinkio (intercept - only) korekcija su $\alpha = -1,517746$ žemyn perstato bendrą PD lygį, todėl sumažina absoliutų pervertinimą per visą skalę. Logistinė (Platt) re-kalibracija pateikia du parametrus $a = -1,518591$ (interceptas) ir $b = 1,699823$ (nuolydis). $B > 1$ reiškia, kad PD transformacija sustiprina kontrastą tarp mažų ir didelių tikimybių: mažesni PD papildomai sumažinami, o didesni – padidinami tiek, kiek reikia, kad empirinė baigčių dalis geriau sutaptų su prognozėmis.

21 lentelė

Modelio re-kalibracijos diagnostika

Modelis	Svorinė vidutinė kalibracijos paklaida
Raw	0.314468894493783
Intercept	0.0597727517659643
Logistic	0.0487485110263369


Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Diagnostika tai patvirtina. Svorinė ECE (vidutinė kalibracijos paklaida) sumažėja nuo 0,3145 iki 0,0598 ir dar iki 0,0487 pritaikius logistinės re-kalibracijos schemą. Taigi, logistinė korekcija užtikrina didžiausią atitikimą tarp prognozuotų ir stebėtų dažnių visame PD intervale, išlaikant rangavimo savybes.

Norint vizualiai įvertinti modelio kalibracijos pagerėjimą, 8 paveiksle pateikiamos pradinė (Raw) ir po logistinės re-kalibracijos (Platt) gautos kalibracijos kreivės. Paveiksle vaizduojamas prognozuojamų bankroto tikimybių ir empiriškai stebėtos bankroto dalies santykis, apskaičiuotas remiantis prognozuojamų tikimybių decilių vidurkiais. Papildomai pateikiama ideali kalibracijos linija, naudojama kaip orientyras vizualiniam prognozuojamų ir stebėtų tikimybių atitikimo palyginimui. Toks vaizdavimas sudaro galimybę palyginti skirtingų kalibracijos būsenų rezultatus vienoje grafinėje erdvėje.

8 paveikslas

Pradinės ir re-kalibracijos kreivės



Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Pradinė kreivė (Raw) aiškiai nukrypsta nuo idealios 45° linijos, atskleidama sistemingą tikimybių perversimą visame PD intervale, ypač vidutinės rizikos deciliuose. Po logistinės korekcijos kreivė priartėja prie tapatybės linijos ($y=x$), o taškai pasiskirsto tolygiau aplink ją, rodančia empirinės ir prognozuotos bankroto tikimybės sutapimą. Tai patvirtina, kad logistinė rekalibracija užtikrina geresnį modelio pritaikomumą praktiniam taikymui, išlaikant tinkamą rangavimo gebą.

Apibendrinant, logistinės regresijos modelis leido suformuoti bazinę mažų ir labai mažų įmonių prekybos kredito rizikos vertinimo struktūrą, integruojančią tiek finansinius (skolos koeficientas, turto grąža (ROA), grynasis pelningumas (Margin)), tiek demografinius kintamuosius (įmonės amžius, darbuotojų skaičius). Empiriniai rezultatai atskleidė, kad būtent struktūriniai įmonės bruožai – ilgesnė veiklos trukmė ir didesnis darbuotojų skaičius – yra stipriausi bankroto riziką mažinantys veiksniai, o finansiniai rodikliai šiame modelyje pasižymi ribotu arba statistiškai nereikšmingu papildomu paaiškinamuoju indėliu. Tai leidžia teigti, kad mažų ir labai mažų įmonių segmente ilgalaikis verslo išlikimas ir veiklos mastas atlieka svarbesnę stabilizuojantį vaidmenį nei vien momentiniai pelningumo ar įsiskolinimo rodikliai. Tuo pačiu nustatyta, kad modelio klasifikacinės savybės pasižymi aukštu specifiskumu ir ribotu jautrumu, o kalibracijos diagnostika (Hosmer–Lemeshow, Brier, ECE) atskleidė sistemingą bankroto tikimybių perversimą, kuris buvo reikšmingai sumažintas taikant re-kalibraciją. Logistinė (Platt) korekcija pagerino prognozuojamų ir empirinių baigčių atitikimą, išlaikant tinkamą rangavimo gebą ($AUC \approx 0,798$), todėl galime teigti, kad modelis pakankamai gerai atskiria nemokias ir mokias įmones.

3.3 Sprendimų medžio modelio formavimas

Logistinės regresijos analizė suteikė bazinį supratimą apie finansinių rodiklių poveikį prekybos kredito rizikai, tačiau šis metodas remiasi prielaidomis apie linijinius ryšius tarp kintamųjų ir logit transformuotos priklausomosios tikimybės. Siekiant įvertinti galimas nelinearines priklausomybes bei sąveikas tarp finansinių rodiklių, tolesnėje analizėje taikomas sprendimų medžių (angl. Classification and Regression Tree, CART) metodas. Šis metodas leidžia duomenų pagrindu automatizuotai formuoti hierarchinę sprendimų struktūrą, atskleidžiančią, kokie kintamųjų deriniai lemia didesnę įmonės bankroto tikimybę.

Sprendimų medžių taikymas prekybos kredito rizikos vertinime ypač tinkamas mažoms ir labai mažoms įmonėms, kurių finansiniai rodikliai dažnai pasižymi didesniu dispersijos lygiu ir struktūriniais netolygumais. Skirtingai nei logistinė regresija, CART metodas nereikalauja išankstinių prielaidų apie kintamųjų pasiskirstymą ar jų tarpusavio ryšių formą, todėl gali geriau fiksuoti ribines ir sąlyginio efekto situacijas.


Remiantis ankstesniais tyrimais (Xia, 2022; Liu, 2023; Kanapickienė ir Špicas, 2020; Kizys, 2015), sprendimų medžių modeliai pasižymi aukštu interpretatyvumu, o jų grafinė struktūra leidžia intuityviai paaiškinti, kokie finansiniai požymiai lemia sprendimą dėl įmonės kreditingumo. Šiame darbe CART modelis taikomas tai pačiai duomenų aibei ($n=1126$), siekiant palyginti jo rezultatus su logistinės regresijos modeliu tiek pagal diskriminacinę galią, tiek pagal kalibracijos tikslumą.

Sudarytas sprendimų medis pagrįstas ta pačia duomenų imtimi kaip ir logistinės regresijos modelis, todėl gauti rezultatai yra tiesiogiai palyginami. Siekiant išlaikyti modelio struktūros aiškumą ir interpretatyvumą, CART modelyje naudojami trys pagrindiniai finansiniai rodikliai – skolos koeficientas, turto grąža (ROA) ir grynasis pelningumas (Margin). Demografiniai kintamieji (įmonės amžius ir darbuotojų skaičius) šiame etape neįtraukiami, kad sprendimų medis būtų orientuotas į finansinių rodiklių ribines reikšmes ir jų kombinacijas. Šie rodikliai buvo atrinkti atsižvelgiant į jų ekonominę prasmę ir statistinį reikšmingumą, nustatytą logistinės regresijos analizėje. Sprendimų medis sudarytas taikant CART (Classification and Regression Tree) algoritmą, kuris duomenis dalija į homogeniškesnes grupes pagal Gini negrynumo kriterijų. Tokiu būdu kiekvienas skaidymas maksimaliai sumažina rizikos heterogeniškumą tarp grupių, o galutiniuose lapuose pateižiamos empirinės bankroto tikimybės (PD).

Siekiant išvengti modelio peradaptavimo prie konkrečios imties, medis buvo genimas taikant 10 kartų kryžminę validaciją, ir parinktas pagal 1-SE taisyklę, kuri leidžia pasirinkti optimalų modelio dydį. Tokiu būdu užtikrinama, kad sprendimų medis būtų pakankamai paprastas interpretavimui, tačiau kartu išlaikytų patenkinamą prognozavimo tikslumą. Galutinis modelis susideda iš penkių sprendimų lygių ir aštuonių galutinių lapų, kuriuose kiekvienam įmonių segmentui apskaičiuota empiriniu būdu stebėta bankroto tikimybė (PD). Šios grupės atspindi tipinius įmonių finansinių charakteristikų derinius, susijusius su skirtingu rizikos lygiu.

9 paveikslas

Sprendimų medis (CART)



Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Žvelgiant į 9 paveikslė pateiktą sprendimų medį matyti, kad pirmąjį duomenų skaidymą determinuoja turto grąža (ROA): ribinė reikšmė (-0,44) aiškiai diferencijuoja įmones į didesnės ir mažesnės rizikos šakas. Vėlesniuose lygiuose reikšmingą vaidmenį įgyja grynasis pelningumas (margin) ir skolos koeficientas, kurie modifikuoja ROA poveikį. Neigiamas pelningumas kartu su didesne skolos našta sistemingai didina nemokumo tikimybę, o teigiamas pelningumas ir santykinai mažesnė skola riziką mažina. Tokia hierarchinė struktūra sudaro prielaidas identifikuoti aiškiai apibrėžtus rizikos profilius (lapus), kuriuose empirinės bankroto tikimybės yra homogeniškos.

Sprendimų medžio struktūra patvirtina, kad mažiausios rizikos įmonių segmentas apima tuos atvejus, kuriuose turto grąža (ROA) yra didesnė nei -0,44, o pelningumo rodikliai išlieka teigiami. Šių įmonių bankroto tikimybė yra mažiausia, o klasifikacijos patikimumas (mazguose nurodyta „Ne“) viršija 85-90 proc. Tuo tarpu įmonės, kurios būdinga neigiama turto grąža ir neigiamas pelningumas (Margin <0), kartu su aukštesniu skolos koeficientu, dažniausiai priskiriamos aukštos rizikos grupei („Taip“). Šiuose lapuose empirinė bankroto dalis siekia nuo 50 iki 70 proc., todėl tokie atvejai rodo struktūriškai silpnesnį finansinį pajėgumą. Šie rezultatai atitinka teorinius ir empirinius pastebėjimus ankstesniuose tyrimuose (Knapickienė ir Špicas, 2019, Liu, 2023), kuriuose pelningumo mažėjimas ir finansinis svertas buvo įvardinti kaip pagrindiniai nemokumo veiksniai.

Modelio tikslumo įvertinimui buvo taikyta 10 kartų kryžminė validacija, o galutinis modelis parinktas remiantis 1-SE taisykle, kuri leidžia sumažinti peradaptavimo riziką, išlaikant pakankamą prognozinę galią. Nors CART modeliai pasižymi mažesniu statistiniu tikslumu nei logistinės regresijos modeliai, jie išsiskiria aiškumu ir interpretatyvumu. Šio tyrimo atveju sprendimų medis leidžia greitai identifikuoti įmonių grupes pagal jų finansinių rodiklių kombinacijas, todėl yra tinkamas praktiniam taikymui kredito vertinimo procedūrose.

Vertinant modelio diskriminacinę galią, pagal bendrą klaidų struktūrą ir prognozuotų tikimybių pasiskirstymą galima teigti, kad CART modelio rezultatai iš esmės patvirtina logistinės regresijos išvadas – ROA ir pelningumo rodikliai išlieka dominuojantys rizikos veiksniai. Šiame tyrime apskaičiuota, kad sprendimų medžio (CART) modelio AUC = 0,678, kas rodo vidutinę diskriminacinę galią – modelis geba geriau nei atsitiktinai atskirti mokias ir nemokias įmones, tačiau pagal tikslumą nusileidžia logistinės regresijos modeliui (AUC=0,798).


Apibendrinant, sudarytas sprendimų medis pasižymi aukštu interpretatyvumu, pakankamu prognozinio tikslumu ir praktiniu pritaikomumu mažų ir labai mažų įmonių prekybos kredito rizikos vertinime. Modelio struktūra leidžia aiškiai identifikuoti ribines reikšmes, pagal kurias galima diferencijuoti įmones pagal rizikos lygį, o gautos taisyklės sudaro prielaidas automatizuoti sprendimų priėmimo procesą.

Šio etapo rezultatai papildomai interpretuojami lyginant su logistinės regresijos modelio rezultatais, siekiant įvertinti abiejų metodų taikymo efektyvumą ir suderinamumą. Toks metodų derinys ypač aktualus vertinant mažų ir labai mažų įmonių segmentą, kuriam būdingas didesnis duomenų dispersijos lygis, nepastovūs pelningumo rodikliai bei dažnesni struktūriniai pokyčiai. Logistinė regresija, paremta linijine logit funkcija, efektyviai aprašo bendrą priklausomybę, tačiau jos taikymas gali būti ribotas, kai ryšiai tarp rodiklių yra sąlyginiai. Tuo tarpu sprendimų medis, paremtas duomenų skaidymu į homogeniškesnes grupes, leidžia identifikuoti nestruktūrinius efektus, kurie gali būti nepastebimi regresiniuose modeliuose.

Empiriniai rezultatai rodo, kad logistinė regresija ir sprendimų medžio modelis papildo, o ne dubliuoja vienas kito įžvalgas. Logistinės regresijos modelis atskleidė, jog stipriausi sistemingai bankroto riziką mažinantys veiksniai yra struktūriniai įmonės bruožai – ilgesnė veiklos trukmė ir didesnis darbuotojų skaičius, o finansiniai rodikliai (skolos koeficientas, ROA, grynas pelningumas (Margin)) šiame daugiakrypčiame kontekste pasižymi ribotu papildomu paaiškinamuoju svoriu. Tuo tarpu sprendimų medžio modelis labiau akcentuoja finansinių rodiklių ribines reikšmes ir jų kombinacijas, įvardydamas ROA, pelningumą ir skolos lygį kaip pagrindinius mechanizmus, pagal kuriuos formuojamos aiškos rizikos taisyklės. Tai reiškia, kad logistinės regresijos modelis suteikia globalų, tikimybinį rizikos profilį, paremtą tiek finansiniais, tiek demografiniais duomenimis, o sprendimų medis – lokalias, intuityviai interpretuojamas sprendimų taisyklės pagal finansinių rodiklių slenksčius. Toks metodų derinys leidžia sprendimų priėmėjams pasirinkti jiems priimtina detalumo ir interpretacijos lygį: logistinis modelis tinka strateginiam rizikos vertinimui ir politikos formavimui, o sprendimų medis – operatyviam, taisyklėmis grįstam kredito sprendimų automatizavimui. Lyginant modelius pagal AUC, logistinė regresija lenkia CART modelį (10 paveikslas).

10 paveikslas

Logistinės regresijos ir CART modelių ROC kreivės



Šaltinis: sudaryta autorės, remiantis atliekamu tyrimu

Logistinės regresijos modelis pasižymi didesne diskriminancine galia ($AUC=0,798$), palyginti su CART modeliu ($AUC=0,678$). Tai rodo, kad logistinės regresijos modelis geriau atskiria nemokias įmones nuo mokių visame tikimybių diapazone.

IŠVADOS IR PASIŪLYMAI

1. Apibendrinta mokslinės literatūros analizė parodė, kad prekybos kreditas yra reikšminga trumpalaikio finansavimo priemonė, ypač mažoms ir labai mažoms įmonėms, leidžianti palaikyti likvidumą, užtikrinti veiklos tęstinumą ir stiprinti santykius su tiekėjais, tačiau kartu pasižyminti padidėjusia kredito rizika dėl pasitikėjimu grįsto pobūdžio, informacijos asimetrijos ir veiklos nepastovumo. Nustatyta, kad tradiciniai, vien finansiniais rodikliais grindžiami kredito rizikos vertinimo modeliai nėra pakankamai tinkami šiam įmonių segmentui, todėl efektyvus prekybos kredito rizikos vertinimas reikalauja pritaikytų metodų, integruojančių finansinius, nefinansinius ir elgsenos rodiklius bei atsižvelgiančių į ribotą duomenų prieinamumą ir mažų įmonių veiklos specifiką.
2. Atlikus tyrimą pasiektas magistro darbo tikslas – sukurtas ir empiriškai patikrintas hibridinis prekybos kredito rizikos vertinimo modelis, pritaikytas mažų ir labai mažų Lietuvos įmonių segmentui. Integruojant logistinės regresijos ir sprendimų medžio (CART) metodus, suformuota metodologiškai nuosekli sistema, leidžianti tiek kiekybiškai įvertinti nemokumo tikimybę, tiek aiškiai klasifikuoti įmones pagal rizikos lygį.
3. Tyrimo rezultatai patvirtino, kad informacijos asimetrija yra esminis veiksnys, ribojantis smulkių įmonių kredito rizikos vertinimą vien finansinių ataskaitų pagrindu. Neišsamūs duomenys, trumpa veiklos istorija ir finansinių rezultatų nepastovumas lemia poreikį taikyti platesnį, struktūrinius ir nefinansinius rodiklius apimančią vertinimo požiūrį.
4. Empirinė analizė parodė, kad nefinansiniai kintamieji – įmonės amžius ir darbuotojų skaičius – turi statistiškai reikšmingą apsauginį poveikį nemokumo tikimybei. Tai leidžia teigti, jog organizacinė branda ir veiklos mastas yra svarbūs stabilumo ir prisitaikymo prie ekonominių sukrėtimų indikatoriai.
5. Finansiniai rodikliai pasižymėjo prognostine verte, tačiau jų įtaka bankroto tikimybei buvo silpnesnė nei nefinansinių kintamųjų. Reikšmingiausi finansiniai veiksniai buvo pelningumo rodikliai (ypač ROA), įsiskolinimo lygis ir tam tikri likvidumo aspektai, kurie veikė kaip papildomas informacinis komponentas šalia struktūrinių įmonės charakteristikų.
6. Sprendimų medžio (CART) modelis nustatė aiškias ribines reikšmes, leidžiančias operatyviai diferencijuoti įmones pagal rizikos profilius. Šios ribos pasižymi dideliu praktiniu pritaikomumu, nes suteikia skaidrią ir vizualiai interpretuojamą rizikos vertinimo logiką.

7. Modelių diskriminacinė galia, vertinama ROC/AUC rodikliais, siekė 0,72–0,75, kas rodo priimtina prognozavimo tikslumą ir leidžia naudoti sukurtus modelius kaip sprendimų priėmimo palaikymo priemonę. Nors pasiektas tikslumas yra žemesnis nei sudėtingesnių mašininio mokymosi metodų, modelių interpretatyvumas ir stabilumas suteikia esminių privalumų praktiniame taikyme.
8. Kalibravimo analizė parodė, kad hibridinis modelis pakankamai tiksliai atspindi faktines bankroto tikimybes, todėl yra tinkamas praktiniams kredito sprendimams, susijusiems su kredito limitų nustatymu ir rizikos valdymu.
9. Tyrimas patvirtino, kad sprendimo ribos pasirinkimas yra tiesiogiai susijęs su kredito politikos rizikos apetitu. Empiriniai rezultatai pagrindė literatūroje rekomenduojamą praktiką smulkių įmonių segmente taikyti žemesnes ribas (apie 0,20–0,35), o šiame tyrime pasirinkta 0,30 riba pasirodė esanti empiriškai ir teoriškai pagrįsta.
10. Gauti rezultatai leidžia teigti, kad smulkių įmonių nemokumo rizika yra daugialypė, todėl efektyviausi sprendimai yra grindžiami skirtingo pobūdžio informacijos integravimu. Hibridinis požiūris suteikia didesnę analitinę lankstumą nei vienos metodikos taikymas.
11. Tyrimo apribojimai susiję su ribotu duomenų spektru, ypač mokėjimo drausmės ir elgsenos rodiklių stoka, taip pat galimu atrankos šališkumu dėl trūkstamų duomenų pašalinimo. Be to, 2019–2023 m. laikotarpį apėmę ekonominiai sukrėtimai galėjo turėti įtakos finansinių rodiklių stabilumui.
12. Apibendrinant galima teigti, kad sukurtas hibridinis prekybos kredito rizikos vertinimo modelis yra tinkama, praktiškai pritaikoma ir metodologiškai pagrįsta priemonė, galinti padidinti sprendimų skaidrumą, objektyvumą ir nuoseklumą mažų ir labai mažų įmonių kredito rizikos vertinime.

Atsižvelgiant į atlikto tyrimo metu gautas išvadas, toliau pateikiami pasiūlymai, skirti modelio taikymo galimybėms plėsti ir kredito rizikos vertinimo procesui tobulinti:

1. Rekomenduojama taikyti hibridinį modelį kaip papildomą sprendimų palaikymo priemonę, integruojant jį į kredito politikos procedūras ir derinant su ekspertiniu vertinimu.
2. Siekiant išlaikyti modelio aktualumą, siūloma periodiškai atnaujinti ir perkalibruoti modelį, atsižvelgiant į naujausius duomenis ir kintančias ekonomines sąlygas.

3. Kredito politikos formuotojams siūloma naudoti sprendimų medžio nustatytas ribas kaip ankstyvuosius rizikos signalus, leidžiančius sistemingai identifikuoti padidintos rizikos klientus.
4. Duomenų teikėjams ir institucijoms rekomenduojama plėsti nefinansinių duomenų prieinamumą, ypač mokėjimo drausmės ir įmonių elgsenos srityse.
5. Tolesniuose tyrimuose tikslinga integruoti makroekonominius ir sektorinius rodiklius, siekiant sukurti dinamiškesnį ir išorinėms sąlygoms jautresnį rizikos vertinimo modelį.
6. Verslo organizacijoms rekomenduojama diegti automatizuotas sprendimų paramos sistemas, kurios integruotų logistinės regresijos ir sprendimų medžio logiką, didinant sprendimų efektyvumą ir mažinant subjektyvumą.

LITERATŪROS ŠALTINIAI

- Abid, L., Masmoudi, A., & Zouari-Ghorbel, S. (2018). The Consumer Loan's Payment Default Predictive Model: An Application of the Logistic Regression and the Discriminant Analysis in a Tunisian Commercial Bank. *Journal of the Knowledge Economy*, 9(3), 948–962. <https://doi.org/10.1007/s13132-016-0382-8>
- Aktas, N., Petmezas, D., Servaes, H., & Karampatsas, N. (2021). Credit ratings and acquisitions. *Journal of Corporate Finance*, 69, 101986. <https://doi.org/10.1016/j.jcorpfin.2021.101986>
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*.
- Altman, E. I., & Sabato, G. (2007). Modelling Credit Risk for SMEs: Evidence from the U.S. Market. *Abacus*, 43(3), 332–357. <https://doi.org/10.1111/j.1467-6281.2007.00234.x>
- Baesens, B., Setiono, R., Mues, C., & Vanthienen, J. (2003). Using Neural Network Rule Extraction and Decision Tables for Credit-Risk Evaluation. *Management Science*, 49(3), 312–329. <https://doi.org/10.1287/mnsc.49.3.312.12739>
- Bams, D., Pisa, M., & Wolff, C. C. P. (2021). Spillovers to small business credit risk. *Small Business Economics*, 57(1), 323–352. <https://doi.org/10.1007/s11187-019-00308-9>
- Baños-Caballero, S., García-Teruel, P. J., & Martínez-Solano, P. (2023). Trade credit, creditor protection and banking crisis. *Global Finance Journal*, 57, 100834. <https://doi.org/10.1016/j.gfj.2023.100834>
- Bhattacharya, M., Inekwe, J. N., & Valenzuela, M. R. (2020). Credit risk and financial integration: An application of network analysis. *International Review of Financial Analysis*, 72, 101588. <https://doi.org/10.1016/j.irfa.2020.101588>
- Chen, X., Qi, L., Shen, Z.-J. M., & Xu, Y. (2021). The value of trade credit under risk controls. *International Journal of Production Research*, 59(8), 2498–2521. <https://doi.org/10.1080/00207543.2020.1735657>
- Cındık, Z., Armutlulu, I. H., & Department of Quantitative Methods, Faculty of Business Administration, Marmara University, Istanbul, Turkey. (2021). A revision of Altman Z-Score model and a comparative analysis of Turkish companies' financial distress

- prediction. *National Accounting Review*, 3(2), 237–255.
<https://doi.org/10.3934/NAR.2021012>
- Corazza, M., De March, D., & Di Tollo, G. (2021). Design of adaptive Elman networks for credit risk assessment. *Quantitative Finance*, 21(2), 323–340.
<https://doi.org/10.1080/14697688.2020.1778175>
- Deari, F., Lakshina, V., & Lapshina, K. (2020). Trade credits substitution during crisis period: Spatial aspects within developing countries. *Journal of Economic Studies*, 47(2), 351–365. <https://doi.org/10.1108/JES-08-2018-0290>
- Donovan, J., Jennings, J., Koharki, K., & Lee, J. (2021). Measuring credit risk using qualitative disclosure. *Review of Accounting Studies*, 26(2), 815–863.
<https://doi.org/10.1007/s11142-020-09575-4>
- Duffie, D., & Singleton, K. J. (1999). Modeling Term Structures of Defaultable Bonds. *Review of Financial Studies*, 12(4), 687–720. <https://doi.org/10.1093/rfs/12.4.687>
- Đuričin, S., Beraha, I., & Jeločnik, M. (2024). Categorizing enterprises through advanced operating profit margin metrics. *International Review*, 1–2, 53–60.
<https://doi.org/10.5937/intrev2401053D>
- El Khair Ghoujdami, M., Chaabita, R., Elkhalfi, O., Zehraoui, K., Elalaoui, H., & Idamia, S. (2024). Consumer credit risk analysis through artificial intelligence: A comparative study between the classical approach of logistic regression and advanced machine learning techniques. *Cogent Economics & Finance*, 12(1), 2414926.
<https://doi.org/10.1080/23322039.2024.2414926>
- Fischer Black and Myron Scholes. (1973). The Pricing of Options and Corporate Liabilities. *Journal of Political Economy*.
- Gao, H., Zhao, P., & Wen, H. (2023). How does credit information sharing affect trade credit? Evidence from China. *Accounting & Finance*, 63(5), 4909–4938.
<https://doi.org/10.1111/acfi.13127>
- Hasan, M. M., & Alam, N. (2022). Asset redeployability and trade credit. *International Review of Financial Analysis*, 80, 102024. <https://doi.org/10.1016/j.irfa.2022.102024>
- Hasan, M. M., Hossain, A. T., & Hossain, T. (2022). CEO inside debt holdings and trade credit. *Accounting & Finance*, 62(3), 3677–3709. <https://doi.org/10.1111/acfi.12901>

- Hasan, Md. M., Hossain, Md. S., & Tree, D. R. (2024). Executives' horizon and trade credit. *Accounting & Finance*, 64(1), 1135–1157. <https://doi.org/10.1111/acfi.13175>
- Yin, J., Han, B., & Wong, H. Y. (2022). COVID-19 and credit risk: A long memory perspective. *Insurance: Mathematics and Economics*, 104, 15–34. <https://doi.org/10.1016/j.insmatheco.2022.01.008>
- Kanapickiene, R., & Spicas, R. (2019). Credit Risk Assessment Model for Small and Micro-Enterprises: The Case of Lithuania. *Risks*, 7(2), 67. <https://doi.org/10.3390/risks7020067>
- Kanazir, S. D. (2023). Credit risk cyclicalities in Serbian banking sector. *Applied Economics*, 55(22), 2505–2520. <https://doi.org/10.1080/00036846.2022.2103083>
- Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, 34(11), 2767–2787. <https://doi.org/10.1016/j.jbankfin.2010.06.001>
- Kladakis, G., & Skouralis, A. (2024). Credit rating downgrades and systemic risk. *Journal of International Financial Markets, Institutions and Money*, 90, 101902. <https://doi.org/10.1016/j.intfin.2023.101902>
- Li, Y., Wang, H., Gao, H., Li, Q., & Sun, G. (2024). Credit rating, repayment willingness and farmer credit default. *International Review of Financial Analysis*, 93, 103117. <https://doi.org/10.1016/j.irfa.2024.103117>
- Liu, J., Liu, J., Wu, C., & Wang, S. (2024). Enhancing credit risk prediction based on ensemble tree-based feature transformation and logistic regression. *Journal of Forecasting*, 43(2), 429–455. <https://doi.org/10.1002/for.3040>
- Lourie, B., Ozel, N. B., Nekrasov, A., & Zhu, C. (2024). Consensus credit ratings: A view from banks. *Review of Accounting Studies*, 29(3), 2391–2436. <https://doi.org/10.1007/s11142-024-09835-7>
- Mackevičius, J., & Silvanavičiūtė, S. (2006). Įmonių bankroto prognozavimo modelių tinkamumo nustatymas. *Verslas: teorija ir praktika*, 7(3), 193–202. <https://doi.org/10.3846/btp.2006.24>
- Matanga, N., & Holman, G. (2024). Adapting Altman Z-score models for early warning signals: Evidence from delisted mining stocks on the Johannesburg Stock Exchange. *Investment Analysts Journal*, 53(3), 249–261. <https://doi.org/10.1080/10293523.2024.2397892>

- Merton, R. C. (1974). On the Pricing of Corporate Debt: The Risk Structure of Interest Rates. *The Journal of Finance*.
- Naresh, V. S., & Ayyappa, D. (2024). PPDNN-CRP: CKKS-FHE Enabled Privacy-Preserving Deep Neural Network Processing for Credit Risk Prediction. *Computational Economics*. <https://doi.org/10.1007/s10614-024-10731-0>
- Ohlson, J. A. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 18(1), 109. <https://doi.org/10.2307/2490395>
- Pridotkienė, J. (2012). PREKINIO KREDITAVIMO POKYČIAI ES ŠALIŲ TARPTAUTINĖJE PREKYBOJE. *ECONOMICS AND MANAGEMENT*, 17(2), 554–559. <https://doi.org/10.5755/j01.em.17.2.2181>
- Shen, F., Wang, R., & Shen, Y. (2019). A COST-SENSITIVE LOGISTIC REGRESSION CREDIT SCORING MODEL BASED ON MULTI-OBJECTIVE OPTIMIZATION APPROACH. *Technological and Economic Development of Economy*, 26(2), 405–429. <https://doi.org/10.3846/tede.2019.11337>
- The Risks of Financial Institutions. (2007). F. Allen, T. G. Andersen, T. Beck, J. Berkowitz, T. Bollerslev, M. Carey, M. Carey, N. Chan, P. F. Christoffersen, A. Demirgüç-Kunt, F. X. Diebold, & R. M. Stulz (Sud.), *The Risks of Financial Institutions*. University of Chicago Press.
- Thomas, L. C., Edelman, D., & Crook, J. N. (with Society for Industrial and Applied Mathematics). (2002). Credit scoring and its applications. *Credit scoring and its applications*. Society for Industrial and Applied Mathematics. <https://doi.org/10.1137/1.9780898718317>
- Trinh, L. T. (2024). A comparative analysis of consumer credit risk models in Peer-to-Peer Lending. *Journal of Economics, Finance and Administrative Science*, 29(58), 346–365. <https://doi.org/10.1108/JEFAS-04-2021-0026>
- Ubarhande, P., Chandani, A., Pathak, M., Agrawal, R., & Bagade, S. (2024). Modelling Financial Variables Using Neural Networking to Access Creditworthiness. *Financial Internet Quarterly*, 20(2), 62–76. <https://doi.org/10.2478/fiqf-2024-0012>
- Valvonis, V. (2004). PASKOLŲ REGISTRO NAUDOJIMAS KREDITO RIZIKAI VALDYTI. *PASKOLŲ REGISTRO NAUDOJIMAS KREDITO RIZIKAI VALDYTI*.

- Xia, Y., Guo, X., Li, Y., He, L., & Chen, X. (2022). Deep learning meets decision trees: An application of a heterogeneous deep forest approach in credit scoring for online consumer lending. *Journal of Forecasting*, 41(8), 1669–1690. <https://doi.org/10.1002/for.2891>
- Xie, X., Hu, X., Xu, K., Wang, J., Shi, X., & Zhang, F. (2022). Evaluation of associated credit risk in supply chain based on trade credit risk contagion. *Procedia Computer Science*, 199, 946–953. <https://doi.org/10.1016/j.procs.2022.01.119>
- Xu, H., & Dao, M. (2020). Government contracts and trade credit. *Advances in Accounting*, 49, 100473. <https://doi.org/10.1016/j.adiac.2020.100473>
- Zhang, J., Mo, H., Hu, Z., & Zhang, T. (2024). The effect of stability and concentration of upstream and downstream relationships of focal firms on two-level trade credit. *International Journal of Production Economics*, 270, 109173. <https://doi.org/10.1016/j.ijpe.2024.109173>

MAŽŲ IR LABAI MAŽŲ ĮMONIŲ PREKYBOS KREDITO RIZIKOS

VERTINIMO MODELIS

ALMINA KAFITULOVAITĖ

Magistro baigiamasis darbas

Finansai ir bankininkystė

Vilniaus universitetas, Ekonomikos ir verslo administravimo fakultetas

Darbo vadovė – Prof., Dr. (HP) Rasa Kanapickienė

Vilnius, 2026

SANTRAUKA

67 puslapiai, 21 lentelė, 10 paveikslų, 45 literatūros šaltiniai.

Magistro baigiamojo darbo tikslas – sukurti ir empiriškai įvertinti prekybos kredito rizikos vertinimo modelį mažoms ir labai mažoms Lietuvos įmonėms, taikant hibridinį metodinį pagrindą, sudarytą iš logistinės regresijos ir sprendimų medžio (CART) metodų. Tyrimas orientuotas į įmonių nemokumo (bankroto) tikimybės prognozavimą ir praktinio modelio pritaikomumą kredito sprendimų priėmimo procese.

Darbas susideda iš trijų dalių: mokslinės literatūros analizės, tyrimas bei jo rezultatai, išvados ir pasiūlymai.

Literatūros analizėje apžvelgiamos pagrindinės kredito rizikos teorijos ir bankroto prognozavimo metodai, skiriant mažų ir labai mažų įmonių specifikai. Aptariama šios įmonių grupės ekonominė reikšmė Lietuvos mastu, jų veiklos rizikingumas ir su informacijos asimetrija susiję kreditavimo iššūkiai. Analizėje detalai pristatomi finansiniai ir nefinansiniai rodikliai, dažniausiai taikomi vertinant smulkių įmonių mokumo riziką, taip pat aptariamos sprendimų automatizavimo galimybės ir ribos. Kitiškai įvertinami tradiciniai ir modernūs kredito rizikos vertinimo metodai,

pagrindžiant hibridinio modelio – logistinės regresijos ir sprendimų medžio (CART) – pasirinkimą šiame tyrime.

Po literatūros analizės atliekamas empirinis tyrimas, kuriame mažų ir labai mažų įmonių kredito rizika vertinama remiantis „Registrų centro“ finansinėmis ataskaitomis. Modelio kūrimui taikoma hibridinė metodika – logistinė regresija ir sprendimų medis (CART), naudojant R programą. Tyrime atliekama nuosekli duomenų diagnostika: trūkstumų analizė, ekstremalių reikšmių vertinimas, koreliacijų analizė, Mann–Whitney testai su Benjamini–Hochberg korekcija, Chi-kvadrato priklausomumo testai, multikolinearumo (VIF) patikra, ROC/AUC analizė ir modelių kalibravimas (Hosmer–Lemeshow, Brier, ECE). Šie metodai leidžia suformuoti statistiškai pagrįstą ir praktiškai taikomą kredito rizikos vertinimo modelį mažų ir labai mažų įmonių segmentui.

Tyrimo rezultatai parodė, kad sudarytas mažų ir labai mažų įmonių kredito rizikos modelis yra empiriškai pagrįstas ir veiksmingas. Logistinė regresija atskleidė, kad stipriausi bankroto riziką mažinantys veiksniai yra įmonės amžius ir darbuotojų skaičius, o finansiniai rodikliai suteikia papildomos informacijos. CART sprendimų medis identifikavo aiškias ROA, pelningumo ir įsiskolinimo ribas, leidžiančias tiksliai diferencijuoti rizikos profilius. Abu modeliai pasižymėjo tinkama diskriminacine galia ($AUC \approx 0,72\text{--}0,75$), o atlikta kalibracija pagerino prognozių tikslumą.

Apibendrinus galima teigti, kad logistinė regresija ir sprendimų medis sudaro vienas kitą papildančią sistemą, kuri padidina sprendimų objektyvumą ir pagerina rizikingų įmonių identifikavimą. Gauti rezultatai rodo, kad modeliai gali būti praktiškai taikomi prekybos kredito rizikos vertinime, o pateiktos įžvalgos naudingos institucijoms, siekiančioms diegti duomenų analitiką ir automatizuotas vertinimo technologijas.

TRADE CREDIT RISK ASSESSMENT MODEL FOR SMALL AND MICRO ENTERPRISES

ALMINA KAFITULOVAITĖ

Master's Thesis

Finance and Banking

Vilnius University, Faculty of Economics and Business Administration

Supervisor – Prof., Dr. (HP) Rasa Kanapickienė

Vilnius, 2026

SUMMARY

67 pages, 21 tables, 10 figures, 45 references.

The aim of this Master's thesis is to develop and empirically evaluate a trade credit risk assessment model for small and micro enterprises in Lithuania by applying a hybrid methodological framework combining logistic regression and decision tree (CART) methods. The study focuses on forecasting the probability of corporate insolvency (bankruptcy) and assessing the practical applicability of the model in trade credit decision-making processes.

The thesis consists of three main parts: a review of scientific literature, the empirical research and its results, and conclusions and recommendations.

The literature review examines the main theories of credit risk and bankruptcy prediction methods, with particular emphasis on the specific characteristics of small and micro enterprises. The economic importance of this group of firms in the Lithuanian context, their higher risk exposure, and credit-related challenges arising from information asymmetry are discussed. The analysis provides a detailed overview of financial and non-financial indicators commonly used in assessing the insolvency risk of small enterprises, as well as the possibilities and limitations of decision automation. Traditional and modern credit risk assessment methods are critically evaluated,

substantiating the choice of a hybrid model based on logistic regression and a decision tree (CART) in this study.

Following the literature review, an empirical analysis is conducted in which the credit risk of small and micro enterprises is assessed using financial statements obtained from the Lithuanian Centre of Registers. Model development is based on a hybrid methodology combining logistic regression and a decision tree (CART), implemented using the R programming environment. The study includes a comprehensive data diagnostics procedure encompassing missing data analysis, outlier assessment, correlation analysis, Mann–Whitney tests with Benjamini–Hochberg correction, chi-square tests of independence, multicollinearity assessment (VIF), ROC/AUC analysis, and model calibration techniques (Hosmer–Lemeshow, Brier score, ECE). These methods enable the construction of a statistically sound and practically applicable credit risk assessment model for the segment of small and micro enterprises.

The results of the empirical analysis indicate that the developed credit risk model for small and micro enterprises is empirically robust and effective. Logistic regression reveals that firm age and the number of employees are the strongest factors reducing bankruptcy risk, while financial ratios provide additional explanatory power. The CART decision tree identifies clear threshold values for ROA, profitability, and indebtedness, allowing for accurate differentiation of risk profiles. Both models demonstrate adequate discriminatory power ($AUC \approx 0.72\text{--}0.75$), while calibration procedures improve the accuracy of probability forecasts.

In summary, logistic regression and the decision tree form a complementary system that enhances decision objectivity and improves the identification of high-risk enterprises. The findings suggest that the developed models can be practically applied in trade credit risk assessment, while the insights obtained are valuable for institutions seeking to implement data analytics and automated risk evaluation technologies.