

VILNIAUS UNIVERSITETAS
EKONOMIKOS IR VERSLO ADMINISTRAVIMO FAKULTETAS

FINANSAI IR BANKININKYSTĖ

Simona Adomaitytė
MAGISTRO BAIGIAMASIS DARBAS

MAŽŲ IR VIDUTINIŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMAS	ASSESSMENT OF CREDIT RISK FOR SMALL AND MEDIUM-SIZED ENTERPRISES
--	---

Darbo vadovas Prof., Dr. (HP) Rasa Kanapickienė

Vilnius, 2025

Turinys

LENTELIŲ SĄRAŠAS	3
PAVEIKSLŲ SĄRAŠAS	4
ĮVADAS	5
1. MAŽŲ IR VIDUTINIŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO LITERATŪROS ANALIZĖ	8
1.1. Kredito rizikos samprata	8
1.2. Mažų ir vidutinių įmonių kredito rizika	15
1.3. Kredito rizikos vertinimo modelių teorinis vertinimas	20
2. MAŽŲ IR VIDUTINIŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO TYRIMO METODIKA	32
3. MAŽŲ IR VIDUTINIŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO TYRIMAS	44
IŠVADOS IR PASIŪLYMAI	56
LITERATŪROS ŠALTINIAI	58
SUMMARY	64

LENTELIŲ SĄRAŠAS

- 1 lentelė.** Literatūroje nagrinėtų autorių kredito rizikos sampratos
- 2 lentelė.** Nagrinėtų autorių tikrinamų bei naujai sukurtų kredito rizikos modelių suvestinė
- 3 lentelė.** Rodikliai, sudaryti iš Lietuvoje viešai prieinamos informacijos
- 4 lentelė.** Nagrinėjamų kredito rizikos modelių formulės bei kintamieji
- 5 lentelė.** Naujojo modelio kūrime naudojami rodikliai
- 6 lentelė.** Modelyje naudojamų sektorių pavadinimai
- 7 lentelė.** Sudaryto naujo logistinės regresijos modelio kintamieji bei formulė
- 8 lentelė.** Naujo modelio kintamųjų koreliacija
- 9 lentelė.** Naujo modelio kintamųjų VIF
- 10 lentelė.** Naujo modelio reikšmės
- 11 lentelė.** Naujo ir kitų naudojamų analizuoti MVĮ kredito riziką modelių tikslumo palyginimas

PAVEIKSLŲ SĄRAŠAS

- 1 paveikslas.** Literatūroje nagrinėtų autorių kredito rizikos sampratų požiūriai
- 2 paveikslas.** Literatūroje nagrinėtų autorių kredito rizikos poveikių kryptys
- 3 paveikslas.** Mažų ir vidutinių įmonių apibrėžimo kriterijai
- 4 paveikslas.** Įmonės dydžio poveikio kredito rizikai diskusija
- 5 paveikslas.** MVĮ didesnės kredito rizikos veiksniai
- 6 paveikslas.** Kredito rizikos vertinimo modelių klasifikacija
- 7 paveikslas.** Kredito rizikos vertinimo modeliai, sukurti arba autorių laikomi tiksliausi naudoti Lietuvoje veikiančioms įmonėms
- 8 paveikslas.** Naujo modelio plotas po ROC kreive (AUC)

IVADAS

Temos aktualumas: Šiuolaikinėje verslo aplinkoje, kuri sparčiai kinta ir tampa vis sudėtingesnė, įmonės, ypač mažos ir vidutinės įmonės (toliau – MVĮ), turi išlikti lanksčios ir konkurencingos. MVĮ yra būtinos šalies ekonomikos augimui ir plėtrai, kadangi atlieka esminį vaidmenį užtikrinant ekonomikos augimą bei darbo vietų kūrimą. Tačiau Europos Sąjungoje pastebima bankrotų skaičiaus didėjimo tendencija dar nuo 2020 m. (Eurostat, 2024), o tai daro tiesioginę įtaką ir Lietuvai, kaip atvirai ekonomikai, kurios šalys partnerės taip pat patiria padidėjusį bankrotų skaičių. Lietuvoje ši problema taip pat išlieka aktuali – 2024 m. pirmąjį pusmetį bankroto procesų pradėta 15,1 % daugiau nei per tą patį laikotarpį 2023 m., kaip skelbia Audito, apskaitos, turto vertinimo ir nemokumo valdymo tarnyba (AVNT). Kadangi net 99,8 % Europos įmonių sudaro būtent MVĮ (European Investment Bank Group, 2022), bankrotai paliečia ir šį sektorių, nes MVĮ, skirtingai nei didelėms įmonėms, tenka dažnai susidurti su didesne finansų išteklių stoka bei ribotomis galimybėmis gauti kreditą, o tai gali apriboti MVĮ augimą bei padidina jų bankroto tikimybę. MVĮ taip pat laikomos rizikingesnėmis nei didelės įmonės, kadangi jos neturi arba turi mažai užstato, kredito istorija yra nenusistovėjusi, o finansinės ataskaitos kreditoriams suteikia mažiau informacijos, skirtos įvertinti kredito riziką. Dėl šių priežasčių kreditoriai, prieš suteikdami kreditą MVĮ, turi ypatingą atsakomybę ir interesą įvertinti MVĮ kredito riziką – jie privalo atidžiai išanalizuoti šių įmonių finansinę būklę bei atsižvelgti į kitus įmonių kintamuosius, naudojant būtent MVĮ tinkantį kredito rizikos modelį, kadangi tik naudojant tinkamą kredito rizikos įvertinimo modelį galima tinkamai nustatyti kredito riziką ir užtikrinti, jog skolintojai gebės įvykdyti savo įsipareigojimus, kartu neblogindami savo finansinės situacijos. Tačiau kredito rizikos įvertinimas yra ne mažiau svarbus ir kitoms įmonėms, kurios dirba ar ketina dirbti su tam tikra MVĮ – tiekėjams, partneriams ar užsakovams. Šios įmonės turi būti tikros, kad jų verslo partneriai yra finansiškai stabilūs, jog vykdomi projektai bus įgyvendinti laiku, o verslo sandoriai netaps nuostolingi dėl galimo MVĮ nemokumo. Šiame kontekste ypač svarbu, kad naudojami kredito rizikos modeliai būtų pagrįsti tik viešai prieinamais duomenimis, kadangi dauguma MVĮ neprivalo viešai skelbti finansinių ataskaitų. Tai leidžia užtikrinti modelių pritaikomumą esant ribotai prieigai prie įmonių privačių duomenų. Be to, tokie modeliai prisideda prie didesnio verslo skaidrumo, suteikdami galimybę kreditoriams ir kitoms suinteresuotoms šalims objektyviai įvertinti įmonių finansinį stabilumą taip mažinant finansinių nuostolių riziką ir prisidedant prie stabilios ekonominės aplinkos kūrimo. Taigi, MVĮ kredito rizikos įvertinimas yra itin svarbus ne tik dėl pačių įmonių gyvybingumo, bet ir siekiant išlaikyti gerą finansų sektoriaus būklę bei

skatinti ekonominį augimą. Investavimas į šių įmonių stabilumą ir augimą ne tik padeda užtikrinti jų pačių sėkmę, bet ir prisideda prie ekonominės gerovės visuomenėje.

Lietuvoje kredito rizikos (Kiyak ir Labanauskaitė, 2012; Špicas ir Nekrošiūtė, 2012; Špicas, Kanapickienė, Vijūnas ir Kirka, 2018) bei bankroto (Grigaravičius, 2003; Mackevičius ir Rakštelienė, 2005; Mackevičius ir Silvanavičiūtė, 2006; Krušinskas, Lakštutienė ir Stankevičiūtė, 2014; Marcinkevičius ir Kanapickienė, 2014; Grikietytė ir Mačiulytė-Šniukienė, 2023) įvertinimui yra atlikta nemažai tyrimų. Tačiau tik vienas iš šių tyrimų, atliktas Kiyak ir Labanauskaitės (2012), buvo skirtas įvertinti būtent Lietuvoje veikiančių MVĮ kredito riziką 2006 – 2010 m. laikotarpiu. Nagrinėjant naujausius užsienio autorių sukurtus modelius, skirtus MVĮ kredito rizikai nagrinėti (Cheraghali, 2018 bei Lisboa ir kt., 2021) pastebima, jog įvertinant šio sektoriaus įmones ir jų galimą nemokumą naudojama ne tik finansinė informacija, kaip kad modeliuose, kuriuos naudojo Lietuvoje veikiančių įmonių kredito riziką ar bankroto tikimybę tiriantys mokslininkai, bet ir nefinansinė informacija, tokia kaip įmonių gyvavimo trukmė, veikimo sektorius bei darbuotojų skaičius, kuri, autorių teigimu, taip pat prisideda prie MVĮ kredito rizikos vertinimo tikslumo. Nefinansinė informacija dažnai yra viešai prieinama, todėl jos naudojimas modelyje tik didina jo universalumą ir tikslumą įvertinti kredito riziką.

Tačiau pastebėta, jog nėra sukurto kredito rizikos modelio, skirto Lietuvoje veikiančioms MVĮ analizuoti, tuo labiau – kuris apimtų tik viešai prieinamą informaciją, todėl ši sritis nėra pilnai ištirta. Tai kelia poreikį kurti modelius, pagrįstus tiek finansine, tiek nefinansine informacija, kurie remtųsi tik viešai prieinamais duomenimis, jog būtų užtikrintas jų pritaikomumas praktikoje. Tad šiame darbe sudaromas logistinės regresijos modelis, skirtas Lietuvoje veikiančių MVĮ kredito rizikai įvertinti ne tik iš finansinės, bet ir nefinansinės viešai prieinamos informacijos.

Darbo objektas: Lietuvoje veikiančių MVĮ kredito rizikos įvertinimas, naudojant tik viešai prieinamą finansinę ir nefinansinę informaciją.

Darbo problema: Kaip sukurti kredito rizikos vertinimo modelį, pagrįstą tik viešai prieinamais duomenimis, kuris būtų tinkamas Lietuvoje veikiančių MVĮ kredito rizikos įvertinimui, kuomet egzistuojančių modelių taikymas yra ribotas dėl modelyje naudojamų duomenų prieinamumo?

Darbo tikslas: Sukurti ir įvertinti logistinės regresijos modelį, skirtą Lietuvoje veikiančių MVĮ kredito rizikai analizuoti, naudojant tik viešai prieinamą finansinę ir nefinansinę informaciją.

Darbo uždaviniai:

1. Išnagrinėjus skirtingų autorių atliktus tyrimus, nustatyti kredito rizikos vertinimo svarbą, MVĮ kredito rizikos ypatybes bei naudojamus kredito rizikos nustatymo modelius.

2. Parengti logistinės regresijos metodiką, skirtą Lietuvoje veikiančių MVĮ kredito rizikai vertinti, bei patikrinti literatūroje minimų modelių, tinkamų MVĮ kredito rizikai vertinti, pritaikomumą Lietuvoje, atsižvelgiant į tai, ar šiuose modeliuose naudojama informacija yra viešai prieinama.
3. Sukurti naują logistinės regresijos modelį, skirtą Lietuvoje veikiančių MVĮ kredito rizikai vertinti, remiantis tik viešai prieinama finansine ir nefinansine informacija, bei įvertinti jo tikslumą bei tinkamumą praktiniam taikymui.

Darbo metodai: Lyginamoji mokslinės literatūros analizė, duomenų apdorojimas tyrimui, kintamųjų eliminavimas, logistinė regresija, koreliacinė analizė, modelio tikslumo vertinimas (įskaitant Hosmer – Lemeshow testą ir AUC), lyginamasis modelių vertinimas.

Darbo struktūra: Literatūros analizės dalyje išanalizuoti ir lyginami skirtingų autorių atliktų tyrimų išvados analizuojant kredito rizikos sampratą bei MVĮ kredito rizikos ypatybes lyginant su didelėmis įmonėmis. Taip pat analizuoti Lietuvos mokslininkų atliktų kredito rizikos tyrimų rezultatai bei užsienio autorių tyrimai, siekiant įvertinti būtent MVĮ kredito riziką. Literatūros analizėje taip pat nagrinėta, kokią įtaką kredito rizikos modelio tikslumui daro papildomai modelyje naudojama nefinansinė informacija, tokia kaip įmonės veikimo sektorius, gyvavimo metai bei darbuotojų skaičius. Be to, aptartas viešųjų duomenų naudojimo modelyje tikslingumas vertinant MVĮ kredito riziką.

Metodikoje pirmiausia pristatoma naujo sukurto modelio metodika, pagrįsta logistinės regresijos analize ir viešai prieinamais finansiniais bei nefinansiniais rodikliais, skirtais MVĮ kredito rizikai vertinti. Toliau aptariami literatūroje minimi kredito rizikos modeliai, naudojami MVĮ analizei, jų lygtys ir naudojami kintamieji, bei vertinama, ar šie modeliai gali būti pritaikomi Lietuvoje veikiančioms MVĮ remiantis tik viešai prieinama informacija. Įvertinus šiuose modeliuose naudojamą informaciją, nustatyta, jog nei vienas nagrinėjamas modelis negali būti taikomas dėl naudojamos informacijos, kuri nėra viešai prieinama Lietuvoje.

Tyrime sukurtas naujas kredito rizikos modelis, skirtas Lietuvoje veikiančioms MVĮ, remiantis tik viešai prieinamais duomenimis, bei įvertintas jo tikslumas. Naujasis modelis pasižymi paprastesniu naudojimu vartotojams, turintiems ribotą prieigą prie išsamių įmonių duomenų, todėl demonstruoja tinkamumą praktiniam taikymui norint įvertinti MVĮ kredito riziką. Modelis taip pat pasižymi aukštesniu tikslumu lyginant su literatūroje aprašytais modeliais, taikytais kitų šalių MVĮ analizei. Dar vienas naujo modelio pranašumas – jo sudarymas tik iš viešai prieinamų duomenų, kas užtikrina modelio universalumą ir paprastą taikymą.

1. MAŽŲ IR VIDUTINIŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO LITERATŪROS ANALIZĖ

Tam, jog būtų įmanoma nustatyti tinkamiausią kredito rizikos vertinimo modelį, skirtą atsižvelgiant į MVĮ išskirtinumus, būtina suprasti kredito rizikos apibrėžimą bei svarbą ją vertinti, kadangi tinkamai įvertinta kredito rizika leidžia ne tik sumažinti galimus finansinius nuostolius, bet ir leidžia išvengti bankroto tikimybės. Kreditoriams netinkamai įvertinta rizika gali reikšti skolų neišieškojimą, prarastas investicijas, išlaidas skolų administravimui ir išieškojimo procesams, o tai mažina kreditoriaus pelningumą. Tiekėjai, dirbantys su rizikingomis įmonėmis, gali patirti nuostolių dėl nesumokėtų sąskaitų, prarasto laiko ar nepavykusių projektų. Pačios įmonės atžvilgiu, nepakankamas kredito rizikos įvertinimas gali lemti nepalankias kredito sąlygas arba sumažėjusias finansavimo galimybes, o tai ilgainiui apsunkina įmonės veiklos tęstinumą ir augimą. Be to, jei įmonė tinkamai neįvertina savo kredito rizikos ir bankroto tikimybę lieka nevaldyta, ji gali nesugebėti laiku reaguoti į finansinius sunkumus. Todėl kredito rizikos vertinimas tampa gyvybiškai svarbus tiek siekiant finansinio stabilumo, tiek užtikrinant ilgalaikį verslo tęstinumą. Taip pat labai svarbu nustatyti MVĮ kredito rizikos vertinimo skirtumus lyginant jas su didelėmis įmonėmis, nes nors ir MVĮ yra ypatingai svarbios šalies ekonomikos augimui ir nuo jų augimo ir rezultatų priklauso ekonominė sėkmė ir finansinis stabilumas (Wang, Han, Huang ir Mi, 2021), skirtumai su didelėmis įmonėmis didina MVĮ kredito riziką, todėl kreditoriai, siekdami išvengti neapibrėžtumo skolinant, prieš nusprenddami skolinti MVĮ, turi naudoti tinkamą kredito rizikos vertinimo modelį, skirtą būtent šiam sektoriui dėl didesnio tikslumo tikimybės, o tiekėjai ar pati įmonė turi turėti įrankį, kurio pagalba galėtų įsivertinti riziką. Dėl šios priežasties yra kuriami nauji, tikrinami ir pritaikomi jau sukurti kredito rizikos modeliai, kadangi stengiamasi nustatyti, kurie modeliai tinkamiausi vertinti skirtingose šalyse ir sektoriuose veikiančių įmonių bei nuo įmonių dydžio priklausančią kredito riziką.

1.1. Kredito rizikos samprata

Kreditas – (lot. credit – jis tiki) – kreditoriaus pasitikėjimas, kurį kreditorius išreiškia skolininkui tiesiogiai (skolinant pinigus) arba netiesiogiai (skolon parduodant prekes ir paslaugas) (Lietuvių Žodynas, 2024). Pagal LR Civilinį kodeksą, kredito gavėjas įsipareigoja grąžinti

kreditoriui gautą sumą ir už tai sumokėti nustatytas palūkanas. Kredito samprata ir taikymas turi senas šaknis, siekiančias senovės civilizacijas. Kreditas atsirado ir pradėjo plisti visuomenėse, kuriose ėmė irti gentimis bei giminėmis pagrįsti santykiai. Pirmieji kredito susitarimai buvo natūriniai – skolininkai skolinosi prekes, derlių ar gyvulius mainais už ateityje pažadėtus grąžinimus. Tačiau laikui bėgant, ekonomikos vystymosi ir piniginių sistemų atsiradimo dėka, kreditas, kurio formavimosi pėdsakų galima rasti jau senovės Babilone, Graikijoje, Egipte bei Romoje, įgavo piniginę formą. Nepaisant ankstyvo kredito egzistavimo, ilgą laiką į jį buvo žiūrima neigiamai. Tik po technologinio perversmo IXX a. antrojoje pusėje į kreditą pradėta žiūrėti iš teigiamos perspektyvos – jis netgi buvo pradėtas laikyti ekonomikos sudedamąja dalimi (Visuotinė lietuvių enciklopedija, 2023). Kreditas tapo ne tik priemone finansuoti individualias investicijas, bet ir įrankiu, leidžiančiu verslams plėstis, o vyriausybėms – finansuoti projektus. Šiuolaikinėje ekonomikoje kreditas atlieka dvejopą paskirtį – jis yra ne tik reikalingas stabilizuojant rinką, bet taip pat naudojamas kapitalo panaudojimo lygio didinimui. Pagrindinė sąlyga, jog kreditas atliktų teigiamą vaidmenį ekonomikoje bei ji galėtų nuolat vystytis, yra geras, patikimas kreditas, tačiau kredituojant neišvengiamai kyla grėsmė kreditoriams nesusigražinti skolininkams suteikto kredito (Zhou, Chen ir Meng, 2019). Taigi, ši kylanti grėsmė yra įvardijama kaip kredito rizika. Jos samprata tarp skirtingų laikotarpių bei tarp skirtingų autorių turi panašumų, bet tuo pačiu tarp apibrėžimų egzistuoja ir požiūrių skirtumai.

1 lentelė

Literatūroje nagrinėtų autorių kredito rizikos sampratos

Autoriai	Metai	Samprata
Fiedler ir Pech	1971	Kredito rizika – tikimybė, kad kreditas nebus grąžintas pagal sutarties sąlygas.
Špicas ir Nekrošiūtė	2012	Kredito rizika išreiškia netekimų galimybę sandorio šaliai, neįvykdžius savo įsipareigojimų.
Zhou ir kt.	2019	Kredito rizika – rizika, kad sandorio šalis neįvykdys mokėtinos skolos, kuri yra ne tik kredito, bet ir garantijų bei vertybinių popierių investicijų versle.
Corazza, De March ir Di Tollo	2021	Kredito rizika – tikimybė, kad skolininkas neįvykdys savo skolinimo įsipareigojimų.

Phan Thi Hang	2023	Kredito rizika – tai galimas grynujų pajamų ir kapitalo rinkos vertės pokytis, atsirandantis dėl to, kad klientas neatsiskaito arba vėluoja sumokėti.
Afjal, Salamzadeh ir Dana	2023	Kredito rizika yra galimas nuostolis dėl skolininko nemokėjimo už kreditą ar kitas kredito linijas.
Galvis-Ciro, de Moraes ir García-Lopera	2023	Kredito rizika – rizika, kad kreditas nebus sumokėtas (iš dalies arba visiškai) skolininkui.
Lietuvos bankas	2024	Kredito rizika – rizika patirti nuostolių dėl to, kad sandorio šalis arba vertybinius popierius išleidusi valstybė, finansų įstaiga ar bendrovė nevykdys savo įsipareigojimų.

Sudaryta autorės, remiantis literatūros apžvalgoje nagrinėtais autoriais


Taigi, analizuojant kredito rizikos sąvokos kitimą, pastebima įvairesnių interpretacijų skirtumų tarp skirtingų autorių požiūrių, taip pat atkreipiamas dėmesys į metus, kuomet buvo pasiūlytas konkretus kredito rizikos apibrėžimas. Fiedler ir Pech (1971) kredito riziką įvardijo kaip tikimybę, jog kreditas nebus gražintas pagal sutarties sąlygas. Špicas ir Nekrošiūtė (2012) pritaria ir kredito riziką įvardija kaip kreditoriaus netekimų galimybę skolininkui neįvykdžius įsipareigojimų. Corazza ir kt. (2021) taip pat neplėtoja senų autorių įvardinto apibrėžimo įvardinant kredito riziką kaip tikimybę, jog skolininkas neįvykdys savo įsipareigojimų. Taigi, šie autoriai kredito riziką įvardija kaip tikimybę ar galimybę, jog įsipareigojimai nebus įvykdyti arba kreditas nebus gražintas pagal nustatytas sutarties sąlygas.

Tuo tarpu kiti autoriai pateikia platesnį požiūrį į kredito rizikos apibrėžimą – ši tendencija praplėsti kredito rizikos apibrėžimą pastebima tarp beveik visų naujausių, išskyrus Corazza ir kt. (2021), analizuojamų autorių. Mokslininkai į kredito riziką pasiūlo požiūrį iš skirtingų kampų – išplėtojant ar papildant jų nuomone reikšmingą kredito rizikos apibrėžimo dalį. Lietuvos bankas (2024) tradiciniame kredito rizikos apibrėžime praplečia skolininko sąvoką nurodant, kad valstybė, finansų įstaiga ar bendrovė išleidus vertybinių popierių taip pat gali sukelti kredito riziką nevykdant savo įsipareigojimų. Šiam apibrėžimui pritaria Zhou ir kt. (2019) ir papildo, jog kredito riziką sukelia ir garantijų neapmokėjimo faktas. Afjal ir kt. (2023) samprata išsiskiria iš kitų, teigiant, kredito rizika yra galimas nuostolis dėl skolininko nemokėjimo už kreditą ar kitas kredito linijas. O Galvis-Ciro ir kt. (2023) teigia, jog rizika egzistuoja ne tik skolininkui pilnai

negražinus kredito, bet ir iš dalies. Tačiau vienas naujausių autorių – Phan Thi Hang (2023) – pateikia unikalų požiūrį į kredito rizikos sampratą, susiedamas ją su grynujų pajamų ir kapitalo rinkos vertės pokyčiais dėl kliento neatsiskaitymo arba vėlavimo apmokėti. Taip pat nagrinėjame straipsnyje yra minima, jog kredito rizika egzistuoja ne tik tuomet, kai skolininkas visiškai neapmoka pasiimto kredito, bet ir vėluoja ją apmokėti. Toks išreikštas požiūris praplečia kredito rizikos apibrėžimo įvairovę tarp skirtingų autorių pateiktų sampratų ir reikšmingai skiriasi nuo senųjų analizuojamų autorių pateiktos sampratos. Išanalizavus skirtingą autorių požiūrį į kredito riziką pastebima, jog kredito rizika tampa vis sudėtingesne sąvoka, kuri apima ne tik tradicinius skolinimo aspektus, bet ir platesnes finansų bei rinkos vertės pokyčius. Tai paaiškina autorių gebėjimą prisitaikyti prie besikeičiančių sąlygų bei tiksliau ir plačiau atspindėti kredito rizikos sąvoką šiuolaikinėje ekonominėje aplinkoje.

1 paveikslas

Literatūroje nagrinėtų autorių kredito rizikos sampratų požiūriai



Sudaryta autorės, remiantis literatūros apžvalgoje nagrinėtais autoriais

Nagrinėjant kredito riziką yra svarbu ne tik suprasti jos apibrėžimą, bet taip pat ir kokią vaidmenį šį riziką atlieka. Analizuojant poveikį kredito rizikai yra išskiriami du požiūriai – mikro ir makro lygmenimis – tačiau visi autoriai vieningai pritaria, jog poveikis kredito rizikai gali būti ir teigiamas, ir neigiamas atitinkamai ją didinant arba mažinant. Analizuojant poveikį kredito rizikai mikro lygmeniu teigiama, jog įmonės finansiniai rodikliai daro įtaką įmonės kredito rizikai – Mitra, Dongre, Dangare, Goswami ir Tiwari (2023) nurodo, jog likvidumo koeficientas (angl. Current Ratio) yra pagrindinis įmonės likvidumo arba jos gebėjimo laiku įvykdyti turimus trumpalaikius įsipareigojimus rodiklis. Padidėjęs jis laikomas teigiamu ženklu, teigiančiu, jog įmonė turi pakankamai trumpalaikio turto turimiems įsipareigojimams padengti, o tai mažina įmonės kredito riziką. Tačiau mažas likvidumo koeficientas laikomas neigiamu ženklu, teigiančiu, jog įmonė patirtų sunkumų apmokant trumpalaikius įsipareigojimus bei yra tikimybė, jog iškilis įsipareigojimų nevykdymo rizika. Taigi, įmonės, turinčios aukštą likvidumo koeficientą ir neturinčios finansinių sunkumų, kredito rizika vertinama kaip žemesnė nei įmonių, kurių likvidumo koeficientas yra žemas ir kurios praeityje turėjo finansinių problemų. Tai pagrindžia finansinių rodiklių poveikį kredito rizikai mikro lygmeniu.

Kredito rizika yra veikiama ne tik mikro lygmeniu, bet ir makro – analizuojant ekonomikos rodiklių poveikį kredito rizikai Kolumbijoje naudojant 28 didelių bankų imtį 2009 – 2019 m. laikotarpiu bei naudojant panelinius duomenis (angl. – Dynamic Data Panel) buvo nustatyta, jog pagrindinis veiksnys, veikiantis kredito riziką šalyje, yra makroekonominė aplinka. Teigiama, jog kredito rizika, vertinama pagal neveiksnius kreditus ir atidėjimus, šalyje išauga pablogėjus makroekonominėi aplinkai – lėtėjant BVP augimui, didėjant nedarbo lygiui bei palūkanų normoms. Ir atvirkščiai – gerėjant ekonominėms sąlygoms, nustatyta, kad kredito rizika mažėja. Atliktas tyrimas taip pat atskleidžia skirtingų kredito tipų reakcijas į makroekonominius pokyčius. Verslo kreditai labiausiai susiję su nedarbo lygiu – kai nedarbas didėja, įmonės gali susidurti su sunkumais grąžinant verslo kreditus. Tuo tarpu vartojimo kreditai yra jautriausi palūkanų normų pokyčiams – palūkanų normų augimas didina gyventojų išlaidas už pasiskolintas lėšas ir mažina galimybes vykdyti finansinius įsipareigojimus. Tyrime pažymima, jog svarbiausi rodikliai kredito rizikos mažinimui yra nedarbo lygio mažinimas ir BVP augimo skatinimas, kurie kartu leidžia užtikrinti palankesnę makroekonominę aplinką kredito grąžinimui ir finansiniam stabilumui. Šie veiksniai parodo, kaip makroekonominė politika gali tiesiogiai prisidėti prie finansų sektoriaus rizikų valdymo ir stabilumo (Galvis-Ciro ir kt., 2023).


Egzistuoja ne tik poveikis kredito rizikai – analizuojamas ir atvirkštinis ryšys. Yra išskiriami taip pat du požiūriai į kredito rizikos poveikį – mikro ir makro lygmenimis – tačiau visi autoriai vieningai pritaria, jog kredito rizikos poveikis vienu ar kitu kampu išlieka neigiamas.

Analizuojant mikro lygmeniu teigiama, jog maža kredito rizika sukelia finansinius nuostolius kreditoriui – atsiradus kredito rizikai, atsiras ir blogi kreditai, kuomet skolininkai neatsiskaito su kreditoriumi, dėl to padidės administracinės bei skolų išieškojimo išlaidos ir svarbiausia – mažės banko kapitalo apyvarta, kadangi nors skolininkai ir negrąžina kredito pagal sutartį, kitų klientų taupomieji indėliai vis tiek turi būti sugrąžinti laiku, o tai susilpnins kreditoriaus mokumą. Ilgainiui tokia situacija gali sukelti banko veiklos nuostolingumą, o kraštutiniais atvejais – privesti netgi prie bankroto, destabilizuojant finansų sistemą (Phan Thi Hang, 2023). Kredito rizika daro poveikį ne tik kreditoriams, bet ir skolininkams. Vertinant iš skolininko perspektyvos, geresnis kredito reitingas suteikia įmonei daugiau galimybių – įmonės su aukštu reitingu gali lengviau gauti kreditus, o jų sąlygos dažniausiai būna palankesnės, įskaitant mažesnes palūkanų normas (Bruns ir Fletcher, 2008). Priešingai, žemas kredito reitingas riboja įmonės prieigą prie finansavimo šaltinių, didina kredito kainą ir apsunkina skolinimosi procesą, o tai gali trukdyti įmonės veiklos plėtrai arba net sukelti likvidumo problemas.

Vertinant kredito rizikos poveikį makro lygmeniu, kredito rizika laikoma viena iš sudėtingiausių problemų, su kuria susiduria finansų rinkos ir ekonomikos. Galvis-Ciro ir kt. (2023) bei Zhou ir kt. (2019) nurodo, kad didelė kredito rizika gali destabilizuoti visą finansų sistemą. Tai gali sukelti kreditų krizę, kuomet įmonės ir fiziniai asmenys susiduria su finansavimo problemomis, kurios lemia plataus masto ekonomines pasekmes. Kreditų krizės gali sutrikdyti rinkos veikimą, sumažinti ekonomikos efektyvumą ir sulėtinti bendrą ekonominę plėtrą. Be to, kredito rizikos įtaka makro lygiu dažnai pasireiškia socialine prasme – ekonomikos nuosmukio metu didėja nedarbas, mažėja gyventojų pajamos, o tai sukelia socialines įtampą. Kita vertus, pernelyg žema kredito rizika taip pat gali turėti netikėtų padarinių rinkos efektyvumui. Kai rinkos dalyviai jaučia mažą riziką, tai gali paskatinti pernelyg laisvą skolinimą ir mažiau atsargų kredito suteikimą, dėl ko atsiranda išpūsti kredito burbulai arba iškraipoma kreditų rinka (Zhou ir kt., 2019). Taigi, kredito rizikos valdymas turi būti subalansuotas – per didelė kredito rizika kelia sistemines grėsmes, o per maža – gali sukelti neefektyvumą ir iškraipyti rinkos veikimą.

2 paveikslas

Literatūroje nagrinėtų autorių kredito rizikos poveikių kryptys



Sudaryta autorės, remiantis literatūros apžvalgoje nagrinėtais autoriais

Taigi, apžvelgus kredito rizikos sampratą ir jos kitimą remiantis įvairių autorių požiūriais nustatyta, jog anksčiau analizę atlikę autoriai dažnai apibrėžia kredito riziką trumpai ir aiškiai neišsiplečiant bei ją įvardijant tikimybe, jog kreditas nebus grąžintas pagal nustatytas sutarties sąlygas. Tačiau naujausi tyrimai išplečia šią sampratą atsižvelgdami į platesnes finansų ir rinkos vertės pokyčių perspektyvas. Taip pat pastebima autorių nuomonių diskusija analizuojant kredito rizikos poveikį ir poveikį pačiai kredito rizikai mikro ir makro lygmenimis. Atskiriami teigiami ir neigiami poveikiai, kurie gali didinti ar mažinti kredito riziką. Mikro lygmeniu kredito rizikos analizėje akcentuojama individualių įmonių finansinių rodiklių svarba, kadangi jie tiesiogiai lemia įmonės gebėjimą laiku vykdyti finansinius įsipareigojimus, tarkime aukštas likvidumo koeficientas rodo stiprų įmonės finansinį stabilumą, mažinantį kredito riziką, o žemas šio rodiklio lygis signalizuoja apie galimus sunkumus vykdant įsipareigojimus. Taip pat nurodoma, kad makroekonominės aplinkos pablogėjimas, pavyzdžiui tokių veiksnių kaip lėtesnis BVP augimas ar nedarbo lygis didėjimas, padidina riziką, jog skolininkai nesugebės įvykdyti savo

įsipareigojimų, o tai galiausiai gali paveikti visą finansų rinkos stabilumą. Galiausiai aptariamai kredito rizikos poveikiai ne tik iš kreditoriaus, bet ir iš skolininko perspektyvos. Kreditoriaus požiūriu, didelė kredito rizika tiesiogiai didina veiklos išlaidas dėl skolų administravimo ir išieškojimo procesų, mažina kapitalo apyvartumą bei stabilumą, o kraštutiniais atvejais gali net privesti prie nuostolingumo ar bankroto. Tačiau pernelyg žema kredito rizika taip pat gali sukelti iššūkių, nes skatinamas laisvas skolinimas gali lemti išpūstus kredito burbulus ar rinkos iškraipymus. Iš skolininko perspektyvos, geras kredito reitingas yra labai svarbus, nes suteikia galimybę ne tik lengviau gauti finansavimą, bet ir užtikrina palankesnes skolinimosi sąlygas, tokias kaip mažesnės palūkanų normos ir lankstesnės atsiskaitymo sąlygos. Tuo tarpu žemas kredito reitingas apriboja galimybes skolintis ir padidina kredito kainą, kas gali neigiamai paveikti įmonės veiklos stabilumą ar plėtros galimybes. Dėl šių priežasčių itin svarbu tiksliai įvertinti kredito riziką tiek kreditoriams, tiek skolininkams, siekiant išvengti neigiamų padarinių skolinant bei skolinantis. Tinkamas kredito rizikos vertinimas yra ne tik finansinio stabilumo, bet ir efektyvios ekonominės veiklos pagrindas, leidžiantis užtikrinti subalansuotą rizikos valdymą ir ilgalaikį finansų rinkų stabilumą.


1.2. Mažų ir vidutinių įmonių kredito rizika

Apžvelgus bendrąją kredito rizikos sampratą, taip pat labai svarbu atkreipti dėmesį į tai, kurios įmonės identifikuojamos kaip MVĮ ir kuo jos skiriasi nuo didelių įmonių kredito rizikos ir finansavimo galimybių aspektais, kadangi norint gauti kreditą MVĮ susiduria su specifiniais iššūkiais, kuriuos lemia jų dydis, ir dėl jo atsiradusios unikalios kredito rizikos dinamikos ypatybės. Taigi, MVĮ apibrėžimas skiriasi tarp šalių dėl skirtingų teisės aktų ir reguliavimo ypatumų. Paprastai apibrėžimai grindžiami tokiais kriterijais kaip įmonėje dirbančių darbuotojų skaičius, bendra balanso suma, įmonės vidutinės pajamos, priklausymas tam tikrai pramonės šakai, šių kriterijų deriniai ir pan. Europos Komisija, kuri reguliuoja MVĮ veiklos rėmus Europos Sąjungos šalyse, MVĮ apibrėžia kaip įmones, kuriose dirba iki 250 darbuotojų, kurių apyvarta mažesnė nei 50 mln. EUR arba bendra balanso suma nesiekia 43 mln. EUR (Wang ir kt., 2021). Tačiau šis apibrėžimas skiriasi nuo to, kuris taikomas kitose šalyse. Palyginimui, JAV MVĮ apibrėžimas pirmiausia grindžiamas įmonės priklausymu tam tikrai pramonės šakai, o tik vėliau atsižvelgiama į kitus kriterijus, tokius kaip darbuotojų skaičius ar pajamos. U.S. Small Business Administration (2023) teigia, kad dauguma gamybos įmonių, kuriose dirba 500 ar mažiau darbuotojų, bei dauguma negamybinių įmonių, kurių vidutinės metinės pajamos mažesnės nei 7,5 mln. USD, laikomos MVĮ. Šis požiūris atspindi didesnę dėmesį sektorių specifikai, kuris gali turėti

reikšmingos įtakos MVĮ kredito rizikos vertinimui, nes pramonės šakos ypatumai dažnai lemia įmonių finansinių srautų ir veiklos stabilumo skirtumus. Apibendrinant, MVĮ apibrėžimo skirtumai tarp šalių atspindi ne tik ekonominius ir teisės aktų skirtumus, bet ir skirtingą požiūrį į šių įmonių reikšmę bei vaidmenį ekonomikoje.

3 paveikslas

Mažų ir vidutinių įmonių apibrėžimo kriterijai




Sudaryta autorės, remiantis Wang ir kt. (2021) ir U.S. Small Business Administration, (2023), European Circular Economy Stakeholder Platform (2023) ir GOV.UK (2023)

Teigiama, jog dėl savo dydžio MVĮ gali labai prisidėti prie gamybos bei būti efektyvioms, kadangi jos geba specializuotis nišinėse rinkose ir greitai reaguoti į besikeičiančius klientų poreikius, o tai šiuolaikinėje verslo aplinkoje ypatingai svarbu (Mitra ir kt., 2023). Tačiau nagrinėjant literatūrą nustatyti du skirtingi požiūriai dėl įmonės dydžio įtakos kredito rizikai siekiant išorinio finansavimo. Bruns ir Fletcher (2008) teigia, jog problemos, su kuriomis susiduria MVĮ norint gauti išorinį finansavimą, priklauso nuo įmonės kapitalo struktūros, bet ne nuo pačios įmonės dydžio. Tačiau naujausių tyrimų išvados sutampa, jog kredito rizikos požiūriu MVĮ ir didelės įmonės ypatingai skiriasi. Vienas iš tyrimų, atliktas remiantis žinių grafiku pagrįstu kredito rizikos vertinimo modeliu RGCN – RF (angl. Relational Graph Convolutional Network – Random

Forest), atkleidžia skirtumus tarp MVĮ ir didelių įmonių vertinant kredito riziką. Tyrimas parodo, jog MVĮ turi mažiau užstato, mažiau nusistovėjusią kredito istoriją bei yra labiau pažeidžiamos dėl ekonominių ir rinkos sąlygų nei didelės įmonės, todėl MVĮ laikomos rizikingesnėmis įmonėmis nei didelės, bei dėl to MVĮ dažniau patiria sunkumų siekiant išorinio finansavimo, be kurio yra apribojamas mažų ir vidutinių įmonių augimas (Mitra ir kt., 2023). Wang ir kt. (2021) taip pat išskiria mažesnę MVĮ pajėgumą pateikti užstatą kreditoriams kaip didinantį riziką dalyką bei papildo, jog dėl to MVĮ yra labiau pažeidžiamos egzistuojančių finansavimo suvaržymų. Prie šių išvadų dėl skirtingo įmonių dydžio įtakos kredito rizikai prisideda ir tyrimas, atliktas remiantis daugiau nei 22 tūkst. įsipareigojimų nevykdymo atvejų 2003 – 2010 metų laikotarpiu. Tyrime išvados patvirtina, jog įmonės dydis lemia įsipareigojimų nevykdymo tikimybę – nustatyta, jog įsipareigojimų nevykdymo tikimybė yra žymiai didesnė MVĮ (0,35%) negu didelių įmonių (0,14%) (Keijzers, Diris, ir Kole, 2018). Tačiau nors ir teigiama, jog MVĮ kredito rizika yra didesnė nei didelių įmonių, Serbijos bankų sektoriuje atliktas tyrimas, vertinantis ilgalaikį ryšį tarp makroekonominių bei įsipareigojimų nevykdymo rodiklių, nustatė, jog tarp BVP ir MVĮ įsipareigojimų nevykdymo rodiklio nėra ilgalaikio ryšio, o tai reiškia, jog Serbijos MVĮ kredito rizika yra atspariausia verslo ciklų pokyčiams, kas prieštarauja anksčiau aptartiems požiūriams. Autoriaus nuomone tai lemia MVĮ lankstumas dėl nedidelio dydžio, tačiau taip pat MVĮ, kitaip nei labai smulkioms įmonėms, negresia rizika keičiantis verslo ciklui prarasti turimą vieną stambų klientą (Kanazir, 2023).

4 paveikslas

Įmonės dydžio poveikio kredito rizikai diskusija



Sudaryta autorės, remiantis literatūros apžvalgoje nagrinėtais autoriais


Įvertinus įmonės dydžio poveikį kredito rizikai nagrinėjami autoriai sutaria dėl problemų vertinant ir taip padidinant MVĮ kredito riziką dėl informacijos, pateiktos įmonių finansinėse ataskaitose. Wang ir kt. (2021) išanalizavo daugiau nei 74 tūkst. MVĮ finansinę informaciją tirdami kredito naudojimo poveikį MVĮ finansiniams rezultatams ir veiklos sunkumams 2006 – 2015 m. laikotarpiu. Tyrimo metu buvo nustatyta, jog MVĮ didesnę kredito riziką lemia didesnis finansinis neskaidrumas lyginant su didelėmis įmonėmis. Tyrimo išvadose taip pat teigiama, jog tik skaidrumas gali sumažinti informacijos asimetriją tarp MVĮ ir kreditorių bei taip atitinkamai sumažinti įmonių kredito riziką – įmonės turi tvarkingai rengti savo finansines ataskaitas, laikytis taikomų įstatymų bei apskaitos standartų, teisingai parodyti savo atskaitomybę suinteresuotoms šalims, įskaitant kreditorius, taip sumažinant kredito riziką (Mutamimah, Alifah ir Adnjani, 2023).

Autoriai sutaria ne tik dėl informacijos neskaidrumo problemos, bet ir dėl MVĮ finansinių ataskaitų skirtumų palyginus su didelių įmonių ataskaitomis, dėl kurių kreditoriams apsunkinamas MVĮ kredito rizikos įvertinimas. Tačiau tie skirtumai atsirado dėl skirtingų įmonių, atsižvelgiant į jų dydį, galimybes ir pajėgumus rengti finansines ataskaitas. Tam, jog būtų laikomasi visų privalomų teisės aktų ir informacija būtų atvaizduojama tinkamai, įmonės turi turėti buhalterio kvalifikaciją turintį specialistą. Kaip teigia Kanapickienė ir Špicas (2019), 2004 m. Lietuvoje finansinės apskaitos reglamentavimas pasikeitė įsigaliojus Verslo apskaitos standartams teigiant, jog MVĮ yra pajėgios teikti tokią finansinę informaciją, kaip ir didelės įmonės, tačiau buvo suprasta, jog skirtingų įmonių poreikiai skiriasi ir MVĮ yra per sudėtinga ir tuo pačiu per brangu samdyti papildomą darbuotoją ar paslaugą suteikiančią įmonę tam, jog galėtų atitikti visus didelėms įmonėms nustatytus reikalavimus rengiant finansines ataskaitas. Tai paskatino imtis struktūrinių pertvarkų – nuo 2016 m. buvo dar labiau supaprastinta finansinių ataskaitų struktūra, o MVĮ buvo leidžiama rengti mažiau išsamias ataskaitas. Dėl šių pokyčių atsirado skirtumų tarp didelių ir vidutinių, mažų ir labai mažų įmonių finansinių ataskaitų rengimo – šiuo atveju MVĮ teikiamose finansinėse ataskaitose sumažėjo pateikiamos informacijos kiekis. Taigi, kadangi Lietuvoje pagal LR įmonių ir įmonių grupių atskaitomybės įstatymą MVĮ finansinėms ataskaitoms nustatyti žemesni reikalavimai nei didelėms įmonėms, kreditoriams iškyla problemų įvertinant MVĮ kredito riziką, nes dėl nepakankamai išsamios MVĮ finansinės informacijos kreditoriai negali apskaičiuoti visų reikalingų finansinių rodiklių ir negali naudoti rodiklių tokių kaip pinigų srautų, išlaidų lygio finansinių ir kitų rodiklių, o dėl to atsiranda tam tikrų kredito rizikos įvertinimo modelių apribojimai (Špicas ir kt., 2015). Dėl šios priežasties MVĮ teikiant paraiškas kreditui, kreditoriams gali trūkti patikimos informacijos, tam, jog galėtų įvertinti skolininko kreditingumą ir dėl to MVĮ yra laikomos rizikingesnėmis nei didelės įmonės (Wasiuzzaman, Nurdin, Abdullah

ir Vinayan, 2020). Apibendrinant, informacijos trūkumas MVĮ finansinėse ataskaitose ir jų pateikiamų duomenų neskaidrumas lemia didesnę kredito riziką, apsunkindamas kreditorių sprendimų priėmimą. Todėl reikalingi sprendimai, kurie skatintų MVĮ didinti savo finansinį skaidrumą, siekiant sumažinti informacijos asimetriją ir užtikrinti kreditorių pasitikėjimą.

5 paveikslas

MVĮ didesnės kredito rizikos veiksniai



Sudaryta autorės, remiantis literatūros apžvalgoje nagrinėtais autoriais

Taigi, galime daryti išvadą, kad MVĮ skiriasi nuo didelių įmonių ne tik dėl dydžio, bet ir dėl jo atsiradusių unikalių kredito rizikos dinamikos ypatybių. Taip pat atkreipiamas dėmesys į MVĮ apibrėžimą, kuris skiriasi tarp šalių dėl skirtingų teisės aktų ir ekonominių sąlygų. Pavyzdžiui, Europos Sąjungoje MVĮ apibrėžiamos pagal darbuotojų skaičių, apyvartą ir balanso

sumą, tuo tarpu JAV pirmenybė teikiama įmonių pramonės sektoriui ir metinėms pajamoms. Šie skirtumai atspindi skirtingus šalių ekonominius prioritetus ir rinkos struktūras. Literatūroje pastebimi du skirtingi požiūriai į įmonės dydžio įtaką kredito rizikai. Vienas teigia, kad problemos, susijusios su išoriniu finansavimu, priklauso nuo įmonės kapitalo struktūros, o ne dydžio. Tačiau naujesni tyrimai rodo, kad kredito rizikos požiūriu MVĮ ir didelės įmonės yra skirtingos. MVĮ turi mažiau užstato, mažiau nusistovėjusią kredito istoriją ir yra labiau pažeidžiamos dėl rinkos svyravimų bei ekonominių sąlygų. Be to, įmonės dydžio poveikis kredito rizikai yra glaudžiai susijęs su informacijos neskaidrumu, o tai lemia didesnę kredito riziką. Taip pat skirtumai tarp MVĮ ir didelių įmonių finansinių ataskaitų sudaro kliūtis kredito rizikos įvertinimui, kai įmonės teikia nepakankamai išsamią finansinę informaciją. Tai gali kelti sunkumų siekiant išorinio finansavimo, ribojant MVĮ augimą, o tokia situacija daro poveikį ne tik atskirų įmonių, bet ir visos ekonomikos konkurencingumui, nes MVĮ dažnai sudaro reikšmingą šalies BVP dalį ir užtikrina didelę dalį darbo vietų.

1.3. Kredito rizikos vertinimo modelių teorinis vertinimas


Komerciniai bankai susiduria su esmine problema – kredito rizika, kuri, kaip nurodo tyrimai (Mutamimah ir kt., 2023; Phan Thi Hang, 2023), iki šiol nebuvo visiškai išspręsta nepaisant pažangos kredito rizikos valdymo srityje. Dar 1997 m. Bazelio bankų komitetas savo pagrindiniuose bankininkystės priežiūros principuose identifikavo kredito riziką kaip pagrindinį iššūkį, su kuriuo susiduria bankai (Špicas ir kt., 2018), sukeliantį kreditorių nuostolius (Phan Thi Hang, 2023), todėl nuoseklus ir tikslus jos valdymas yra būtinas.

Tam, jog ši rizika būtų kiek įmanoma suvaldyta, kreditoriai yra suinteresuoti numatyti skolininkų neveiksnia padėtį bei potencialų skolininkų įsipareigojimų nevykdymą (Corazza ir kt., 2021). Dėl šių priežasčių kreditingumo vertinimas tampa neatsiejama bankų veiklos dalimi, nes nuo jo priklauso ne tik kredito suteikimo sprendimai, bet ir finansų sistemos stabilumas. Taigi, kreditoriai prieš skolinant turi tinkamai įvertinti skolininko kreditingumą, o ypač MVĮ, kadangi nors finansavimas yra laikomas esminiu MVĮ plėtros veiksniu (Wang ir kt., 2021) bei nors šios įmonės laikomos ekonomikos varikliu, jos sudaro net 99,8% visų įmonių, veikiančių Europoje (European Investment Bank Group, 2022), taip prisidedant prie ekonomikos augimo, darbo vietų kūrimo ir plėtros (Mitra ir kt., 2023), pastarųjų kredito rizika yra laikoma reikšmingai didesne nei didelių įmonių (Špicas ir kt., 2015; Kanapickienė ir Špicas, 2019; Wasiuzzaman ir kt., 2020; Wang ir kt., 2021; Mutamimah ir kt., 2023; Mitra ir kt., 2023).

Kredito rizikos vertinimo modeliai yra būtini tiek kredito įstaigoms, tiek kitoms susijusioms šalims, norint įvertinti įmonės gebėjimą vykdyti finansinius įsipareigojimus. Šie modeliai dažnai vadinami kredito rizikos, bankroto tikimybės, nemokumo ar įsipareigojimų nevykdymo modeliais ir yra taikomi siekiant prognozuoti būsimus finansinius sunkumus. Modeliai yra skirstomi į klasikinius ir dirbtinio intelekto pagrindu veikiančius modelius. Klasikiniai modeliai, tokie kaip tiesinė diskriminantinė analizė ir logistinė regresija, yra plačiai taikomi dėl jų teorinio pagrįstumo ir interpretavimo paprastumo. Šie modeliai remiasi statistiniais metodais, leidžiančiais nustatyti ryšį tarp įmonės finansinių rodiklių ir jos tikimybės patirti finansinius sunkumus. Dirbtinio intelekto modeliai, tokie kaip neuronų tinklai ir sprendimų medžiai, išsiskiria gebėjimu analizuoti didelius duomenų kiekius ir aptikti sudėtingesnius ryšius tarp įvairių veiksnių, tačiau dažnai reikalauja daugiau duomenų ir yra sudėtingesni interpretuoti (Mackevičius ir Silvanavičiūtė, 2006; Krušinskas ir kt., 2014; Corazza ir kt., 2021).

6 paveikslas

Kredito rizikos vertinimo modelių klasifikacija



Sudaryta autorės, remiantis Mackevičiumi ir Silvanavičiūte (2006), Krušinsku ir kt. (2014) bei Corazza ir kt. (2021)

Šių įvertinimo modelių pradininkas yra laikomas E. Altman. Jis dar 1968 m. pristatė diskriminantinės analizės modelį, skirtą nagrinėti įmonių, kurių akcijos yra kotiruojamos vertybinių popierių biržoje, bankroto tikimybei nustatyti. Šis modelis, dažnai vadinamas Altmano Z modeliu, tapo vienu iš pirmųjų bandymų kiekybiškai įvertinti įmonės finansinį stabilumą. Vėliau, 1983 m. Altman pritaikė sukurtą modelį įmonėms, kurių akcijos nėra kotiruojamos

vertybinių popierių biržoje bei būtent paslaugų ir individualių įmonių bankroto tikimybei nustatyti. Šių modelių pritaikymas įrodė, kad modeliai gali būti universalūs, prisitaikant prie skirtingų įmonių tipų ir rinkos segmentų. Jo pavyzdžiu sekė ir kiti mokslininkai – Taffler ir Tisshaw bei G. Springate, tuo tarpu Zavgren ir Chesser sukūrė modelius, paremtus logistine regresija (Mackevičius ir Silvanavičiūtė, 2006). Tačiau pastaraisiais dešimtmečiais technologijų pažanga atvėrė kelią dirbtinio intelekto modeliams, tokiems kaip neuronų tinklai ir sprendimų medžiai. Šie modeliai išsiskiria gebėjimu apdoroti didelius duomenų kiekius, aptikti kompleksinius ryšius tarp kintamųjų ir pasiekti aukštą prognozių tikslumą. Nepaisant pastarųjų modelių aukšto tikslumo ir skaičiavimo laiko, jų sudarymas yra sudėtingas ir reikalaujantis papildomų išteklių. Klasikiniai modeliai, tokie kaip diskriminantinė analizė ir logistinė regresija, išlieka populiarūs, nes jie pasižymi paprastesne įvertinimo metodika ir taip pat aukštu patikimumu. Kaip pažymi Corazza ir kt. (2021) bei Savickienė ir Baliūnė (2021), šių modelių lengvumas interpretuoti rezultatus, mažesni duomenų poreikiai ir metodinis aiškumas daro juos itin patraukliais, ypač tais atvejais, kai naudojami riboti duomenys ar turimi ištekliai.

2 lentelė

Nagrinėtų autorių tikrinamų bei naujai sukurtų kredito rizikos modelių suvestinė

			2003	2005	2005	2006	2012	2012	2014	2014	2018	2018	2020	2021	2021	2022	2022	2023	
Klasifikacija	Grupės	Kredito rizikos analizės modeliai	Grigavičius	Altman ir Sabato	Mackevičius ir Rakštienė	Mackevičius ir Silvanavičiūtė	Kiyak ir Labanuskaitė	Špicas ir Nekrošius	Krušiskas ir kt.	Marcinkevičius ir Kanapickienė	Špicas ir kt.	Hamid Cheralghali	Corazza ir kt.	Isil Erem Ceylan	Lisboa, Costa ir Santos	Grikietytė ir Mačiulytė – Šniukienė	Da ir Peng	Mitra ir kt.	Kartai
Klasikiniai	Tiesinė diskriminantinė analizė	Altmano Z		✓	✓	✓	✓	✓	✓	✓					✓	✓			9
	Logistinė regresija	Zavgen				✓	✓	✓	✓	✓									5
	Tiesinė diskriminantinė analizė	Springate				✓	✓		✓	✓				✓					5
		Taffler ir Tisshaw				✓			✓	✓									3
	Logistinė regresija	Chesser				✓	✓		✓	✓									4
		Logistinė regresija									✓	✓			✓				3
		Grigavičiaus modelis	✓						✓										2

		Ohlson* o O														√			1
	Tiesi nė diskri mina ntinė anali zė	Zmijews ki X														√			1
Dirbtinio intelekto	Spren dimų medi s	Mackevi čiaus ir Silvanav ičiūtės spendim ų medis				√			√										2
		Frydma n, Altman ir Kao sprendi mų medis					√		√										2
		Trumpal aikių įsipareig ojimų neįvykd ymo modelis															√		1
	Neur onų tinkla i	RGCN- RF																√	1
		Elman										√							1

Sudaryta autorės, remiantis lentelėje nurodytais autoriais

Išnagrinėjus autorius ir jų pritaikomus kredito rizikos modelius pastebima, kad lietuviai mokslininkai ypatingai dažnai naudoja klasikinius modelius – tiesinę diskriminantinę analizę (Altman, Springate, Taffler ir Tisshaw) ir logistinę regresiją (Chesser bei Zavgren). Tuo tarpu dirbtinio intelekto metodai, tokie kaip neuronų tinklai ar sprendimų medžiai, yra naudojami tik retais atvejais, nes jie dažnai reikalauja didesnių duomenų kiekių ir sudėtingesnių analitinių įrankių. Be to, lietuvių mokslininkai stengiasi kurti naujus, vietos rinkai pritaikytus modelius, atsižvelgdami į specifinius Lietuvos ekonomikos, įmonių dydžio bei sektorių ypatumus. Tokie modeliai siekia atspindėti Lietuvoje veikiančių įmonių veiklos realijas ir užtikrinti, kad rizikos vertinimo procesai būtų kuo tikslesni. Tai rodo, kad mokslininkai ne tik remiasi tarptautine praktika, bet ir adaptuoja metodikas, pritaikydami jas prie vietos sąlygų, siekdami pagerinti kredito rizikos valdymo efektyvumą.

Taigi, mokslininkai remiantis klasikinais modeliais tikrina jų tikslumą analizuojant Lietuvoje veikiančių įmonių bankroto/kredito rizikos tikimybę. Išanalizavus straipsnius pastebėta, jog autorių atliktų tyrimų išvados yra prieštaringos. 7 paveiksle pateikta kredito rizikos įvertinimo modelių klasifikacija leidžia geriau suprasti, kurie modeliai yra laikomi tinkamiausiais taikyti Lietuvos įmonėms, atsižvelgiant į skirtingas analitines metodikas ir sektorių specifiką. Šių tyrimų tikslas – sukurti naują modelį arba įvertinti, ar užsienyje sukurti ir naudojami modeliai gali būti pritaikomi Lietuvos ekonomikos ir įmonių specifikai, taip pat siekiama nustatyti, kurie modeliai yra tinkamiausi prognozuoti finansinius sunkumus. Dalis autorių teigia, jog geriausi modeliai prognozuoti bankrotą/kredito riziką – modeliai, sukurti remiantis tiesine diskriminantine analize. Pavyzdžiui, Mackevičius ir Rakštelienė (2005) tikrino dvi Altman Z modelio variacijas – skirtą įmonėms, kurių akcijos yra kotiruojamos vertybinių popierių biržoje, bei paslaugų ir individualioms įmonėms skirtą variaciją. Šis tyrimas buvo atliktas remiantis 1993–2002 m. laikotarpio bankrutuojančių ir bankrutavusių įmonių finansiniais duomenimis. Atlikus analizę, autoriai padarė išvadą, kad Altman Z modelis yra tinkamas naudoti prognozuojant bankrotą Lietuvos įmonėse. Vėliau Mackevičius ir Silvanavičiūtė (2006) išplėtė šią analizę ir nagrinėjo Altman, Springate, Taffler ir Tisshaw, Zavgren bei Chesser modelių prognozavimo tikslumą, taikydami juos keturioms didelėms Lietuvos gamybos įmonėms 2000–2004 m. laikotarpiu. Autoriai nustatė, kad iš visų nagrinėtų modelių Lietuvos įmonėms tinkamiausi yra tiesinės diskriminantinės analizės modeliai – Altman, Springate, Taffler ir Tisshaw, kadangi jie pasižymėjo aukštesniu tikslumu ir gebėjimu atspindėti įmonių realią finansinę būklę. Tuo tarpu logistinės regresijos pagrindu sukurti Zavgren ir Chesser modeliai nebuvo tokie tikslūs – jų rezultatai dažnai neatitiko realių įmonių finansinių rodiklių, o skirtingais laikotarpiais gauti rezultatai buvo priešaringi. Grikietytė ir Mačiulytė – Šniukienė (2023) taip pat pirmenybę teikia

Altman Z modeliui – autorės įvertinusios bankroto tikimybę 3 Lietuvos bankams – „SEB bankas“, „General Financing bankas“ ir „Medicinos bankas“ – remiantis įmonių 2021 m. finansinės atskaitomybės duomenimis teigia, jog šis modelis yra tinkamiausias analizuoti bankroto tikimybę Lietuvos finansų sektoriaus įmonėms. Taip pat autorės pabrėžia, jog nors Zmijewski X modelis sparčiai populiarėja jį pritaikant finansų sektoriui, autorės jo Lietuvoje veikiančioms finansų sektoriaus įmonėms taikyti nerekomenduoja.

Tačiau ne visi autoriai teigia, jog tiksliausi kredito rizikos įvertinimo modeliai remiasi tiesine diskriminantine analize. Dalis nagrinėjamų autorių išskiria logistinę regresiją paremtus modelius kaip tinkamiausius įvertinimo modelius analizuojant Lietuvoje veikiančių įmonių kredito riziką. Pavyzdžiui, Špicas ir Nekrošiūtė (2012) įvertino 8 Lietuvoje veikiančių kredito unijų kredito rizikos įvertinimui naudojamus modelius. Jų tyrimo rezultatai parodė, kad logistinės regresijos modeliai – Zavgren ir Chesser – yra tinkamiausi vertinant kredito riziką dėl jų gebėjimo tiksliai nustatyti nevykdomų įsipareigojimų tikimybę bei efektyviai naudoti ribotus duomenis – šie modeliai pasirodė esantys jautrūs finansiniams rodikliams, kurie buvo reikšmingi analizuojant mažesnių finansinių įstaigų, tokių kaip kredito unijos, veiklos stabilumą. R. Krušinskas ir kt. (2014) taip pat pateikia argumentų, palaikančių logistinės regresijos modelių pranašumą – autoriai tyrė didesnę imtį viešųjų įmonių – 17 gamybos, 4 paslaugų ir 1 prekybos įmonę 2006–2010 m. laikotarpiu, kuris apėmė ir pasaulinės finansų krizės poveikį. Atlikus analizę teigiama, jog Lietuvos įmonių bankroto tikimybę nustatyti patikimiausia remtis logistinės regresijos modeliais, kadangi mokslininkai teigia, jog logistinės regresijos modelių tikslumas (77%) viršija tiesinės diskriminantinės analizės modelių tikslumą (52%).

Tačiau yra ir autorių, kurie teigia, jog atlikus tyrimą, du geriausi modeliai yra paremti skirtingomis modelių grupėmis. Ši nuomonė iliustruoja, kad nei viena modelių grupė negali būti laikoma universaliai tinkamiausia, nes modelių tikslumas gali skirtis priklausomai nuo sektoriaus, rinkos sąlygų ar analizuojamo laikotarpio. Pavyzdžiui, R. Marcinkevičius ir R. Kanapickienė (2014) atliko išsamų tyrimą, kuriame nagrinėjo bankroto tikimybę, analizuodami 521 statybų sektoriaus įmonę, veikiančią Lietuvoje, kurios susidūrė su bankroto procesu 2009–2013 metų laikotarpiu. Tyrime naudoti įvairūs klasikiniai modeliai, tokie kaip Altman, Springate, Taffler ir Tisshaw, Zavgren bei Chesser, siekiant įvertinti jų tikslumą prognozuojant bankrotą. Straipsnyje teigiama, jog tiksliausi modeliai bankroto tikimybei nustatyti Lietuvos statybų sektoriui yra Springate (86,94%) ir Chesser (92,7%) modeliai. Šie modeliai išsiskiria aukštu tikslumu ir gebėjimu atspindėti statybų sektoriaus specifiką, kuriai būdingas didesnis sezoniškumas, projektų vykdymo rizika bei finansinio srauto nepastovumas. Šiek tiek mažesnio tikslumo buvo Zavgren (77,35%) ir Altman (74,47%) modeliai, kurie taip pat yra laikomi tinkamais bankroto tikimybei

nustatyti, tačiau jų prognozės nebuvo tokios tikslios, kaip pirmųjų dviejų modelių. Tuo tarpu autoriai pačiu netiksliausiu modeliu, skirtu Lietuvos statybų sektoriui, identifiko Taffler ir Tisshaw modelį, kurio tikslumas siekė tik 42,99%. Šios išvados pabrėžia, kad modelių tikslumas ir pritaikomumas gali labai skirtis priklausomai nuo analizuojamo sektoriaus ir konkrečių ekonominių sąlygų. Tai rodo, kad nėra vieno universalaus kredito rizikos vertinimo modelio, kuris galėtų tiksliai prognozuoti bankroto tikimybę visuose sektoriuose ar šalyse.


Autoriai ne tik naudojami ir tikrino kitų mokslininkų sukurtus modelius bankroto ar kredito rizikos vertinimui, bet ir patys prisidėjo prie naujų modelių kūrimo, siekdami pritaikyti juos specifinėms Lietuvos rinkos sąlygoms. Šie nauji modeliai yra orientuoti į vietos rinkos ypatumus, leidžiantys tiksliau analizuoti Lietuvos įmonių finansinę būklę ir riziką. Grigaravičius (2003), išanalizavęs 20 skirtingų finansinių rodiklių grupių, atrinko 9 reikšmingiausius koeficientus ir sukūrė nemokumo diagnozavimo modelį, paremtą logistinės regresijos principu. Šis modelis buvo pritaikytas Lietuvoje veikiančioms įmonėms, kurių akcijos kotiruojamos vertybinių popierių biržoje, ir buvo skirtas įvertinti šių įmonių finansinę būklę bei galimą nemokumą. R. Špicas ir kt. (2018) taip pat prisidėjo prie kredito rizikos modelių kūrimo, sudarydami statistinį modelį, skirtą Lietuvos kredito unijoms. Kuriant šį modelį taip pat buvo remiamasi logistine regresija. Vienas iš modelio ypatumų – patikslintas „bloga“ skolininko apibrėžimas, kuris leido tiksliau skirstyti kredito gavėjus pagal jų išsipareigojimų vykdymo riziką. Špicas ir kt. (2018) pabrėžė, jog rengiant kredito rizikos modelį būtina atsižvelgti ne tik į finansinius, bet ir į nefinansinius rodiklius. Be to, autoriai pabrėžė įmonės veiklos tęstinumo perspektyvos svarbą, teigdami, kad modelio prognozės bus tikslesnės, jei į analizę bus integruoti kintamieji, leidžiantys įvertinti, ar įmonė yra pajėgi stabiliai vykdyti veiklą ateityje. Šių naujų modelių kūrimas parodo, kad klasikiniai modeliai dažnai yra adaptuojami arba išplečiami, siekiant juos pritaikyti konkrečioms ekonominėms ir rinkos sąlygoms. Tai rodo mokslininkų pastangas ne tik taikyti jau egzistuojančius metodus, bet ir kurti inovatyvius sprendimus, kurie geriau atitinka Lietuvos įmonių ir finansinių institucijų poreikius.

Taigi, pastarieji autoriai nagrinėjo Lietuvoje veikiančių kitų, ne MVĮ, sektorių įmonių bankroto tikimybes. Tačiau literatūroje taip pat pastebima autorių, kurie klasikinius modelius tikslingai pritaikė MVĮ sektoriaus įmonėms, analizė. Kiyak ir Labanauskaitės (2012) atrinktos 7 įmonės 2006 – 2010 m. laikotarpiu pasižymėjo šiais požymiais – buvo MVĮ bei veikė dideliame Lietuvos mieste. Išvados teigia, jog geriausiai nagrinėjamų įmonių bankroto tikimybę nustatė Altman ir Springate modeliai, tuo tarpu logistinės regresijos modelių Chesser ir Zavgren rezultatai neatitiko realios įmonių finansinės padėties, tad autorės teigia, jog šie modeliai yra netinkami Lietuvos įmonių bankroto tikimybei prognozuoti. Be to, Kiyak ir Labanauskaitė (2012) pabrėžė,

kad pasitikėti vien tik vieno modelio išvadomis nėra pakankama. Autorių nuomone, skirtingų modelių išvadų lyginimas tarpusavyje yra būtinas, nes tai padeda tiksliau identifikuoti rizikas ir sumažinti klaidingų prognozių tikimybę.

7 paveikslas

Kredito rizikos vertinimo modeliai, sukurti arba autorių laikomi tiksliausi naudoti Lietuvoje veikiančioms įmonėms



Sudaryta autorės, remiantis paveiksle nurodytais autoriais

Taigi, nors populiariausi kredito rizikos vertinimo modeliai Lietuvoje veikiančios įmonės yra Altman, Springate, Taffler ir Tisshaw bei Chesser bei Zavgren, jie Lietuvoje veikiančioms MVĮ buvo pritaikyti tik kartą prieš daugiau nei 10 metų analizuojant 7 įmonių finansinius rodiklius apimant 2008 m. finansinės krizės metus (Kiyak ir Labanauskaitė, 2012), tad rezultatai pritaikant šiuos modelius šių dienų Lietuvoje veikiančių MVĮ kredito rizikai įvertinti gali būti netikslūs. Taip pat analizuojant užsienio literatūrą, buvo pastebėta prieštaringa informacija, rodanti, jog ne visi šie modeliai yra tinkami ar plačiai naudojami MVĮ kredito rizikai įvertinti. Lisboa ir kt. (2021) teigia, jog Altman Z 1986 m. modelis, kuris 2012 m. Kiyak ir

Labanauskaitės taip pat buvo pritaikytas Lietuvoje veikiančioms įmonėms, nėra tikslus analizuojant šių dienų MVĮ kredito riziką – remiantis Portugalijos įmonių finansiniais rodikliais buvo apskaičiuotas tik 27,6% modelio tikslumas. Atsižvelgdami į šiuos trūkumus, Lisboa ir kt. (2021) sukūrė naują logistinį modelį, naudodami 2012 – 2017 m. laikotarpio 2658 Portugalijos MVĮ duomenis. Šis modelis pasiekė 88,74% tikslumą, todėl jis laikomas reikšmingai pranašesniu už Altman Z modelį. Taigi, Kiyak ir Labanauskaitės tyrime minėto Altman 1986 m. modelio vietoje tikslinga būtų tikrinti kitą autoriaus darbą – Altman ir Sabato (2005) modelį. Šis modelis, skirtas būtent MVĮ analizei JAV, yra pagrįstas logistine regresija ir buvo sukurtas remiantis 2000 įmonių 1994 – 2002 m. duomenimis. Patikrinus šį modelį, jis pasirodė gerokai tikslesnis nei Altman 1968 m. modelis – atitinkamai 87,22% ir 68,57%. Toks tikslumo padidėjimas rodo, kad naujesni modeliai, sukurti specialiai MVĮ, gali būti tinkamesni ir analizuojant Lietuvoje veikiančių MVĮ kredito riziką. Taip pat būtų tikslinga tikrinti ir Lisboa ir kt. (2021) sukurtą modelį Portugalijoje veikiančioms MVĮ, kadangi gali būti, jog minimas modelis tiktų analizuoti ir Lietuvoje veikiančių MVĮ kredito riziką.

Iš likusių populiariausių modelių ne Lietuvoje pavyko rasti informacijos tik apie Springate modelio pritaikymą MVĮ. Tačiau net ir ši informacija yra ribota, nes autoriai nesiekė įvertinti Springate modelio tikslumo, o naudojo šį modelį kaip priklausomą kintamąjį, analizuojant įvairių įmonės vidinių bei makroekonominių veiksnių įtaką finansinių sunkumų rizikai Turkijoje veikiančioms MVĮ (Ceylan, 2021). Tokiu būdu Springate modelis tyrime buvo pasitelktas kaip tam tikras indikatorius, todėl nėra pakankamai informacijos, leidžiančios įvertinti šio modelio tikslumą MVĮ sektoriui, tačiau Springate modelis visgi buvo pasirinktas analizuojant MVĮ, todėl negalime atmesti šio modelio tinkamumo MVĮ sektoriui. Tačiau atsižvelgiant į šią informaciją, galima daryti prielaidą, kad ne visi modeliai, kurie yra populiarūs Lietuvoje, šiuo metu yra tinkami ar yra naudojami MVĮ kredito rizikai nustatyti, nes nebuvo rasta tyrimų, analizuojančių jų tikslumą MVĮ sektoriuje.

Taip pat remiantis logistine regresija kredito rizikos įvertinimo modelį skirtą MVĮ sukūrė ir Cheraghali (2018) naudojant Norvegijoje veikiančių MVĮ finansinę informaciją bei įmonių gyvavimo metus. Tokiu būdu buvo pasiektas 82,7% modelio tikslumas. Tačiau taip pat buvo tirta kaip prie modelio tikslumo prisideda kita informacija apie įmones – teigiama, jog prie pradinio modelio su finansine informacija bei įmonių amžiumi pridėjus sektorių, buvo pasiektas 82,98%, regioną – 82,83% bei darbuotojų skaičių – 82,85% tikslumas. Tad autorius teigia, jog iš šių minimų kriterijų sektoriaus informacijos naudojimas modelyje labiausiai daro įtaką tikslumui, todėl modelis buvo sudarytas iš finansinės informacijos, įmonės amžius bei sektoriaus. Tiesa, nors visi tyrime minimi papildomi kriterijai sukėlė tik nežymų pokytį analizuojant Norvegijoje

veikiančių MVĮ kredito rizikos tikimybę, tačiau ši informacija pagerino šio modelio tikslinimą, tad būtų tikslinga Lietuvoje veikiančių MVĮ kredito rizikos modelį sudaryti ne tik iš finansinių, bet ir iš nefinansinių rodiklių.

Taigi, kredito rizika yra ypatingai svarbi siekiant išvengti nuostolių bei bankroto tikimybės. MVĮ kredito rizikos įvertinimas Lietuvoje yra minimalus ir ši sritis nėra pilnai išnagrinėta. Nepaisant didelės MVĮ svarbos šalies ekonomikai, mokslininkų dėmesys šiam sektoriui Lietuvoje išlieka ribotas, o taikomi modeliai dažnai yra adaptuoti iš kitų šalių. Kredito rizikos įvertinimui Lietuvos mokslininkai naudoja dažniausiai tik klasikinius metodus, kadangi dirbtinio intelekto modeliai yra nauji, dar nėra iki galo ištirti, juos tirti reikalingos papildomos kompiuterinės programos (Mackevičius ir Silvanavičiūtė, 2006; Bručaitė, 2018; Giriūnienė, Giriūnas, Morkūnas ir Bručaitė, 2019), todėl jų sudarymas yra sudėtingas bei reikalaujantis papildomų išteklių, o klasikiniai modeliai pasižymi nesudėtinga įvertinimo metodika bei taip pat aukštu patikimumu (Corazza ir kt., 2021; Savickienė ir Baliūnė, 2021). Taip pat egzistuoja diskusija tarp autorių dėl Lietuvos įmonėms tinkamiausių kredito rizikos modelių, kadangi atliktuose tyimuose skiriasi analizuojamų įmonių dydis, jų priklausymas skirtingiems sektoriams bei nagrinėjamas laikotarpis, tačiau yra išskiriami dažniausiai naudojami modeliai – Altman, Springate, Taffler ir Tisshaw, Zavgren bei Chesser – kurie buvo naudojami analizuoti Lietuvoje veikiančių MVĮ kredito riziką (Kiyak ir Labanauskaitė, 2012). Tiesa, atsižvelgus į nagrinėjamus užsienio autorių aktualius tyrimus Portugalijoje rasta informacija dėl Lietuvoje naudotos Altman modelio versijos netikslumo analizuojant MVĮ ir teigiama, jog šiuo metu tikslingiau įvertinti MVĮ kredito riziką su 2005 m. Altman ir Sabato sukurta modelio versija, skirta būtent šioms įmonėms. Be Altman modelio kitas rastas užsienio literatūroje naudojamas MVĮ kredito rizikai įvertinti iš modelių, naudotų tirti Lietuvoje veikiančias įmones, yra tik Springate modelis, tad nors Lietuvoje dažniausiai naudojami klasikiniai kredito rizikos modeliai 2012 m. buvo naudoti tirti Lietuvoje veikiančių MVĮ kredito rizikos įvertinimo tikslumą, tai nėra visai aktuali informacija norint analizuoti šių dienų veikiančias MVĮ. Taip pat pastebėta, jog analizuojant Lietuvoje veikiančių MVĮ kredito riziką naudojami kitoms šalims pritaikyti modeliai, tad jie nėra sukurti remiantis Lietuvoje veikiančių MVĮ informacija ir dėl to modelių rezultatai analizuojant Lietuvoje veikiančias MVĮ gali neatitikti realybės. Dar viena problema naudojant nagrinėtus kitoms šalims autorių kurtus modelius yra modeliuose naudojamų duomenų prieinamumas – ne visa informacija yra viešai prieinama Lietuvoje, kas modelį paverčia tik teoriniu, bet ne praktiniu įrankiu įvertinti įmonės kredito riziką.

Ši situacija pabrėžia poreikį kurti modelius, pritaikytus Lietuvoje veikiančioms MVĮ, kurie remtųsi viešai prieinamais duomenimis. Atsižvelgiant į tai, tyrime siekiama sukurti modelį, kuris

būtų skirtas analizuoti būtent Lietuvoje veikiančias MVĮ su viešai prieinama informacija. Kiti modeliai, atrinkti kaip galimi tikrinti MVĮ kredito riziką (Altman ir Sabato, 2005; Springate, 1978; Cheraghali, 2018; Lisboa ir kt., 2021) tiriami siekiant įrodyti, jog svarbu sukurti modelį, skirtą būtent Lietuvoje veikiančioms įmonėms su būtent viešai prieinama informacija dėl modelio didesnio tikslumo ir platesnių galimybių pritaikyti modelį praktikoje.

2. MAŽŲ IR VIDUTINIŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO TYRIMO METODIKA

Taigi, atlikus literatūros analizę pastebėta, jog yra ypatingai svarbu laiku įvertinti įmonių, o ypatingai mažų ir vidutinių, finansinę būklę norint išvengti nuostolių bei blogiausiu atveju – bankroto. Tinkamas kredito rizikos modelio parinkimas gali padėti kreditoriams priimti pagrįstus sprendimus dėl finansavimo, sumažinant galimų nuostolių riziką ir užtikrinant, kad kreditai bus suteikti finansiškai stabilioms įmonėms. Be to, tai yra svarbu ir kitoms įmonėms, kurios bendradarbiauja su analizuojama įmone – tiekėjams, partneriams ar klientams. Šie verslo subjektai turi būti tikri, kad jų partneriai yra patikimi ir finansiškai pajėgūs vykdyti savo įsipareigojimus. Šiuo atveju tinkamai parinktas kredito rizikos modelis leidžia sumažinti verslo santykių neapibrėžtumą, padeda užkirsti kelią galimiems finansiniams sunkumams ir užtikrina stabilumą tiekimo grandinėje bei vykdomuose projektuose. Taip pat įvertinti kredito riziką svarbu ir pačiai įmonei, kadangi jei įmonė tinkamai neįvertina savo kredito rizikos ir bankroto tikimybė lieka nevaldoma, ji gali nesugebėti laiku reaguoti į finansinius sunkumus. Dėl šių priežasčių stengiamasi atrasti tinkamus kredito rizikos modelius, skirtus analizuoti tam tikrai šaliai, skirtingiems sektoriams ar tam tikro dydžio įmonei. Ypatingas dėmesys MVĮ kredito rizikos vertinimui yra reikalingas todėl, jog šios įmonės dažnai yra labiau pažeidžiamos, kuomet kyla ekonominiai sunkumai. Skirtingai nei didelės įmonės, kurios gali lengviau pasiskolinti kapitalo arba sulaukti investuotojų paramos, MVĮ yra labiau priklausomos nuo pajamų bei dažnai turi mažesnes finansines atsargas. Todėl tinkamas kredito rizikos modelis atsižvelgiantis į specifinius MVĮ veiklos rizikos veiksnius, gali padėti išvengti bankrotų ir užtikrinti tvarų augimą.

Kredito rizikos modeliai yra pritaikomi Lietuvos rinkai. Mokslininkai, siekdami įvertinti Lietuvoje veikiančių įmonių kredito riziką, naudoja klasikinius kredito rizikos modelius dėl jų nesudėtingos metodikos įgyvendinimo bei aukšto tikslumo. Modeliai buvo naudojami analizuojant įmonių kredito riziką (Kiyak ir Labanauskaitė, 2012; Špicas ir Nekrošiūtė, 2012; Špicas, Kanapickienė, Vijūnas ir Kirka, 2018) bei bankroto tikimybę (Grigaravičius, 2003; Mackevičius ir Rakštelienė, 2005; Mackevičius ir Silvanavičiūtė, 2006; Krušinskas, Lakštutienė ir Stankevičiūtė, 2014; Marcinkevičius ir Kanapickienė, 2014; Grikietytė ir Mačiulytė-Šniukienė, 2023). Remiantis atlikta literatūros analize dažniausiai Lietuvoje yra naudojami tiesinės diskriminantinės regresijos (Altman, Springate, Taffler ir Tisshaw) bei logistinės regresijos (Zavgren ir Chesser) metodai.

Nors Lietuvoje šie dažniausiai naudojami modeliai buvo pritaikyti prieš daugiau nei dešimtmetį analizuojant MVĮ kredito riziką (Kiyak ir Labanauskaitė, 2012), dabartiniai tyrimai užsienyje rodo, kad kai kurie iš šių klasikinių modelių nėra tinkami analizuoti MVĮ. Pavyzdžiui, Altman Z (1986) modelis, kuris buvo taikytas Lietuvoje veikiančioms įmonėms, užsienio tyrimuose rodė tik 27,6% tikslumą Portugalijoje veikiančių MVĮ atveju (Lisboa ir kt., 2021), todėl jo tikslumas gali būti ribotas ir Lietuvos įmonių kontekste. Be Altman modelio kitas rastas užsienio literatūroje naudojamas MVĮ kredito rizikai įvertinti iš modelių, naudotų tirti Lietuvoje veikiančias įmones, yra tik Springate modelis, o apie Taffler ir Tisshaw, Zavgren bei Chesser pritaikymą MVĮ užsienio autorių tyrimuose nebuvo rasta aktualios informacijos. Tad nors Lietuvoje dažniausiai naudojami klasikiniai kredito rizikos modeliai 2012 m. buvo naudoti tirti Lietuvoje veikiančių MVĮ kredito rizikos įvertinimo tikslumą (Kiyak ir Labanauskaitė, 2012), tai nėra visai aktuali informacija norint analizuoti šiomis dienomis veikiančias MVĮ.

Tyrimuose, susijusiuose su MVĮ kredito rizikos įvertinimu, svarbu atsižvelgti į tai, jog modeliai būtų adaptuoti tam tikroms rinkoms ir sektoriams. Užsienyje atlikti tyrimai rodo, kad universalūs modeliai, tokie kaip Altman Z, gali būti nepakankamai tikslūs analizuojant MVĮ, todėl būtina kurti arba pritaikyti modelius, orientuotus į specifinius rinkos ypatumus. Be to, daugelyje literatūros analizėse nagrinėjamų kitoms šalims sukurtų modelių naudojama informacija, kuri gali būti nepasiekiamo ar viešai neprieinama Lietuvos rinkoje. Tai lemia, jog šie modeliai tampa tik teoriniai be galimybės modelį naudoti praktiškai. Todėl tyrime siekiama sukurti tokį vertinimo modelį, kuris būtų ne tik tikslus, bet ir praktiškai pritaikomas siekiant įvertinti Lietuvoje veikiančių MVĮ kredito riziką.

Atsižvelgiant į šiuos iššūkius, šio tyrimo tikslas yra sukurti kredito rizikos įvertinimo modelį, skirtą būtent Lietuvoje veikiančioms MVĮ, naudojant viešai prieinamą informaciją, kuris būtų praktiškai pritaikomas ir tiksliai atspindėtų įmonių kreditingumą, pagrįstą ne tik finansiniais rodikliais, bet ir kitais svarbiais nefinansiniais kintamaisiais, kurie gali turėti įtakos kredito rizikai. Modelis kuriamas remiantis logistine regresija, kadangi teigiama, jog modeliai, paremti logistine regresija, yra patikimesni (Savickienė ir Baliūnė, 2021; Žebrytė ir Mačiulytė-Šniukienė, 2021). Taip pat lietuvių mokslininkai, kūrę naujus kredito rizikos ar bankroto įvertinimo modelius, naudojo būtent logistinę regresiją. Tyrimo metu papildomai analizuojami modeliai, kurie, remiantis ankstesniais tyrimais, buvo autorių naudojami analizuojant MVĮ – Altman ir Sabato (2005), Springate (1978), Cheraghali (2018) bei Lisboa ir kt. (2021) modeliai. Tyrimo metu siekiama nustatyti, ar šiuos modelius įmanoma adaptuoti Lietuvos MVĮ sektoriui naudojant viešai prieinamą informaciją ir jei taip – nustatyti modelių tikslumus bei juos palyginti tarpusavyje.

Tyrimo tikslas – sukurti naują kredito rizikos modelį skirtą Lietuvoje veikiančioms MVĮ naudojant tik viešai prieinamą informaciją; išsiaiškinti, kuriuos iš Altman ir Sabato (2005), Springate (1978), Cheraghali (2018) bei Lisboa ir kt. (2021) modelių galima pritaikyti Lietuvoje veikiančioms MVĮ dėl modeliuose naudojamų duomenų prieinamumo; jų rezultatus palyginti bei nustatyti tinkamiausią modelį Lietuvoje veikiančių MVĮ kredito rizikos įvertinimui.

Tyrimo uždaviniai:

1. Sukurti naują kredito rizikos modelį, paremtą logistine regresija, skirtą Lietuvoje veikiančių MVĮ kredito rizikos įvertinimui naudojant tik viešai prieinamą informaciją;
2. Įvertinti naujojo modelio tikslumą vertinant Lietuvoje veikiančias MVĮ;
3. Nustatyti, kuriuos nagrinėjamų autorių modelius – Altman ir Sabato (2005), Springate (1978), Cheraghali (2018) bei Lisboa ir kt. (2021) – galima pritaikyti Lietuvoje veikiančioms MVĮ, remiantis tik viešai prieinama informacija.
4. Palyginti naujojo ir nagrinėjamų modelių tinkamumą Lietuvoje veikiančių MVĮ kredito rizikos vertinimui ir rekomenduoti tinkamiausią modelį.

Duomenys: Tyrime naudojami Lietuvoje veikiančių įmonių finansinių ataskaitų duomenys, gauti iš duomenų bazės „TPCatalyst“. Tačiau siekiant užtikrinti, kad tyrimas remtųsi tik viešai prieinama informacija, analizei naudojama tik ta informacija, kuri yra viešai prieinama internetiniame „Verslo žinių“ puslapyje rekvizitai.vz.lt. Tokiu būdu užtikrinamas modelio pritaikomumas remiantis realiomis sąlygomis, kai prieinama informacija yra ribota.

Tyrimui atrinktos duomenų bazėje nurodytos Lietuvoje veikiančios įmonės, kurios atitinka MVĮ dydžio kategoriją 2022 m. ir 2023 m. patyrė restruktūrizavimą ar bankroto iškelimą. Vėlesnis laikotarpis po nemokumo bylos iškelimo nėra nagrinėjamas, kadangi tyrimui aktualus tik pats finansinių sunkumų nustatymo faktas (Savickienė ir Baliūnė, 2021). Tyrime nagrinėtas įmonių kiekis, atsižvelgiant į tai, kiek 2023 m. Lietuvoje veikiančių įmonių pradėjo bankroto ar restruktūrizavimo procesus, apie tai yra informacija naudojamoje duomenų bazėje ir neturima trūkstamos informacijos. Tokiam pačiam kiekiui – 254 įmonių, susidūrusių su finansiniais sunkumais – parinktos atsitiktinės, gerai veikiančios MVĮ, neturėjusios trūkstamos informacijos (Cheraghali, 2018). Taip užtikrinamas proporcingas duomenų paskirstymas tarp įmonių, patyrusių finansinius sunkumus, ir tų, kurios veikė stabiliai, kas yra svarbu siekiant sukurti patikimą ir tikslų

modelį. Tyrime naudota 508 (254 susidūrusių su restruktūrizavimu ar bankrotu bei 254 gerai veikiančių) įmonių informacija.

Pirmoje tyrimo dalyje sudarytas naujas MVĮ kredito rizikos įvertinimo modelis, skirtas naudoti su viešai prieinama informacija, bei įvertintas jo statistinis patikimumas naudojant duomenų analizės programą RStudio. Modelio kūrimo procesas prasidėjo nuo viešai prieinamos informacijos apie įmones identifikavimo, siekiant užtikrinti, kad sukurtas modelis būtų praktiškai pritaikomas realiomis sąlygomis. Išanalizavus internetiniame „Verslo žinių“ puslapyje rekvizitai.vz.lt viešai pateiktus duomenis, nustatyta, kad galima naudoti šiuos rodiklius: pardavimo pajamas, pelną (nuostolius) prieš mokesčius, pelningumą prieš mokesčius, grynąjį pelną (nuostolius), grynąjį pelningumą, nuosavą kapitalą, mokėtinas sumas ir įsipareigojimus, ilgalaikį turtą, trumpalaikį turtą, darbuotojų skaičių, įmonės amžių ir veiklos sektorių. Šių rodiklių įvairovė leidžia įvertinti tiek finansinius, tiek nefinansinius įmonės veiklos aspektus, kurie yra svarbūs analizuojant kredito riziką.

Naudojant šią viešai prieinamą informaciją sudaryti finansiniai rodikliai, siekiant eliminuoti įmonių dydžio skirtumus ir užtikrinti, kad modelis būtų tinkamas analizuoti įvairių dydžių MVĮ. Šis žingsnis svarbus, nes įmonių dydis gali turėti reikšmingą įtaką absoliučių finansinių rodiklių reikšmėms, todėl jų standartizavimas padeda objektyviau vertinti įmonių finansinę būklę. Renkantis, kuriuos rodiklius įtraukti į kuriamą modelį, pastebėta, kad nagrinėjami autoriai dažnai naudoja skirtingus finansinius rodiklius. Altman ir Sabato (2005) teigia, jog taip yra todėl, kadangi skiriasi tyrimuose analizuojamų įmonių sektoriai, kuriuose jos veikia, bei įmonių amžius. Tai rodo, jog nėra universalaus rodiklių rinkinio, tinkamo visiems atvejams, ir kad modelių kūrimas turi būti pritaikytas konkrečiai rinkai bei įmonių grupei. Nepaisant to, visi nagrinėjami autoriai, atrinkę finansinius rodiklius, koncentruojasi į 5 pagrindines finansinių rodiklių kategorijas – finansinio stabilumo, likvidumo, padengimo, pelningumo bei veiklos efektyvumo (Altman ir Sabato, 2005; Springate, 1978; Cheraghali, 2018; Savickienė ir Baliūnė, 2021; Lisboa ir kt., 2021). Taigi, autoriai savo modeliuose naudoja dažniausiai skirtingus rodiklius, tarp kurių tikėtina yra didelė koreliacija (pvz. EBIT/Turtas ir EBITDA/Turtas), kas gali iškreipti analizės rezultatus, tačiau koncentruojasi į tas pačias penkias finansų rodiklių kategorijas, todėl tyrime naujas modelis kurtas atsižvelgiant į nagrinėjamų autorių naudojamą penkias finansų rodiklių kategorijas bei siekiant, jog rodikliai būtų sudaryti iš Lietuvoje viešai prieinamos informacijos bei nekoreliuotų tarpusavyje. Taip pat svarstant kuriuos finansinius rodiklius įtraukti į modelį atsižvelgta į Lietuvos Respublikos juridinių asmenų nemokumo įstatymą, kuris teigia, jog „juridinio asmens nemokumas (toliau – nemokumas) – juridinio asmens būseną, kai juridinis asmuo laiku negali vykdyti turtinių prievolių arba juridinio asmens įsipareigojimais viršija jo turto

vertė“, t. y. skolos rodiklis (Įsipareigojimai / Turtas). Rodiklis įtraukiamas, kadangi atliekant Lietuvoje veikiančių MVĮ analizę modelis turi būti atsižvelgta į būtent šioje šalyje galiojančiame teisės akte apibrėžtą įmonių finansinių sunkumų būklės nustatymą (Savickienė ir Baliūnė, 2021).

Taip pat renkantis rodiklius, kuriuos siekiama įtraukti į kuriamą naują kredito rizikos modelį, būtina atsižvelgti ne tik į tai, kad modelis kuriamas Lietuvoje veikiančioms įmonėms, bet ir į tai, kad jis bus skirtas būtent MVĮ, kurioms būdingos tam tikros specifinės savybės ir iššūkiai, skiriantys jas nuo didelių įmonių. MVĮ dažnai susiduria su ribotais finansiniais ištekliais ir mažesniu turto kiekiu, kurie galėtų būti panaudoti kaip užstatas, o tai sudaro reikšmingą kliūtį siekiant išorinio finansavimo. Tai riboja jų galimybes gauti išorinį finansavimą, nes finansų įstaigos paprastai reikalauja užtikrinto turto, kad sumažintų kreditavimo riziką (Mitra ir kt., 2023; Wang ir kt., 2021). Dėl šios priežasties MVĮ yra labiau pažeidžiamos ekonominių ir rinkos sąlygų pokyčių, nes jų veiklos lankstumas ir gebėjimas atsispirti ekonominiams sukrėtimams yra riboti bei MVĮ dažniau susiduria su veiklos finansavimo sunkumais, nes didesnės įmonės paprastai turi daugiau alternatyvių finansavimo šaltinių arba stipresnius ryšius su finansinėmis institucijomis. Todėl kuriant kredito rizikos modelį reikia užtikrinti, kad į jį būtų įtraukti tokie rodikliai kaip turtas ir pardavimų pajamos. Šie rodikliai leidžia geriau įvertinti MVĮ finansinę būklę ir stabilumą, nes turto vertė gali būti naudojama kaip „finansinė pagalvė“, suteikianti tam tikrą saugumą esant nepalankioms rinkos sąlygoms. Tai ypač aktualu, nes turto vertė atspindi įmonės galimybes užtikrinti kreditorių interesus ar esant poreikiui pasitelkti išorinius finansinius šaltinius. Pardavimų pajamos taip pat yra vienas svarbiausių rodiklių, nes jos atspindi įmonės gebėjimą generuoti pinigų srautus, užtikrinančius galimybę vykdyti trumpalaikius ir ilgalaikius įsipareigojimus net ir esant sudėtingoms finansinėms aplinkybėms.

Nagrinėjant modelius, tinkamus analizuoti MVĮ kredito riziką, pastebėta, jog naujausiuose tyrimuose (Cheraghali, 2018; Lisboa ir kt. 2021) yra naudojami ne tik įmonių finansiniai rodikliai, bet ir nefinansinė informacija, kuri praplečia modelio pritaikomumą bei tikslumą. Vienas iš tokių papildomai naudojamų rodiklių – įmonių gyvavimo metai, kurie modelyje skaičiuojami nuo įmonių įkūrimo iki tų metų, kuomet yra prognozuojamas bankrotas (šio tyrimo atveju – iki 2022 m.). Cheraghali (2018) ir Lisboa ir kt. (2021) teigia, jog įmonės veiklos trukmė yra svarbus rizikos veiksnys – kuo trumpesnė įmonės gyvavimo istorija, tuo didesnė tikimybė, kad įmonė susidurs su sunkumais vykdydama įsipareigojimus. Be finansinių rodiklių ir įmonės gyvavimo metų Cheraghali (2018) į modelį taip pat įtraukė ir sektorių, regioną bei darbuotojų skaičių. Autorius teigia, jog iš šių nefinansinių rodiklių prie finansinės informacijos prognozavimo labiausiai prisidėjo sektorius, kadangi skirtingų sektorių įmonės gali nevienodai reaguoti į politinius, ekonominius ir rinkos pokyčius. Dėl šios priežasties į naująjį modelį įtraukiama sektoriaus

informacija. Kadangi kuriamo modelio tikslas – sukurti plačiai pritaikomą modelį, skirtą Lietuvoje veikiančioms įmonėms, į naująjį modelį nėra įtrauktas regionas, tačiau įtrauktas darbuotojų skaičius, kadangi Cheraghali (2018) teigia, jog šis kintamasis taip pat daro poveikį MVĮ kredito rizikos įvertinimo tikslumui.

Taigi, naujajame modelyje derinami finansiniai rodikliai su gyvavimo metais, sektoriaus informacija ir darbuotojų skaičiumi. Tai leidžia atsižvelgti į MVĮ specifinius iššūkius ir suteikia platesnį įmonių rizikos vertinimo pagrindą.

3 lentelė

Rodikliai, sudaryti iš Lietuvoje viešai prieinamos informacijos

Rodiklio rūšis	Formulė
Finansinio stabilumo	Įsipareigojimai / Turtas
	Įsipareigojimai / Nuosavas kapitalas
Likvidumo	Trumpalaikis turtas / Įsipareigojimai
Padengimo	Turtas / Įsipareigojimai
Pelningumo	Pelnas (nuostoliai) prieš mokesčius / Pardavimo pajamos
	Pelnas (nuostoliai) prieš mokesčius / Turtas
Veiklos efektyvumo	Pardavimų pajamos/Turtas
	Pardavimo pajamos / Darbuotojų skaičius
Nefinansiniai	Amžius
	Sektorius
	Darbuotojų skaičius

Parengta autorės, remiantis internetiniu Verslo žinių puslapiu rekvizitai.vz.lt bei Lietuvos Respublikos juridinių asmenų nemokumo įstatymu

Kuriant naują logistinės regresijos modelį, skirtą įvertinti Lietuvoje veikiančių MVĮ kredito riziką, remiamasi pagrindinėmis logistinės regresijos prielaidomis. Šios prielaidos leidžia tiksliai modeliuoti tikimybę, jog įmonė nevykdys savo įsipareigojimų, t. y. vadinamąją nemokumo tikimybę, remiantis nepriklausomų kintamųjų reikšmėmis (Savickienė ir Baliūnė, 2021). Logistinė

regresija yra tinkama, nes ji leidžia prognozuoti dviejų būsenų išvadą (pvz., ar įmonė susidurs su nemokumu, ar ne) pagal finansinius ir nefinansinius rodiklius.

Logistinės funkcijos formulė:

$$P = \frac{1}{1+e^{-z}} \quad (1)$$

kur:

P – priklausomas kintamasis, kuriuo matuojama kredito rizikos (nemokumo) tikimybė. Ši reikšmė visada yra tarp 0 ir 1, o tai leidžia interpretuoti rezultatą kaip tikimybę. Tokiu būdu galima įvertinti kiekvienos įmonės kredito riziką, leidžiant klasifikuoti jas į vykdančias ir nevykdančias įsipareigojimus;

e – konstanta 2,711828;

Z – tiesinės analizės funkcija:

$$Z = b_0 + b_1X_1 + b_2X_2 + \dots + b_iX_i \quad (2)$$

kur:

b_0 – konstanta;

X_i – nepriklausomas kintamasis, $i=1, \dots, n$;

b_i – koeficientas, išreiškiantis ryšį tarp priklausomo ir nepriklausomų kintamųjų, $i=1, \dots, n$.

Modelyje kiekvienai įmonei priskirta bendra reikšmė, atspindinti jos įsipareigojimų vykdymo būklę:

- „1“ – įmonės, kurios nevykdo savo įsipareigojimų, t. y., susidūrė su finansiniais sunkumais, tokiais kaip bankroto ar restruktūrizavimo procesų pradžia;

- „0“ – įmonės, kurios vykdo savo įsipareigojimus, t. y., jų finansinė būklė yra stabili ir jos neturi didesnių finansinių problemų.

Šis kodavimas leidžia logistinės regresijos modeliu prognozuoti tikimybę, jog tiriamą įmonę pateks į vieną iš šių dviejų kategorijų, remiantis nepriklausomais kintamaisiais. Tokiu būdu galima tiksliai atskirti rizikingas įmones nuo nerizikingų ir įvertinti jų kredito riziką.

Modelyje naudojamų kintamųjų parinkimas:

Atliekant tyrimą ir sudarant kredito rizikos modelį Lietuvoje veikiančioms MVĮ naudojama duomenų analizės sistema RStudio. Ši sistema leidžia efektyviai apdoroti ir analizuoti duomenis, atlikti modelių sudarymo, tikslumo ir kokybės vertinimo procedūras. Tyrimas pradedamas naudojant finansinius ir nefinansinius rodiklius, nurodytus 3 lentelėje. Kintamųjų atranka modeliui vykdoma etapais, kai mažiau reikšmingi kintamieji yra laipsniškai šalinami iš modelio tol, kol modelyje lieka tik tie kintamieji, kurie turi statistiškai reikšmingą įtaką Lietuvoje veikiančių MVĮ kredito rizikos įvertinimui, atsižvelgiant į 95 % reikšmingumo lygį.

Koreliacijos tikrinimas:

Galutiniame modelyje tikrinama kintamųjų tarpusavio koreliacija, siekiant išvengti klaidingų ryšių ir netikslumų. Aukšta koreliacija laikoma tuomet, kai kintamųjų koreliacijos koeficientas yra didesnis nei +0,7 arba mažesnis nei -0,7, o tai gali rodyti, jog kintamieji pernelyg stipriai priklauso vieni nuo kitų (Sousa ir kt., 2022). Tokio pobūdžio koreliacija gali reikšti multikolinearumo problemą, kai modelyje tam tikri kintamieji dubliuoja informaciją, todėl sumažėja modelio tikslumas ir prognozavimo efektyvumas.

Multikolinearumo tikrinimas:

Multikolinearumo problema yra tikrinama naudojant VIF metodą, kuris leidžia nustatyti, ar modelyje nėra per didelio koreliuojančių kintamųjų poveikio. Siekiant išvengti multikolinearumo, kiekvieno kintamojo VIF turi būti mažesnis nei 10. Jei šis rodiklis viršija 10, tai signalizuoja apie per didelį kintamųjų tarpusavio priklausomumą, dėl kurio modelis gali tapti nestabilus ar mažiau patikimas (Sousa ir kt., 2022).

Modelio kokybės vertinimas:

Modelio kokybė įvertinama naudojant R^2 rodiklį, kuris parodo, kiek modelio paaiškinta variacija atitinka realius duomenis. Teigiama, jog kuo didesnė R^2 reikšmė, tuo tiksliau modelis prognozuoja įmonės riziką. Aukšta R^2 reikšmė rodo, kad modelis geba patikimai numatyti priklausomo kintamojo, šiuo atveju Lietuvoje veikiančių MVĮ kredito rizikos, pokyčius, atsižvelgiant į nagrinėjamame modelyje naudojamus nepriklausomus kintamuosius (Sousa ir kt., 2022).

Modelio tinkamumo vertinimas naudojant Hosmer - Lemeshow testą:

Naujasis modelis taip pat įvertintas naudojant Hosmer – Lemeshow testą, kuris yra vienas iš pagrindinių metodų, skirtų logistinės regresijos modelio tinkamumui įvertinti. Šis testas leidžia nustatyti, ar nėra statistiškai reikšmingų skirtumų tarp stebėtų ir prognozuotų reikšmių, o tai yra esminis žingsnis vertinant modelio pritaikomumą ir patikimumą. Modelio prognozuotų tikimybių duomenys suskirstomi į 10 grupių pagal jų reikšmes, užtikrinant vienodą stebėjimų pasiskirstymą grupėse. Tai leidžia tiksliai palyginti prognozuotas tikimybes su stebėtais rezultatais kiekvienoje grupėje. Testo rezultatai interpretuojami pagal p – reikšmę, gautą atliekant šį testą. Jei p – reikšmė yra didesnė nei 0,05, laikoma, kad nėra statistiškai reikšmingų skirtumų tarp stebėtų ir prognozuotų reikšmių, todėl modelis laikomas tinkamu ir gerai atitinkančiu duomenis (Jawa, 2022).

Modelio tikslumo patikrinimas:

Sudarius modelį yra atliekamas jo prognozių tikslumo patikrinimas, siekiant nustatyti, kiek tiksliai jis gali prognozuoti Lietuvoje veikiančių MVĮ kredito riziką. Tam tikslui modelio prognozės apie įmonės statusą po metų yra lyginamos su tikrąja įmonės būseną – ar įmonė vykdo įsipareigojimus (statusas „0“), ar nevykdo (statusas „1“). Tokiu būdu apskaičiuojamas teisingai numatytų atvejų procentas, kuris leidžia įvertinti, kaip tiksliai modelis nustato kredito riziką (Wu, 2023):

$$\text{Tikslumas} = \frac{TP + TN}{TP + TN + FP + FN} * 100\% \quad (3)$$

kur:

- TP (angl. True Positives) – teisingai identifikuotos įmonės, kurios nevykdo įsipareigojimų (modelis prognozavo „1“ ir tikrasis statusas yra „1“).
- TN (angl. True Negatives) – teisingai identifikuotos įmonės, kurios vykdo įsipareigojimus (modelis prognozavo „0“ ir tikrasis statusas yra „0“).
- FP (angl. False Positives) – klaidingai identifikuotos įmonės, kurios vykdo įsipareigojimus (modelis prognozavo „1“, bet tikrasis statusas yra „0“).
- FN (angl. False Negatives) – klaidingai identifikuotos įmonės, kurios nevykdo įsipareigojimų (modelis prognozavo „0“, bet tikrasis statusas yra „1“).

Be to, siekiant dar tiksliau įvertinti modelio prognozių kokybę, analizuojamas ROC kreivės plotas po kreive (AUC). Jei šis rodiklis yra didesnis nei 0,9, modelis laikomas itin našiu, t. y., gebančiu patikimai atskirti įsipareigojimus vykdančias ir nevykdančias įmones (Sousa ir kt., 2022).

Toliau antroje tyrimo dalyje turėtų būti įvertinami ir tarpusavyje lyginami nagrinėjamų modelių kredito rizikos tikslumai, tačiau jau metodikoje išanalizavus kiekvieno nagrinėjamo modelio, tinkamo įvertinti MVĮ kredito riziką, naudojamą informaciją nustatyta, jog modeliuose yra duomenų, kurie nėra Lietuvoje viešai prieinami, tad norint įvertinti MVĮ kredito riziką naudojant tik viešai prieinamą informaciją šiais modeliais pasinaudoti yra neįmanoma – viešai prieinamoje informacijoje nėra duomenų apie įmonės nepaskirstytą pelną, EBIT, EBITDA, nematerialųjį turtą, palūkanų išlaidas, darbo užmokesčio sąnaudas bei nusidėvėjimą, tad nagrinėjami modeliai negalės būti taikomi naudojant viešai prieinamą informaciją bei modelių tikslumai negalės būti tiesiogiai lyginami su naujo sukurto modelio tikslumu.

4 lentelė

Nagrinėjamų kredito rizikos modelių formulės bei kintamieji

Grupė	Modelis	Formulė	Kintamieji
Logistinė regresija	Altman ir Sabato (2005)	Žinoma tikimybė gerai įmonei (angl. Known Probability of Being Good) $KPG = 53,48 + 4,09 * X_1 -$	$X_1 - \ln(1 - EBITDA / \text{Turtas});$ $X_2 - \ln(\text{Trumpalaikiai įsipareigojimai} / \text{Nuosavybė});$ $X_3 - \ln(1 - \text{Nepaskirstytas pelnas} / \text{Turtas});$

		$1,13 * X_2 + 4,32 * X_3 + 1,84 * X_4 + 1,97 * X_5$	$X_4 - \ln(\text{Pinigai} / \text{Turtas});$ $X_5 - \ln(\text{EBITDA} / \text{Išlaidos palūkanoms apmokėti})$
Tiesinė diskriminantinė	Springate (1978)	$S = 1,03 * X_1 + 3,07 * X_2 + 0,66 * X_3 + 0,4 * X_4$	$X_1 - \text{Apyvartinis kapitalas} / \text{Turtas};$ $X_2 - \text{EBIT} / \text{Turtas};$ $X_3 - \text{EBIT} / \text{Trumpalaikiai įsipareigojimai};$ $X_4 - \text{Pardavimų pajamos} / \text{Turtas}.$
Logistinė regresija	Cheraghali (2018)	$P = 1 / (1 + e^{-Z}),$ kur $Z = 14,11 * X_1 + 156,5 * X_2 + 0,0552 * X_3 + 5,138 * X_4 + 0,0135 * X_5 + 1,4 * X_6 + 0,0278 * X_7 + 0,977 * X_8 + 1 * X_9 + 0,816 * X_{10} + 1,544 * X_{11} + 1,52 * X_{12} + 1,103 * X_{13} + 0,249 * X_{14} + 0,682 * X_{15} + 0,99 * X_{16} + 0,647 * X_{17}$	$X_1 - \text{Įsipareigojimai} / \text{Turtas};$ $X_2 - \text{Mokesčiai} / \text{Turtas};$ $X_3 - \text{Pinigai} / \text{Turtas};$ $X_4 - \text{Nematerialus turtas} / \text{Turtas};$ $X_5 - \text{Pelnas prieš apmokestinimą} / \text{Turtas};$ $X_6 - \text{Darbo užmokesčio sąnaudos} / \text{Turtas};$ $X_7 - \text{Nusidėvėjimas} / \text{Turtas};$ $X_8 - \text{Amžius};$ $X_9 - \text{Sektorius} - \text{žemdirbystė};$ $X_{10} - \text{Sektorius} - \text{laivyba};$ $X_{11} - \text{Sektorius} - \text{transportas};$ $X_{12} - \text{Sektorius} - \text{gamyba};$ $X_{13} - \text{Sektorius} - \text{technologijų};$ $X_{14} - \text{Sektorius} - \text{elektros tiekėjų};$ $X_{15} - \text{Sektorius} - \text{statybų};$ $X_{16} - \text{Sektorius} - \text{prekybos};$ $X_{17} - \text{Sektorius} - \text{kita}.$
	Lisboa ir kt. (2021)	$\text{Įsipareigojimų nevykdymo tikimybė } P = (1 + \exp \{ - [- 2.6114 - 0.5833 * X_1 + 3.0395 * X_2 + 0.8360 * X_3 - 0.7798 * X_4 - 0.0517 * X_5 - 0.6449 * X_6 + 0.0967 * X_7] \})^{-1}$	$X_1 - \text{Nepaskirstytas pelnas} / \text{Turtas};$ $X_2 - \text{Įsipareigojimai} / \text{Turtas};$ $X_3 - \text{Ilgalaikiai įsipareigojimai} / \text{Turtas};$ $X_4 - \text{Pardavimų pajamos} / \text{Turtas};$ $X_5 - \text{Veiklos pinigų srautai} / \text{Turtas};$

			$X_6 - \ln(\text{Amžius});$ $X_7 - \ln(\text{Amžius})^2.$
--	--	--	--

Parengta autorės, remiantis Altman ir Sabato (2005), Cheraghali (2018), Lisboa ir kt., (2021) bei Supitriyani ir kt., (2022).

Taigi, atlikus darbo metodiką ir išnagrinėjus autorių naudojamus modelius, kurie galėtų būti naudojami MVĮ kredito rizikai įvertinti, nustatyta, jog nagrinėjamuose modeliuose yra naudojami duomenys, kurie nėra viešai prieinami, tad tyrime jie nebus naudojami, kadangi tyrimo principas – naudoti tik viešai prieinamą informaciją. Todėl tyrimas orientuotas į vieną pagrindinę užduotį – sukurti naują kredito rizikos modelį, skirtą Lietuvoje veikiančioms MVĮ, naudojant tik viešai prieinamą informaciją, jog modelis būtų laisvai ir plačiai pritaikomas.

3. MAŽŲ IR VIDUTINIŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO TYRIMAS

Taigi, kaip minėta metodikoje, tyrimas fokusuojasi į naujo kredito rizikos modelio, skirto Lietuvoje veikiančioms MVĮ įvertinti, sukūrimą, kadangi autorių analizuojami modeliai, naudoti įvertinti MVĮ kredito riziką, yra sudaryti iš informacijos, kuri viešai nėra prieinama. Dėl šios priežasties kitų autorių modeliai nebus pritaikomi Lietuvoje veikiančioms MVĮ, kadangi pagrindinis tyrimo tikslas – sukurti kredito rizikos vertinimo modelį, remiantis tik viešai prieinamais finansiniais ir nefinansiniais rodikliais, siekiant užtikrinti modelio universalumą, paprastą taikymą ir galimybę jį naudoti įvairioms suinteresuotoms šalims, tokioms kaip tiekėjai, verslo partneriai, investuotojai ar pačioms MVĮ. Nors ES bankai privalo naudoti ECB patvirtintus sudėtingus vidiniais reitingais pagrįstus modelius (angl. IRB models) ar ECB standartizuotus modelius (ECB, 2024), šiame darbe sukurtas modelis gali būti vertingas kaip papildomas įrankis pradiniam kredito rizikos vertinimo etape. Tai padėtų bankams greitai identifikuoti mažesnės rizikos paraiškas ar MVĮ grupes, kurias reikia vertinti išsamiau, o nebankiniams subjektams, kaip tiekėjams ar investuotojams, – įvertinti finansinės partnerystės riziką remiantis viešai prieinamais duomenimis. Modelis taip pat teikia svarbią naudą pačioms MVĮ, nes leidžia įmonėms savarankiškai įvertinti savo kredito riziką, identifikuoti silpnas finansinės veiklos sritis ir, esant poreikiui, laiku imtis veiksmų rizikos mažinimui. Be to, aiškus ir objektyvus rizikos įvertinimas gali padėti MVĮ efektyviau pasiruošti kreditavimo procesui ir didinti pasitikėjimą išorės finansuotojų bei verslo partnerių akyse.

Naujo modelio sudarymas prasidėjo išsamia rodiklių, galinčių turėti įtakos MVĮ kredito rizikai, analize. Tyrimo metu pradinis logistinės regresijos modelis sudarytas naudojant visus 5 lentelėje nurodytus kintamuosius. Šis modelis apėmė tiek finansinius rodiklius, tokius kaip likvidumo koeficientas, pelningumo rodikliai ar skolos lygis, tiek nefinansinius rodiklius, tokius kaip įmonės veiklos sektorius, gyvavimo trukmė bei darbuotojų skaičius. Šių rodiklių įtraukimas leido užtikrinti, kad modelis neapsiribotų vien tik finansiniais duomenimis, bet atsižvelgtų ir į platesnį kontekstą, kuriame veikia MVĮ, taip padidinant jo tikslumą ir praktinę vertę. Vėliau pradėta rodiklių atranka siekiant suformuoti galutinį modelį, kuriame liktų tik statistiškai reikšmingi rodikliai. Šiam tikslui naudojamas kintamųjų pašalinimo metodas, kai mažiausiai reikšmingi rodikliai šalinami vienas po kito, atsižvelgiant į jų p – reikšmes. Modelyje palikti tik tie kintamieji, kurių p – reikšmės mažesnės nei 0,05, užtikrinant 95 % patikimumo intervalą. Šis

procesas leido ne tik supaprastinti modelį, bet ir padidinti jo efektyvumą, nes tokiu būdu pašalinami rodikliai, kurie neturi reikšmingos įtakos priklausomajam kintamajam – kredito rizikai (nemokumui). Atrinkus statistiškai reikšmingus rodiklius buvo pastebėta, jog rodikliai Įsipareigojimai / Turtas (rodiklis remiantis Lietuvos Respublikos juridinių asmenų nemokumo įstatymu) bei Turtas / Įsipareigojimai (vienintelis modelyje padengimo rodiklis) liko modelyje, abu reikšmingi ir gali koreliuoti. Todėl iš šių rodiklių galutiniam modelyje buvo paliktas tik rodiklis Įsipareigojimai / Turtas dėl įstatymo svarumo. Atrinkti rodikliai yra paryškinti 5 lentelėje. Tai rodikliai, kurie geriausiai atspindi Lietuvoje veikiančių MVĮ kredito riziką. Tuo tarpu neparyškinti rodikliai, nepaisant jų potencialios naudos, pašalinti iš galutinio modelio dėl jų nedidelės statistinės reikšmės.

5 lentelė

Naujojo modelio kūrime naudojami rodikliai

Rodiklio rūšis	Formulė
Finansinio stabilumo	Įsipareigojimai / Turtas
	Įsipareigojimai / Nuosavas kapitalas
Likvidumo	Trumpalaikis turtas / Įsipareigojimai
Padengimo	Turtas / Įsipareigojimai
Pelningumo	Pelnas (nuostoliai) prieš mokesčius / Pardavimo pajamos
	Pelnas (nuostoliai) prieš mokesčius / Turtas
Veiklos efektyvumo	Pardavimų pajamos/Turtas
	Pardavimo pajamos / Darbuotojų skaičius
Nefinansiniai	Amžius
	Sektorius
	Darbuotojų skaičius

Sudaryta autorės, remiantis darbe atliktu tyrimu

Tačiau, atsižvelgiant į didesnę modelio tikslumą, nuspręsta modelyje palikti visų, net ir įvardijamų kaip statistiškai nereikšmingų, sektorių informaciją. Šis sprendimas priimtas dėl to, kadangi kokybiniai sektorių kintamieji kuria didelę pridėtinę vertę modelio tikslumui –

papildomai atlikta analizė parodė, jog išmetus sektorių kintamuosius iš galutinio modelio tikslumas sumažėtų iki 89,76%, R2 sumažėtų iki 57,27%, plotas po ROC kreive (AUC) sumažėtų iki 93,01% bei padidėtų AIC ($253,82 < 314,9$). Tokia situacija pabrėžia sektorių svarbą ir indėlį į modelio galutinį prognozavimo pajėgumą.

Svarbu paminėti, jog vienas sektorius privalo būti išmestas iš modelio, siekiant išvengti vadinamųjų „fiktyviųjų kintamųjų spąstų“ (angl. dummy variable trap). Todėl būtina pašalinti vieną kintamąjį – tai leidžia kitų sektorių poveikį analizuoti lyginant su pasirinktu lyginamuoju sektoriumi (Mohan, 2023). Modelyje Sektorius2 (Chemikalų ir chemijos produktų gamyba) pasirinktas kaip lyginamasis sektorius, todėl jis nėra tiesiogiai įtrauktas į modelio lygtį. Šio sektoriaus pasirinkimas grindžiamas jo vidutine pozicija pagal bankrotų atvejų skaičių – jis neišsiskiria kaip sektorius su itin aukštu ar itin žemu bankrotų dažniu analizuojamuose duomenyse. Tokia pozicija užtikrina, kad sektorius būtų tinkamas kaip bazė, su kuria gali būti lyginami kitų sektorių poveikiai bankroto tikimybei. Pasirinkus Sektorių2 kaip lyginamąjį sektorių, užtikrinama tinkama modelio identifikacija ir pašalinama multikolinearumo problema, kylanti dėl visiškos fiktyviųjų kintamųjų tarpusavio priklausomybės.

6 lentelė

Modelyje naudojamų sektorių pavadinimai

Sektoriaus kodas	Sektoriaus pavadinimas
0	Žemės ūkis, miškininkystė ir žuvininkystė
1	Apdirbamoji gamyba
2	Chemikalų ir chemijos produktų gamyba
3	Kitų transporto priemonių ir įrangos gamyba
4	Statyba
5	Vandens transportas
6	Programų rengimas ir transliavimas
7	Pagrindinių buveinių veikla; konsultacinė valdymo veikla
8	Apsaugos ir tyrimo veikla
9	Kūrybinė, meninė ir pramogų organizavimo veikla

Parengta autorės remiantis Oficialiosios statistikos portalu (2024)

Remiantis Lisboa ir kt. (2021) atliktu tyrimu, nefinansinis skaitinis kintamasis „Darbuotojų skaičius“ modelyje logaritmuotas siekiant užtikrinti didesnę tikslumą. Logaritminė transformacija leido geriau atspindėti santykinį pokytį tarp kintamųjų, sumažinant reikšmingų skirtumų įtaką, kurie galėjo sukelti modelio šališkumą. Šis metodas padėjo pagerinti modelio prognozavimo pajėgumą, kartu užtikrinant tikslumą, reikalingą MVĮ kredito rizikos vertinime.

Reikšmingumo žymėjimas prie kintamųjų naudojamas norint pabrėžti, kiek stipriai nepriklausomi kintamieji (pvz., X_1 , X_2 ir t.t.) yra susiję su priklausomu kintamuoju. Dažniausiai jos nurodo p – vertės reikšmę, kuri leidžia nustatyti, ar rezultatas yra statistiškai reikšmingas.

Šiame tyrime žymimi reikšmingumai:

- *** (trys žvaigždutės): p – vertė $< 0,001$;
- ** (dvi žvaigždutės): p – vertė $< 0,01$;
- * (viena žvaigždutė): p – vertė $< 0,05$.

7 lentelė

Sudaryto naujo logistinės regresijos modelio kintamieji bei formulė

$P = \frac{1}{1 + e^{-Z}}$, kai Z yra;		
$Z = 4,569 + 0,9665 * X_1 + 0,07586 * X_2 - 1,118 * X_3 - 1,428 * X_4 - 0,001310 * X_5 + 1,446 * X_6 + 1,643 * X_7 + 2,156 * X_8 + 0,4644 * X_9 + 2,155 * X_{10} + 2,954 * X_{11} + 1,134 * X_{12} + 6,586 * X_{13} + 3,461 * X_{14} - 1,964 * X_{15}$		
X_1	Įsipareigojimai / Turtas	***
X_2	Įsipareigojimai / Nuosavas kapitalas	***
X_3	Pelnas (nuostoliai) prieš apmokestinimą / Pardavimų pajamos	*
X_4	Pelnas (nuostoliai) prieš apmokestinimą / Turtas	***
X_5	Pardavimų pajamos / Darbuotojų skaičius	***
X_6	Sektorius0	
X_7	Sektorius1	

X ₈	Sektorius3	*
X ₉	Sektorius4	
X ₁₀	Sektorius5	
X ₁₁	Sektorius6	**
X ₁₂	Sektorius7	
X ₁₃	Sektorius8	***
X ₁₄	Sektorius9	
X ₁₅	ln(Darbuotojų skaičius)	***

Parengta autorės remiantis atlikto tyrimo rezultatais

X₁ – Įsipareigojimai / Turtas yra vienas reikšmingiausių rodiklių, didinančių bankroto tikimybę. Šis rezultatas atitinka tiek teorines prielaidas, tiek ankstesnių tyrimų rezultatus, kur Cheraghali (2018) ir Lisboa ir kt. (2021) modeliuose šis rodiklis buvo pabrėžtas kaip vienas svarbiausių vertinant įmonės mokumo riziką. Aukštas įsipareigojimų ir turto santykis rodo didelę skolų našą ir prastesnę įmonės finansinę padėtį, nes didesnis skolų kiekis mažina įmonės gebėjimą įgyvendinti savo finansinius įsipareigojimus bei tampa potencialiu rizikos veiksniu esant ekonominiams svyravimams.

X₂ – Įsipareigojimai / Nuosavas kapitalas taip pat didina kredito riziką. Rodiklis parodo, kokia dalis įmonės turto yra finansuojama skolintomis lėšomis, palyginti su nuosavu kapitalu. Aukštesnis šio rodiklio lygis signalizuoja apie didesnę priklausomybę nuo skolinto kapitalo, o tai gali kelti papildomą riziką įmonės finansiniam stabilumui, ypač jei sumažėtų pajamų srautai ar padidėtų finansavimo sąnaudos. Šis rodiklis taip pat naudojamas Altman ir Sabato (2005) modelyje, kur jis išskiriamas kaip svarbus įmonės finansinės rizikos vertinimo kriterijus.

X₃ – Pelnas (nuostoliai) prieš apmokestinimą / Pardavimų pajamos yra rodiklis, kuris mažina kredito rizikos (nemokumo) tikimybę. Didėjant pelningumui prieš apmokestinimą, įmonė tampa stabilesnė ir finansiškai atsparesnė, nes sugeba efektyviau kontroliuoti veiklos sąnaudas ir generuoti grynąsias pajamas, užtikrinančias ilgalaikį veiklos tęstinumą. Šis rodiklis nėra naudojamas kituose nagrinėtuose modeliuose, tačiau jo reikšmė kuriamame kredito rizikos

modelyje yra ypatingai svarbi, kadangi padeda tiksliau įvertinti įmonės gebėjimą vykdyti finansinius įsipareigojimus.

X_4 – Pelnas (nuostoliai) prieš apmokestinimą / Turtas taip pat mažina bankroto tikimybę. Didėjantis pelnas rodo įmonės gebėjimą generuoti grynąsias pajamas ir efektyviai naudoti savo turtą, o tai leidžia ne tik stabilizuoti finansinius srautus, bet ir sumažina priklausomybę nuo skolinto kapitalo. Šis rodiklis naudojamas Cheraghali (2018) modelyje, kuris pabrėžia jo reikšmę vertinant įmonės pelningumą kaip stabilumo indikatorius.

X_5 – Pardavimų pajamos / Darbuotojų skaičius yra rodiklis, mažinantis bankroto tikimybę, nes didesnės pajamos vienam darbuotojui rodo aukštesnį darbo našumą ir efektyvų išteklių naudojimą. Šis rodiklis leidžia identifikuoti įmones, kurios geba generuoti didesnę pridėtinę vertę su turimais resursais, o tai tiesiogiai prisideda prie jų finansinio stabilumo ir konkurencingumo rinkoje. Šio rodiklio naudojimas kituose modeliuose nėra nurodytas, tačiau jo įtraukimas į dabartinį modelį parodo jo svarbą efektyvumo vertinime.

$X_6 - X_{14}$ – remiantis modelio rezultatais, referencinis sektorius (sektorius2 – Chemikalų ir chemijos produktų gamyba) buvo pasirinktas kaip lyginamoji bazė, su kuria vertinami kitų sektorių nemokumo tikimybės pokyčiai. Rezultatai rodo, jog skirtingų sektorių rizika bankrotui yra nevienoda. Lyginant su lyginamuoju sektoriumi, didžiausią nemokumo tikimybę turi apsaugos ir tyrimo veikla (6,586 karto didesnė) ir statybų sektorius (4,644 karto didesnė). Priešingai, mažiausią riziką lyginant su referenciniu sektoriumi rodo pagrindinių buveinių veikla ir konsultacinės valdymo veikla (1,134 karto didesnė). Šie rezultatai pabrėžia, kad tam tikri sektoriai, tokie kaip apsaugos ir tyrimo veikla ar statybos, yra labiau pažeidžiami ekonominių veiksmų, o kiti, pavyzdžiui, chemikalų gamyba ar konsultacinė veikla, pasižymi santykinai mažesne rizika. Sektorių informacija taip pat buvo įtraukta ir į Cheraghali (2018) sukurtą modelį,

$X_{15} - \ln(\text{Darbuotojų skaičius})$ mažina bankroto tikimybę, nes didesnės organizacijos dėl masto ekonomijos gali veikti efektyviau ir patikimiau. Didelis darbuotojų skaičius taip pat rodo įmonės gebėjimą palaikyti veiklos apimtį ir stabilumą, o tai dažnai siejama su stipresne rinkos pozicija ir didesniu pasitikėjimu iš kreditorių bei investuotojų pusės. Šis rodiklis buvo nagrinėjamas įtraukti į Cheraghali (2018) modelį, kuriame darbuotojų skaičius vertinamas kaip vienas iš įmonės augimo ir ilgalaikio stabilumo indikatorius.

Atrenkant rodiklius į galutinį modelį taip pat patikrinta, ar tarp atrinktų rodiklių nėra stiprios tarpusavio koreliacijos. Tikslas – užtikrinti, kad modelis liktų stabilus ir patikimas, kadangi stipriai koreliuojantys kintamieji gali sukelti multikolinearumo problemą, dėl kurios modelio prognozės gali tapti netikslios ar nestabilios. Atlikus kintamųjų koreliacijos analizę

nustatyta, kad Įsipareigojimai / Turtas ir Pelnas (nuostoliai) prieš apmokestinimą / Turtas koreliacijos koeficientas yra gan aukštas, bet neviršija 0,7, o tai rodo, kad ryšys tarp šių kintamųjų nėra pakankamai stiprus, jog juos reikėtų laikyti itin koreliuojančiais (Sousa ir kt., 2022). Dėl to kintamieji įtraukti į galutinį modelį kaip nepriklausomi rodikliai.

8 lentelė

Naujo modelio kintamųjų koreliacija

	Įsipareigojimai / Turtas	Įsipareigojimai / Nuosavas kapitalas	Pelnas (nuostoliai) prieš mokesčius / Pardavimų pajamos	Pelnas (nuostoliai) prieš apmokestinimą / Turtas	Pardavimo pajamos / Darbuotojai	ln (Darbuotojų skaičius)
Įsipareigojimai / Turtas	1.000					
Įsipareigojimai / Nuosavas kapitalas	-0.030	1.000				
Pelnas (nuostoliai) prieš mokesčius / Pardavimų pajamos	-0.168	-0.004	1.000			
Pelnas (nuostoliai) prieš apmokestinimą / Turtas	-0.699	0.024	0.160	1.000		
Pardavimo pajamos / Darbuotojai	-0.034	0.111	0.027	0.035	1.000	
ln(Darbuotojų skaičius)	-0.172	-0.008	0.128	0.130	-0.145	1.000

Parengta autorės remiantis atlikto tyrimo rezultatais

VIF rodiklis kiekvienam kintamajam apskaičiuotas siekiant įvertinti, ar nėra per didelio ryšio tarp nepriklausomų kintamųjų. Kintamasis laikomas problemišku dėl multikolinearumo, jei jo VIF reikšmė viršija 10, nes tai reiškia, kad jis gali turėti stiprų ryšį su kitais modelyje esančiais kintamaisiais. Tačiau atlikus skaičiavimus šiame tyrime, nustatyta, kad nei vieno modelyje esančio

kintamojo VIF reikšmė nesiekia 10. Šis rezultatas patvirtina, kad multikolinearumo problema modelyje išvengta (Sousa ir kt., 2022). Statybų sektoriaus VIF reikšmė yra didžiausia (6.02), o tai gali būti paaiškinama ne tik šio sektoriaus reikšmingumu ekonomikoje ir jautrumu ekonominiams ciklams, bet ir tuo, kad šio sektoriaus stebėtų reikšmių modelyje buvo daugiau nei kitų sektorių. Nepaisant to, ši reikšmė neviršija kritinės ribos (>10), todėl galima teigti, kad multikolinearumo problema modelyje yra išvengta.

9 lentelė

Naujo modelio kintamųjų VIF


Rodiklis	VIF
Įsipareigojimai / Turtas	1,22
Įsipareigojimai / Nuosavas kapitalas	2,24
Pelnas (nuostoliai) prieš apmokestinimą / Pardavimų pajamos	1,34
Pelnas (nuostoliai) prieš apmokestinimą / Turtas	1,39
Pardavimo pajamos / Darbuotojai	2,79
Sektorius0	1,86
Sektorius1	3,03
Sektorius3	2,68
Sektorius4	6,02
Sektorius5	2,03
Sektorius6	2,15
Sektorius7	1,78
Sektorius8	2,14
Sektorius9	1,00
ln (Darbuotojų skaičius)	2,16

Parengta autorės remiantis atlikto tyrimo rezultatais

Sukurto naujo kredito rizikos modelio, skirto Lietuvoje veikiančioms MVĮ, plotas po ROC kreive (AUC) siekia 0,96. Ši reikšmė rodo, kad modelis pasižymi aukštu našumu. Remiantis įprasta interpretacija, AUC reikšmė, viršijanti 0,9, laikoma labai geru modelio kokybės rodikliu, nes tai reiškia, jog modelis efektyviai atskiria skirtingas kategorijas – šiuo atveju mokia ir nemokia įmonės (Sousa ir kt., 2022).

8 paveikslas

Naujo modelio plotas po ROC kreive (AUC)



Parengta autorės remiantis atlikto tyrimo rezultatais

Modelis taip pat buvo įvertintas naudojant Hosmer – Lemeshow tinkamumo testą, kurio rezultatai parodė, kad p – reikšmė yra 0,0896. Kadangi ši reikšmė yra didesnė nei 0,05, galima konstatuoti, jog nėra statistiškai reikšmingų skirtumų tarp stebėtų ir prognozuotų reikšmių. Tai rodo, kad modelio prognozės patikimai atitinka faktinius stebėjimus, todėl modelis gali būti laikomas tinkamu analizuojamiems duomenims. Hosmer – Lemeshow testo rezultatai sustiprina modelio pagrįstumą ir užtikrina, kad jis tinkamai atspindi priklausomojo kintamojo elgseną pagal nepriklausomus kintamuosius (Jawa, 2022).

Taigi, atlikus naujo kredito rizikos modelio, skirto Lietuvoje veikiančioms MVĮ, kūrimą ir įvertinimą, galima daryti išvadą, jog modelis yra tinkamas ir veiksmingas praktiniam naudojimui.

Modelio našumas įvertintas pagal ROC kreivės plotą (AUC), kuris siekia 96,07 %. Tokia reikšmė rodo puikų modelio gebėjimą atskirti mokias ir nemokias įmones, o tai yra itin svarbu vertinant kredito riziką. Be to, R^2 reikšmė yra 68,5 %, o tai reiškia, jog modelis gerai atitinka duomenis ir turi aukštą interpretacinę vertę. Modelio tikslumas, siekiantis 93,11 %, dar labiau patvirtina jo patikimumą. Ši reikšmė reiškia, kad didžioji dalis modelio prognozių yra teisingos. Be to, atlikta koreliacinė analizė ir multikolinearumo vertinimas (VIF) patvirtino, jog modelis neturi multikolinearumo problemos, todėl visi į modelį įtraukti kintamieji yra pagrįsti. Taip pat Hosmer – Lemeshow testo rezultatai parodė, jog modelio prognozės gerai atitinka stebėtus duomenis, kas dar labiau sustiprina modelio tinkamumą. Todėl šis modelis gali būti naudojamas kaip efektyvus ir patikimas įrankis Lietuvoje veikiančių MVĮ kredito rizikos vertinimui.

10 lentelė

Naujo modelio reikšmės

	Tikslumas	ROC	R^2
Naujas modelis	93,11%	0,96	68,5%

Parengta autorės remiantis atlikto tyrimo rezultatais

Taigi, įvertinus naujo modelio tikslumą vertinant Lietuvoje veikiančių MVĮ kredito riziką galima teigti, jog jis yra veiksmingas. Nors nėra tikslinga tiesiogiai lyginti šį modelį su kitų autorių sukurtų modelių pasiektais tikslumais, kadangi tyrimai buvo atliekami naudojant skirtingus tyrimų laikotarpius ir pritaikyti skirtingoms rinkoms bei sektoriams, tačiau sukūrus naują modelį svarbu suprasti, ar pasiektas tikslumas yra laikomas aukštu pagal analogiškus tyrimus. Lyginant naują sudarytą logistinį modelį su kitais, naudotais analizuoti MVĮ kredito riziką, modeliais, pastebėta, jog naujasis modelis pasižymi didžiausiu tikslumu. Be to, naujasis modelis pasižymi ypač lengvu pritaikomumu, nes jis sudarytas tik iš viešai prieinamų duomenų. Tai yra svarbus modelio privalumas, nes eliminuojamos problemos, susijusios su ribota duomenų prieiga, kuri dažnai trukdo pritaikyti kitų autorių sukurtus modelius praktikoje – dėl šios problemos ir nebuvo galima atlikti 11 lentelėje nurodytų kitų autorių modelių. Naujojo modelio universalumas ir pritaikomumas daro jį itin naudingą įrankiu ne tik kreditoriams, bet ir kitoms suinteresuotoms šalims, tokioms kaip tiekėjai ar partneriai, kurie siekia įvertinti finansinį stabilumą bendradarbiaujant su MVĮ bei, žinoma, pačiai MVĮ.

11 lentelė

Naujo ir kitų naudojamų analizuoti MVĮ kredito riziką modelių tikslumo palyginimas

Autorius/modelis	Modelio tikslumas
Kiyak ir Labanauskaitės (2012) pritaikytas Springate (1978) Lietuvoje veikiančioms MVĮ	85,71%
Altman ir Sabato (2005)	87,22 %
Cheraghali (2018)	82,70 %
Lisboa ir kt. (2021)	88,74 %
Naujas modelis	93,11 %

Parengta autorės remiantis atlikto tyrimo rezultatais ir literatūros analizėje nagrinėtais autoriais

Taigi, atlikto tyrimo rezultatai parodo, kad naujai sukurtas logistinės regresijos modelis yra ne tik itin tikslus, bet ir lengvai pritaikomas vertinant Lietuvoje veikiančių MVĮ kredito riziką. Modelio tikslumas, siekiantis 93,11 %, yra aukščiausias lyginant su kitais analogiškais modeliais, o tai patvirtina, jog šis modelis yra tinkamiausias ir veiksmingiausias Lietuvoje veikiančioms MVĮ. Šis aukštas tikslumo lygis užtikrina, kad dauguma prognozių bus teisingos. Viena iš svarbiausių modelio savybių yra jo lengvas pritaikomumas, kadangi jis remiasi tik viešai prieinamais duomenimis. Tai suteikia modeliui reikšmingą pranašumą praktikoje, nes jį įmanoma naudoti net tuomet, kai nėra prieigos prie išsamesnės ar konfidencialios informacijos apie įmonių finansinę būklę. Ši ypatybė ypač aktuali MVĮ, kurios dažnai susiduria su ribotomis galimybėmis teikti išsamius finansinius duomenis. Be to, atlikus koreliacijos analizę ir įvertinus multikolinearumo problemą, patvirtinta, jog naujasis modelis neturi didelių koreliacijos problemų arba multikolinearumo rizikos, kas padidina jo patikimumą ir naudingumą praktikoje. Modelis buvo įvertintas naudojant Hosmer – Lemeshow tinkamumo testą, kurio rezultatai patvirtino, jog nėra statistiškai reikšmingų skirtumų tarp stebėtų ir prognozuotų reikšmių, o tai rodo, kad modelis gerai atitinka duomenis. Taip pat nustatyta, jog modelio AUC siekia netgi 96%, kas yra dar vienas įrodymas, jog modelis pasižymi ypatingu efektyvumu, gebėdamas tiksliai atskirti mokias ir nemokias įmones. Visų šių priežasčių sąveika lemia, kad naujasis modelis tinkamiausias analizuoti Lietuvoje veikiančių MVĮ kredito riziką, todėl tampa vertinga priemone kredito rizikos vertinimui Lietuvoje veikiančioms MVĮ, demonstruojant aukštą tikslumą ir efektyvumą. Tai suteikia ne tik mokslinę vertę, bet ir praktinę naudą verslo aplinkoje, padėdama kreditoriams,

suinteresuotoms šalims bei pačioms įmonėms geriau suprasti ir valdyti savo finansinę padėtį bei rizikos lygį.

IŠVADOS IR PASIŪLYMAI

Išvados:

1. Taigi, išnagrinėjus skirtingų autorių atliktų tyrimų išvadas nustatyta, jog kredito rizikos apibrėžimas per laiką vis kinta – anksčiau analizę atlikę autoriai dažnai apibrėžia kredito riziką trumpai ir aiškiai neišsiplečiant bei ją įvardijant tikimybe, jog kreditas nebus gražintas pagal nustatytas sutarties sąlygas. Tačiau šiuolaikiniai tyrimai išplečia šią sampratą atsižvelgdami į platesnes finansų ir rinkos vertės pokyčių perspektyvas. Taip pat teigiama, jog kredito rizika ne tik daro poveikį finansų rinkoms ir ekonomikai, sukeldama nuostolius kreditoriams bei ribodama skolininkų galimybes, bet ir pati yra veikiamą mikro ir makro lygmens veiksnių, tokių kaip įmonių finansiniai rodikliai, BVP augimas ar nedarbo lygis. Todėl kredito rizikos įvertinimas yra ypatingai svarbus norint išvengti su kreditavimu susijusių pasekmių. O ypač reikalinga nustatyti MVĮ kredito riziką – nes nors MVĮ sudaro didžiąsą dalį visų veikiančių įmonių ir šis sektorius yra svarbi ekonomikos dalis, MVĮ kredito rizika laikoma didesne nei didelių įmonių, kadangi MVĮ turi mažiau užstato, mažiau nusistovėjusią kredito istoriją, taip pat įmonės dydžio poveikis kredito rizikai yra glaudžiai susijęs dėl skirtumų tarp teikiamų mažesnių finansinių ataskaitų bei jų galimo neskaidrumo. Vertinant kredito riziką mokslininkai naudoja klasikinius (tiesinės diskriminantinės regresijos ir logistinės regresijos) bei dirbtinio intelekto (neuronų tinklų ir sprendimų medžių) modelius.
2. Sukurta naujo modelio metodika remiasi logistinės regresijos metodu, kuris buvo pritaikytas siekiant įvertinti Lietuvoje veikiančių MVĮ kredito riziką naudojant tik viešai prieinamus finansinius ir nefinansinius duomenis. Metodika apima rodiklių atranką į galutinį modelį. Be to, analizuotos kitų autorių – Spingate (1978), Altman ir Sabato (2005), Cheraghali (2018) bei Lisboa ir kt. (2021) – sukurtų modelių galimybės būti pritaikytomis Lietuvoje veikiančių MVĮ kredito rizikos įvertinimui, tačiau nustatyta, kad daugeliu atvejų minimi modeliai naudoja duomenis, kurie nėra viešai prieinami (pvz., EBITDA, palūkanų išlaidos). Tai patvirtina poreikį sukurti modelį, kuris atitiktų Lietuvos rinkos specifiką remiantis viešai prieinamais duomenimis.
3. Tyrimo rezultatai parodo, kad naujas logistinės regresijos modelis pasižymi labai aukštu, 93,11%, tikslumu vertinant Lietuvoje veikiančių MVĮ kredito riziką. Naujajam modeliui būdingas ne tik aukštas tikslumo lygis, bet ir lengvas pritaikomumas, nes jis sudaromas naudojant tik viešai prieinamus duomenis. Tai suteikia papildomą lankstumą ir padidina

modelio praktinę vertę. Be to, atlikus koreliacijos analizę bei vertinant multikolinearumo problemą, patvirtinta, jog naujasis modelis neturi reikšmingų koreliacijos arba multikolinearumo problemų – tai tik stiprina jo patikimumą. Modelis taip pat buvo patikrintas naudojant Hosmer –Lemeshow tinkamumo testą, kuris parodė, jog modelio prognozės gerai atitinka faktinius stebėjimus. Svarbiausia, naujojo modelio AUC (plotas po ROC kreive) siekia 0,96, kas rodo jo ypatingą efektyvumą. Visų šių priežasčių sąveika lemia, jog naujasis modelis yra tinkamiausias analizuoti Lietuvoje veikiančių MVĮ kredito riziką, todėl tampa vertinga priemone kredito rizikos vertinimui Lietuvoje veikiančioms MVĮ, demonstruojant aukštą tikslumą ir efektyvumą.

Pasiūlymai:

1. Rekomenduojama į modelį integruoti informaciją apie įmonių skolas, pateikiamą „Verslo žinių“ internetiniame puslapyje rekvizitai.vz.lt esančioje skiltyje „Skolos“, apimančią įsiskolinimus VMĮ ir Sodrai. Šie duomenys gali būti itin svarbūs prognozuojant įmonių kredito riziką, nes įmonės įsiskolinimas valstybės institucijoms gali būti tiesioginis nemokumo rizikos indikatorius. Nors šie duomenys yra prieinami, šiuo metu jie pasiekiami tik įmonės lygmeniu. Dėl šios priežasties nėra techninių galimybių masiškai apdoroti šių duomenų modelio kūrimo tikslais. Ateityje, bendradarbiaujant su rekvizitai.vz.lt galėtų būti sudaryta galimybė gauti šiuos duomenis centralizuotai ir panaudoti juos modelio analizėje. Toks papildymas leistų tiksliau vertinti įmonių kredito riziką ir geriau atspindėti realias jų finansines problemas.
2. Šio darbo tikslas buvo sukurti modelį, kuris galėtų būti taikomas bendrai Lietuvai, todėl regioniniai skirtumai nebuvo nagrinėjami detaliau. Tačiau ateityje šį modelį būtų galima išskaidyti ir regioniniu lygiu, siekiant įvertinti skirtingų regionų ekonomines ypatybes ir jų poveikį kredito rizikai. Toks regioninis pritaikymas galėtų suteikti dar tikslesnes prognozes ir pagerinti modelio pritaikymą praktikoje.
3. Šio tyrimo tikslas buvo sukurti modelį, pagrįstą įmonių viešai prieinama finansine ir nefinansine informacija, atspindinčia individualius įmonių veiklos duomenis. Makroekonominių rodiklių integravimas galėtų būti kito tyrimo dalis, kadangi tai reikalautų papildomų duomenų surinkimo, atitinkančio ekonominių ciklų laikotarpius, ir specifinės metodikos šių kintamųjų poveikiui įvertinti. Toks papildymas leistų geriau įvertinti ekonominių sąlygų pokyčių įtaką MVĮ kredito rizikai ir užtikrinti modelio tikslumą įvairiomis makroekonominėmis sąlygomis.

LITERATŪROS ŠALTINIAI

- Afjal, M., Salamzadeh, A., ir Dana, L.-P. (2023). Financial Fraud and Credit Risk: Illicit Practices and Their Impact on Banking Stability. *Journal of Risk and Financial Management*, 16(9), 386. <https://doi.org/10.3390/jrfm16090386>
- Altman, E. I., ir Sabato, G. (2005). MODELING CREDIT RISK FOR SMES: EVIDENCE FROM THE US MARKET. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=872336
- Audito, apskaitos, turto vertinimo ir nemokumo valdymo tarnyba prie Lietuvos Respublikos Finansų ministerijos (2024). NEMOKUMO PROCESŲ 2023 M. APŽVALGA. Prieiga internetu: <https://avnt.lrv.lt/media/viesa/saugykla/2024/4/PvSSmuqmZFo.pdf>
- Audito, apskaitos, turto vertinimo ir nemokumo valdymo tarnyba prie Lietuvos Respublikos Finansų ministerijos (2024). NEMOKUMO PROCESŲ 2024 M. I PUSM. APŽVALGA. Prieiga internetu: https://avnt.lrv.lt/public/canonical/1726742586/570/2024-08_Nemokumo_APZVALGA_2024_m._I_pusm..pdf
- Bručaitė, L. (2018). Bankroto prognozavimo modelių taikymo tyrimas. <https://talpykla.elaba.lt/elabafedora/objects/elaba:33240974/datastreams/MAIN/content>
- Bruns, V., ir Fletcher, M. (2008). Banks' risk assessment of Swedish SMEs. *Venture Capital*, 10(2), 171–194. <https://doi.org/10.1080/13691060801946089>
- Ceylan, I. E. (2021). The impact of firm-specific and macroeconomic factors on financial distress risk: A case study from Turkey. *Universal Journal of Accounting and Finance*, 9(3), 506–517. <https://doi.org/10.13189/ujaf.2021.090325>
- Cheraghali, H. (2018). Modeling Credit Risk for Small and Medium-Sized Enterprises Evidence from Norway. <http://hdl.handle.net/11250/2586743>
- Cındık, Z., ir Armutlulu, I. H. (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., ir 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>

- Da, F., ir Peng, Y. (2023). Non-financial indicators for credit risk analysis of Chinese technology-oriented micro and small enterprises. *Journal of the Operational Research Society*, 74(4), 1198–1210. <https://doi.org/10.1080/01605682.2022.2072781>
- European Central Bank (2024). ECB guide to internal models. (Žiūrėta 2024-12-15). Prieiga internetu: https://www.bankingsupervision.europa.eu/ecb/pub/pdf/ssm.supervisory_guides202402_internal_models.en.pdf?61a93d263e1d6f6cc0733f836f803086=
- European Circular Economy Stakeholder Platform. (2023). The role of SMEs in China's circular economy transition. Circular Innovation Lab. <https://circulareconomy.europa.eu/platform/en/knowledge/role-smes-chinas-circular-economy-transition>
- European Investment Bank. (2022). Small and medium enterprises - overview 2022. Žiūrėta 2023-10-21. Prieiga internetu: <https://www.eib.org/en/publications/smes-overview-2022>
- Eurostat. (2023). Business registration and bankruptcy index by NACE Rev.2 activity - quarterly data. Žiūrėta 2023-12-02. Prieiga internetu: https://ec.europa.eu/eurostat/databrowser/view/STS_RB_Q__custom_7176440/bookmark/table?lang=en&bookmarkId=7161b630-dcc8-4d56-82ed-2ba314953c72
- Eurostat. (2023). Q2 2023: Business bankruptcies at highest level since 2015. <https://ec.europa.eu/eurostat/web/products-eurostat-news/w/ddn-20230817-1>
- Fiedler, E. R., ir Pech, M. R. (1971). Measures of credit risk and experience. National Bureau of Economic Research; distributed by Columbia University Press. 10-18. <http://www.nber.org/books/fied71-1>
- Galvis-Ciro, J. C., de Moraes, C. O., ir García-Lopera, J. (2023a). The Macroeconomic Impact on Bank's Portfolio Credit Risk: The Colombian Case. *Emerging Markets Finance and Trade*, 59(1), 60–77. <https://doi.org/10.1080/1540496X.2022.2091434>
- Giriūniene, G., Giriūnas, L., Morkunas, M., ir Brucaite, L. (2019). A comparison on leading methodologies for bankruptcy prediction: The case of the construction sector in Lithuania. *Economies*, 7(3). <https://doi.org/10.3390/economies7030082>
- GOV.UK. (2023). Small to medium sized enterprise (SME) action plan. <https://www.gov.uk/government/publications/fcd0-small-to-medium-sized-enterprise-sme-action-plan/small-to-medium-sized-enterprise-sme-acti>

- Grikietytė, G., ir Mačiulytė-Šniukienė, A. (2023). APPLICABILITY OF BANKRUPTCY PROBABILITY ASSESSMENT MODELS TO FINANCIAL SECTOR COMPANIES. *Mokslas - Lietuvos ateitis*, 15(0), 1–9. <https://doi.org/10.3846/mla.2023.17761>
- Jawa, T. M. (2022). Logistic regression analysis for studying the impact of home quarantine on psychological health during COVID-19 in Saudi Arabia. *Alexandria Engineering Journal* (T. 61, Issue 10, p. 7995–8005). Elsevier BV. <https://doi.org/10.1016/j.aej.2022.01.047>
- 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>
- Keijsers, B., Diris, B., ir Kole, E. (2018). Cyclicalities in losses on bank loans. *Journal of Applied Econometrics*, 33(4), 533–552. <https://doi.org/10.1002/jae.2612>
- Kiyak, D., ir Labanauskaitė, D. (2012). ASSESSMENT OF THE PRACTICAL APPLICATION OF CORPORATE BANKRUPTCY PREDICTION MODELS. *ECONOMICS AND MANAGEMENT*, 17(3). <https://doi.org/10.5755/j01.em.17.3.2106>
- Kyriazopoulos, G., Kanavas, V., ir Galyfianakis, G. (2023). PREDICTING BANKRUPTCY OF MOBILE COMPANIES BEFORE AND AFTER THE PANDEMIC COVID-19 IN THE GREEK EMERGING MARKET. *International Journal of Advanced Economics*, 5(9), 298–313. <https://doi.org/10.51594/ijae.v5i9.656>
- Krušinskas, R., Lakštutienė, A., ir Stankevičienė, J. (2014). The Research of Bankruptcy Prediction Models Reliability in Lithuanian Companies. *Transformations in Business & Economics*, 13(2), 102–123. <https://etalpykla.lituanistika.lt/object/LT-LDB-0001:J.04~2014~1581952882692/J.04~2014~1581952882692.pdf>
- Lietuvių Žodynas. (2024). Kreditas reikšmė. Lietuvių Žodynas. Žiūrėta 2024-11-18. Prieiga internetu: <https://www.lietuviuzodynas.lt/terminai/Kreditas>
- Lietuvos bankas. (2024). Rizikos valdymas. Žiūrėta 2024-11-18. Prieiga internetu: <https://www.lb.lt/lt/rizikos-valdymas>
- Lietuvos Respublikos civilinio kodekso įstatymas (galiojanti suvestinė redakcija nuo 2023-05-01). XIII-2221. <https://www.e-tar.lt/portal/lt/legalAct/TAR.8A39C83848CB>
- Lietuvos Respublikos juridinių asmenų nemokumo įstatymas (galiojanti suvestinė redakcija nuo 2022-12-01). XIII-2221. <https://e-eimas.lrs.lt/portal/legalAct/lt/TAD/56df69a293fa11e9aab6d8dd69c6da66/asr>

- Lisboa, I., Costa, M., ir Santos, F. (2021). Analysis of family smes default risk: The portuguese case. *Australasian Accounting, Business and Finance Journal*, 15(4), 76–92.
<https://doi.org/10.14453/aabfj.v15i4.5>
- Mackevičius J, ir Rakštelienė A. (2005). ALTMAN MODELIŲ TAIKYMAS LIETUVOS ĮMONIŲ BANKROTUI PROGNOZUOTI. *Ekonomikos teorija ir praktika*, 1.
<https://www.lituanistika.lt/content/326>
- Mackevičius, J., ir Silvanavičiūtė, S. (2006). ĮMONIŲ BANKROTO PROGNOZAVIMO MODELIŲ TINKAMUMO NUSTATYMAS. *VERSLAS: TEORIJA IR PRAKTIKA*, VII(4), 193–202.
https://www.lb.lt/uploads/documents/docs/publications/mackevicius_2.pdf
- Mavilasseril, M. (2023). Understanding the Dummy Variable Trap in Regression Models. Unpublished. <https://doi.org/10.13140/RG.2.2.17430.52806>
- Mitra, R., Dongre, A., Dangare, P., Goswami, A., ir Tiwari, M. K. (2023). Knowledge graph driven credit risk assessment for micro, small and medium-sized enterprises. *International Journal of Production Research*. <https://doi.org/10.1080/00207543.2023.2257807>
- Mutamimah, M., Alifah, S., ir Adnjani, M. D. (2023). Corporate governance innovation framework to reduce credit risk in MSMEs using blockchain technology. *Cogent Business and Management*, 10(3). <https://doi.org/10.1080/23311975.2023.2250504>
- Oficialiosios statistikos portalas. (2024). Ekonominės veiklos rūšių klasifikatorius 2 redakcija (EVRK 2 red.). Žiūrėta 2024-06-19. Prieiga internetu: <https://osp.stat.gov.lt/static/evrk2.htm>
- Phan Thi Hang, N. (2023). Policy recommendations for controlling credit risks in commercial banks after the Covid-19 pandemic in Vietnam. *Cogent Economics and Finance*, 11(1).
<https://doi.org/10.1080/23322039.2022.2160044>
- Rekvizitai.lt. (2024). Rekvizitai.lt – Lietuvos įmonių katalogas. Žiūrėta 2024-09-14. Prieiga internetu: <https://rekvizitai.vz.lt/>
- Saulius GRIGARAVIČIUS. (2003). Corporate Failure Diagnosis RELIABILITY AND PRACTICE.
<https://www.lituanistika.lt/content/38460>
- Savickienė, J., ir Baliūnė, J. (2021). Finansinių sunkumų nustatymas statybos sektoriaus įmonėse. *Science and Studies of Accounting and Finance: Problems and Perspectives*, 15(1), 54–64.
<https://doi.org/10.15544/ssaf.2021.06>

- Sousa, A., Braga, A., ir Cunha, J. (2022). Impact of macroeconomic indicators on bankruptcy prediction models: Case of the Portuguese construction sector. *Quantitative Finance and Economics*, 6(3), 405–432. <https://doi.org/10.3934/QFE.2022018>
- Supitriyani, S., Astuti, A., & Azwar, K. (2022). Implementation of Springate, Altman, Grover and Zmijewski Models in Measuring Financial Distress. *INTERNATIONAL JOURNAL OF TRENDS IN ACCOUNTING RESEARCH* (T. 3, Issue 1, p. 001–008). Assosiasi Dosen Akuntansi Indonesia. <https://doi.org/10.54951/ijtar.v3i1.169>
- Špicas, R., ir Nekrošiūtė, G. (2012). ĮMONIŲ KREDITO RIZIKOS VERTINIMO MODELIŲ TAIKYMAS LIETUVOS KREDITO UNIJOSE. *Ekonomika ir vadyba: aktualijos ir perspektyvos*, 28, 120–132. <https://etalpykla.lituanistika.lt/object/LT-LDB-0001:J.04~2012~1367188401436/J.04~2012~1367188401436.pdf>
- Špicas, R., Kanapickienė, R., ir Ivaškevičiūtė, M. (2015). Filter Methods of Variable Selection for Enterprise Credit Risk Prediction. <https://www.lituanistika.lt/content/80038>
- Špicas, R., Kanapickienė, R., Vijūnas, M., ir Kirka, R. (2018). Development of Enterprise Credit Risk Assessment Model for Lithuanian Credit Unions. *Transformations in Business & Economics* (T. 17, Numeris 1). <https://etalpykla.lituanistika.lt/object/LT-LDB-0001:J.04~2018~1580281711479/J.04~2018~1580281711479.pdf>
- Tong, Z., ir Yang, S. (2021). The Research of Agricultural SMEs Credit Risk Assessment Based on the Supply Chain Finance. *E3S Web of Conferences*, 275. <https://doi.org/10.1051/e3sconf/202127501061>
- U.S. Small Business Administration. (2024). Basic requirements. Tikrinta 2024-12-15. Prieiga internetu: <https://www.sba.gov/federal-contracting/contracting-guide/basic-requirements>
- Visuotinė lietuvių enciklopedija. (2023). <https://www.vle.lt/straipsnis/kreditas-1/>. Visuotinė lietuvių enciklopedija. Žiūrėta 2024-06-15. Prieiga internetu: <https://www.vle.lt/straipsnis/kreditas-1/>
- Wang, X., Han, L., Huang, X., ir Mi, B. (2021). The financial and operational impacts of European SMEs' use of trade credit as a substitute for bank credit. *European Journal of Finance*, 27(8), 796–825. <https://doi.org/10.1080/1351847X.2020.1846576>
- Wasiuzzaman, S., Nurdin, N., Abdullah, A. H., ir Vinayan, G. (2020). Creditworthiness and access to finance: a study of SMEs in the Malaysian manufacturing industry. *Management Research Review*, 43(3), 293–310. <https://doi.org/10.1108/MRR-05-2019-0221>

- Wu, S., ir Yang, T. (2023). Towards Fair Credit Risk Assessment: Developing Mathematical Models with Equity and Accuracy. *Advances in Economics, Management and Political Sciences* (T. 44, Issue 1, p. 151–165). EWA Publishing. <https://doi.org/10.54254/2754-1169/44/20232211>
- Zhou, W., Chen, Q., ir Meng, S. (2019). Knowledge mapping of credit risk research: scientometrics analysis using CiteSpace. *Economic Research-Ekonomska Istrazivanja* , 32(1), 3451–3478. <https://doi.org/10.1080/1331677X.2019.1660202>

ASSESSMENT OF CREDIT RISK FOR SMALL AND MEDIUM-SIZED ENTERPRISES

SIMONA ADOMAITYTĖ

Master thesis

Finance and Banking

Vilnius University, Faculty of Economics and Business Administration

Supervisor – Prof. Dr. (HP) Rasa Kanapickienė

Vilnius, 2025

SUMMARY

64 pages, 8 pictures, 11 tables, 54 references.

The objective of this final master's thesis is to assess credit risk prediction methods for their accuracy in predicting the probability of default for Small and Medium-sized Enterprises (SMEs) in Lithuania. The study is based on an analysis of scientific literature and research that involved the development of a new logistic regression model using financial and non-financial data from 2022 to evaluate the accuracy of credit risk for SMEs in Lithuania. The thesis is structured into four main sections: analysis of scientific literature, research methodology, research results, and conclusions and suggestions.

The literature analysis explores various interpretations of the "credit risk" concept from different scientific sources, as well as highlighting distinctions between SMEs and large companies in terms of credit risk. Additionally, it examines credit risk models applied in Lithuania, with a focus on their suitability for local businesses. The analysis also includes a review of credit risk models specifically tailored to SMEs, emphasizing the importance of incorporating not only financial but also non-financial information, such as the sector, the company's years of operation, and the number of employees, to improve the accuracy and applicability of credit risk assessment models.

Following the literature analysis, the research methodology was established. The methodology included a detailed discussion of the approach for creating a new logistic regression model for the assessment of SME credit risk, specifically tailored to SMEs operating in Lithuania, and identified that existing models suitable for analysing SME credit risk could not be applied, as the study aimed to rely exclusively on publicly available information for SMEs operating in Lithuania.

Research results indicate that the new logistic regression model, developed using exclusively publicly available information, achieves high accuracy, reaching 93.11%, in predicting SME credit risk in Lithuania. Its adaptability and reliance on publicly accessible data enhance its practical value and broad usability. Furthermore, correlation analysis, assessment of multicollinearity, and the results of the Hosmer-Lemeshow test confirm the reliability and goodness-of-fit of the new model. Notably, the model's Area Under the Curve (AUC) reaches 0.96, indicating exceptional efficiency. Therefore, the model is identified as the most suitable for assessing the credit risk of SMEs operating in Lithuania.

The conclusions summarize key findings from the scientific literature and provide suggestions on how to enhance the model's accuracy, such as incorporating macroeconomic indicators like inflation and unemployment rates, testing the model across different economic cycles to ensure its robustness and adaptability, and segmenting the analysis by regions to capture potential regional economic disparities and improve the model's precision.