

**VILNIAUS UNIVERSITETAS**  
**EKONOMIKOS IR VERSLO ADMINISTRAVIMO FAKULTETAS**

**FINANSAI IR BANKININKYSTĖ**

**Kamilė Dailidonytė**  
**MAGISTRO BAIGIAMASIS DARBAS**

<b>MAŽŲ IR LABAI MAŽŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO MODELIS</b>	<b>CREDIT RISK ASSESSMENT MODEL FOR SMALL AND MICRO- ENTERPRISES</b>
--	--

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

**Vilnius, 2024**

## TURINYS

<b>LENTELIŲ SĄRAŠAS</b> .....	3
<b>PAVEIKSLŲ SĄRAŠAS</b> .....	4
<b>ĮVADAS</b> .....	5
<b>1. MAŽŲ IR LABAI MAŽŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO LIETUVOS IR UŽSIENIO MOKSLINĖJE LITERATŪROJE TEORINIAI ASPEKTAI</b> .....	8
<b>1.1. Kredito rizikos koncepcija ir vertinimas</b> .....	8
<b>1.1.1. Kredito rizikos samprata</b> .....	8
<b>1.1.2. Kredito rizikos vertinimo modeliai</b> .....	13
<b>1.2. Smulkaus verslo koncepcija ir vertinimas</b> .....	18
<b>1.2.1. Mažų ir labai mažų įmonių samprata ir finansavimo prieinamumo analizė</b> .....	18
<b>1.2.2. Mažų ir labai mažų ekonominė reikšmė ir kreditavimo iššūkiai</b> .....	25
<b>1.3. Automatizacija kredito sprendimų priėmimo procese – smulkaus verslo vertinimo metodų taikymo galimybės ir kritinis vertinimas</b> .....	28
<b>2. KREDITO RIZIKOS VERTINIMO MODELIO LIETUVOS MAŽOMS IR LABAI MAŽOMS ĮMONĖMS TYRIMO METODIKA</b> .....	33
<b>2.1. Tyrimo tikslas ir dizainas</b> .....	33
<b>2.2. Duomenų atranka, rinkimo ir sisteminimo metodai</b> .....	41
<b>2.3. Metodo pasirinkimo pagrindumas ir tyrimo apribojimai</b> .....	46
<b>3. KREDITO RIZIKOS VERTINIMO MODELIO, ORIENTUOTO Į SPRENDIMŲ PRIĖMIMĄ, LIETUVOS MAŽOMS IR LABAI MAŽOMS ĮMONĖMS REZULTATAI IR JŲ INTERPRETACIJA</b> .....	48
<b>3.1. Pareiškėjų atvejo analizė alternatyvaus finansuotojo aplinkoje</b> .....	48
<b>3.2. Klientų klasifikavimas ir statistiniai ryšiai</b> .....	60
<b>3.3. Kredito rizikos vertinimo modelio formavimas ir veikimo principai</b> .....	68
<b>3.4. Kredito rizikos vertinimo modelio analizė ir tyrimo rezultatų vertinimas praktinėje aplinkoje</b> .....	75
<b>IŠVADOS IR PASIŪLYMAI</b> .....	83
<b>LITERATŪROS IR ŠALTINIŲ SĄRAŠAS</b> .....	89
<b>SANTRAUKA</b> .....	97
<b>SUMMARY</b> .....	98
<b>PRIEDAI</b> .....	99

## LENTELIŲ SĄRAŠAS

- 1 lentelė. Kredito rizikos samprata skirtinguose moksliniuose šaltiniuose
- 2 lentelė. Įmonių skaičius Europos Sąjungoje 2022 m.
- 3 lentelė. Lietuvos įmonių skaičius metų pradžioje 2019–2023 m.
- 4 lentelė. Įregistruotos ir išregistruotos įmonės Europos Sąjungoje ir Lietuvoje 2021 m.
- 5 lentelė. Įmonių išlikimo rodikliai Europos Sąjungoje ir Lietuvoje 2018–2020 m.
- 6 lentelė. Paraiškų patenkinimo dalis Lietuvos bankuose 2019–2022 m.
- 7 lentelė. Finansavimo neprieinamumo Lietuvos bankuose priežastys 2019–2022 m.
- 8 lentelė. Mašininio mokymosi modelių metodų privalumai ir trūkumai – mokslinių tyrimų analizės rezultatai
- 9 lentelė. Modelio sprendimų analizė – I ir II rūšies klaidos
- 10 lentelė. Modelio klasifikavimo patikimumo vertinimo rodikliai ir formulės
- 11 lentelė. Duomenų rinkimo būdai
- 12 lentelė. Finansinių ataskaitų informacija
- 13 lentelė. Imties dydžio nustatymo kriterijai
- 14 lentelė. Alternatyvaus finansuotojo patvirtintos ir atmestos paraiškos 2022 m.
- 15 lentelė. Pasikartojančių klientų paraiškų analizės rezultatai 2022 m.
- 16 lentelė. Tikėtinas maksimalus nuostolis dėl pasikartojančių klientų įsipareigojimų nevykdymo 2022 m.
- 17 lentelė. Įsipareigojimų neįvykdymas pagal įmonės amžiaus grupes 2022 m.
- 18 lentelė. Įsipareigojimų neįvykdymas pagal neigiamą informaciją ir mokėjimų istoriją 2022 m.
- 19 lentelė. Juridinių asmenų finansinių ataskaitų duomenų neigiamos reikšmės
- 20 lentelė. Įsipareigojimų neįvykdymas pagal kredito tipą 2022 m.
- 21 lentelė. Kintamojo „bankroto reitingas“ statistinio reikšmingumo analizės rezultatai
- 22 lentelė. Kintamųjų „aktyvūs pradesti mokėjimai valstybinėms institucijoms“ ir „teismai“ statistinio reikšmingumo analizės rezultatai
- 23 lentelė. Kintamųjų „įsipareigojimų nevykdymas“ ir „įmonės amžius“ statistinio reikšmingumo analizės rezultatai
- 24 lentelė. Kliento informacijos duomenų sudedamosios dalys ir apribojimai
- 25 lentelė. Pasiūlymo informacijos duomenų sudedamosios dalys ir apribojimai
- 26 lentelė. Duomenų segmentuose įgyjamos reikšmės – atitikties taisyklių rinkinys
- 27 lentelė. Kredito rizikos vertinimo modelio sprendimų priėmimo rezultatai – pavyzdys
- 28 lentelė. Momentinių sprendimų priėmimo modulio duomenų generavimas
- 29 lentelė. Kintamųjų „modelio sprendimas“ ir „įsipareigojimų nevykdymas“ statistinio reikšmingumo analizės rezultatai
- 30 lentelė. Modelio charakteristikos – klasifikavimo patikimumo analizės rezultatai
- 31 lentelė. Modelio rezultatų analizė ir paaiškinimo galimybės
- 32 lentelė. Papildomų įsipareigojimo užtikrinimo priemonių taikymas

## PAVEIKSLŲ SĄRAŠAS

- 1 paveikslas. Kredito rizikos formos
- 2 paveikslas. Įmonių reitingavimo proceso schema
- 3 paveikslas. Tradiciniai kredito rizikos vertinimo modeliai
- 4 paveikslas. Tyrimo schema
- 5 paveikslas. Taisyklėmis pagrįsto modelio prielaidos
- 6 paveikslas. Momentinių sprendimų modulio schema
- 7 paveikslas. Juridinių asmenų segmentavimo pagal rizikingumą nustatymo būdai
- 8 paveikslas. Klientų klasifikavimo matrica
- 9 paveikslas. Duomenų skirstymas pagal informacijos tipą
- 10 paveikslas. Kredito suteikimo proceso schema
- 11 paveikslas. Detalizuoti patvirtintų ir atmestų paraiškų duomenys 2022 m.
- 12 paveikslas. Nepatvirtintų paraiškų atmetimo priežastys 2022 m. (proc.)
- 13 paveikslas. Nepatvirtintos paraiškos pagal finansavimo sumas 2022 m. (proc.)
- 14 paveikslas. Juridinių asmenų įsipareigojimų nevykdymo atvejai 2022 m. pabaigoje (proc.)
- 15 paveikslas. Įsipareigojimų nevykdymo atvejų neatitikimai kredito rizikos politikai 2022 m. pabaigoje (proc.)
- 16 paveikslas. Klientų klasifikavimas pagal bankroto reitingą sprendimo priėmimo dieną 2022 m. (proc.)
- 17 paveikslas. Klientų klasifikavimas pagal mokėjimų istoriją sprendimo priėmimo dieną 2022 m. (proc.)
- 18 paveikslas. Klientų klasifikavimo statistinio reikšmingumo analizės rezultatai
- 19 paveikslas. Monitoringo pranešimų tipai pagal rizikos grupę
- 20 paveikslas. Sąlygos ir modelio sprendimo sąveika
- 21 paveikslas. Modelio sprendimą veikiančios sritys
- 22 paveikslas. Duomenų validacijos schema
- 23 paveikslas. Kredito rizikos vertinimo modelio mažoms ir labai mažoms įmonėms sprendimo rezultatai (proc.)
- 24 paveikslas. Klasifikavimo matricos rezultatai
- 25 paveikslas. Kredito rizikos vertinimo modelio paraiškų atmetimo priežastys (proc.)
- 26 paveikslas. Sprendimų priėmimo transformacija su modelio integracija alternatyvaus finansuotojo veikloje

# IVADAS

## Darbo temos aktualumas

Daugelis šalių, siekdamos sukurti palankią verslo aplinką, turi aiškius politikos tikslus. Nors palanki verslo aplinka apima daugybę komponentų, mokslinėje literatūroje vis dažniau pabrėžiama, kad suvaržymai pasinaudoti kreditavimo galimybėmis yra pagrindinis įmonių veiklos apribojimo faktorius (Bakhtiari, Breunig, Magnani ir Zhang, 2020). Kadangi vidinių lėšų trūkumas kelia įtampą įmonėms, susiduriančioms su išorės finansavimo neprieinamumu, o po pasaulinės finansų krizės sugriežtėję banko finansavimo standartai ir reikšmingai sumažėjęs skolinimas dar labiau gilina prieigos prie finansavimo problemas, savo ruožtu, kredito rizikos prognozavimas tapo pagrindiniu šiuolaikinių finansų iššūkiu.

Tikslus kredito rizikos įvertinimas atlieka esminį vaidmenį tiek ekonomikos, tiek visuomenės kontekste. Kreditą teikiančios organizacijos kasdien susiduria su sprendimais suteikti finansavimą ar jį atmesti. Suteikdamos paskolas šios įstaigos susiduria su rizika, kuri pasireiškia galimybe, jog klientas negrąžins skolos sumos ir taip neįvykdys savo finansinių įsipareigojimų. Nuo septintojo dešimtmečio pradėtos nagrinėti įvairios kredito rizikos koncepcijos, modeliai ir teorijos, o per pastaruosius kelis dešimtmečius kredito rizikos vertinimas tapo viena iš plačiausiai nagrinėjamų sričių, ypač verslo finansų sektoriuje. Įvairių sričių mokslininkai sutaria dėl kredito rizikos svarbos, tačiau kredito rizikos modeliavimas vis dar yra nemaža verslo problemų sritis, reikalaujanti žinių ir teisingo kuriamų modelių pritaikymo. Tai priverčia atsigręžti į egzistuojančius kredito rizikos modelius ir įpareigoja išplėsti duomenų rinkinius, kad būtų galima numatyti tinkamus sprendimo priėmimą sąlygojančius veiksmus, siekiant užkirsti kelią įsipareigojimų nevykdymui ir priimti objektyvias strategijas mažinant kredito riziką.

## Analizuojamos temos ištyrimo lygis

Iki šiol pareiškėjų kreditingumui įvertinti buvo taikomi įvairūs kredito rizikos modeliai, naudojant tradicinius statistinius metodus arba pažangius dirbtinio intelekto, ypač mašininio mokymosi srityje, metodus (Abdou ir Pointon, 2011; Aziz ir Dowling, 2019; Bussmann, Giudici, Marinelli ir Papenbrock, 2021; Malakauskas ir Lakštutienė, 2021a). Šiuo metu egzistuoja gausybė modelių kredito rizikos vertinimo kontekste, tačiau naujoji literatūra ima kelti klausimus dėl šių modelių tarpusavio lyginimo dviprasmiškumo (Tran, Nicolau, Nayak ir Verhoeven, 2021). Teigti, kad

kažkuris modelis yra pranašesnis už kitą, iš dalies, yra klaidinga, nes kiekvienas modelis ir jo kūrimui taikomų metodų pasirinkimas bei derinimas tarpusavyje remiasi mokslinių prielaidų šioje srityje taikymu. Dėl šios priežasties šiame darbe bandoma paaiškinti modelio, orientuoto į konkretų rezultatą – finansavimo sprendimo priėmimo, svarbą. Žvelgiant iš dar vienos perspektyvos, galima pastebėti, jog egzistuoja mokslinių straipsnių, kuriuose analizuojama nebankinių finansų institucijų svarba finansuojant įmones, kurių paraiškos nepatenkinamos bankinio sektoriaus (Gopal ir Schnabl, 2022; Huang ir kt., 2020). Šis darbas siekia užpildyti literatūros stygių prieigos prie išorinio finansavimo kontekste ir išryškinti poreikį kurti kredito rizikos modelius mažoms ir labai mažoms įmonėms, taikant metodus, kurie būtų tinkami skolinimo veiklą atstovaujančių įmonių kredito rizikos politikos gairių integravimui, siekiant išvengti galimų nuostolių, ir tuo pačiu atsižvelgiant į smulkaus verslo esminius kreditavimo iššūkius.

## **Darbo naujumas**

Teoriniu lygmeniu šiame darbe siekiama atskleisti prieinamumo prie išorinio finansavimo spragas bei akcentuoti kredito rizikos vertinimo metodų pasirinkimą ir pagrindinius jų apribojimus kuriant kredito rizikos modelius. Tikimasi, kad teoriniu pagrindu daugiau dėmesio bus skiriama atskirai smulkaus verslo, t. y. mažų ir labai mažų įmonių, finansavimo galimybių ir kredito vertinimo procesų nagrinėjimui. Praktiniu lygmeniu šis darbas gali pateikti modelį, kuris padeda skolinimo įstaigoms integruoti priimtinas taisykles, tuo pačiu išvengti kredito rizikos ir suteikti veiksmingą bei greitą kredito sprendimą. Empiriniu tyrimu siekiama paskatinti naudoti modelius atsižvelgiant į jų pritaikomumą kredito rizikos vertinimo taisyklių įvedimui bei pateikti sprendimo rezultatą dėl finansavimo suteikimo. Pagrindinis šio darbo indėlis į mokslinius tyrimus yra modelio, grindžiamo taisyklėmis, tinkamumas konkrečiam tikslui pasiekti.

**Darbo problema.** Ar, atsižvelgiant į prieinamų duomenų apie klientus apimtį, kredito rizikos vertinimo modelis, sukurtas Lietuvos mažoms ir labai mažoms įmonėms bei integruojantis kredito rizikos politikos taisykles, gali efektyviai priimti finansavimo sprendimą ir paaiškinti sprendimo rezultatus?

**Darbo tikslas.** Atlikus mokslinės literatūros analizę, apibrėžti kredito rizikos sampratą, nustatyti jos vertinimo būdus ir identifikuoti pagrindinius rizikos veiksnius, sukurti praktinį kredito rizikos vertinimo modelį, orientuotą į sprendimų priėmimą, mažoms ir labai mažoms įmonėms.

## **Darbo uždaviniai:**

1. Išnagrinėjus skirtingų autorių pateiktą kredito rizikos sampratą, išskirti bendrus kredito rizikos bruožus ir įvertinti kredito rizikos vertinimo ypatybes;
2. Atlikus mokslinės literatūros analizę, susisteminti egzistuojančius kredito rizikos vertinimo modelius bei identifikuoti jų pagrindines savybes;
3. Išnagrinėjus nacionalinių bei tarptautinių institucijų pateikiamus apibrėžimus, apibrėžti bendrą mažų ir labai mažų įmonių sampratą bei remiantis skirtingais oficialios statistikos šaltiniais, atlikti finansavimo prieinamumo analizę;
4. Pagrįsti mažų ir labai mažų įmonių svarbą ekonomikoje ir nustatyti pagrindines kliūtis, susijusias su smulkaus verslo finansavimu;
5. Atlikti kredito rizikos vertinimo metodų taikymo galimybių ir kritinį vertinimą automatizuotų procesų kredito sprendimo priėmimo kontekste;
6. Remiantis atlikta literatūros analize, pagrįsti metodologijos praktiniam tyrimui pasirinkimą;
7. Pateikti kredito rizikos vertinimo modelio, orientuoto į sprendimų priėmimą, mažoms ir labai mažoms įmonėms tyrimo rezultatus bei jų vertinimą<sup>1</sup>.

**Darbo metodai.** Lyginamoji mokslinės literatūros analizė, sintezė, informacijos sisteminimo ir grafinio vaizdavimo metodai, aprašomoji statistinė analizė, kiekybiniai ir kokybiniai duomenų analizės metodai, taisyklėmis pagrįstas metodas, požymių nepriklausomumo testas.

**Darbo struktūra.** Magistro baigiamojo darbo dėstomoji dalis išskiriama į tris skyrius. Pirmajame skyriuje teoriniu pagrindu vertinama kredito rizikos samprata ir esminiai jos bruožai, identifikuojami pagrindiniai kredito rizikos vertinimo modeliai, iškeliami mažų ir labai mažų įmonių finansavimo prieinamumo problema, ekonominiu požiūriu pagrindžiama šių įmonių reikšmė bei įvertinamos su kredito sprendimo priėmimu susijusių automatizuotų procesų galimybės bei kritinis požiūris. Antrojoje (metodinėje) darbo dalyje pristatomas pasirinktas tyrimo dizainas, kuriuo remiantis siekiama sukurti kredito rizikos vertinimo modelį mažoms ir labai mažoms įmonėms taisyklėmis pagrįstu metodu, pagrindžiama duomenų atranka ir atskleidžiami tyrimo apribojimai. Empirinėje dalyje atliekama tyrimo rezultatų interpretacija, pateikiamos pagrindinės išvados ir pasiūlymai.

---

<sup>1</sup> Tyrimo uždaviniai atskleisti metodinėje darbo dalyje.

# 1. MAŽŲ IR LABAI MAŽŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO LIETUVOS IR UŽSIENIO MOKSLINĖJE LITERATŪROJE TEORINIAI ASPEKTAI

## 1.1. Kredito rizikos koncepcija ir vertinimas

Kredito valdymas, atsižvelgiant į jo prieinamumą, susijusią riziką ir klientų mokėjimo įsipareigojimų nevykdymą, yra viena iš pagrindinių skolinimo organizacijų veiklų. Finansinių paslaugų teikėjai, susidurdami su įvairiais neapibrėžtumais dėl skolininkų galimybės gražinti pasiskolintą sumą, yra priversti įgyvendinti proaktyvias strategijas<sup>2</sup>, kurių pagrindu, kredito rizikos vertinimas tampa lemiamu rizikos valdymo įrankiu. Siekiant nustatyti būdus, kuriais kliaujasi finansinės institucijos, svarbu išanalizuoti, kas slypi po kredito rizikos samprata bei išsiaiškinti, kokie kredito rizikos vertinimo modeliai yra sukurti ir kaip jie prisideda prie bendro rizikos valdymo proceso.

### 1.1.1. Kredito rizikos samprata

Kredito vertinimas yra laikomas efektyviu rizikos valdymo metodu, kuris gali pateikti atitinkamas finansavimo gaires ir sumažinti riziką finansų srityje. Kredito analizė apima visapusišką fizinio ar juridinio asmens veiklos rezultatų bei finansuojamo projekto analizę, kurios pagrindinis siekis ir galutinis tikslas – įvertinti finansavimo pareiškėjo kreditingumą, dar kitaip vadinamą, kredito riziką. Ši rizika visame pasaulyje yra laikoma viena iš pagrindinių rizikų, su kuria susiduria įvairios kredito ir kitos finansų įstaigos, ir kuri atsiranda dėl priežasčių, susijusių su skolinimo klientams veikla (Gorgijevska ir Gjorgieva-Trajkovska, 2019). Pasak Zhang, Tadikamalla ir Shang (2016), kredito vertinimas yra sudėtingas procesas dėl egzistuojančių įvairių rizikos formų, o efektyvus kredito rizikos stebėjimas ir valdymas yra svarbūs veiksniai, darantys įtaką ekonomikos išlikimui ir sėkmei. Nuolat keičiantis rinkos padėčiai, makroekonominėi aplinkai, plėtojantis finansinėms technologijoms bei didėjant informacijos srautui, skolintojai yra priversti prisitaikyti prie naujovių ir įvertinti galimybes nustatyti kredito riziką.

---

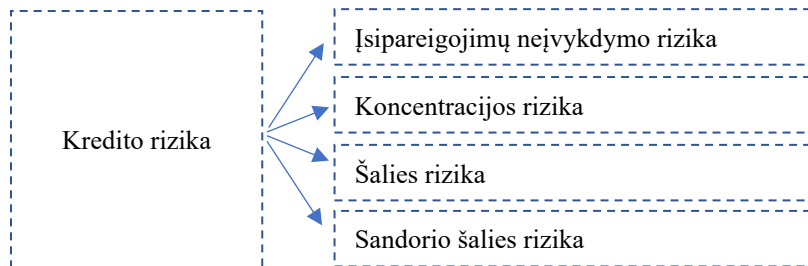
<sup>2</sup> Proaktyvi strategija šiame darbe reiškia veiksmus, kuriuos įgyvendinant siekiama ne tik reaguoti į esamas problemas, bet ir užkirsti kelią potencialioms problemoms ateityje.



Paskolų portfelių valdymo tikslais bankai ir nebankinės finansų institucijos taiko kredito rizikos priemones. Moksliniuose straipsniuose analizuojama daugybė kredito rizikos formų, tačiau, remiantis plačiausiai literatūroje nagrinėjamais parametrais, toliau pateikiamas skirstymas į 4 kredito rizikos tipus.

## 1 paveikslas

### *Kredito rizikos formos*



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

Skirtingi kredito rizikos tipai gali nulemti teigiamo arba neigiamo sprendimo dėl finansavimo priėmimą. Kadangi visi jie yra susiję su tikėtiniais nuostoliais dėl įsipareigojimų nevykdymo, įprastu atveju, tikimasi, jog finansų rinkos dalyviai tiksliai įvertins kitos sandorio šalies gebėjimą įvykdyti būsimus skolinius įsipareigojimus, paprastai vertinamus kredito reitingu (arba balu), kuris yra siejamas su įsipareigojimų neįvykdymo tikimybe.

Nagrinėdami kredito rizikos komponentus, užsienio autoriai išskiria ir daugiau kredito rizikos rūšių, pavyzdžiui, skirtumo rizika (Alam, Hettler ir Gao, 2020) ir kredito reitingo sumažėjimo rizika (Zamore, Ohene Djan, Alon ir Hobdari, 2018). Lietuvos moksliniuose darbuose išskiriama politinė ir teisinė rizika, specifinė verslo rizika, vadovavimo ir vadybos rizika (Špicas ir Nekrošiūtė, 2012). Pastebima, jog kredito rizikos rūšių mokslinėje literatūroje yra labai daug, tačiau nėra vieningos nuomonės dėl konkrečių formų išskyrimo ir reikšmingumo. Galima teigti, jog šių komponentų analizė padeda bankams, finansų institucijoms ir nebankinėms finansų įmonėms įsivertinti galimybes finansuoti pareiškėją ir priimti „tinkamą“ rizikos lygį.

## 1 lentelė

### *Kredito rizikos samprata skirtinguose moksliniuose šaltiniuose*

Špicas ir Nekrošiūtė (2012)	Kredito rizika – tai netekimų galimybė sandorio šaliai nevykdant įsipareigojimų.
Lindset, Lund ir Persson (2014)	Kredito rizika – piniginių nuostolių rizika dėl skolų emitentų, kurie nevykdo sutartyje numatytų skolų mokėjimo.
Veličkienė (2015)	Kredito rizika atsiranda tada, kai kita šalis nenori arba negali vykdyti savo sutartinių įsipareigojimų.
Akwaa-Sekyi ir Moreno (2017)	Kredito rizika – tikimybė, kad skolininkas ar sandorio šalis nevykdys paskolos sutarties sąlygų.
Peškauskaitė ir Jurevičienė (2017)	Kredito rizika – tai rizika, kai kita sandorio šalis negali vykdyti savo įsipareigojimų.
Dvorský, Schönfeld, Kotasková ir Petraková (2018)	Kredito rizika yra galimybė, kad skolininkai negalės laiku įvykdyti savo įsipareigojimų, kylančių iš santykių su kreditoriumi.
Arora ir Kaur (2020)	Kredito rizika apibrėžiama kaip tikimybė, kad skolininkas nesugebės grąžinti pasiskolintos sumos.
Zhu (2020)	Kredito rizika – tai sandorio šalių įsipareigojimų neįvykdymo rizika.
Carvalho, Curto ir Primor (2022)	Kredito rizika – tai galimas skolininko negebėjimas grąžinti paskolas, kliento – mokėti skolas arba sandorio šalies nesugebėjimas atsiskaityti už finansinį turtą ir finansinius įsipareigojimus.

Šaltinis: sudaryta autorės, remiantis lentelėje nurodytais autoriais.

Mokslinėje literatūroje kredito rizikos samprata apibrėžiama gana panašiai ir nurodo, jog kredito rizika daugiausiai siejama su finansinių įsipareigojimų neįvykdymo rizika. Dėl šios priežasties, tarp skirtingų rizikos formų šiame darbe pagrindinis dėmesys skiriamas būtent šiam rizikos tipui. Iš 1 lentelėje pateikiamų kredito rizikos apibrėžimų, galima daryti išvadą apie tai, jog kredito rizika glaudžiai susijusi su nemokumo tikimybe, kas reiškia, jog klientas gali negebėti vykdyti įsipareigojimų, o tai lemia tikimybę skolintojams patirti finansinius nuostolius. Dėl šios priežasties, finansų institucijos linkusios spręsti finansinės paramos skolininkui suteikimą pagal jo galimybes grąžinti suteiktą kreditą.

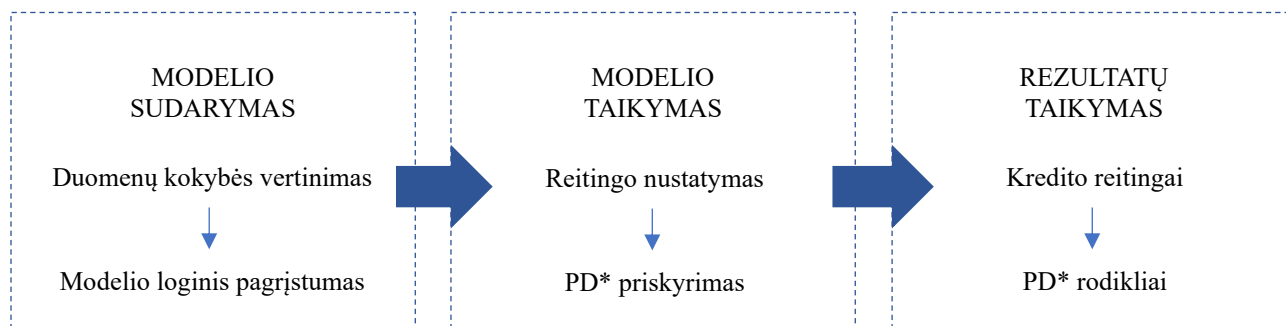
Įsipareigojimų neįvykdymo rizika ir pats kredito rizikos valdymas naujausioje literatūroje traktuojami kaip klasifikavimo problema (Tran ir kt., 2021), todėl pabrėžiama pareiškėjų atskyrimo svarba. Tai reiškia, jog būtina atskirti galimus įsipareigojimų vykdytojus (mokėtojus) nuo įsipareigojimų nevykdančių fizinių ar juridinių asmenų (nemokančiųjų). Šiuo požiūriu, įsipareigojimų nevykdymas tampa viena svarbiausių sudedamųjų nagrinėjant kredito riziką, o pareiškėjų klasifikavimas į „gerus“ ir „blogus“ skolininkus kredito teikėjui padeda priimti atitinkamą sprendimą dėl potencialaus kliento finansavimo. Neteisingo sprendimo priėmimas dėl kredito suteikimo yra

susijęs su būsimais nuostoliais, kurie atsiranda dėl sandorio šalies finansinių įsipareigojimų nesilaikymo.

Akademinėje visuomenėje paplito ir daugiau užsienio mokslininkų rekomendacijų, kaip galima grupuoti skolininkus, pavyzdžiui, ilgainiui siekiant įvertinti kredito riziką, priemone, leidžiančia atskirti „blogus“ pareiškėjus nuo „gerų“, tapo kredito balai arba reitingai. Mokslinėje literatūroje kredito balas yra finansinių institucijų kredito reitingų, sprendimų dėl paskolos išdavimo ir rizikos valdymo pagrindas (Lu ir kt., 2022). Reitingus, kaip kategoriškas mokumo priemones, gali suteikti išorės reitingų agentūros arba pačios finansų institucijos (dos Reis, Pfeuffer ir Smith, 2020). Pasak Ubarhande, Chandani ir McMillan (2021), kredito reitingo skaidrumas yra svarbus veiksnys, kad kredito reitingų agentūros užsitarnautų klientų, investuotojų ir reguliavimo institucijų pasitikėjimą. Bankų veiklą reglamentuoja įvairūs ES teisės aktai, pavyzdžiui, bendram priežiūros mechanizmui taikoma Europos bankų veiklos reguliavimo sistema, kurios pagrindą sudaro Bazelio susitarimai, ir kuri yra taikoma visoms finansų įstaigoms bendrojoje rinkoje. Dėl šio reguliavimo, bankai, norėdami taikyti vidaus reitingais grindžiamą metodiką, turi atitikti nustatytus reikalavimus, o neprižiūrimi finansiniai tarpininkai gali remtis tiek išorės kredito reitingo agentūromis, tiek kurti bei naudoti savo vidinius modelius neapsiribojant reikšmingais suvaržymais. Nepaisant reguliacinės aplinkos, kredito reitingai kinta, todėl juos reikia nuolat peržiūrėti. Kadangi kredito duomenys susideda iš kelių dimensijų, bendras rodiklių skaičius yra didelis ir dažnai trūksta daug reikšmių, todėl prieš nustatant kredito balų modelius, ypatingai svarbu pasirinkti didelio masto kredito duomenis.

## 2 paveikslas

### *Įmonių reitingavimo proceso schema*



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

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

Turint omenyje prieš tai minėtą kredito reitingo sąsają su įsipareigojimų neįvykdymo tikimybe, svarbus suvokimas apie įmonių reitingavimo procesą, pateikiamą 2 paveiksle. Sudarant modelius, skirtus įmonių kredito reitingui nustatyti, ypatingą reikšmę turi informacija, kuri vertinama nustatant kredito balą, tačiau nereikėtų pamiršti, jog reitingavimo procedūra, apimanti modelio patikimumo vertinimą taip pat yra viena iš sudedamųjų proceso dalių. Taikant modelius reikalinga reitingų peržiūra, o rezultatų taikymas reikšmingas tik tada, jei tai integruojama organizacijos veikloje.

Kredito rizikos vertinimas gali būti laikomas daugialype problema dėl susidūrimo su daugybe duomenų. Svarbu paminėti, jog nors praktikoje ir susiduriama su ta pačia informacija, verslininkai yra linkę reaguoti skirtingai. Šių skirtumų atsiradimą lemia skirtingas požiūris į riziką (Qian, Feng ir Gu, 2021). Rizikos suvokimas turi įtakos skirtingų sprendimų priėmimui. Natūralu, jog aukšta kredito rizika ir kredito bei kitų finansų įstaigų nuostoliai, susiję su jų skolinimo veikla, gali lemti skolinimo veiklos masto apribojimą, kas turės įtakos jų ekonominei veiklai, o kartu didins išorinio finansavimo prieinamumo problemas. Daugybė rizikų kyla iš veiksmų, lemiančių įsipareigojimų nevykdymą kredito laikotarpiu ar suėjus jų terminui. Taigi, objektyvus skolininko patikimumo ir paskolos grąžinimo galimybių vertinimas, pasitelkiant duomenų analizę, yra svarbi sudedamoji dalis bendrame kredito vertinimo kontekste.

Remiantis Yin, Jiang, Jain ir Wang (2020), kredito rizikos vertinimas yra sutelktas į kredito rizikai įtakos turinčių ypatybių nustatymą ir įsipareigojimų nevykdymo tikimybę. Požymius, turinčius įtakos kredito rizikai įprasta skirstyti į du tipus: finansinius ir nefinansinius. Kredito analizė apima didelį kiekį informacijos ir duomenų, o atsižvelgiant į jų kiekybinį ir kokybinį pobūdį, gali būti vertinama dviem aspektais – kaip kiekybinė ir kaip kokybinė analizė (Gorgijevska ir Gjorgieva-Trajkovska, 2019; Zamore ir kt., 2018). Istrate ir Ionescu (2017) atskleidžia, jog nagrinėjant įsipareigojimų nevykdymo tikimybę, svarbu atrinkti ekonominius ir finansinius rodiklius, kurie atspindi įmonės ekonominę ir finansinę padėtį, tačiau reikšmingas ir kokybinės informacijos integravimas. Kokybinė analizė yra susijusi su informacija, kuri apibūdina skolininko savybes, o kiekybinė analizė apima duomenų, gautų iš įmonės finansinių ataskaitų, dažniausiai pelno nuostolio ataskaitos bei balanso ataskaitos, vertinimą. Finansiniai rodikliai yra kintamieji, nustatyti kredito rizikos prognozavimo modeliams kurti. Kintamųjų pasirinkimas kredito vertinimo procese turi didelę reikšmę, tačiau jų statistinis reikšmingumas dažnai lieka neaiškus, nes skirtingi tyrimai siūlo vertinti skirtingus santykinus dydžius kaip pagrindinius finansinių problemų rodiklius.

Mokslinėje literatūroje išreiškiama pozicija, atspindinti kokybinės analizės naudą, nes pateikiamas skaidresnis įmonės veiklos ir ją supančios aplinkos būklės vaizdas, o pagrindiniu privalumu išryškinama galimybė prognozuoti galimas įmonės rizikas ateityje. Pasak Gabbi, Giammarino ir Matthias (2020), analizuojant dažniausiai sutinkamus kredito rizikos modelius, pastebima, jog naudojami kiekybiniai kintamieji, kurie remiasi istoriniais finansinių ataskaitų duomenimis bei tendencijomis. Įprastai kiekybinė analizė laikoma objektyvesne, nes pateikia konkrečias ir lengvai interpretuojamas reikšmes, tačiau mokslininkai turi dvejonų dėl kiekybinės informacijos patikimumo. Pastebima, jog nors finansiniai rodikliai turėtų suteikti nešališką kiekybinį veiklos atvaizdą, mažesnių įmonių finansinės ataskaitos gali būti neišsamios arba neauditotos, todėl informacijos neskaidrumas tampa pagrindine vertinimo problema, kuri prisideda prie išorinio finansavimo apribojimų.

Apibendrinant, kredito rizika gali būti suprantama kaip pagrindinė finansų įstaigų rizikos valdymo sritis, susijusi su finansinių įsipareigojimų neįvykdymo tikimybės prognozavimu, naudojant kiekybinius ir kokybinius duomenis. Kredito rizikos modeliavimas yra esminė bankų ir nebankinių finansų įstaigų užduotis, padedanti priimti sprendimus dėl paskolų suteikimo, o skolintojo požiūriu, vertinant kreditingumą, svarbu nustatyti skolininkus, kurie galės vykdyti savo įsipareigojimus nepatirdami mokėjimo sunkumų.

### **1.1.2. Kredito rizikos vertinimo modeliai**

Suprasdami apie tai, jog kredito rizika yra bene svarbiausia finansų rizikos rūšis, mokslininkai pradėjo nagrinėti įvairius metodus ir kurti skirtingus kredito rizikos modelius. Pastarąjį dešimtmetį augant susidomėjimui kredito rizikos vertinimo modeliais akademinėje visuomenėje, matoma, jog egzistuojantys metodai vis dažniau derinami tarpusavyje, siekiant apimti kiek įmanoma didesnę kredito rizikos veiksnių derinį. Tačiau sisteminis tyrimų sudėtingumas ir nevienalytiškumas dažnai trukdo suvienodinti jų rezultatus (Belás, Smrcka, Gavurova ir Dvorský, 2018). Pasak Lu, Yang, Shi, Li ir Abedin (2022), kaip iš didelio masto duomenų atrinkti pagrindines kredito rizikai įtakos turinčias savybes tapo kritiniu tašku, siekiant tiksliai įvertinti kredito riziką ir sumažinti finansavimo suvaržymus. Prieš pradėdant nagrinėti esamus kredito rizikos vertinimo modelius, svarbu apžvelgti istorinę raidą ir suprasti pagrindinius modelių principus.

Modelių grupės bei jų skirstymas pirmiausiai yra susiję su atskirų kredito rizikos sudedamųjų vertinimu. Didžiausios kredito rizikos vertinimo modelių grupės gali skirtis priklausomai nuo to,

kokius kredito rizikos aspektus ar rinkas jie vertina. Toliau pristatomi skirtingi modelių tipai apibūdina modelių struktūrą ar naudojamą metodologiją, tačiau terminai nėra vertinami vienareikšmiškai ir gali būti naudojami įvairiuose kontekstuose. Modeliai tam tikra prasme gali būti grupuojami pagal atskiras kategorijas ar grupes. Šiame darbe terminai suskirstyti naudojant hierarchinę struktūrą:

- **Modelio grupė** yra pristatoma kaip aukščiausias lygmuo, apibūdinantis bendrą kategoriją modelių, kurie turi panašius tikslus arba pritaikymo sritis;
- **Modelis** yra konkrečios kategorijos arba grupės atstovas. Tai gali būti specifiška struktūra, naudojama sprendimui;
- **Metodai** yra specifinės technikos arba algoritmai, kurias naudoja tam tikras modelis.

Kredito rizikos modeliai paprastai naudojami siekiant įvertinti tikėtinus finansinius nuostolius, kuriuos kreditorius (bankas arba finansinis tarpininkas) gali patirti, jei skolininkas nevykdo finansinių įsipareigojimų (Bussmann ir kt., 2021). Tačiau modelių atranka vis dar kelia daugybę klausimų dėl jų sudėtingumo ir kompleksiško. Šiais laikais yra sukurta daugybė būdų, kaip spręsti rizikos problemas, o esami kredito rizikos modeliai įgauna įvairių modifikacijų ir nuolat keičiasi, todėl jų pasirinkimas daugiau priklauso nuo pritaikomumo praktinėje ir (arba) akademinėje veikloje. Nesiekiant išskirti visų egzistuojančių modelių, toliau išryškunami pagrindiniai modelių grupei priklausantys modeliai pagal individualius požūrius, o vėliau gilinamasi į modelius, pagal taikomus metodus ir jų privalumus bei trūkumus.

**Tradiciniai (statistiniai) modeliai.** Daugelį metų kredito rizikos vertinimas buvo daugiausiai pagrįstas klientų duomenų modeliavimu (Locatelli, Pepe ir Salis, 2022). Mokslinėje literatūroje išsamiai nagrinėjami įvairūs požūriai į tradicinius modelius<sup>3</sup>. Ankstyvieji darbai, nagrinėjantys kredito rizikos modeliavimą ir prognozuojantys ūmonių įsipareigojimų nevykdymą, pasirodė septintajame dešimtmetyje. Svarbiausiais moksliniais darbais kuriant kredito rizikos modelius laikomi Beaver (1966) ir Altman (1968) tyrimai, kuriuose naudojamas finansinių rodiklių rinkinys verslo nesėkmėms nustatyti. Bėgant laikui atskleisti statistinės technikos trūkumai parodė, kad naudojant kiekybinius modelius nustatomos nerealistiškos prielaidos, kas lemia neobjektyvius reikšmingumo testus ir klaidų lygį. Nors šie tyrimai gali būti laikomi vieni pirmųjų kredito rizikos vertinimo srityje, tačiau tradiciniai modeliai daugiausiai rėmėsi didelių korporacijų duomenimis, kurie buvo lengvai prieinami, o pagrindinė modelių kritika aiškinama istorinės informacijos koeficientų pagrįstumu.

---

<sup>3</sup> Tradiciniais modeliais šiame darbe laikomi kiekybiniai modeliai, pagrįsti senesniais statistiniais metodais, kurie yra gerai suprantami ir patikimi bei remiasi turimais istoriniais duomenimis.

### 3 paveikslas

#### Tradiciniai kredito rizikos vertinimo modeliai

Modelių grupė	Modelis	Rezultatas
Įsipareigojimų neįvykdymo tikimybės	Aktuarinis	Įsipareigojimų neįvykdymo tikimybės (angl. <i>probability of default, PD</i> ) nustatymas
	Pasirinkimo sandorio	
	Vertinimo balais	
	Kredito maržos	
Kredito pozicijos	Kredito ekvivalento pozicijos	Nuostolių dėl įsipareigojimų neįvykdymo (angl. <i>loss given default, LGD</i> ) ir pozicijos vertės esant įsipareigojimų neįvykdymo rizikai (angl. <i>exposure at default, EAD</i> ) įvertinimas
	Grąžinimo lygio	
Portfelio nuostolio	Rinkos vertės	Tikėtino nuostolio (angl. <i>expected loss, EL</i> ) ir netikėto nuostolio (angl. <i>unexpected loss, UL</i> ) įverčiai
	Įsipareigojimų neįvykdymo	

Šaltinis: sudaryta autorės, remiantis Kamienas ir Valvonis, 2004.

Atsižvelgiant į konkretų modelių grupės rezultatą, naujuose moksliniuose darbuose įsipareigojimų neįvykdymo tikimybės modelius nagrinėja Jamil (2021), Chatterjee, Corbae, Dempsey ir Ríos-Rull (2023), kredito pozicijos modeliai vertinami Papouskova ir Hájek, (2019), Shi, Chi ir Li (2020) darbuose, portfelio nuostolio modelius tiria Dolfín, Knopoff, Limosani ir Xibilia (2019), Misra, Rahman ir Tiwari (2023). Pastebima, jog naujų mokslinių darbų, nagrinėjančių tradicinius kredito rizikos vertinimo modelius teoriniu aspektu pastaraisiais metais mažėja, tačiau kredito rizikos vertinimo ir modeliavimo tematika išlieka aktuali naujų kredito rizikos vertinimo modelių kūrimo kontekste.

**Struktūriniai modeliai.** Mokslinėje literatūroje plačiai tiriami skirtingi struktūriniai modeliai (Laajimi, 2012; Ma ir Xu, 2016; Schäfer ir Koivusalo, 2013; Tarashev, 2005; Zatore ir kt., 2018). Struktūrinių modelių grupės analizė yra daugiausiai tęstinio rezultato produktas, atsirandantis kaip išvestinė priemonė iš pirmųjų darbų pamato, todėl jų prielaidos, teoriniai aspektai ir rezultatai bėgant laikui gana reikšmingai skiriasi. Zatore ir kt. (2018), nagrinėdami kredito rizikos modelių literatūrą ir atlikę bibliometrinę citatų analizę, nustatė, jog daugiausiai dėmesio sulaukė struktūriniai modeliai gali būti siejami su Black and Scholes (1973) ir Merton (1974) darbais, kuriuose struktūriniai modeliai grindžiami kapitalo struktūros teorija (Modigliani ir Miller, 1958), remdamiesi prielaida, jog

įsipareigojimų nevykdymo tikimybė atsiranda tada, kai įmonės turto vertė tampa mažesnė už skolos vertę. Black-Scholes modelis įrodė pasirinkimo sandorių įtakingumą skolos vertei, tačiau modelis buvo apribotas tiesioginio turto vertės stebėjimo suvaržymais. Priešingai, Merton modelis pateikė prielaidas, pagal kurias galima apskaičiuoti turto vertę, kuri gali būti pritaikoma įsipareigojimų nevykdymo tikimybės nustatymui. Dėl šios priežasties Merton modelis gali būti laikomas įtakingiausiu struktūriniu kredito rizikos modeliu. Visgi, vieni tyrimai, prieštaraujantys Merton modeliui, atskleidžia šio modelio trūkumus, kvestionuodami jų tikslumą ir prieš tai pripažintą dominavimą (Laajimi, 2012; Tarashev, 2005), kiti – nurodo, jog tik išplėstas struktūrinis modelis gali pagerinti kredito rizikos vertinimo rezultatus (Ma ir Xu, 2016; Schäfer ir Koivusalo, 2013). Atsižvelgiant į šias pastabas, tai rodo, jog tyrimų kryptis generuoja naujas žinias bei kelia abejonių dėl struktūrinių modelių tinkamumo šiuolaikiniame kredito rizikos vertinime.

**Dirbtinio intelekto modeliai.** Prieiga prie didėjančio skaitmenizuoto duomenų srauto paskatino išmanesnių duomenų apdorojimo ir sisteminimo technologijų diegimą bei suteikė pagrindą ieškoti būdų, kaip įgyti konkurencinį pranašumą, siekiant užtikrinti mažesnes išlaidas ir automatizuoti sprendimo priėmimo procesus, kurie būtų geriausiai pritaikomi sandorio šalims. Automatizuoti procesai, taikant įvairius skirtingus metodus, sulaukė didelio susidomėjimo akademinėje visuomenėje, tuomet pradėta gilintis į dirbtinio intelekto modelių grupę (Wu ir Hsu, 2012; Aziz ir Dowling, 2019; Golbayani, Florescu ir Chatterjee, 2020). Dirbtinio intelekto modeliai, taikomi kredito rizikos vertinimui, daugiausiai siejami su mašininio mokymosi metodais. Jie veikia kaip tikimybiniai klasifikatoriai, kai nustatomi „numatytieji“ atvejai interpretuojami pagal pasirinktus kriterijus, nurodo galutinį rezultatą. Coenen, Abdullah ir Guns (2020) pabrėžia, jog standartiniai mašininio mokymosi metodai yra pritaikyti tik mokymuisi iš tų atvejų, kai rezultatas buvo pastebėtas, todėl bendras atsakymas į klausimą, ar galima naudoti tokį mokymosi modelį, parengtą pagal konkrečias bylas, turėtų būti neigiamas. Tai priverčia peržvelgti naujus (potencialius) klientus, kurie gali priklausyti tiems atvejams, kurių modelis dar nepastebėjo.

Paprastai klasifikavimo taisyklės išreiškiamos „JEIGU-TAI“ (angl. *IF-THEN*) forma ir nurodo, jog jei tam tikros sąlygos yra teisingos, tai daroma atitinkama išvada. Anot Aziz ir Dowling (2019), dirbtinis intelektas kredito rizikos vertinime demonstruoja galimybę atvaizduoti rizikos valdymo intelektą, aukštesnį nei žmogaus intelektas kredito rizikos srityje. Dėl šios priežasties daugumoje pasaulio bankų ir kitų finansų institucijų dirbtinio intelekto (angl. *artificial intelligence, AI*) modelių taikymas tapo itin reikšmingas. Anot Golbayani ir kt. (2020), dirbtinio intelekto metodų įtraukimas į modeliavimą padidina duomenų informacinę galią, o tradicinių ir alternatyvių metodų



derinys leidžia pasiekti didesnę reitingų modelių tikslumą, tačiau jų interpretavimas tampa daug sudėtingesnis nei įprastų tradicinių modelių. Priešingai, pastebėta, kad kredito rizikos prognozavimo klasifikatorių veikimas gali skirtis, kai jie taikomi skirtingiems kriterijams, pavyzdžiui, tikslumui, jautrumui ir specifiškumui, taip pat ir skirtingose aplinkose (Wu ir Hsu, 2012). Tai reiškia, jog joks konkretus klasifikatorius negali pasiekti geriausių visų matavimų rezultatų.

**Hibridiniai modeliai.** Viena naujausių modelių grupių – hibridiniai modeliai. Jų tikslas – kombinuoti skirtingus modelius bei taikomus metodus siekiant gauti tikslesnę ir išsamesnę kredito rizikos įvertinimą. Paprastai, tokie modeliai siekia „peržengti“ tradicinių modelių ribas ir į vertinimo procesą įtraukti daugialypę informaciją bei nagrinėti skirtingas perspektyvas. Pasak Locatelli ir kt., (2022), alternatyvių duomenų rinkinių derinimas su dirbtinio intelekto metodais gali padidinti modelių prognozavimo galimybes bei geriau atskirti riziką, tuo pačiu metu išlaikant kredito balų nustatymo metodų kontrolę. Alternatyviais arba papildomais duomenimis paprastai laikomi duomenys, kurių didžioji dalis yra nestruktūrizuota ir nebūtinai finansinė bei gali apimti naujienas, padedančias pasiekti fizinio ar juridinio asmens informaciją viešai prieinamu būdu. Tradiciniai duomenų ir modeliavimo metodai gali būti derinami kartu su alternatyviais duomenimis, todėl atsiranda galimybė išplėsti pradinį duomenų rinkinį, pridėti alternatyvių duomenų ir šią informaciją apdoroti naudojant pasirinktus metodus. Tačiau, kai atskiri modeliai yra sujungiami, susiduriama su dar vienu iššūkiu. Tran ir kt. (2021) savo darbe pateikia argumentus apie konceptualios sistemos trūkumą, kuri vadovautų bazinių modelių sujungimo procesui. Autorių teigimu, kiekvienas tyrimas turi savo metodą, kaip pasirinkti ir derinti bazinius modelius tarpusavyje ir kombinuoti gaunamus rezultatus, todėl tai paaiškina, kodėl kiekvienas tyrimas linkęs daryti išvadą, kad darbe taikomas derinimo metodas yra geriausias iš konkuruojančių modelių variantų. Įvertinus šias pastabas, galima svarstyti apie tai, jog modelių kūrimas pirmiausiai turėtų būti orientuotas į rezultatus, paaiškinamus kredito rizikos modelių informacijos vartotojams tose srityse, kuriose yra arba bus naudojami. Taip pat, modelio kūrimas, įtraukiant skirtingą informaciją, turėtų būti paremtas konkrečiau tyrimo pagrindiniu tikslu ir atsiriboti nuo perteklinės informacijos integravimo.

Nors nauji metodai yra taikomi siekiant didinti modelių tikslumą, tačiau vieningos nuomonės apie optimalią techniką, kuriant patikimus modelius nėra. Tyrimai atskleidžia, jog modelių pagrindinis apribojimas yra tikslinės klasės generavimas, kuris nesuteikia paaiškinimo, todėl modeliai negali vienu metu ieškoti modelių interpretacijos ir prognozavimo tikslumo. Kadangi finansų įstaigos siekia užtikrinti skaidrumą ir rezultatų aiškumą, kad sprendimo priėmimas būtų aiškus tiek vertintojams, tiek pareiškėjams, Soui, Gasmi, Smiti ir Ghédira (2019) šią problemą siūlo spręsti

taisyklėmis pagrįstu modeliu, akcentuodami tai, kad bet koks taisyklėmis pagrįstas modelis yra naudingas tuo, jog finansų įstaigos duomenų rinkinius gali paversti lengvai suprantama informacija. Įmonės, užsiimančios skolinimo veikla, tam tikrus apribojimus gali integruoti į taisyklėmis pagrįstą modelį, kuris suteiktų skaidrų, aiškius rezultatus nustatantį sprendimą, kas leistų pasiekti tikslumo bei aiškinamumo pusiausvyrą vertinant naujus pareiškėjus.

Apibendrinant galima teigti, jog tinkamai parinkti kredito vertinimo modeliai ir metodai gali tapti labai svarbūs ne tik priimant sprendimus dėl potencialių klientų kreditavimo, tačiau ir turėti didelę įtaką sprendžiant kredito rizikos modeliavimo klausimus. Pagrindine išvada laikoma tai, jog pasirenkant taikyti skirtingus metodus pirmiausiai dėmesys turi būti sutelktas į norimą pasiekti rezultatą, modelio pritaikomumą praktiniame lygmenyje ir nesudėtingą rezultatų interpretaciją.

## **1.2. Smulkaus verslo koncepcija ir vertinimas**

Prieiga prie išorinio finansavimo yra viena iš pagrindinių temų, kurias bandoma spręsti tiek akademinėje, tiek socialinėje erdvėje. Išorinio finansavimo prieinamumo problemos gali ne tik sudaryti kliūtis įsteigtoms mažesnėms įmonėms augti, o naujoms įmonėms pradėti veiklą, tačiau ir prisidėti prie bendros ekonomikos svyravimų. Kredito rizikos vertinimo kontekste, mokslininkai, nagrinėjantys finansavimo galimybes, dažnai neatsižvelgia į situaciją, kai vertinant kredito riziką ir kuriant įvairius modelius, kurie padėtų priimti atitinkamus sprendimus bei išvengti nuostolių, nėra galimybės modelių adaptuoti visiems finansinių paslaugų sektoriaus dalyviams ir juos pritaikyti skirtingo dydžio įmonių vertinimui. Šiame skyriuje pateikiamas mažų ir labai mažų įmonių apibrėžimas ir statistinės analizės rezultatai Europos Sąjungos (toliau tekste – ES-27) bei Lietuvos regiono lygmenyje, toliau analizuojamos esminės smulkaus verslo savybės.

### **1.2.1. Mažų ir labai mažų įmonių samprata ir finansavimo prieinamumo analizė**

Finansavimo prieinamumas išlieka aktualia tema, nes mažos ir labai mažos įmonės užima svarbią vietą visoje ekonomikoje, o jų galimybės gauti finansavimą vis tiek išlieka ribotos. Šiuo metu esamoje mokslinėje literatūroje atskiras mažų ir labai mažų įmonių nagrinėjimas yra daugiau teoriniame lygyje, atliktų tyrimų yra pakankamai mažai, o iki šiol šios įmonės dažniausiai nagrinėtos kartu su vidutinėmis įmonėmis, ir patenka į smulkaus ir vidutinio verslo (toliau tekste – SVV)

nagrinėjimo sritį. Dėl šios priežasties, pirmiausiai aptariama šių įmonių kartu su vidutinėmis įmonėmis, kaip grupės, charakteristika.

Lietuvos Respublikos smulkiojo ir vidutinio verslo plėtros įstatymo<sup>4</sup> II skyriaus „Smulkiojo ir vidutinio verslo subjektų samprata“ 3 straipsnis, kaip ir kitų ES narių įstatymai dėl labai mažų, mažų ir vidutinių įmonių (toliau tekste – MVI) apibrėžimo, remiasi Europos Komisijos (toliau tekste – EK) rekomendacija 2003/361/EB<sup>5</sup>, paskelbta *Europos Sąjungos oficialiame leidinyje* (OL L 124, 2003 5 20, p. 36), kuriame atsižvelgiama į 3 kriterijus – darbuotojų skaičių, metinę apyvartą ir bendrą metinį balansą:

- labai mažomis įmonėmis laikomos įmonės, kuriose:
  - darbuotojų skaičius neviršija 10 darbuotojų ir kurios finansiniai duomenys atitinka bent vieną iš dviejų kriterijų:
    - 1) metinės pajamos neviršija 2 mln. eurų,
    - 2) balanse nurodyto turto vertė neviršija 2 mln. eurų;
- mažomis įmonėmis laikomos įmonės, kuriose:
  - darbuotojų skaičius neviršija 50 darbuotojų ir kurios finansiniai duomenys atitinka bent vieną iš dviejų kriterijų:
    - 1) metinės pajamos neviršija 10 mln. eurų,
    - 2) balanse nurodyto turto vertė neviršija 10 mln. eurų;
- vidutinėmis įmonėmis laikomos įmonės, kuriose:
  - darbuotojų skaičius neviršija 250 darbuotojų ir kurios finansiniai duomenys atitinka bent vieną iš dviejų kriterijų:
    - 1) metinės pajamos neviršija 50 mln. eurų,
    - 2) balanse nurodyto turto vertė neviršija 43 mln. eurų.

Remiantis EK, „*nustatyti, kurios įmonės iš tiesų yra MVI, svarbu <...> todėl, kad MVI reikia tokios pagalbos, kurios nereikia kitoms įmonėms*“ (European Commission, 2015). Palyginti su kitomis įmonėmis, šios grupės akcentuoja susidūrimą su joms būdingomis problemų sritimis, tokiomis kaip rinkos nepakankamumas bei struktūrinės kliūtys. Europos Komisija (EK) kartu su Europos investicijų banku (EIB) ir Europos investicijų fondu (EIF) nurodo, jog rinkos nepakankamumas lemia veiklos vykdymą ir konkurenciją su kitais rinkos dalyviais sudėtingesnėmis sąlygomis ir pabrėžia sunkumo

---

<sup>4</sup> Lietuvos Respublikos Seimas. Lietuvos Respublikos smulkiojo ir vidutinio verslo plėtros įstatymas. 1998 m. lapkričio 24 d. Nr. VIII-935. *Galiojanti suvestinė redakcija nuo 2022-03-31*.

<sup>5</sup> [EU recommendation 2003/361](#) – Europos Komisijos rekomendacija, kurioje apibrėžiamos mažos ir labai mažos įmonės.

gauti finansavimą problemas, o struktūrinės kliūtys yra susijusios su darbo rinkos apribojimais bei nepakankamomis žiniomis bei techninių įgūdžių trūkumu.

Atsižvelgiant į smulkaus verslo specifiką, finansuotojui svarbus ne tik kredito rizikos įvertinimas, tačiau būtinas supratimas apie verslo galimybes, portfelio diversifikavimą bei rinkos situaciją. Turėdamos informaciją apie veikiančių įmonių skaičių, finansų įstaigos gali prognozuoti paklausą, efektyviai valdyti portfelį bei įvertinti rinkos dydį, augimo potencialą ir konkurencijos lygį.

## 2 lentelė

*Įmonių skaičius Europos Sąjungoje 2022 m.*

Įmonės dydis	ES-27	
	Įmonių skaičius   vnt.	Įmonių dalis   proc.
Labai mažos įmonės	22 744 173	93,5
Mažos įmonės	1 332 200	5,5
Vidutinės įmonės	204 786	0,8
Didelės įmonės	43 112	0,2
Visos įmonės	24 324 271	100,0

Šaltinis: sudaryta autorės, remiantis Di Bella ir kt., 2023.

2022 m. duomenys yra pagrįsti apskaičiavimais, remiantis 2022 m. gruodžio mėnesio turimais ekonominiais duomenimis, ir rodo, jog apie 99,0% ES įmonių yra priskiriamos smulkaus verslo kategorijai. Ženklaus smulkaus verslo dominavimas ES ekonominėje sistemoje išryškina labai mažų ir mažų įmonių svarbą šioje erdvėje.

## 3 lentelė

*Lietuvos įmonių skaičius metų pradžioje 2019–2023 m.*

Įmonės dydis	2019	2020	2021	2022	2023
	<b>Veikiančių įmonių skaičius metų pradžioje   vnt.</b>				
Labai mažos įmonės	69 223	71 841	72 542	78 098	84 999
Mažos įmonės	12 853	12 461	12 264	12 141	12 549
Vidutinės įmonės	2 434	2 436	2 478	2 389	2 497
Didelės įmonės	380	405	423	431	443
Visos įmonės	84 890	87 143	87 707	93 059	100 488
<b>Veikiančių įmonių skaičius metų pradžioje   proc.</b>					
Labai mažos įmonės	81,5	82,4	82,7	83,9	84,6
Mažos įmonės	15,1	14,3	14,0	13,0	12,5

Šaltinis: sudaryta autorės, remiantis Lietuvos statistikos departamento duomenimis, 2023.

Pateikti duomenys atskleidžia tendenciją, jog Lietuvos Respublikoje smulkaus verslo dalis didėja. Per pastaruosius 5 metus mažos ir labai mažos įmonės sudarė nuo 96,7% visų įmonių 2019 m. iki 97,1% 2023 m. Per šį laikotarpį labai mažos įmonės užima dominuojančią poziciją, šių įmonių dalis linkusi dar labiau augti, o mažų įmonių dalis laipsniškai mažėja.

Įmonių skaičius, atspindintis konkurencijos lygį ir verslo aplinką, kasmet kinta. Remiantis naujausiais Europos Sąjungos statistikos tarnybos (EUROSTAT) duomenimis, 2021 m. ES-27 buvo 31,5 mln. aktyvių įmonių, iš kurių – 11% (3,4 mln.) yra įregistruotos nagrinėjamais metais.

#### 4 lentelė

*Įregistruotos ir išregistruotos įmonės Europos Sąjungoje ir Lietuvoje 2021 m.*

	Įregistruotos įmonės   proc.	Išregistruotos įmonės   proc.
<b>ES-27</b>	10,7	8,5
<b>Lietuva</b>	20,2	22,6

Šaltinis: sudaryta autorės, remiantis Eurostat, 2023a.

4 lentelėje pateikiami ES-27 ir Lietuvos įmonių „gimimo“ (angl. *enterprise birth*) ir „žūties“ (angl. *enterprise death*) rodikliai, kurie vaizduoja 2021 m. įregistruotų ir išregistruotų įmonių dalį<sup>6</sup> procentais. Oficialios statistikos duomenys rodo, jog 2021 m. daugumoje ES šalių buvo įsteigta daugiau įmonių nei likviduota, tačiau 6 šalyse narėse (įskaitant Lietuvą) – likviduotų įmonių skaičius viršijo įsteigtų įmonių skaičių. Kai įregistruotų įmonių skaičius viršija išregistruotų įmonių skaičių, tai reiškia, jog daugiau įmonių pradeda veikti nei jų baigia savo veiklą. Ši situacija iš dalies demonstruoja palankią verslo aplinką, todėl tai gali būti laikoma pozityviu reiškiniu, galinčiu skatinti verslumo augimą. Priešingai, kai įmonių žlugimo rodiklis viršija įmonių įsteigimo rodiklį, tai rodo, jog daugiau įmonių baigia vykdyti veiklą. Tokia situacija gali rodyti neigiamus ekonominės veiklos aspektus, verslo aplinkos sunkumus arba tam tikrus struktūrinius pokyčius – neigiamai paveikti darbo vietų skaičių, ekonominį augimą, bendrą verslo aplinką. Ši tendencija gali būti laikoma įspėjamuoju signalu valstybės ar regiono mastu ir atspindėti sektorių nestabilumą, konkurencijos sąlygas bei kitus veiksnius trukdančius įmonių įsteigimui ir sėkmei.

<sup>6</sup> Įregistruotų ir išregistruotų įmonių rodikliai parodo įregistruotų ir išregistruotų įmonių skaičių, išreikštą aktyvių įmonių visumos procentine dalimi per ataskaitinį laikotarpį (įprastai, vienerius kalendorinius metus).

Finansavimo apribojimai yra viena iš kliūčių verslo steigimui, dėl neturimo užstato ir teisinio statuso. Tačiau nemažiau svarbus įmonių išlikimo klausimas, pritrūkus apyvartinių lėšų įmonės veikloje. Įmonių žlugimą lemia daugybė veiksnių, tačiau istorinėje perspektyvoje, remiantis oficialios statistikos duomenimis, įmonių žlugimas gali būti siejamas ir su įmonės amžiumi. Šio veiksnio įvertinimas finansinių paslaugų teikėjams suteikia papildomos informacijos apie įmonės stabilumą, ilgalaikį perspektyvumą, patikimumą ir galimus rizikos faktorius. Siekiant įvertinti įmonių įmonių gyvavimo laikotarpį, skaičiuojamas įmonių išlikimo rodiklis<sup>7</sup> (angl. *survival rate*), kuris verslo demografijos kontekste reiškia, kad įmonė yra aktyvi užimtumo ir (arba) apyvartos požiūriu įsteigimo ir kitais metais.

## 5 lentelė

*Įmonių išlikimo rodikliai Europos Sąjungoje ir Lietuvoje 2018–2020 m.*

t	2018		2019		2020	
t-n <sup>8</sup>	ES-27   proc.	Lietuva   proc.	ES-27   proc.	Lietuva   proc.	ES-27   proc.	Lietuva   proc.
t-1	80,7	63,6	81,7	63,4	82,1	64,2
t-2	67,5	47,6	67,3	46,2	67,8	47,3
t-3	58,5	37,9	58,5	38,5	58,5	37,4
t-4	50,4	33,4	51,7	31,6	51,9	32,5
t-5	45,0	26,4	45,1	29,0	46,1	27,2

Šaltinis: sudaryta autorės, remiantis Eurostat, 2023b.

Įmonių išlikimo rodikliai rodo, jog daugiausiai naujai įsteigtų įmonių „išgyvena“ pirmaisiais metais, toliau šis dydis mažėja. Nors įmonėms augant pastebima bendra mažėjimo tendencija tiek ES, tiek Lietuvoje, tačiau šie dydžiai gana stipriai skiriasi. Lietuvoje įmonių išlikimo dalis nagrinėjamu laikotarpiu yra pastebimai žemesnė nei ES vidurkis, pirmaisiais įmonės gyvavimo metais didžiausias atotrūkis siekia iki 18,3 proc. punktų 2019 m., penktaisiais – iki 18,9 proc. punktų 2020 m. Tai rodo, jog istorinėje perspektyvoje Lietuvos įmonės, pradėjusios veiklą, turi didesnę tikimybę patirtį nesėkmę palyginti su ES vidurkiu, tačiau naujausi duomenys yra neprieinami.

EK metinėje Europos MVĮ ataskaitoje pastebima, jog „*padėtis ES MVĮ yra pavojinga ir tokia išliks artimiausioje ateityje*“ (Di Bella ir kt., 2023). Tai grindžiama istorine kelių pastarųjų metų

<sup>7</sup> Įmonių išlikimo rodiklis parodo atskaitiniu laikotarpiu naujai įsteigtų įmonių, išlikusių iki t laikotarpio, skaičių, išreikštą naujai įsteigtų įmonių visumos procentine dalimi per atskaitinį laikotarpį.

<sup>8</sup> t-n – yra įmonių išlikimo matas, kur t – atskaitinis laikotarpis, n – metai, nurodantys, kiek įmonė išliko.

padėti ir yra siejama su 2020 m. COVID-19 pandemija, kur MVĮ visame pasaulyje susidūrė su beprecedenčiu ekonominiu netikrumu, 2022 m. drastišku infliacijos lygio augimu bei 2022 m. Rusijos invazija į Ukrainą. Tuo tarpu tarptautinių institucijų ir Lietuvos banko apklausų rezultatai, atskleidžia, jog nuo 2019 m. „pagal kredito prieinamumo SVV įmonėms rodiklius Lietuva atsilieka nuo kitų ES šalių“. Lietuvos banko ir Lietuvos Respublikos konkurencijos tarybos (2021) atlikto smulkiojo ir vidutinio verslo finansavimo galimybių tyrimo rezultatai išryškina Lietuvos SVV finansavimo 2018–2019 m. spragas. Vertinimo metu gauti rezultatai atskleidė, jog SVV įmonės retai gauna visą reikalingą finansavimą iš bankų, o atmetamų paraiškų<sup>9</sup> dalis šalyje pastebimai išaugusi ir viena didžiausių ES. Lietuvos banko apklausos duomenys rodo paraiškų statuso vertinimą.

## 6 lentelė

*Paraiškų patenkinimo dalis Lietuvos bankuose 2019–2022 m.*

Lietuvos banko įmonių apklausos duomenys   paraiškų statusas	2019	2020	2021	2022
	Tiriamų įmonių skaičius   vnt.			
	501	501	504	501
Finansavimo sprendimo rezultatas   proc.				
Patenkinti prašymai	27%	37%	26%	17%
Patenkinti prašymai su papildomomis sąlygomis	33%	21%	40%	44%
Iš dalies patenkinti prašymai	12%	10%	25%	31%
Atmesti prašymai	28%	33%	9%	8%

Šaltinis: sudaryta autorės, remiantis Lietuvos banko duomenimis, 2019; 2020; 2021; 2022.


Apklausos rezultatai, pateikti 6 lentelėje rodo, jog atmestų paraiškų dalis 2021–2022 m. ženkliai sumažėjo, o didesnė dalis respondentų prašymų buvo patenkinti pritaikius kreditoriaus nurodytas sąlygas, be to, stipriai išaugo iš dalies patenkintų prašymų dalis. Lietuvos banko (2022) įmonių apklausos rezultatai rodo, jog Lietuvos verslas daugiausiai finansuojamas vidaus ištekliais, o daugiau nei pusė įmonių nesinaudoja finansų įstaigų paslaugomis dėl priežasčių, susijusių su nenoru skolintis bei finansavimo neprieinamumu. Tyrimas atskleidžia, jog Rusijos karo prieš Ukrainą pasekmės bei didelė infliacija lemia Lietuvos verslo produkcijos paklausos augimo sulėtėjimą ir didina bankroto riziką. Nors kai kurios įmonės susiduria su sunkumais dėl kredito įstaigų skolinimo apribojimų – ši problema dažniausiai kyla dėl prastos įmonių finansinės padėties. Finansavimo

<sup>9</sup> Šioje dalyje paraiškos vertinamos kaip įmonių prašymai dėl naujo finansavimo suteikimo arba esamų įsipareigojimų sąlygų pakeitimų.

neprieinamumas, remiantis reguliariai vykdomomis įmonių apklausomis per pastaruosius 4 metus, gali būti paaiškinamas pagrindinėmis 5 priežastimis.

## 7 lentelė

*Finansavimo neprieinamumo Lietuvos bankuose priežastys 2019–2022 m.*



Šaltinis: sudaryta autorės, remiantis Lietuvos banko duomenimis, 2019; 2020; 2021; 2022.

7 lentelėje pateikiama po 3 dažniausiai įvardijamas priežastis dėl finansavimo paraiškos atmetimo kiekvienais metais. Galima pastebėti, jog prasta įmonių finansinė būklė visuomet buvo vienas iš pagrindinių ribojančiųjų veiksnių, tačiau kitos kategorijos bėgant laikui turi tendenciją keistis. 2019 m. ir 2020 m. aukštą paraiškų atmetimo priežastingumą lėmė aukštas išiskolinimo lygis, mokėjimų istorija bei užstato reikalavimai, o 2021 m. ir 2022 m. didesnę reikšmingumą įgauna bendra ekonominė padėtis bei nemotyvuotas kredito įstaigos atsisakymas. Tai rodo, jog nors kreditoriai nagrinėja įmonių paraiškas, atsižvelgdamos į finansinius rodiklius, kiti veiksniai taip pat prisideda prie sprendimų priėmimo proceso.

Apibendrinant, galima daryti išvadą, jog nustatant smulkaus verslo subjektus, svarbu atsižvelgti į jų specifinius iššūkius ir poreikius. Analizuojant ES ir Lietuvos regiono smulkaus verslo struktūrą, ji tampa esmine ekonominės erdvės dalimi. Nepaisant ekonominių veiksnių poveikio, pastebimas labai mažų įmonių augimas, o finansavimo paraiškų tenkinimo lygis šiek tiek pagerėjo, rodydamas galimą verslo aplinkos stabilizaciją. Svarbu sutelkti dėmesį į likusią nepatenkintų banko paraiškų dalį ir ieškoti alternatyvių būdų, kaip kiti finansų rinkos dalyviai gali prisidėti prie šių problemų sprendimo. Toks požiūris nereiškia, jog finansavimas būtų prieinamas visiems rinkos



dalyviams, tačiau tai yra paskata finansinių paslaugų teikėjams kritiškai vertinti verslo aplinką ir nustatyti strategijas siekiant užtikrinti finansinį stabilumą bei tinkamą kredito rizikos lygio įvertinimą.

### **1.2.2. Mažų ir labai mažų ekonominė reikšmė ir kreditavimo iššūkiai**

Pasauliniu mastu smulkaus ir vidutinio verslo įmonės yra laikomos pagrindiniais varikliais, kurie gali užtikrinti tvarų ekonomikos augimą ir sėkmingai prisitaikyti prie globalizacijos ir skaitmeninio pokyčių (Godke Veiga ir McCahery, 2019; Eggers, 2020; Jabbouri ir Farooq, 2021). Socialiniu aspektu jos sudaro sąlygas ištraukti ir plėtoti ekonominę šalies veiklą ir prisidėti prie vienos iš didžiausių socialinių problemų – nedarbo mažinimo (Błach, Wieczorek-Kosmala ir Trzęsiok, 2020). Davulis (2013) atskleidžia, jog SVV įmonės ne tik geba prisitaikyti prie rinkos pokyčių, didina užimtumą, bet ir skatina naujų bei dažnu atveju geresnės kokybės produktų, paslaugų ir gamybos procesų kūrimą, todėl sudarydamos konkurencingą aplinką, ženkliai prisideda prie inovacijų kūrimo. Liustrovaitė ir Martinkutė-Kaulienė (2015) dar kartą pabrėžia darbo jėgos užimtumo didinimą, kuriant naujas darbo vietas, o kartu nurodo, jog smulkus ir vidutinis verslas yra prioritetinga sritis, skatinanti spartesnį BVP augimą. Malakauskas ir Lakštienė (2021b) išryškina MVI vaidmenį užtikrinant šalies ekonominę ir socialinę gerovę. Dėl visų išvardintų savybių ir akivaizdžios šių įmonių svarbos ekonominiu bei socialiniu požiūriu, finansavimo kliūčių šalinimas yra esminis veiksnys skatinant jų augimą ir vystymąsi.

Ankstyvieji mažų ir labai mažų įmonių tyrimai, orientuojami tik į smulkųjį segmentą, nurodo, jog šios įmonės linkusios savo savybėmis skirtis nuo didelių ir vidutinių įmonių. Moksliniuose darbuose pabrėžiama, jog mažos ir labai mažos įmonės, kaip grupė, turi didelę ekonominę jėgą, tačiau jos yra lengvai pažeidžiamos, kai yra vertinamos kaip atskiri subjektai. To priežastimi įvardijami tokie veiksniai kaip: nepakankamas finansavimas ir jautrumas socialinei, teisinei bei verslo aplinkai (Belás ir kt., 2018). Nors mikroįmonės yra labai mažos, tačiau jos turi didelę naudą ekonomikos augimui, užimtumui ir pajamų generavimui. Norėdamos augti, mažos įmonės turi didinti kapitalą, kad galėtų palaikyti veiklos tęstinumą, įsigyti turtą ar padengti veiklos išlaidas (Civelek, Ključnikov, Krištofik ir Rozsa, 2019). Būtent todėl mažos ir labai mažos įmonės išorės finansavimo lėšas dažniausiai naudoja investicijų, atsargų ir apyvartinio kapitalo užtikrinimui, o prieigos prie išorės finansavimo spragos gali mažinti šių įmonių pelningumą. Siekiant palaikyti tvarų ekonomikos lygį, svarbia problema tampa šių įmonių išlikimo klausimas.

Finansavimas, gaunamas reikiamu metu, turi didelę reikšmę įmonėms, tam tikru laikotarpiu susiduriančioms su lėšų trūkumu. Anot Liu (2016), dauguma mažų ir labai mažų įmonių susiduria su didelėmis lėšų sąnaudomis, o finansavimo kryptis sumažina didesnę socialinės realybės riziką. Liustrovaitė ir Martinkutė-Kaulienė (2015) pastebi, jog kredito suteikimas įmonėms leidžia didesniu tempu padidinti gamybą, kurios apimtys taip sparčiai neišaugtų naudojantis vien nuosavomis lėšomis, taip pat užtikrina apyvartines lėšas, gerina įmonės finansinius rodiklius bei spartina mokslo ir technologinę pažangą. Atsiradus pajamų ir išlaidų skirtumui įmonės gali šį atotrūkį spręsti kreditavimo galimybėmis. Kreditavimo vertinimas skolinimo veikloje reikalauja išsamios informacijos, siekiant pažinti potencialų klientą, todėl finansų įstaigos, susidurdamos su informacijos trūkumu, yra linkusios susilaikyti nuo skolinimo arba riziką valdyti pakeičiant stygių aukštesniais užstato reikalavimais.

Pasaulinė finansų krizė privertė atsižvelgti į kredito rizikos vertinimą ir paskatino finansines institucijas tai laikyti esminiu uždaviniu dėl didelių nuostolių, patirtų dėl netinkamų finansavimo sprendimų. Pasak Ciampi, Giannozzi, Marzi ir Altman (2021), finansų krizės metu įmonės susidūrė su vis didesniais sunkumais, o skolinotojai privalėjo stebėti laipsniško neįvykdytų paskolų skaičiaus didėjimo padarinius. Tai yra vienas iš įrodymų, jog įvairūs finansiniai sukrėtimai bei paveikta makroekonominė aplinka padarė įtaką išorinio finansavimo prieinamumui, dėl to išaugo poreikis kurti naujus prognozavimo modelius ir kredito rizikos modeliai grįžo į akademinį akiratį. Belás ir kt. (2018) taip pat pastebi, jog empiriniuose tyrimuose randama įrodymų apie pasaulinės finansų krizės pasekmes bankų skolinimui, o įmonės net ir šiais laikais vis dar susiduria su problemomis gauti banko finansavimą. Esant tokiai padėčiai, svarbus uždavinys – finansinės padėties išlaikymas, o kreditavimo iššūkių pasekme tampa didėjanti įmonių finansinė rizika, nes trūksta tinkamų ir prieinamų išorės finansavimo šaltinių.

Bankų finansavimo spragas iš dalies taisė kiti skolinimo rinkos veikėjai. Huang ir kt. (2020) atskleidžia, jog iki šiol papildomą vaidmenį vaidino „FinTech“ skolinimas, papildydamas tradicinę bankininkystę pasiekiant nepakankamai aptarnaujamus klientus. Gopal ir Schnabl (2022) teigia, jog įvairios finansų bendrovės ir „FinTech“ skolinotojai yra pagrindiniai kreditų tiekėjai mažoms įmonėms ir vaidino svarbų vaidmenį atsigaunant po 2008 m. finansų krizės. Nors pastebima, jog bankų skolinimas yra sumažėjęs, tačiau nebankiniai skolinotojai sugebėjo kompensuoti nuosmukį išplėte skolinimą. Nepaisant to, tenka pripažinti, jog finansinių paslaugų sektoriaus dalyviai prisiima skirtingą rizikos lygį, todėl kredito rizikos vertinimo kriterijai skiriasi. Atsižvelgiant į oficialios statistikos duomenis, dažniausiai šių rinkos veikėjų skolinimas įmonėms grindžiamas užstato arba

garantijos suteikimu, tačiau priežastis, jog daugelis mažų įmonių neturi turto, kurį galėtų pateikti kaip įsipareigojimų užtikrinimo priemonę, taip pat riboja finansavimo galimybes.

Per pastarąjį dešimtmetį, stebint prieigos prie finansavimo kliūtis, SVV sektorius sulaukė didelio susidomėjimo, todėl akademiniai tyrimai pradėjo gilintis į pagrindines šių įmonių savybes, kurios gali paaiškinti finansų institucijų, o ypač bankų, susilaikymą finansuoti mažas ir vidutines įmones. Civelek ir kt. (2019) nustatė, kad dėl nepakankamų vidinių šaltinių, mažos įmonės dažniau susiduria su įvairiomis kliūtimis nei didesnės įmonės, todėl dažniausiai kreipiasi į skolinimo veikla užsiimančias institucijas. Smulkus verslas dėl savo mažo masto dažnai neturi konkurencinio pranašumo, o nuosavų lėšų trūkumas, ypač įmonės steigimo stadijoje, riboja jos plėtrą, todėl ir susiduriama su finansavimo poreikiu. Šiuolaikiniai tyrimai mokslinėje erdvėje rodo, jog įmonės steigimas, vystymasis, augimas ir jos tolimesnė plėtra daugiausia priklauso nuo finansavimo iš nuolatinio savarankiško kapitalo kaupimo, todėl įmonės nuosavos lėšos yra svarbi tolimesnės plėtros ir augimo garantija (Prijadi, Wulandari, Desiana, Pinagara ir Novita, 2020).

Jin ir Zhang (2019) teigia, jog pagrindinis finansavimo kliūčių šaltinis įmonėms gali tapti kredito normavimas, nurodantis situaciją, kad tarp identiškų pareiškėjų, vieni paskolą gauna, o kitiems kreditas nesuteikiamas. Kadangi kredito rinkose skolininkai kartais yra normuojami pagal galimą paskolinti sumą labiau tikėtina, jog šis normavimas bus taikomas labai mažoms ir mažoms įmonėms. Suryani, Hidayati, Putra ir Syah (2021) teigia, kad skolinio ir skolininko santykių tvirtumas turėjo teigiamos įtakos kredito prieinamumui. Liu (2016) išskiria tai, jog mažos įmonės negali gauti kredito dėl labai svarbių vidinių priežasčių, tokių kaip valdymo stoka, nestabilumas bei pažeidžiamumas rinkos svyravimų atžvilgiu. Abraham ir Schmukler (2017) kaip pagrindines priežastis nurodo neskaidrumą, makroekonominę aplinką ir finansavimo reglamentavimą, kurios trukdo gauti reikiamą finansavimą. Įmonių skaidrumas šiuo atveju vertinamas pagal viešos informacijos prieinamumą, kuris mažų ir labai mažų įmonių kontekste yra kur kas mažesnis, palyginti su didelėmis įmonėmis.

Vis dar vyksta akademinės diskusijos apie ryšį tarp patikimos finansinės informacijos ir mažų įmonių galimybės naudotis įvairiais finansavimo šaltiniais. Dėl riboto duomenų prieinamumo ir mažesnio finansinio lankstumo šios įmonės laikomos rizikingesnėmis (Malakauskas ir Lakštutienė, 2021b). Tai reiškia, jog įmonės taip pat neturi išsamios kredito istorijos, todėl bankai, negalėdami tiksliai nustatyti jų kredito statuso ir veiklos rizikos, kredito suteikimo galimybę dažnai atmeta. Chit (2019) atliko tyrimą, kuriame nagrinėjamas patikimos finansinės informacijos vaidmuo ir jos sąveika su šalies teisine ir reguliavimo aplinka prieigai prie įvairių finansavimo šaltinių 129 besivystančiose šalyse, kurio rezultatai atskleidė, jog priežastis, dėl kurios ribojama mažų įmonių galimybė gauti

išorinį finansavimą, yra konkrečios informacijos, kuri padėtų finansų tiekėjams nustatyti įsipareigojimų nevykdymo riziką, trūkumas. Jingming, L. Xuhui, Daoming, Sumei ir Z. Xuhui (2020), išskiria tokias problemas kaip finansinių ataskaitų neprieinamumas ir nepatikimumas, nedidelis turtas ir mažas mastas. Apibendrinant galima teigti, jog labai mažoms ir mažoms įmonėms finansavimas tampa sudėtinga problema, nes dėl šių apribojimų sunku pagrįstai įvertinti kredito riziką.

Daugelyje ankstesnių tyrimų buvo atlikta finansavimą gaunančių įmonių kredito rizikos įvertinimo būdų, kurie grindžiami skirtingais metodais, tačiau jie ne visada tinkami mažų ir labai mažų įmonių vertinimui, nes prieiga prie smulkaus verslo duomenų yra ribota. Kaip teigia Chai, Wu, Yang ir Shi (2019), yra daugiau tekstinės nefinansinės informacijos, o ne kiekybinių mažų įmonių finansinių duomenų. Finansavimas kreditais vis dar yra pagrindinis mažų ir labai mažų įmonių finansavimo būdas. Tačiau kai kalbama apie mažas ir labai mažas įmones, smulkaus verslo kredito vertinimo sistemos vis dar yra gana žemame mokslinių tyrimų lygyje. Dėl anksčiau minėtų priežasčių, susijusių su politinių, ekonominių, teisinių ir kitų išorinių veiksnių, turinčių įtakos smulkaus verslo finansavimo apribojimams, svarbu sukurti atitinkamą kredito rizikos vertinimo modelį ir įvertinti esamas problemas vertinant duomenų pasiekiamumą.

Taigi, mažos ir labai mažos įmonės vaidina labai svarbų vaidmenį užtikrinant ekonomikos augimą, technologines naujoves, užimtumą ir socialinį stabilumą. Įvertinus smulkaus verslo vaidmenį ekonomikos vystyme ir jo išskirtines savybes, kurios skiriasi nuo didelių ir vidutinių įmonių, nustatyta, jog specialiai smulkiajam verslui skirtų kredito rizikos vertinimo sistemų kūrimas, skirtas atspindėti šių įmonių specifiką, yra būtinas veiksnys prisidedant prie tikslesnės rizikos vertinimo galimybių, didesnio pasitikėjimo kreditavimo procesu bei rinkos lankstumo ir adaptacijos.

### **1.3. Automatizacija kredito sprendimų priėmimo procese – smulkaus verslo vertinimo metodų taikymo galimybės ir kritinis vertinimas**

Šiuolaikinės finansų rinkos dinamika skatina finansuotojus ieškoti inovatyvių būdų optimizuoti kreditavimo procesus ir mažinti susijusias rizikas. Vienas iš šiuolaikinių mokslinių ir praktinių diskursų objektų – automatizuotų sprendimų priėmimo sistemų taikymas smulkaus verslo kredito rizikos vertinime. Remiantis prielaidomis apie pažangių technologijų panaudojimo ir pritaikymo konkrečiai verslo aplinkai potencialą, šiame skyriuje analizuojama dirbtinio intelekto modelių grupės funkcionalumas sprendimų priėmimo kontekste.

Automatizacijos pagrindinis tikslas verslo požiūriu yra optimizuoti veiklos procesus. Vienas iš automatizacijos privalumų – sumažinti arba visiškai pakeisti žmogaus intervenciją atliekant didelės apimties kasdienes užduotis. Kredito rizikos vertinimo kontekste, tai užtikrina sprendimų priėmimo efektyvumą dėl galimybės pateikti sprendimus greičiau nei tai leidžia žmogaus gebėjimai. Pasak Schoeffer, Machowski ir Kuehl (2021), automatizuotos sprendimo dėl kredito suteikimo procedūros teisingumas ir informacijos teisingumas yra glaudžiai susiję su patikimumu, o informacinis teisingumas – su suprantamumu. Autorių atliktas tyrimas atskleidžia automatizuotų procesų naudą atsižvelgiant į sąžiningumo bei objektyvumo motyvus ir pagrindžia faktą, jog automatizuoto sprendimų priėmimo potencialas ir jo nauda yra akivaizdi.

Dirbtinio intelekto modeliai gali būti laikomi automatizuotais procesais, priklausomai nuo jų formavimo būdų ir veikimo principų. Skirtingais metodais grindžiami dirbtinio intelekto modeliai skiriasi savo struktūra ir taikymo sritimi, tačiau jie gali būti siejami su dirbtiniu intelektu, nes yra sukurti tam, kad automatizuotų tam tikrus sprendimų priėmimo procesus. Pastaraisiais metais vis didėjant prognozavimo modelių mastui, būtina analizuoti anksčiau atliktus tyrimus ir kritiškai įvertinti skirtingų metodų pritaikymo galimybes. Atsižvelgiant į ankstesnius dirbtinio intelekto modelių grupės tyrimus, toliau pagrindinis dėmesys skiriamas mašininio mokymosi metodų (Bao, Lianju ir Yue, 2019; Bhattacharya ir kt., 2023; Wang, Liu ir Qi, 2022) vertinimui, „juodųjų dėžių“ (Grant, Behrends ir Basl, 2023; Rudin, 2019; Yang ir kt., 2022) problematikai bei paaiškinamų dirbtinio intelekto sistemų (Luo ir Matz, 2021; Sachan, Yang, Xu, Benavides ir Li, 2020) analizei.

Mašininio mokymosi modeliai, kurie mokosi iš duomenų be iš anksto nustatytų taisyklių, naudoja algoritmus, leidžiančius gerinti savo veikimą be tiesioginio žmogaus įsikišimo. Skirtingi metodai nėra lyginami tarpusavyje, nes skiriasi savo struktūra, tačiau atlikus mokslinių tyrimų rezultatų analizę 8 lentelėje pateikiamos kelios apibendrintos kredito rizikos vertinimo modeliavimo srityje charakteristikos, kurios pagrindžia 1.1.2 poskyryje minėtus mašininio mokymosi tikimybių klasifikatorių apribojimus ir nurodo, jog šie metodai ne visais atvejais yra tinkami modelių formavimui. Moksliniuose tyrimuose šis metodas vertinamas kaip aukštos skaičiavimo pažangos ir optimizavimo algoritmų tobulinimo rezultatus, tačiau tyrėjai nėra linkę įvertinti skirtingais atvejais turimų duomenų kiekio bei struktūros.

## 8 lentelė

*Mašininio mokymosi modelių metodų privalumai ir trūkumai – mokslinių tyrimų analizės rezultatai*

Metodas	Privalumai	Trūkumai
Sprendimų medžiai (angl. <i>decision trees, DT</i> )	Veiksmingi rezultatai dideliems duomenų šaltiniams per palyginti trumpą laikotarpį, aukštas aiškinamumo lygis, lankstumas kelių klasių klasifikavimo problemose	Jautrus trūkstamiems duomenims
Atsitiktiniai miškai (angl. <i>random forests, RF</i> )	Aptinka sąveiką tarp mokymosi procesų funkcijų, turi stiprias nesubalansuotų duomenų rinkinių apdorojimo galimybes, padidina tikslumą, kai kintamieji turi sudėtingus tarpusavio ryšius	Klasifikavimo efektas netinkamas mažiems duomenims
Atraminų vektorių mašinos (angl. <i>support vector machines, SVM</i> )	Pasižymi geromis apibendrinimo galimybėmis ir tinkamas mažiems pavyzdžiams, didelių matmenų funkcijų erdvėms ir netiesiškumui	Jautrus trūkstamiems duomenims, neturi universalios netiesinių problemų sprendimo
K-artimiausi kaimynai (angl. <i>k-nearest neighbors, KNN</i> )	Paprastas ir efektyvus, tinka automatiniam didelio imties dydžio klasių domenų klasifikavimui	Didelės skaičiavimo sąnaudos, netinka didelių matmenų objektų erdvei, jautrus nesubalansuotiems duomenims
Neuroniniai tinklai (angl. <i>neural networks, NN</i> )	Pasižymi aukštu klasifikavimo tikslumu, dideliu atsparumu „triukšmui“, gali suderinti sudėtingus nelinijinius ryšius, ypač greitai pritaikomas prie naujų probleminių situacijų	Reikia daug parametrų, kurių nustatymas neaiškus dėl „geriausio“ rezultato, išvesties rezultatus sunku paaiškinti

Šaltinis: sudaryta autorės, remiantis Bao ir kt., 2019; Bhattacharya ir kt., 2023; Wang ir kt., 2022.

Nors dauguma tyrimų įrodo, jog dirbtinio intelekto sistemos prilygsta ar net yra aukščiau žmogaus galimybių ribų, jų naudojimas vis dar yra vertinamas abejotinai. Pagrindinis mašininio mokymosi trūkumas susijęs su duomenų apimtimi bei universalumu.

Dirbtinio intelekto sistemos neretai siejamos su „juodosios dėžės“ (angl. *black box*) sąvoka. Nors skirtinguose moksliniuose darbuose apibrėžimai ir išskiriamos savybės lieka ne iki galo suprantamos, literatūroje ši sąvoka dažnai apibrėžiama priešingai nei „paaiškinamos“ dirbtinio intelekto sistemos. Rudin (2019) tyrime pateikiamas griežtas požiūris, kuris nurodo, jog „juodųjų dėžių“ dirbtinio intelekto sistemos yra problematiškos ir kad jos netinkamos naudotis priimant svarbius sprendimus, ypač tais atvejais, kai yra geriau interpretuojamų alternatyvų. Priešingai, Grant ir kt. (2023) moksliniame darbe nurodo, jog yra mažiausiai dešimt kontrargumentų, kurie nurodo prieštaravimą minėtam požiūriui. Svarbiausiais iš jų šiame darbe laikomi – turimų įrodymų ignoravimas ir dvigubi standartai, kurie, pasak autorių, gali būti paaiškinami tuo, jog:

- 1) daugelyje sričių geras algoritmas yra linkęs daryti mažiau klaidų nei žmogus, kas reiškia jog algoritmai nėra jautrūs lengvai prieinamai informacijai, kurių žmogus gali nepastebėti,
- 2) žmonės gali būti nemotyvuoti teisingai iškomunikuoti savo pasirinkimo, todėl laikoma, jog sprendimus priimančios žmonės veikia tokiu pačiu „juodosios dėžės“ principu.

Yang ir kt. (2022) nustatė, jog palyginti su „juodosiomis dėžėmis“, nenaudojančiomis savaime paaiškinamo modeliavimo, taisyklėmis pagrįstos sistemos padeda suprasti pagrindinę problemą ir „protingų“ sprendimų bei prognozių priežastis, t. y. jos paaiškinimo galimybes.

Taisyklėmis pagrįsti metodai taip pat gali būti laikomi dirbtinio intelekto sritimi. Nors tokie modeliai remiasi taisyklėmis arba logika, kurią nustato žmogus, sistemos veikia pagal iš anksto nustatytą struktūrą ir gali automatiškai priimti sprendimus. Sachan ir kt. (2020), abejodami mašininio mokymosi modelių skaidrumu, esą jie nesuteikia pakankamos garantijos, kai bus pritaikyti automatizuojant skolinimo sprendimus, sukūrė paaiškinamą dirbtinio intelekto sprendimų palaikymo sistemą, skirtą automatizuoti skolinimo procesą pagal įsitikinimų taisyklių bazę (angl. *belief-rule-base, BRB*). Autorių teigimu, tai yra skaidri sprendimų priėmimo sistema, kuri gali paaiškinti tikrąjį sprendimo priėmimo procesą ir visą įvykių grandinę, kuri veda prie atitinkamo sprendimo. Panašų požiūrį atskleidžia Luo ir Matz (2021). Autoriai, nagrinėdami paaiškinamą dirbtinį intelektą (angl. *explainable artificial intelligence, XAI*) Švedijos kredito vertinimo pramonėje, pastebi, jog pagrindinė mašininio mokymosi kritika remiasi tuo, jog „paaiškinimai gali sukelti perdėtą pasitikėjimą sistemomis“ ir „negalima tikėtis, kad vienas paaiškinimas tinka visoms auditorijoms“. Remdamiesi van der Waa ir kt. (2021), mokslininkai atskleidžia, jog taisyklėmis ir pavyzdžiais paremti paaiškinimai įrodo jų veiksmingumą, nors ir tyrimo dalyviams to nepakanka, kad suprastų pagrindinį modelį, nes šie nori žinoti, kodėl taisyklė yra teisinga. Dėl šios priežasties Luo ir Matz (2021) pasiūlyta trijų etapų sistema paaiškinimų įgyvendinimui praktikoje, įvertina vartotojų pasitikėjimo ir sistemos supratimo lygius, taip pat paaiškinimo naudingumą, įtikinamąją galią ir tinkamumą, o tyrimas įrodo, jog taisyklėmis pagrįsti paaiškinimai geriausiai veikia tarp vartotojų, ypač įtikinimo galios ir suvokiamo sistemos supratimo aspektais.

Goebel ir kt. (2018) tyrimas įrodo, jog „pravartu ne atmesti žmogaus kompetenciją, o papildyti žmogaus intelektą dirbtiniu intelektu“. Schotten, de Sousa Pereira ir Morais (2022) linkę pripažinti, jog „tinkamai“ automatizuoti sprendimai turėtų apibendrinti „skirtingų sprendimus priimančių asmenų perspektyvas, remti organizaciją kredito analizės procese ir, atitinkamai, pagerinti jos veiklą“. Autoriai pateikia kredito suteikimo rūšiavimo modelį, kuris remiasi į sprendimų priėmimą orientuotą teoriją įgyvendinimu. Pagrindinis tyrimo rezultatas yra įrodymas, jog organizacijos

strateginių tikslų integravimas į kredito analizės sprendimų kontekstą sumažina riziką, susijusią su kredito suteikimo operacijomis.

Apibendrinant, automatizacija kredito rizikos vertinimo procese šiuolaikinėje finansų rinkoje tampa neatsiejamu efektyvumo ir optimizacijos elementu. Nepaisant mokslinių tyrimų siekio paaiškinti skirtingus vertinimo metodus, kiekvienam jų priskiriamas unikalių privalumų ir iššūkių rinkinys, o „juodųjų dėžių“ dirbtinio intelekto modeliai išlieka atvira tolimesnių akademinų tyrimų sritimi dėl skaidrumo stokos ir paaiškinimo galimybių. Kita vertus, taisyklėmis pagrįstos sistemos, nukreiptos į aiškias ir objektyviai nustatytas taisykles, tampa patikima alternatyva, papildanti žmogiškąjį racionalumą. Siekiant optimalaus kredito vertinimo proceso, būtina atidžiai įvertinti kiekvieną metodą ir atsižvelgti į jų pritaikymo galimybes, susietas su organizacijos strategija. Akivaizdu, jog tik integruotas požiūris, derinant automatizacijos privalumus su skaidrumo ir efektyvumo siekiu, gali garantuoti pažangių sprendimų priėmimą.



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

Kredito vertinimo modelių kūrimo ir pritaikymo problema, sulaukianti daug akademinės visuomenės dėmesio, yra realaus pasaulio kredito duomenų nepasiekiamumas, nes klientų kredito duomenys daugumoje finansų įstaigų yra konfidencialūs, todėl tyrimams atlikti reikalinga prieiga. Lietuvos Respublikos finansų įstaigų įstatymas<sup>10</sup> nurodo, jog „finansų įstaiga privalo turėti rašytines vidaus taisykles, kurios užtikrintų, kad: 1) finansų įstaiga, sudarydama sandorius dėl finansinių paslaugų teikimo ir investuodama lėšas, veiktų saugiai bei patikimai; 2) finansų įstaiga galėtų laiku pastebėti iš sudaromų sandorių kylančią galimą riziką, tinkamai ją įvertinti bei sumažinti, nuolat ją stebėti bei valdyti“ (Lietuvos Respublikos Seimas, 2023). Taigi, kredito rizikos politikos taisyklių integravimas į kredito rizikos vertinimo modelius gali turėti teigiamą poveikį finansų įmonėms vertinant finansavimo galimybes.

Kredito rizikos vertinimo modelių srities moksliniai darbai yra linkę tobulinti kreditavimo metodikas ir šalinti esamų modelių spragas bei juos lyginti tarpusavyje. Įvairių autorių siūlomi kredito rizikos vertinimo modeliai yra daugiau tęstinis esamų darbų rezultatas. Atsižvelgiant į esamų metodų gausą, šiuo tyrimu siekiama ne papildyti esamus modelius, o sukurti kredito rizikos modelį, orientuotą į finansavimo sprendimo priėmimo rezultatą pagal nustatytas kredito rizikos politikos gaires.

Šiame darbe pagrindinis dėmesys skiriamas sprendimo dėl finansavimo esamiems ir potencialiems klientams integravimui, atsižvelgiant į smulkaus verslo pagrindinius bruožus bei finansinių paslaugų teikėjo rizikos „apetitą“. Remiantis finansų įstaigos kredito rizikos politika ir vidiniais bei išoriniais duomenimis apie klientą, siekiama pasitelkti automatizuotus procesus ir naudojant prieinamą informaciją pateikti sprendimo dėl kredito suteikimo priėmimo rezultatą.

### 2.1. Tyrimo tikslas ir dizainas

#### Tyrimo tikslas

Magistro baigiamojo darbo tyrimo tikslas yra sukurti ir įvertinti kredito rizikos vertinimo modelį mažoms ir labai mažoms įmonėms, pritaikant konkrečias taisykles finansavimo sprendimui

---

<sup>10</sup> Lietuvos Respublikos Seimas. Lietuvos Respublikos finansų įstaigų įstatymas. 2002 m. rugsėjo 10 d. Nr. IX-1068. Galiojanti suvestinė redakcija nuo 2023-11-10.

gauti. Empirinio tyrimo pagrindas yra taisyklėmis pagrįstu metodu formuojamo modelio rezultatas. Kredito rizikos modelio kūrimo metodo pasirinkimas yra grindžiamas konkrečių finansavimo taisyklių, priimtinių kredito rizikos vertinimui, gairėmis. Pasak Zamore ir kt. (2018), tokios sistemos yra struktūrizuotas būdas priimti sprendimą dėl kredito. Sprendimų taisyklės remiasi pramonės lygio duomenimis ir yra nustatytos individualiai pagal kredito paslaugas teikiančios įstaigos galimybes prisiimti atitinkamą rizikos lygį.

Šiuo tyrimu siekiama atsakyti į klausimus, susijusius ne tik su pačiu kredito rizikos vertinimo modeliavimu, tačiau ir konstruktyviai apžvelgti sprendimo priėmimui įtakos turinčius veiksnius bei duomenų pasirinkimą, siekiant nesudėtingos vertinimo rezultatų interpretacijos ir praktinio pritaikomumo pusiausvyros. Empiriniu tyrimu siekiama atskleisti kredito galimybes mažoms ir labai mažoms įmonėms iš skolinimo veikla užsiimančio finansinių paslaugų teikėjo perspektyvos.

Šiam tikslui pasiekti keliami tokie **uždaviniai**:

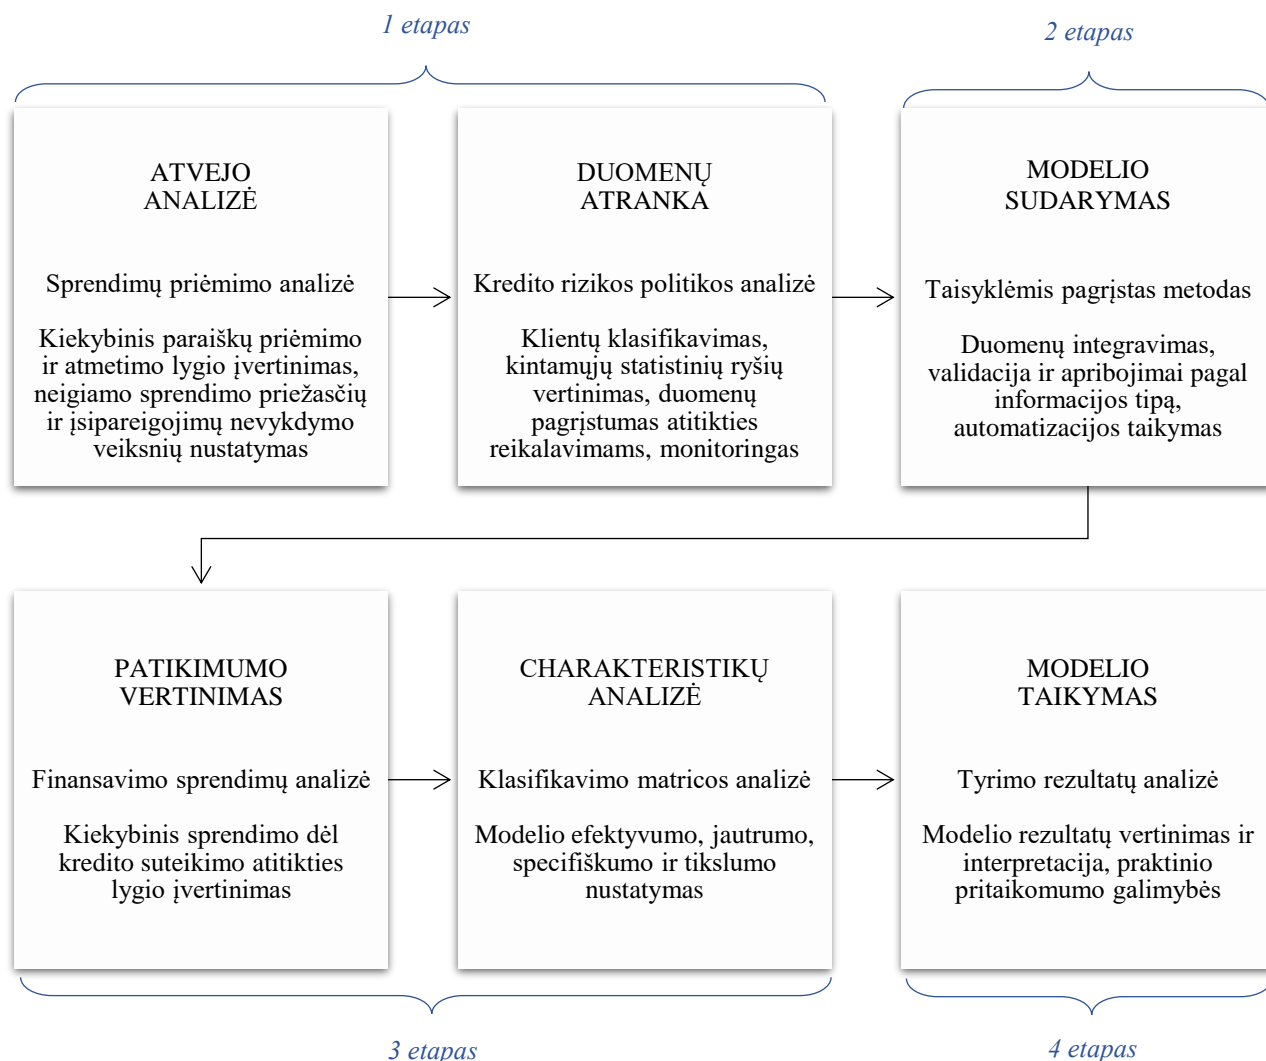
1. Atlikti sprendimų priėmimo dėl kredito suteikimo analizę ir kiekybiškai įvertinti pagrindinius kintamuosius, lemiančius finansavimo atmetimo galimybes bei įsipareigojimų nevykdymą;
2. Išnagrinėjus kredito rizikos politikos gaires bei identifikavus galimus klientų klasifikavimo veiksnius, įvertinti kintamųjų statistinius ryšius;
3. Atlikus monitoringo ataskaitos duomenų vertinimą, pagrįsti kiekybinių ir kokybinių duomenų mažų ir labai mažų įmonių kredito rizikai vertinti pasirinkimą;
4. Sukurti taisyklėmis pagrįstą kredito rizikos vertinimo modelį, orientuotą į finansavimo sprendimo rezultatą mažoms ir labai mažoms įmonėms;
5. Remiantis praeities duomenimis, atlikti kiekybinį modelio patikimumo vertinimą bei palyginti modelio rezultatus su realios praktikos rezultatais;
6. Įvertintus kredito rizikos vertinimo modelio charakteristikas, nustatyti klientų klasifikavimo patikimumą;
7. Atlikti modelio pritaikomumo praktinėje įmonės veikloje analizę, pateikti rezultatų vertinimą ir interpretaciją.

## **Tyrimo dizainas**

Remiantis tyrimo tikslu ir išsikeltais uždaviniais, empirinį tyrimą galima suskirstyti į keturis esminius etapus, kuriuos sudaro šešios pagrindinės dalys. Toliau pateikiama kredito rizikos vertinimo mažoms ir labai mažoms įmonėms tyrimo proceso loginė schema.

## 4 paveikslas

### Tyrimo schema



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Tyrimo proceso eigos aiškinamumas remiasi teorinėje dalyje pateiktomis išvalgomis apie duomenų atrankos svarbą (Gorgijevska ir Gjorgieva-Trajkovska, 2019; Istrate ir Ionescu, 2017; Lu ir kt., 2022; Yin ir kt., 2020; Zamore ir kt., 2018) bei metodo pasirinkimo tinkamumą modelio kūrimo procese (Bao ir kt., 2019; Bhattacharya ir kt., 2023; Rudin, 2019; Wang ir kt., 2022; Yang ir kt., 2022). Sprendimų priėmimo analizės, remiantis istoriniais duomenimis, tikslas – nustatyti finansavimo paraiškų apimtį, priimto sprendimo atžvilgiu, ir įvertinti klientų profilį bei pagrindinius finansavimo

užklauso atmetimo veiksniais. Finansavimo sprendimų analizė grindžiama poreikiu išsiaiškinti, kaip ir kokia apimtimi modelio vertinimas skiriasi nuo žmogaus priimamų sprendimų. Anksčiau atliktuose moksliniuose tyrimuose (Fawcet, 2006; Mileris, 2009; Mileris 2012) naudojami metodai suteikia pagrindą įvertinti modelio specifines charakteristikas. Tyrimo analizė suteikia erdvės pateikti požiūrį į modelį apsvairstant praktinio taikymo galimybes verslo aplinkoje. Toliau analizuojamas tyrimo etapų loginis pagrįstumas, pabrėžiami empirinio tyrimo metodo privalumai ir išsikeltų uždavinių svarba.

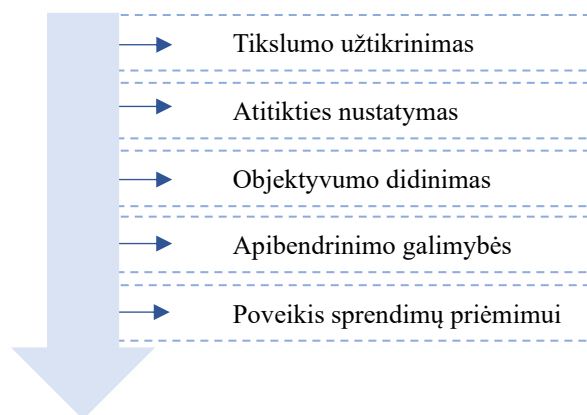
## Tyrimo etapų loginis pagrįstumas

Kredito rizikos vertinimo modelio kūrimo duomenų atranka, apimanti kiekybinių ir kokybinių duomenų vertinimą, yra esminė proceso dalis. Tikslingai atrinkti ir tinkamai naudojami duomenys leidžia užtikrinti modelio tikslumą, patikimumą ir veiksmingumą. Šis procesas padeda išskirti tik reikšmingus duomenis ir nustatyti, ar jie atitinka kredito rizikos vertinimo tikslus. Tai apima teorinių pagrindų, ankstesnių tyrimų ir patirties finansų sektoriuje kombinaciją, kuri pagrindžia, kodėl pasirinkti kintamieji turi įtakos kredito rizikai.

Kiekybinis sprendimo dėl kredito suteikimo atitikties lygio įvertinimas padeda išanalizuoti, ar kredito suteikimo sprendimai atitinka nustatytus kriterijus. Tai apima kredito suteikimo proceso taisykles ir jų vertinimą, rizikos ribas, finansinius rodiklius ir kitus veiksniai, kurie yra svarbūs siekiant užtikrinti, kad finansavimo sprendimai būtų suderinti su organizacijos tikslais ir strategija. Rezultatai leidžia nustatyti, ar kredito suteikimo sprendimai yra pernelyg griežti arba per silpni bei padeda identifikuoti sritis, kuriose gali būti pažeidžiamumų arba trūkumų.

## 5 paveikslas

*Taisyklėmis pagrįsto modelio prielaidos*



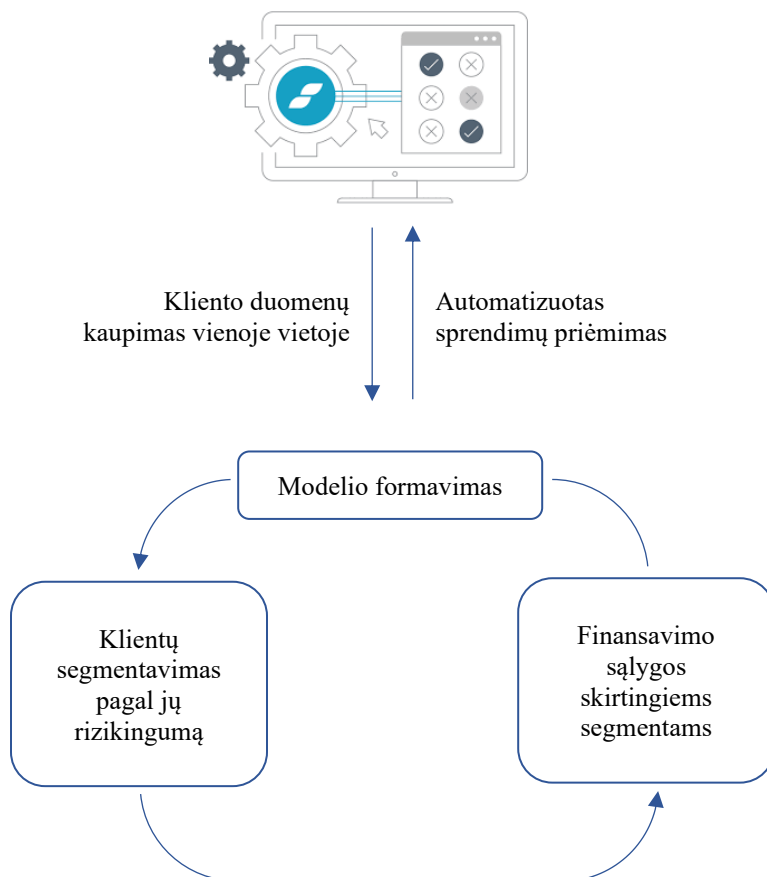
Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Taisyklėmis pagrįstas metodas kredito rizikos vertinimo modelyje leidžia modeliui būti aiškiu, suprantamu ir patikimu. Tai yra vienas svarbiausių modelio privalumų, nes konkrečios taisyklės gali būti lengvai interpretuojamos ir paaiškinamos, todėl jų pagrindu priimami sprendimai yra skaidrūs.

Kredito rizikos vertinimo modelis mažoms ir labai mažoms įmonėms realioje verslo aplinkoje šiame darbe gali būti laikomas momentinių sprendimų moduliu (angl. *instant decision module*), leidžiančiu priimti greitus ir tikslius sprendimus, susijusius su skolinimo veikla ir kredito konkrečiam klientui suteikimu. Pagrįsti sprendimai, akimirksniu atliekant duomenų analizę, kaip išvesties rezultatai, tokiuose moduluose paprastai gaunami pasitelkiant automatizuotus algoritmus. Kredito rizikos vertinimo modelio, orientuoto į sprendimų priėmimą dėl kredito suteikimo, schema pateikiama 6 paveiksle.

## 6 paveikslas

### *Momentinių sprendimų modulio schema*

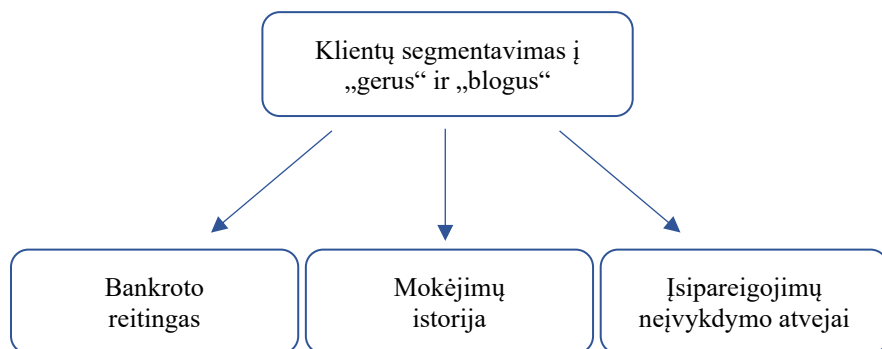


Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Vienas esminių žingsnių modelio formavimui – informacijos apie klientus saugojimas tam tikroje platformoje. Pirmiausiai, vienoje vietoje kaupiant informaciją apie klientus, duomenų valdymas tampa daug efektyvesnis. Jų analizė, apdorojimas ir prieiga tampa organizuota, todėl atsiranda galimybė lengviau susirinkti reikiamą informaciją. Sujungiant klientų duomenis, galima sukurti išsamų kliento profilį bei mokytis iš praeities rezultatų. Tikslesnės duomenų analizės pagrindu galima identifikuoti įspėjamuosius kredito rizikos veiksnius, kurie sumažina klaidingų sprendimų riziką ir leidžia identifikuoti kliento rizikos lygį.

## 7 paveikslas

*Juridinių asmenų segmentavimo pagal rizikingumą nustatymo būdai*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Nagrinėjamos finansavimo įstaigos kredito rizikos politikoje klientų kreditingumo lygis yra nustatomas vertinant išorinį bankroto reitingą, kuris, remiantis ekonometriniais modeliais, apskaičiuoja tikimybę, ar per artimiausią 12 mėnesių laikotarpį, klientas vėluos vykdyti savo finansinius įsipareigojimus ilgiau nei 90 dienų arba bankrutuos.

*Modelio prielaidų tikrinimas:*

---

**H1:** Žmogaus priimti teigiami finansavimo sprendimai savo apimtimi skiriasi nuo modelio pateiktų rezultatų.

---

**H2:** Modelis, kurį sudaro kliento duomenų ir finansuotojo kredito rizikos politikos taisyklių derinys, gali paaiškinti sprendimą dėl kredito suteikimo pagal kliento charakteristiką.

---

**H3:** Modelis negali atpažinti visų įsipareigojimų neįvykdymo atvejų.

---

Kredito rizikos vertinimo modelių efektyvumas gali būti vertinamas sudarant klientų klasifikavimo matricą (Fawcett, 2006). Siekiant nustatyti modelio galimybes atpažinti įsipareigojimų nevykdymo atvejus, tikrinamos 2 statistinės hipotezės:

- 1)  $H_0$ : klientas yra nepatikimas (įsipareigojimų nevykdymas) → suteikiama reikšmė „1“
- 2)  $H_1$ : klientas yra patikimas (įsipareigojimai įvykdyti) → suteikiama reikšmė „0“

## 9 lentelė


*Modelio sprendimų analizė – I ir II rūšies klaidos*

	$H_0$ yra tiesa	$H_0$ yra netiesa
$H_0$ atmetama	I rūšies klaida → FN	Klaidų neaptinkama → TN
$H_0$ priimama	Klaidų neaptinkama → TP	II rūšies klaida → FP

Šaltinis: sudaryta autorės, remiantis Doan, 2005.

## 8 paveikslas

*Klientų klasifikavimo matrica*



Šaltinis: sudaryta autorės, remiantis Fawcett, 2006.

TP – tikrosios reikšmės ir modelio rezultatas rodo, kad klientas yra nepatikimas

TN – tikrosios reikšmės ir modelio rezultatas rodo, kad klientas yra patikimas

FN – tikrosios reikšmės rodo, kad klientas yra nepatikimas, modelio rezultatai – klientas patikimas

FP – tikrosios reikšmės rodo, kad klientas yra patikimas, modelio rezultatai – klientas nepatikimas

Šiuo atveju, vertinant modelio efektyvumą, I rūšies klaida gali būti laikoma svarbesne, nes didesnis pavojus kyla tada, kai poveikis yra nepastebimas, t. y. kai modelio rezultatas klientą identifikuoja kaip patikimą, nors iš tikrųjų taip nėra.

Pasak Milerio (2012), „modelių patikimumo vertinimas yra labai reikšmingas modelių formavimo proceso etapas“, kuris padeda įvertinti įvairius parametrus. Remiantis 8 paveiksle pateikta klasifikavimo matrica, kredito rizikos vertinimo modeliams įvertinti naudojami rodikliai, kurie leidžia įvertinti modelių tinkamumą „gerų“ ir „blogų“ klientų atskyrimui.

## 10 lentelė

### Modelio klasifikavimo patikimumo vertinimo rodikliai ir formulės

Efektyvumas	Teisingo klasifikavimo rodiklis (angl. <i>correct classification rate</i> )	$CCR = \frac{TP + TN}{N}$	[1]
	Klaidingo klasifikavimo rodiklis (angl. <i>misclassification rate</i> )	$MCR = \frac{FP + FN}{N}$	[2]
Klaidingo klasifikavimo rizika	I rūšies klaida ( $H_0$ atmetama) (angl. <i>false negative rate</i> )	$\alpha = \frac{FN}{FN + TP}$	[3]
	II rūšies klaida ( $H_0$ priimama) (angl. <i>false positive rate</i> )	$\beta = \frac{FP}{FP + TN}$	[4]
Statistinis klasifikavimo pajėgumas	Jautrumas (angl. <i>sensitivity</i> )	$Se = 1 - \alpha = \frac{TP}{TP + FN}$	[5]
	Specifiškumas (angl. <i>specificity</i> )	$Sp = 1 - \beta = \frac{TN}{TN + FP}$	[6]
Tikslumas	Įsipareigojimų nevykdymo tikslumas (angl. <i>positive predictive value</i> )	$PPV = \frac{TP}{TP + FP}$	[7]
	Įsipareigojimų vykdymo tikslumas (angl. <i>negative predictive value</i> )	$NPV = \frac{TN}{TN + FN}$	[8]

Šaltinis: sudaryta autorės, remiantis Mileris, 2009.



Mileris (2012) vėlesniuose akademinuose tyrimuose finansinių įsipareigojimų neįvykdymo tikimybę siūlo vertinti bankrutavusių įmonių skaičiaus ir bendro įmonių skaičiaus santykiu:

$$PD = \frac{N}{I} * 100\% \quad [9]$$

Praktinis modelio pritaikomumas yra svarbus dėl dviejų pagrindinių priežasčių – pirma, dėl modelio veikimo išbandymo realioje finansų institucijų aplinkoje, ir antra, dėl jo rezultatų patikimumo. Praktinis pritaikomumas apima modelio pritaikymą konkrečioms organizacijos charakteristikoms, duomenų formatams, technologijoms ir reikalavimams. Pagrindinis tikslas yra tai, kad modelis būtų lengvai įgyvendinamas, suprantamas ir veiktų efektyviai. Interpretuojant modelio rezultatus, galima identifikuoti svarbiausius rizikos veiksnius, įvertinti jų įtaką ir priimti informuotus sprendimus dėl kredito suteikimo. Tai leidžia suprasti modelio veikimo logiką ir pagrindus.

## **2.2. Duomenų atranka, rinkimo ir sisteminimo metodai**

Dėl riboto Lietuvos mažų ir labai mažų įmonių duomenų prieinamumo, empirinio tyrimo duomenys grindžiami įmonės, užsiimančios skolinimo veikla, klientų informacija. Kiekybiniai ir kokybiniai duomenys gaunami tiek iš vidinių, tiek iš išorės šaltinių. Finansų rinkos dalyvių informacija šiame darbe negali būti atskleista dėl konfidencialios informacijos apsaugos, todėl bendrovės ir klientų duomenys yra nuasmeninti ir gali būti naudojami tik akademiniais tikslais.

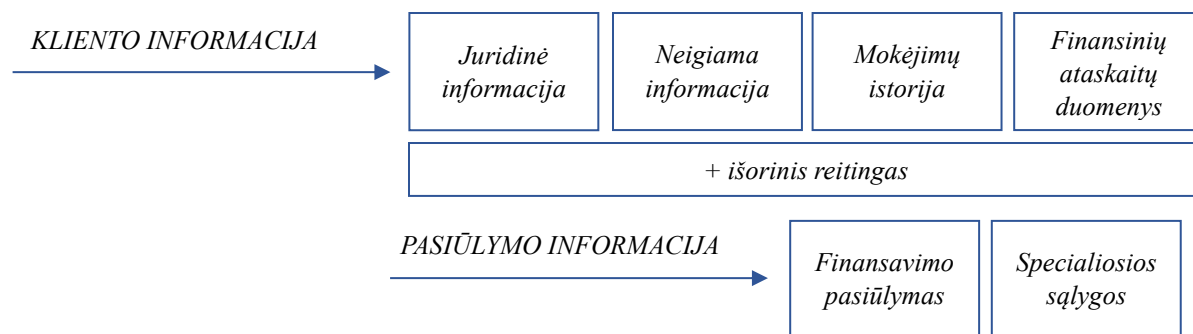
Dauguma duomenų, naudojamų kredito rizikos kredito rizikos vertinimo modeliui kurti ir analizei atlikti, remiasi informacija, kurią apie klientus pateikė didžiausią duomenų bazę turintis kredito biuras Lietuvoje „Creditinfo Lietuva“. UAB „Creditinfo Lietuva“ teikia paslaugas verslui, suteikdami galimybę keistis skolininkų duomenimis, stebėti klientų ekonominę būklę ir gauti išsamią informaciją apie fizinius bei juridinius asmenis. Šie duomenys apima dalį teisinių institucijų ir registru duomenų, t. y. apjungia valstybinio ir privataus sektoriaus valdomą informaciją, ir leidžia įvertinti fizinių bei juridinių asmenų kreditingumą ir mokumą. „Creditinfo Lietuva“ ataskaitose pateikiami fizinių ir juridinių asmenų kredito reitingai, juridinių asmenų vadovų ir akcininkų sąrašas bei kontaktiniai duomenys, informacija apie esamus ir istorinius pradelstus mokėjimus, finansinių ataskaitų duomenys, teismų ir turto areštų informacija, įmonės paminėjimai žiniasklaidoje ir kt. Pavyzdinė juridinių asmenų ataskaitos forma pridedama 1 priede. Kredito biuras, sudaręs tiesioginę sutartį su VĮ „Registru centras“, taip pat pateikia pagrindinius registru duomenų šaltinius, kurie

remiasi nekilnojamojo turto kadastro ir registro (NTR), juridinių asmenų registro (JAR), turto areštų aktų registro, gyventojų registro bei tarptautinių sąsajų registro fiksuojama informacija.

Magistro baigiamajame darbe vertinama kiekybinė ir kokybinė informacija, kredito rizikos vertinimo modelio mažoms ir labai mažoms įmonėms kūrimui naudojami duomenys yra suskirstyti į 2 segmentus pagal informacijos pobūdį, kurie skirstomi į smulkesnius vienetus pagal savo struktūrą, formatą ir tikslus.

## 9 paveikslas

*Duomenų skirstymas pagal informacijos tipą*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Klientų informacijos duomenų pasirinkimas grindžiamas esamų klientų atvejo analizės rezultatais, klientų klasifikavimo į „gerus“ ir „blogus“ metodika ir 4 mėnesių monitoringo<sup>11</sup> ataskaitos stebėjimų rezultatais. Pasiūlymo informacijos duomenų atranka yra finansuotojo kredito rizikos politikos gairėse apibrėžti dydžiai ir kiti apribojimai. Specialiųjų sąlygų duomenys priklauso nuo kredito tipo. Duomenų blokai atskiria skirtingas vertinimo perspektyvas ir leidžia kompleksiskai įvertinti kliento charakteristikas.

<sup>11</sup> Monitoringas kredito rizikos kontekste šiame darbe reiškia nuolatinį esamų įmonės klientų stebėjimą ir vertinimą.

## 11 lentelė

### *Duomenų rinkimo būdai*

Duomenų tipas	Duomenys	Duomenų šaltiniai
<b>Kliento informacija</b>	Juridinė informacija	Kredito biuras „Creditinfo Lietuva“, Juridinių asmenų dalyvių informacinė sistema (JADIS), kliento pateikta informacija
	Išorinis reitingas	Kredito biuras „Creditinfo Lietuva“
	Neigiama informacija	Vyriausioji tarnybinės etikos komisija (VTEK), Gyventojų registras, Finansinių nusikaltimų tyrimo tarnyba (FNTT), mokėjimų įstaiga „ArcaPay“, kredito biuras „Creditinfo Lietuva“
	Mokėjimų istorija	Kredito biuras „Creditinfo Lietuva“, esamų klientų duomenų bazė
	Finansinių ataskaitų duomenys	Kredito biuras „Creditinfo Lietuva“, kliento pateikta informacija
<b>Pasiūlymo informacija</b>	Finansavimo pasiūlymas	Įmonės kredito rizikos politika <sup>12</sup>
	Specialiosios sąlygos pagal kredito tipą	Įmonės kredito rizikos politika

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 12 lentelė

### *Finansinių ataskaitų informacija*

<b>Finansinės ataskaitos metai</b>	2021 m.
<b>Ataskaitos mėnesių skaičius</b>	12 mėnesių <sup>13</sup>
<b>Laikotarpis</b>	2021-01-01 – 2021-12-31
<b>Šaltinis</b>	JAR

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Duomenų apdorojimui naudojamas SPSS programinis paketas (angl. *Statistical Package for the Social Sciences*). Nors pagrindinis kuriamo kredito rizikos vertinimo modelio mažoms ir labai mažoms įmonėms tikslas yra orientuotas į sprendimo priėmimą taikant griežtą taisyklių integravimą, kai kuriems kintamiesiems taikomas požymių nepriklausomumo testas. Siekiant nustatyti, ar ryšys tarp kategorinių kintamųjų yra statistiškai reikšmingas, pagrindinis dėmesys skiriamas neparametriniam kriterijui Chi-kvadratu ( $\chi^2$ ).

<sup>12</sup> Aktuali redakcija 2022-01-01 – 2022-12-31.

<sup>13</sup> Finansinių ataskaitų 12 mėnesių duomenys vertinami, jei įmonė veikia ilgiau nei metus, kitais atvejais – vertinama kliento pateikta informacija ir (arba) remiamasi kitais patikimais šaltiniais už praėjusį periodą nuo įmonės registracijos datos.

Šiame darbe naudojama Pearson'o formulė:

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}, \quad [10]$$

kur:

$O_i$  – nustatyti dažniai,

$E_i$  – tikėtini dažniai,

$k$  – bendras kintamųjų kategorijų ir grupių skaičius, lygus SPSS programinio paketo *Crosstabs* lentelės eilučių ir stulpelių sandaugai.

Vertinami požymiai statistiškai priklausomi, kai  $p < \alpha$  (hipotezė  $H_0$  atmetama), požymiai statistiškai nepriklausomi, kai  $p \geq \alpha$  (hipotezė  $H_0$  priimama), kur  $\alpha$  – nustatytas reikšmingumo lygmuo yra lygus 0,05.

## Imties dydis

Tyrimo imtis sudaryta tikslinės atrankos būdu – atrinktos visos alternatyvaus finansuotojo<sup>14</sup> UAB „X“ mažų ir labai mažų Lietuvoje veikiančių įmonių paraiškos iki 50 tūkst. eurų per nagrinėjamąjį laikotarpį. Analizė atliekama remiantis paraiškos gavimo laikotarpiu sprendimo priėmimo dieną, todėl nagrinėjamų atvejų skaičius savo apimtimi skiriasi nuo pasirašytų sutarčių per ataskaitinį laikotarpį skaičiaus, nes dalis jų praktikoje yra aktyvuojamos kitais metais arba yra perkeliamos iš prieš tai buvusio laikotarpio.

Empiriniame tyrime nustatant imties dydį, netaikomi reprezentatyvios imties apribojimai, nes kredito rizikos vertinimo modelio, pagrįsto taisyklėmis, tikslas yra sprendimų priėmimas kredito rizikos vertinimo kontekste, todėl statistinių parametrų įvertinimas naudojamas tik bendros apžvalgos pateikimui. Tai apibūdina situaciją, kai modelis yra labiau orientuotas į praktinį pritaikymą negu į teorinį statistinį tikslumo įvertinimą. Analizei atlikti naudojami tik juridiniai asmenys.

---

<sup>14</sup> Alternatyvus finansuotojas (arba alternatyvaus finansavimo teikėjas) yra Lietuvos Respublikoje įsteigtos ir veikiančios finansų įmonės (išskyrus kredito įstaigas ir jų susijusias įmones), kurių pagrindinę veiklos dalį sudaro skolinimas juridiniams asmenims ir individualią veiklą vykdančioms fiziniams asmenims, įskaitant faktoringą ir finansinę nuomą (lizingą) ir (ar) Kolektyvinio investavimo subjektai\*, kurių veiklos dokumentai numato kolektyvinio investavimo subjekto lėšų investavimą paskolos formomis, ar, jei jų valdymas perduotas valdymo įmonėms, valdymo įmonės. Šaltinis: UAB „Investicijų ir verslo garantijos“ (INVEGA), 2023.

### 13 lentelė

#### *Imties dydžio nustatymo kriterijai*

Įmonės dydis <sup>15</sup>	Mažos ir labai mažos įmonės
Įmonės teisinis statusas	Veikiantis subjektas
Registracijos šalis	Lietuva
Paraiškos suma	<=50 tūkst. eurų
Limitas	Bendras limitas vienam juridiniam asmeniui ir per grupės įmones <=50 tūkst. eurų
Paraiškos gavimo laikotarpis	2022-01-01 – 2022-12-31

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Tyrimo imtį sudaro 1114 juridinių asmenų, veikiančių Lietuvoje bei turinčių mažų ir labai mažų įmonių statusą. Nustatant nagrinėjamų atvejų skaičių 2022 m., šiame tyrime yra eliminuoti pareiškėjai, kurių paraiškos viršija 50 tūkst. eurų vienam juridiniam asmeniui ir bendrai per grupės įmones. Paraiškos sumos apribojimai kredito rizikos vertinimo modelio formavimo procese grindžiami didele mažų finansavimo užklausų dalimi, kuri, atsižvelgiant į 2022 m. sutarčių skaičių sudaro 89,0% visų pasirašytų sutarčių ir 29,9% visų naujų įsipareigojimų (2 priedas).

#### **Nagrinėjamas laikotarpis**

Nagrinėjamas laikotarpis – tai laikotarpis, per kurį buvo analizuojami įmonių finansiniai ir nefinansiniai duomenys. Šiame tyrime nagrinėjami 2022 m. finansinių paslaugų teikėjo klientų duomenys. Įvertinus tai, kad kredito rizikos vertinimo metodai duoda geriausią rezultatą tada, kai yra pritaikyti prie nuolat kintančios ekonominės padėties ir esamų rinkos sąlygų, pasirinkta naudoti naujausius prieinamus duomenis ir stebėti jų pritaikymą artimiausiam laikotarpiui.

<sup>15</sup> Įmonės dydis nustatomas, remiantis Lietuvos Respublikos smulkiojo ir vidutinio verslo plėtros įstatymu. *Galiojanti teisės akto redakcija nuo 2022-03-31.*

## 2.3. Metodo pasirinkimo pagrindumas ir tyrimo apribojimai

### Metodo pasirinkimas

Modelis, kuris remiasi taisyklėmis, šiame darbe gali būti laikomas ekspertine sistema ir priskiriamas dirbtinio intelekto modelių grupei. „*IF-THEN*“ taisyklėmis suprogramuotas modelis gali priimti sprendimus pagal numatytas taisykles, todėl jo pagrindinis privalumas yra aiškumas ir lengva interpretacija bei pritaikymo konkrečioje aplinkoje galimybės. Kai situacija yra dinamiška arba neapibrėžta, tikėtina, jog tai reikalaus žmogaus įsikišimo.

Kaip buvo pastebėta 1.3 poskyryje, dabartiniai dirbtinio intelekto modeliuose naudojami metodai yra pajėgūs mokytis iš duomenų, prisitaikyti ir generuoti naujus sprendimus. Nors tai leidžia automatiškai išgryninti savybes, o ne priklausyti nuo iš anksto nustatytų taisyklių, tačiau mokymasis reikalauja didelio kiekio duomenų, testavimo ir net užpildant šias spragas modelis dažnai negali suteikti konkretaus paaiškinimo dėl sugeneruotų rezultatų. Dinamiškas kredito rizikos vertinimo procesas ir jautrumas įvykiams rinkoje gali būti iškraipytas, net kai modeliai yra „apmokyti“. Remiantis šiuo požiūriu, taisyklėmis paremtas metodas yra efektyvus būdas, kuriuo galima pasiekti į tikslą orientuotų rezultatų, greičiau reaguoti į sąlygų pasikeitimą ir lanksčiai keisti taisykles, kai matomas poreikis.

Atsižvelgiant į teorinių įžvalgų aspektus ir metodologijoje suformuotą modelio struktūrą, taisyklėmis pagrįsto metodo, nukreipto į sprendimų priėmimą kredito rizikos vertinimo kontekste, pagrindimas apima šiuo punktus:

- Sutapimas su paaiškinamumu → taisyklės atspindi tiesioginį loginį ryšį tarp įvesties ir sprendimo, todėl sprendimų priėmimas yra aiškus;
- Lengvas įgyvendinimas ir priežiūra → taisyklių integracija į modelį yra nesudėtinga, o prireikus jas galima greičiau pritaikyti naujoms sąlygoms, palyginti su „apmokytais“ duomenimis;
- Suderinamumas su žmogiškąja patirtimi → modelis yra lengvai interpretuojamas, nes atspindi žmogiškojo patyrimo racionalumą bei padeda išvengti šališkumo;
- Efektyvumas su skirtingu duomenų kiekiu → modelis gali būti veiksmingas net su ribotu duomenų kiekiu, nes nereikalauja gilaus mokymosi ir kompleksiško testavimo.

## Tyrimo apribojimai

1. Kredito rizikos vertinimo modelis nėra universalus. Tai reiškia, jog papildomus vertinimo kriterijus kiekviena kredito įstaiga turi koreguoti pagal nustatytas kredito rizikos politikos gaires. Modelis yra pritaikytas konkrečiai finansų įstaigai, atsižvelgiant į esamų klientų portfelį ir istorinius įsipareigojimų nevykdymo atvejus per nagrinėjamą laikotarpį.
2. Modelis yra eksperimentinio pobūdžio, todėl neparodys viso galimo poveikio. Svarbu suprasti, jog kredito rizikos vertinimo modelis iš esmės remiasi istoriniais duomenimis, todėl negali numatyti ateities rizikos ir kitų ekonominių pokyčių. Tai gali paveikti skirtingas modelio dalis, kurios nebuvo įtrauktos į modelio kūrimo procesą, arba reikalauti papildomo indėlio į jo praplėtimą bei tobulinimą pasikeitus rinkos sąlygoms ar atsiradus nestandartinėms situacijoms.
3. Modelio integracijai reikalinga tiksli informacija apie pareiškėją, tačiau jos tikslumas gali būti nepakankamas dėl MVĮ įmonių finansinės atskaitomybės subjektyvumo vertinant finansinę situaciją, ypač naujai įsikūrusių įmonių atžvilgiu. Šiuo atveju, žmogaus sprendimas yra nekvestionuojamas.

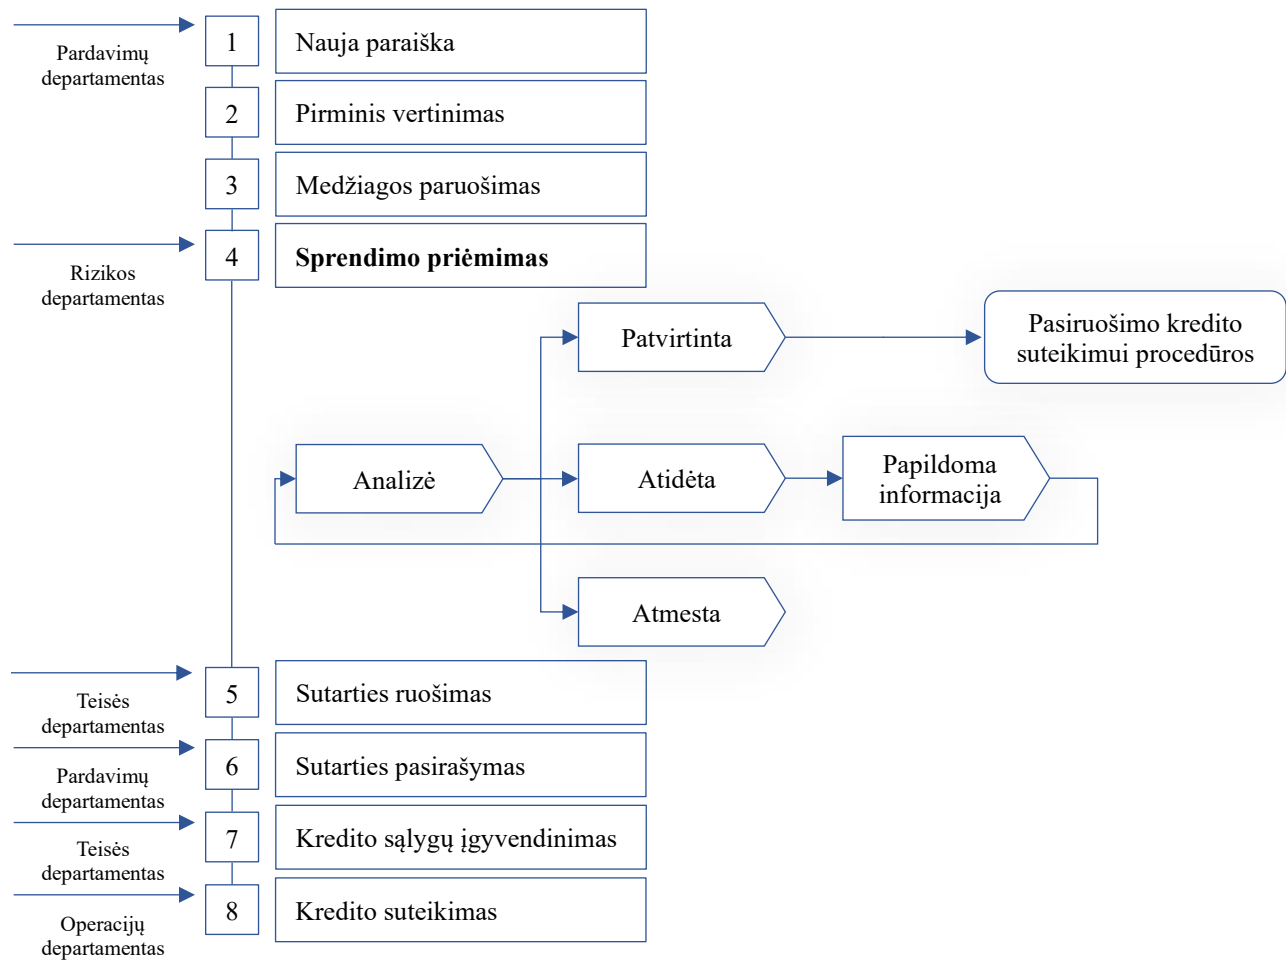
### 3. KREDITO RIZIKOS VERTINIMO MODELIO, ORIENTUOTO Į SPRENDIMŲ PRIĖMIMĄ, LIETUVOS MAŽOMS IR LABAI MAŽOMS ĮMONĖMS REZULTATAI IR JŲ INTERPRETACIJA

#### 3.1. Pareiškėjų atvejo analizė alternatyvaus finansuotojo aplinkoje

Sprendimų priėmimo analizė, vertinant istorinius duomenis, leidžia objektyviai įvertinti finansuotojui priimtina kredito rizikos lygį, tačiau siekiant suprasti finansuotojo kredito suteikimo procesą, pirmiausiai pateikiama procedūrų nuo kliento pasikreipimo iki išmokėjimo schema.

#### 10 paveikslas

*Kredito suteikimo proceso schema*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.



Pirminis vertinimas reiškia, jog projektų vadovai įmonėje veikia kaip pirmasis „filtravimo“ mechanizmas, kuris atrūšiuoja, kurie klientai patenka į sprendimų priėmimo etapą. Kredito paslaugų teikėjo sprendimo priėmimas prasideda 4 etape, kai atliekama projektų vadovų paruoštos vertinimui medžiagos analizė. Už sprendimų priėmimą atsakingas asmuo (kredito rizikos analitikas), suteikia sprendimą dėl finansavimo užklauso patenkinimo. Tolimesnė kredito vertinimo eiga priklauso nuo po atlikto vertinimo įgyjamo paraiškos statuso. Remiantis prielaida, jog pagal kiekybines ir kokybines charakteristikas analizuojant paraiškas, galima sukurti patikimą kredito vertinimo modelį, pritaikytą racionalaus finansavimo sprendimams priimti ir užtikrinti ilgalaikį finansinį tvarumą, nagrinėjami atvejai, apibūdinantys nebankinio finansavimo sektoriuje veikiančio alternatyvaus finansuotojo kredito suteikimo mažoms ir labai mažoms įmonėms charakteristikas.

Siekiant nustatyti finansavimo sprendimo priėmimo apimtis, analizuojamas Lietuvos mažų ir labai mažų įmonių paraiškų patvirtinimo ir atmetimo lygis. Toliau pateikiama nagrinėjamo laikotarpio paraiškų statistika.

#### 14 lentelė

*Alternatyvaus finansuotojo patvirtintos ir atmestos paraiškos 2022 m.*

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Atmesta	102	9,2	9,2	9,2
	Patvirtinta	1012	90,8	90,8	100,0
	Total	1114	100,0	100,0	

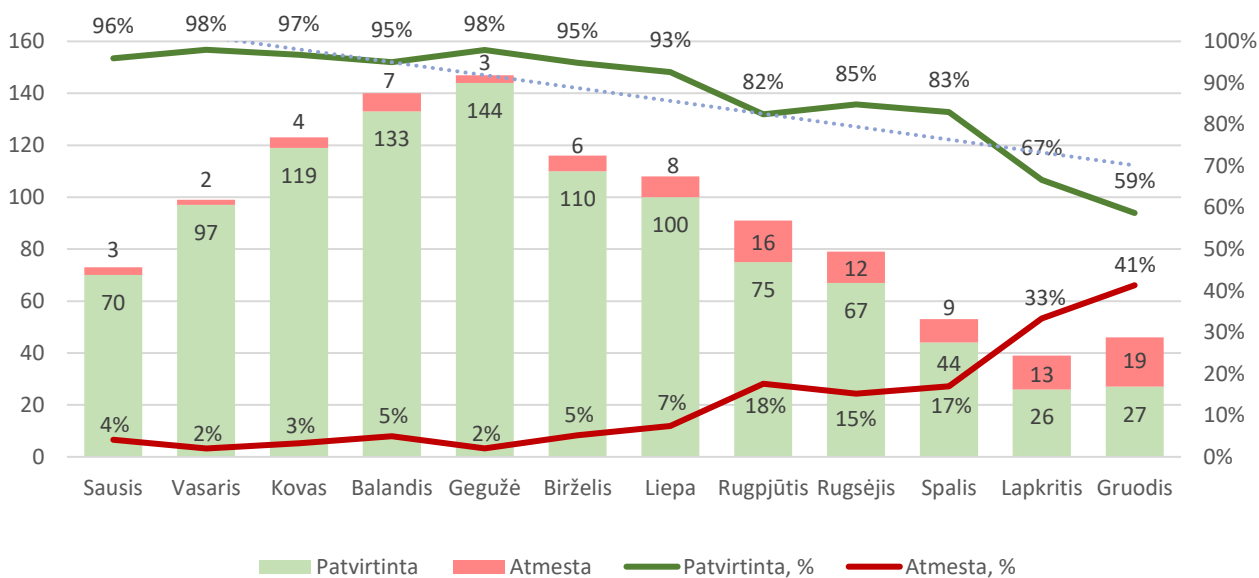
Šaltinis: parengta autorės, remiantis atliktu tyrimu.

14 lentelės rezultatai vaizduoja patvirtintų ir atmestų paraiškų kiekį per nagrinėjamą laikotarpį. Remiantis tyrimo apribojimu, 2022 m. Lietuvos mažos ir labai mažos įmonės finansų įstaigai pateikė 1114 užklauso dėl finansavimo suteikimo, neviršijančių 50 tūkst. eurų, iš kurių 1012 paraiškų yra patvirtintos, 102 – atmestos. 2022 m. fiksuojamas 90,8% metinis paraiškų patvirtinimo lygis. Aukštas finansavimo patvirtinimo lygis reiškia, jog dauguma paraiškų dėl kredito suteikimo buvo sėkmingai patvirtintos. Tai rodo, kad kreditorius yra pajėgus suteikti reikalingą finansavimą klientams, atitinkantiems nustatytus kriterijus ir skolinimo sąlygas. Nepaisant aukšto patvirtinimo lygio, 2022 m. vis dar yra 9,2% užklauso, kurios buvo atmestos. Tai gali būti susiję su įvairiomis priežastimis, tiek iš kliento, tiek iš finansų įstaigos perspektyvos, tokiomis kaip kliento kredito istorija

ir mokėjimų patikimumas, finansinė padėtis, finansavimo paskirtis bei finansų įstaigos konservatyvi kredito rizikos politika, pernelyg mažas arba per didelis atsargos dėl potencialių rizikų, susijusių su suteikiamu finansavimu, lygis.

## 11 paveikslas

Detalizuoti patvirtintų ir atmestų paraiškų duomenys 2022 m.



Šaltinis: parengta autorės, remiantis atliktu tyrimu.


Atsižvelgiant į 11 paveiksle pateiktus analizės rezultatus, paraiškų kiekis per mėnesį siekia nuo 39 paraiškų lapkričio mėnesį iki 147 paraiškų gegužės mėnesį. Pastebima, jog finansavimo poreikis pradeda augti kalendorinių metų pradžioje ir palaipsniui mažėja pradedant birželio mėnesiu, o kartu su šiuo mažėjimu, didėja atmetamų paraiškų skaičius. Paraiškų dėl kredito suteikimo vidurkis per mėnesį siekia 93 vienetus, vidutiniškai per mėnesį patvirtinamos 84 finansavimo užklauskos.

**Nepatvirtintų paraiškų analizė** yra esminė kredito rizikos vertinimo dalis, padedanti gerinti kreditorių veiklos efektyvumą, mažinti riziką bei užtikrinti tvarų finansavimo proceso vykdymą. Atmestų finansavimo užklauskų tyrinėjimas suteikia informacijos apie klientų finansinę situaciją ir padeda priimti informuotus sprendimus dėl kredito suteikimo. Nagrinėjamos kredito įstaigos duomenų kaupimas apie nepatvirtintus atvejus yra apribotas. Nepatvirtintų atvejų duomenų bazėje registruojamas tik sprendimas, registracijos šalis, įmonės pavadinimas, kredito tipas, ir finansavimo paraiškos suma, o atmetimo priežastys fiksuojamos ne visais atvejais (3 priedas). Tai rodo, jog kreditorius mažai dėmesio skiria atmestų paraiškų analizei.

Dėl duomenų trūkumo šios reikšmės negali suteikti visapusiško vaizdo apie klientą, tačiau turimi duomenys gali identifikuoti pagrindines šių atvejų atmetimo priežastis. 102 atmetusių paraiškų duomenys fiksuoja bent 112 reikšmių, dėl kurių finansavimo užklausa buvo atmesta. 4–6 prieduose pateiktos neigiamo sprendimo priežastys grupuojamos pagal duomenų tipą. Pirminiai duomenys rodo, jog paraiškų atmetimo priežastys gali svyruoti nuo 1 iki 3 priežasčių vienai paraiškai. 12 iš 102 atvejų yra nepaaiškinami dėl duomenų trūkumo. 12 paveiksle pateikiamos 2022 m. nepatvirtintų paraiškų priežastys, eliminavus trūkstamas reikšmes. Dėl atsiradusios paklaidos tarp vertinimo pagal nepatvirtintų atvejų skaičių ir pagal priežasčių skaičių, analizės rezultatai pateikiami abejais būdais. Paklaida svyruoja nuo 0,3 iki 2,4 procentinių punktų (7 priedas).

## 12 paveikslas

*Nepatvirtintų paraiškų atmetimo priežastys 2022 m. (proc.)*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.


Toliau rezultatai nagrinėjami pagal nepatvirtintų paraiškų priežasčių skaičių. Didžiausias paraiškos dėl kredito suteikimo atmetimo veiksnys, sudarantis beveik ketvirtadalį visų paraiškų yra pradelsti mokėjimai finansinėms institucijoms (24,1%). Pagal reikšmingumą antrąją ir trečiąją vietą užima priežastys, susijusios su bankrotu ir (ar) nemokumu bei įregistruotais turto areštais (atitinkamai

17,0% ir 10,7%). Šie veiksniai rodo, jog klientas patiria (arba patyrė) finansinių sunkumų, todėl gali būti nepajėgus vykdyti įsipareigojimus, kas rodo finansinį nestabilumą. Finansavimas tokią kredito istoriją turintiems asmenims yra padidintos rizikos. Neigiama mokėjimo istorija (9,8%), susijusi su esamais klientais, taip pat yra reikšminga priežastis nesuteikti papildomo finansavimo darant prielaidą, jog klientas nevykdys įsipareigojimų laiku. Praktikoje nebankinio finansavimo sektoriaus paslaugų teikėjai paprastai nėra linkę griežtai atmesti paraiškų dėl istorinės neigiamos informacijos ir teismų (atitinkamai 8,0% ir 8,9%), todėl daroma prielaida, jog nagrinėjamuose atvejuose priežastys buvo reikšmingos. Vertinant bendroje perspektyvoje, kredito įstaiga daugiausiai atmeta užklausas, kurios leidžia daryti prielaidą apie riziką dėl įsipareigojimų nevykdymo ir kliento mokėjimo elgseną. Ekonominės veiklos rūšies (4,5%) apribojimai daugiausiai yra susiję su teisės aktų reikalavimais, o kiti sektoriaus apribojimai, kurie nenustatomi teisės aktų nustatyta tvarka, remiasi suvokimu apie rizikos valdymą bei vertintojo moralinėmis nuostatomis. Kreditorius gali atsisakyti suteikti finansavimą dėl tam tikrų specifinių savybių, kurios gali reikšti aukštesnę riziką, pavyzdžiui, viešojo valdymo ir gynybos sektorius, lošimų industrija, suaugusiųjų industrija ir pan. Visais atvejais, tai gali būti susiję su teisės aktų pažeidimais, tarptautinėmis politinėmis ir ekonominėmis sankcijomis arba valstybinės priežiūros institucijų nustatytais atitikties reikalavimais, nes šie sektoriai yra reguliuojami ir, priklausomai nuo verslo sektoriaus, gali turėti sunkiai įgyvendinamus, griežtus reikalavimus finansavimo įstaigoms, taip pat gali reikšti neteisėtą veikimą tam tikrose jurisdikcijose. Dėl šių priežasčių, nors ekonominės veiklos rūšis rodo mažą atmetimo lygį, tačiau kredito rizikos vertinimo perspektyvoje yra itin svarbus veiksnys. Įmonės amžius (2,7%), pokyčiai juridinių asmenų dalyvių struktūroje (7,1%) gali būti vertinami kaip papildomi veiksniai, padedantys įvertinti kliento patikimumą bei stabilumą, tačiau neturėtų būti eliminuoti. Didesnis įmonės amžius, kaip ir pokyčių juridinio asmens dalyvių struktūroje nebuvimas, įprastai reiškia aukštesnį patikimumą, todėl trumpas įmonės veikimo laikas ar dažni pokyčiai įmonės valdymo struktūroje gali būti veiksnys, sulaikantis finansų įstaigą nuo kredito suteikimo dėl patirties, ribotų finansinių duomenų bei istorinės informacijos trūkumo.

Didelis finansavimo užklausų atmetimo lygis gali sukelti nestabilumą skolinimo veikloje, pavyzdžiui, jei daug esamų klientų rodo aukštą negebėjimo vykdyti įsipareigojimų lygį, tai gali paveikti kreditoriaus pelningumą. Tenkinant empirinio tyrimo sąlygą dėl maksimalios paraiškos sumos, neviršijančios 50 tūkst. eurų, finansavimo sumos suskirstytos į 5 lygias dalis.

### 13 paveikslas

*Nepatvirtintos paraiškos pagal finansavimo sumas 2022 m. (proc.)*




Šaltinis: parengta autorės, remiantis atliktu tyrimu.

2022 m. didžiausią Lietuvos mažų ir labai mažų įmonių finansavimo užklausų dalį sudaro paraiškos iki 20 tūkst. eurų, kartu pirmoji ir antroji kategorijos sudaro 77,4% visų atmestų paraiškų sumos. Tai rodo, jog didžioji dalis atmestų užklausų yra nedidelės sumos. Vidutinio dydžio (10,8%) ir aukštesnės sumos (11,8%) sudaro likusią dalį visų nepatvirtintų sumų. Atmestų atvejų finansavimo pasiūlymo suma yra reikšminga, nes ji gali parodyti finansinių nuostolių apimtį, kurią kredito įstaiga būtų patyrusi, jei finansavimo užklausos būtų patenkinamos, o klientas – linkęs nevykdyti įsipareigojimų. Vertinant konservatyviai, blogiausio scenarijaus atveju su prielaida, jog visuose segmentuose paraiškos yra maksimalaus dydžio, o įsipareigojimas nėra suamortizuotas, maksimali nuostolių suma gali siekti iki 2,11 mln. eurų, neįskaitant palūkanų mokėjimų (8 priedas). Kita vertus, jei finansavimas būtų patvirtintas ir klientai vykdytų įsipareigojimus, prie šios grąžintinos sumos prisidėtų už kreditą mokama palūkanų norma, kuri nebankinio finansavimo sektoriuje įprastai yra didesnė dėl prisiimto aukštesnio rizikos lygio ir atvejų, kai klientams bankinis finansavimas nėra prieinamas arba reikalingas skubus kredito suteikimas.

Svarbu pažymėti, jog atmestų atvejų analizė turėtų būti daug gilesnė, o finansavimo sumų bei atmetimo priežasčių nagrinėjimas nėra pakankamas, norint tiksliai įvertinti finansų įstaigos klientų kreditingumą, nes jie yra labai skirtingi. Dėl trūkstamų duomenų, toliau atliekama **patvirtintų atvejų analizė**, kurioje vertinami įsipareigojimų neįvykdymo atvejai, leidžia daryti prielaidas apie sprendimo priėmimo atitikimo kredito rizikos politikai lygį ir galimus nuokrypius.

## 14 paveikslas

*Juridinių asmenų įsipareigojimų nevykdymo atvejai 2022 m. pabaigoje (proc.)*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Nustatyta, jog 2022 m. pabaigoje iš viso registruota 63 įsipareigojimų nevykdymo atvejai (9 priedas). Vertinant šį dydį per metus, tai rodo sąlyginai žemą klientų įsipareigojimų nevykdymo lygį, kas leidžia daryti išvadą apie gerą klientų mokėjimų istoriją. Analizuojant duomenis, pastebėta, jog iš 1012 patvirtintų paraiškų, 250 klientų unikalūs kodai yra pažymėti kaip dublikatai, reiškiantys tuos pačius klientus. Esami klientai finansų įstaigoje turi nuo 2 iki 7 paraiškų, kurios bendrai neviršija apriboto 50 tūkst. eurų limitu, kas reiškia, jog skolinasi mažomis sumomis. Svarbu paminėti tai, jog per ataskaitinį laikotarpį analizuojami tik tie atvejai, kol klientas neperžengia 50 tūkst. eurų ribos. Tai reiškia, jog egzistuoja tikimybė, kad esamų įsipareigojimų likutis viršija šią sumą, tačiau jeigu taip yra, šios paraiškos į analizę nebeįtraukiamos.

## 15 lentelė

*Pasikartojančių klientų paraiškų analizės rezultatai 2022 m.*

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	871	86,1	86,1	86,1
	Taip	141	13,9	13,9	100,0
	Total	1012	100,0	100,0	

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Nustatyta, kad 141 paraiška (atitinkamai 13,9%) yra bent jau antroji esamų klientų paraiška. Analizuojant įsipareigojimų nevykdymo perspektyvą, tai yra svarbus veiksnys, siekiant patikrinti, ar esant pasikartojančių klientų skaičiui, jie nėra linkę nevykdyti įsipareigojimų.

## 16 lentelė

*Tikėtinas maksimalus nuostolis dėl pasikartojančių klientų įsipareigojimų nevykdymo 2022 m.*


	Unikalus kodas	Paraiškų skaičius   vnt.	Maksimalus nuostolis   EUR
Patvirtintos paraiškos	LDG1JH4S	2	18 000
	V8B4X1N7	2	20 000
	T28SK7V1	3	28 960
	2SLKF8DG	3	48 705
	KL6HDJ1G	2	30 237
	KSV127T8	2	30 000
	74H3Y96G	2	47 000
	Iš viso:	16	222 902

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Atsižvelgiant į analizės rezultatus, dėl įsipareigojimų neįvykdžiusių pasikartojančių klientų paraiškų, tikėtinas maksimalus nuostolis gali siekti iki 222 902 EUR. Toliau nagrinėjami neatitikimai finansuotojo kredito rizikos politikai pagal informacijos tipą.

## 15 paveikslas

*Įsipareigojimų nevykdymo atvejų neatitikimai kredito rizikos politikai 2022 m. pabaigoje (proc.)*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Įsipareigojimų neįvykdymas gali būti siejami su analitiko priimtais sprendimais tais atvejais, kai teigiami sprendimai buvo priimti neįvertinus įspėjamosios informacijos pobūdžio. Nustatyta, jog didžioji dalis įsipareigojimų nevykdymo atvejų sutampa su neatitikimais vertinant pareiškėjo mokėjimų istoriją (57,1%), išorinį reitingą (49,2%) ir įmonės finansinę būklę (41,3%). Finansavimo pasiūlymo (30,2%), specialiųjų sąlygų pagal kredito tipą (23,8%), juridinės (17,5%) ir neigiamos informacijos (6,3%) ignoravimas gali lemti aukštesnį rizikos lygį.

Įvertinus įmonės amžiaus kintamąjį, nustatyta, jog finansavimas yra svarbus visuose įmonės gyvavimo laikotarpiuose. Įprastai, jaunosms įmonėms tai suteikia plėtros ir augimo galimybes, finansavimas gali užtikrinti plėtros planų įgyvendinimą, padidinti gamybos pajėgumus. Ilgesnę veikos patirtį sukaupusios įmonės taip pat demonstruoja finansavimo poreikį, tai gali būti paaiškinama naujų galimybių ieškojimu, produktų ar paslaugų tobulinimu, investicijomis į inovacijas ir naujų technologijų pritaikymą, pajėgumų didinimą, infrastruktūros plėtrą ir pan. Analizės rezultatai (10 priedas) rodo, jog dauguma pareiškėjų yra ilgametę patirtį sukaupusios įmonės. Pastebima, jog juridiniai asmenys, veikiantys iki 1 metų sudaro mažiausią dalį mažų ir labai mažų įmonių pareiškėjų (5,4%). Daugiau nei pusę visų pareiškėjų sudaro nuo 5 iki 10 metų (26,2%) bei nuo 1 iki 3 metų veikiančios įmonės (23,2%). Nuo 3 iki 5 metų bei nuo 10 iki 20 metų veikiančios įmonės kartu sudaro 35,7% visų patvirtintų atvejų. Daugiau nei 20 metų patirtį veikloje rodo 9,5% visų pareiškėjų. Tarp mažų įmonių dažniausiai pasikartojantis juridinio asmens amžius yra 5-10 metų (7,2%) intervale, tarp mažų įmonių didžiausią dalį sudaro juridiniai asmenys veikiantys 1-3 metų (19,3%) intervale. Ilgesnė veiklos trukmė gali būti suvokiama kaip žemesnės rizikos, tačiau kaip rodo oficialių šaltinių statistikos duomenys – tai gali būti diskutuotina.

## 17 lentelė

*Įsipareigojimų neįvykdymas pagal įmonės amžiaus grupes 2022 m.*

	Įmonės amžius	Įsipareigojimų nevykdymo atvejai tarp visų patvirtintų paraiškų   proc.	Įsipareigojimų nevykdymo atvejai tarp visų įsipareigojimų nevykdymo atvejų   proc.
<b>Patvirtintos paraiškos</b>	Iki 1 metų	18,2	15,9
	Nuo 1 iki 3 metų	4,7	17,5
	Nuo 3 iki 5 metų	6,0	17,5
	Nuo 5 iki 10 metų	7,2	30,2
	Nuo 10 iki 20 metų	3,9	11,1
	20 metų ir daugiau	5,2	7,9
	Iš viso:	6,2	100,0

Šaltinis: parengta autorės, remiantis atliktu tyrimu.



Nustatyta, jog atsižvelgiant į skirstymą pagal amžiaus grupes, iki 1 metų veikiančios įmonės pasižymi aukščiausia įsipareigojimų neįvykdymo rizika tarp visų patvirtintų paraiškų (18,2%), tačiau analizuojant tik įsipareigojimų neįvykdymo duomenis, labiausiai išsiskiria įmonės, veikiančios nuo 5 iki 10 metų laikotarpyje (30,2%), pastebima gana panaši įsipareigojimų neįvykdymo apimtis 0-5 metų laikotarpyje (15,9%), tačiau mažas „blogų“ klientų skaičius palieka vietos diskusijoms ir ateities tyrimams. Vertinimas tarp visų patvirtintų paraiškų nurodo, jog jaunų įmonių finansuotojas turėtų vengti, siekiant išlaikyti stabilų portfelį, nes didėjant trumpai veikiančių įmonių užklausų patvirtinimų kiekiui, didėja tikimybė, jog išaugs įsipareigojimų neįvykdymo atvejų apimtis.

Neigiamos informacijos ir mokėjimų istorijos duomenys atskleidžia, jog kai kurie rodikliai yra tiesiogiai susiję su nagrinėjamų atvejų įsipareigojimų neįvykdymu.

## 18 lentelė

*Įsipareigojimų neįvykdymas pagal neigiamą informaciją ir mokėjimų istoriją 2022 m.*

Patvirtintos paraiškos	Informacijos tipas	Rodiklis	Įsipareigojimų neįvykdymo atvejai tarp visų įsipareigojimų neįvykdymo atvejų   proc.
	Neigiama informacija		Turto areštai
		Teismai	15,9
		Antstolių raginimai	0,0
		Vieša neigiamai prieinama informacija	0,0
Mokėjimų istorija		Bankrotas ir (ar) nemokumas	0,0
		Pradelsti mokėjimai finansinėms institucijoms	17,5
		Aktyvūs pradelsti mokėjimai	17,5
		Aktyvūs pradelsti mokėjimai valstybinėms institucijoms	30,2
		Neigiama mokėjimų istorija	11,1

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Nustatyta, jog neigiamos informacijos segmente teismai (15,9%) turi įtakos įsipareigojimų neįvykdymui, mokėjimų istorijos duomenyse – reikšmingi pradelsti mokėjimų valstybinėms (30,2%), finansinėms (17,5%) ir nefinansinėms institucijoms (17,5%) rodikliai. Įvertinus esamų klientų fiksuotą neigiamos mokėjimų istorijos kintamąjį, šis taip pat buvo aktualus dėl įsipareigojimų neįvykdymo rizikos.

Vertinant pareiškėjų, kurie gavo teigiamą sprendimą dėl kredito suteikimo, finansinių ataskaitų duomenis pastebima, jog iki šiol duomenų apdorojimui naudojama IBM SPSS programa

neatlieka tiesioginės neigiamų dydžių interpretacijos, pagal nustatymus šie dydžiai yra traktuojami kaip trūkstama informacija (19 lentelė). Transformacija programoje neatliekama dėl didelės klaidų tikimybės kuriant naują kintamąjį.

## 19 lentelė

*Juridinių asmenų finansinių ataskaitų duomenų neigiamos reikšmės*

	N	
	Valid	Missing
Sprendimas	1012	0
Pardavimo pajamos	1012	0
Grynasis pelnas (nuostolis)	866	146
Turtas	1012	0
Nuosavas kapitalas	928	84
Ilgalaikiai įsipareigojimai kredito įstaigoms	1012	0
EBITDA	935	77

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Remiantis kredito įstaigos klientų finansinių ataskaitų duomenimis, nustatyta, jog iš 1012 paraiškų – 14,4% pareiškėjų patyrė nuostolį, 8,3% pareiškėjų nuosavas kapitalas buvo neigiamas ir 7,6% paraiškų atveju pelnas eliminavus palūkanas, mokesčius, nusidėvėjimą bei amortizaciją (angl. *Earnings Before Interest, Taxes, Depreciation and Amortization, EBITDA*) metų pabaigoje išliko neigiamas. Kai įmonė dirba pelningai, tai rodo, jog ji yra pajėgi uždirbti pakankamai pajamų, kad galėtų efektyviai vykdyti veiklą, jei įmonė patiria nuostolius – tai gali identifikuoti problemas, susijusias su skolos grąžinimu. Neigiamas nuosavas kapitalas reiškia, jog įmonės skolos yra didesnės nei jos turtas – tai gali būti įspėjimas apie pakankamų lėšų trūkumą aptarnauti esamus įsipareigojimus. EBITDA suteikia vaizdą apie įmonės operacinį pelningumą, šis rodiklis yra nukreiptas į įmonės gebėjimą generuoti pajamas iš pagrindinės veiklos. Atsižvelgiant į finansuotojo taisykles, ilgalaikiai įsipareigojimai turi neviršyti pardavimo pajamų, skolos lygis apribotas penkių EBITDA reikalavimu. Skolos ir EBITDA santykio ir šio santykio, įvertinus naujus įsipareigojimus, neatitinka 9,5% ir 17,5% įsipareigojimų neįvykdymo atvejų, ilgalaikių įsipareigojimų apribojimas nebuvo pastebėtas.

Analizės rezultatai pagal kredito tipą (11 priedas) rodo, smulkus verslas renkasi kredito tipą pagal tam tikrus jų privalumus. Paskolos sudaro didžiausią dalį paraiškų 57,7%, lizingas – 40,5%,

factoringas – 1,8% nagrinėjamų patvirtintų atvejų. Tarp labai mažų įmonių didžiausias patvirtinimo lygis pagal kredito tipą – paskola (64,4%), mažų įmonių – lizingas (56,7%). Pavyzdžiui, paskolos yra tradicinis finansavimo būdas, kai juridinis asmuo gaunamą sumą įsipareigoja gražinti per tam tikrą laikotarpį. Šis kredito tipas gali būti naudojamas įvairioms reikmėms, pradedant kasdienių išlaidų padengimu, kai trūksta apyvartinių lėšų, iki investicijų į verslo plėtrą, todėl tokia statistika yra paaiškinama. Lizingas pasižymi ilgalaikės nuomos sutarties teisėmis, kai tam tikra turtinė arba techninė priemonė yra naudojama, mokant nuomos įmokas. Iš dalies, tai patogus būdas naudotis turtiniais objektais be didelių pradinių investicijų. Šis finansinis produktas ypač svarbus, kai įmonei reikalingas brangesnis turtas. Faktoringas – tai finansavimo forma, kai įmonė perleidžia neapmokėtas sąskaitas debitoriui, kuris atsako už mokėjimus kredito įstaigai. Paprastai ši finansavimo rūšis plačiau paplitusi tarp didesnių apimčių finansavimo, ji suteikia galimybę pasinaudoti klientų sąskaitomis turint papildomų lėšų.

## 20 lentelė

*Įsipareigojimų neįvykdymas pagal kredito tipą 2022 m.*

Patvirtintos paraiškos	Kredito tipas	Įsipareigojimų nevykdymo atvejai tarp visų patvirtintų paraiškų   proc.	Įsipareigojimų nevykdymo atvejai tarp visų įsipareigojimų nevykdymo atvejų   proc.
	Paskola		6,0
Lizingas		6,3	41,3
Factoringas		11,1	3,2
	Iš viso:	6,2	100,0

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Įvertinus kredito tipo kintamąjį, nustatyta, kad tarp visų įsipareigojimų neįvykdymo atvejų dominuoja paskolos (55,6%) ir lizingas (41,3%), tačiau tai gali būti paaiškinama nereikšminga faktoringo dalimi tarp nagrinėjamų atvejų. Visų teigiamų sprendimų atžvilgiu, paskola ir lizingas reikalauja tam tikrų papildomų užtikrinimo priemonių. Iš kreditoriaus perspektyvos paskoloms dažniau taikomos griežtesnės sąlygos, tai yra viena pavojingiausių finansavimo formų, kuriai taikomi įvairūs užstato reikalavimai, kai finansuojama suma yra didesnė. Mažesnių paskolų kontekste, siekiant išvengti nuostolio, dažnai taikomos aukštesnės palūkanų normos. Lizingą galima laikyti saugia finansavimo forma, jei laikomasi tam tikrų apribojimų, tokių kaip turto likvidumo įvertinimas, tuomet net kredito gavėjui netenkinant įsipareigojimų vykdymo, kreditorius turėtų patirti kur kas mažesnę nuostolį nei paskolos atveju. Viena iš faktoringo sąlygų, kuri nėra palanki kreditoriui, yra

didesnė sąnaudų dalis, kurią debitorius taiko už sąskaitų perėmimą. Šiuo atveju, turėtų būti taikomi mažesnio avansavimo apribojimai. Pasirinkus tokį variantą, paprastai suteikiama konkreti procentinė avanso dalis nuo sąskaitos faktūros vertės ir nustatomas apmokėjimo terminas. Specialiosios kredito sąlygos apima unikalias kredito tipo charakteristikas, kurios įgyvendinamos kredito rizikos politikos gairėse numatyta tvarka.

Atlikta atvejo analizė, apimanti patvirtintus ir nepatvirtintus finansavimo atvejus tampa nepakeičiamu įrankiu renkant ir sisteminant duomenis. Pirmiausiai, ji suteikia išsamų kliento profilio vaizdą, apimančią finansinę būklę, mokėjimo istoriją, juridinės bei kitos neigiamos informacijos elementus. Antra, suprantant kredituojamų subjektų panašumus ir skirtumus, šis požiūris į klientų duomenis padeda identifikuoti finansavimo užklausų charakteristikas, suprasti kredito tipo pasirinkimo rizikas bei sudaryti objektyvų pagrindą ateities sprendimų priėmimui. Trečia, finansuotojo atžvilgiu kuriant modelį, šie duomenys padeda klasifikuoti klientus į grupes, siekiant optimalaus sprendimo priėmimo.

Išnagrinėjus pareiškėjų patvirtintus ir atmestus atvejus galima daryti bendrą išvadą, jog juridinė informacija suteikia bendrą informaciją apie klientą. Neigiamos informacijos analizė padeda nustatyti teisinius pavojus ir leidžia įvertinti probleminius veiksnius. Mokėjimų istorijos duomenys padeda įvertinti ankstesnę pareiškėjo kredito patirtį ir jo gebėjimą vykdyti įsipareigojimus. Finansinių ataskaitų duomenys pateikia informaciją apie įmonės finansinę būklę. Į kredito rizikos modelį įtraukiant aptartus duomenų blokus, finansavimo įstaiga gali būti pajėgi prognozuoti ir objektyviai vertinti kredito riziką, numatyti potencialius vėlavimo atsiskaityti atvejus, prognozuoti įsipareigojimų nevykdymą bei skirstyti klientus į aukštesnės ir žemesnės rizikos. Tai padeda sumažinti finansinių nuostolių riziką ir užtikrina patikimesnę finansavimo sprendimo priėmimą.

### **3.2. Klientų klasifikavimas ir statistiniai ryšiai**

Klientų klasifikavimas pagal rizikingumą yra esminis žingsnis kuriant kredito vertinimo modelį, nukreiptą į sprendimų priėmimą. Remiantis kredito rizikos politikos gairėmis, klientų klasifikavimas į „gerus“ ir „blogus“ pagal rizikingumą vertinamas 3 būdais – siejant su bankroto reitingo reikšme, mokėjimų istorijos informacija ir įsipareigojimų nevykdymo atvejais.

---

## Klientų klasifikavimas (1) – bankroto reitingas


---

Prognozavimo balai yra vienas įrankių, kurie gali būti naudojami atskirti klientus į „gerus“ ir „blogus“. Skirtingi kredito biurai, teikiantys kredito informacijos paslaugas, kredito reitingo agentūros bei kredito draudimo bendrovės gali taikyti skirtingą bankroto reitingo įvertinimą, kuris yra perskaičiuojamas nuo didžiausio iki mažiausio, kas reikštų, jog 10 reitingas yra geriausias galimas variantas. Šiame darbe informacija remiasi UAB „Creditinfo Lietuva“ duomenimis, kur 1 reitingas yra laikomas geriausiu, 10 – blogiausiu.

Kredito rizikos politikoje numatytas kreditoriaus požiūriu priimtinas ir nepriimtinas bankroto reitingas. Priimtinu bankroto reitingu laikomi 1-7 balai, 8-10 balais įvertintos įmonės identifikuojamos kaip „aukštos rizikos“.

### 16 paveikslas

*Klientų klasifikavimas pagal bankroto reitingą sprendimo priėmimo dieną 2022 m. (proc.)*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

2022 m. patvirtintos paraiškos rodo sąlyginai žemą rizikos lygį (15,5%). Nors bankroto reitingas atspindi įmonės kredito istoriją, finansinę būklę ir mokumą, nes remiasi įvairiais veiksniais, tokiais kaip įmonės finansinės ataskaitos, mokėjimų istorija, skolos lygis, kredito istorija, juridinė informacija ir panašiai, tačiau svarbu įvertinti faktą, jog fiksuoti balai yra nustatyti sprendimo priėmimo dieną. Tai reiškia, jog jie nėra visiškai stabilūs ir gali kisti, priklausomai nuo atsirandančios

naujos informacijos, vėliau pateiktų finansinių ataskaitų už kalendorinius metus, informacijos apie nepadengtus įsiskolinimus, įsivėlusių fakto klaidų ir kt.

Siekiant įvertinti požymių priklausomybę, atliekamas Chi-kvadrato testas. Toliau pateikiami tik reikšmingi analizės rezultatai, originalūs rezultatai pateikiami 12–15 prieduose.

## 21 lentelė

*Kintamojo „bankroto reitingas“ statistinio reikšmingumo analizės rezultatai*

Chi-Square Tests				
	Value	df	Asymptotic Significance (2-sided)	
Pearson Chi-Square	13,302 <sup>a</sup>	2	,001	← kredito tipas
	Value	df	Asymptotic Significance (2-sided)	
Pearson Chi-Square	27,697 <sup>a</sup>	1	<,001	← aktyvūs pradelsti mokėjimai valstybinėms institucijoms
	Value	df	Asymptotic Significance (2-sided)	
Pearson Chi-Square	36,079 <sup>a</sup>	1	<,001	← aktyvūs pradelsti mokėjimai, išskyrus finansinėms institucijoms
	Value	df	Asymptotic Significance (2-sided)	
Pearson Chi-Square	39,475 <sup>a</sup>	5	<,001	← įmonės amžius


Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Su 95% pasiklovimo lygmeniu, priklausomybė tarp kintamojo „bankroto reitingas“ ir kintamųjų „aktyvūs pradelsti mokėjimai valstybinėms institucijoms“, „aktyvūs pradelsti mokėjimai, išskyrus finansinėms institucijoms“, „įmonės amžius“ yra statistiškai reikšminga – nulinė hipotezė yra atmetama. Atliktos analizės rezultatai rodo, jog šie kintamieji yra priklausomi, todėl laikomi reikšmingais. Priklausomybė tarp bankroto reitingo ir kintamojo „kredito tipas“ yra abejotina, nes yra 1 reikšmė, turinti tikimybę mažesnę nei 5. Svarbu pastebėti, jog statistiškai reikšminga priklausomybė nereikia priežastinio ryšio tarp kintamųjų. Rezultatai tik parodo, kad egzistuoja statistiškai reikšmingas ryšys. Bankroto reitingas yra reikšmingai susijęs su vienu juridinės informacijos kintamuoju, dvejais mokėjimų istorijos kintamaisiais bei vienu finansavimo pasiūlymo kintamuoju.

Klientų segmentavimas į „gerus“ ir „blogus“ taip pat gali būti atliekamas, remiantis juridinio asmens mokėjimų istorija. Remiantis finansų įstaigos kredito rizikos politika, kreditorius nurodo, jog pradelsti mokėjimai per pastaruosius 12 mėnesių, skaičiuojant nuo sprendimo priėmimo dienos yra nepriimtini, juridinio asmens, susijusių įmonių arba asmeninio bankroto ir (ar) nemokumo atvejais – taikomas 5 metų tolerancijos laikotarpis.

### 17 paveikslas

*Klientų klasifikavimas pagal mokėjimų istoriją sprendimo priėmimo dieną 2022 m. (proc.)*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

2022 m. patvirtintos paraiškos rodo, jog didžioji dauguma klientų atitinka kreditoriaus reikalavimus, blogos mokėjimo istorijos faktas fiksuotas 10,0% patvirtintų paraiškų. Pradelsti mokėjimai valstybinėms ir finansinėms institucijoms gali turėti įvairių pasekmių, tokių kaip baudos, teisminiai procesai, turto areštai, o prasta mokėjimų istorija, atsiskaitant su tiekėjais gali reikšti prastėjančią juridinio asmens finansinę būklę. Toliau nagrinėjama kintamųjų priklausomybė ir statistinis reikšmingumas (16 priedas).

## 22 lentelė

Kintamųjų „aktyvūs pradelsti mokėjimai valstybinėms institucijoms“ ir „teismai“ statistinio reikšmingumo analizės rezultatai

Chi-Square Tests					
	Value	df	Asymptotic Significance (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	292,305 <sup>a</sup>	1	<,001		
Continuity Correction <sup>b</sup>	276,137	1	<,001		
Likelihood Ratio	101,343	1	<,001		
Fisher's Exact Test				<,001	<,001
Linear-by-Linear Association	292,016	1	<,001		
N of Valid Cases	1012				

a. 1 cells (25,0%) have expected count less than 5. The minimum expected count is 1,17.

b. Computed only for a 2x2 table

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Atliktos analizės rezultatai atskleidė, jog priklausomybės tarp pradelstų mokėjimų ir teismų, turto areštų, antstolių raginimų nefiksuota. Pateikti rezultatai rodo, jog net kai  $p$  reikšmė yra mažesnė už pasirinktą reikšmingumo lygį ( $\alpha = 0,05$ ), nulinė hipotezė yra priimama, nes yra 1 reikšmė, turinti tikimybę mažesnę nei 5. Tai yra perspėjimas apie tai, jog reikšmė arba duomenų kiekis yra per maži, kad būtų galima daryti išvadas apie statistinį reikšmingumą. Taigi, mokėjimo istorijos ir neigiamos informacijos duomenų ryšys, šiuo atveju, yra statistiškai nereikšmingas. Teismų kintamasis taip pat neparodė statistiškai reikšmingo ryšio su kintamaisiais „pradelsti mokėjimai finansinėms institucijoms“ bei „aktyvūs pradelsti mokėjimai, išskyrus finansinėms institucijoms“.

---

### Klientų klasifikavimas (3) – įsipareigojimų neįvykdymo atvejai

---

Toliau skirstant klientus į segmentus pagal rizikingumą, nagrinėjamas įsipareigojimų neįvykdymo atvejų ryšys su nepriklausomais kintamaisiais. Finansavimo sprendimo priėmimo dieną įsipareigojimų neįvykdymo atvejai buvo lygūs nuliui, 2022 m. pabaigoje – 63 atvejai. Įsipareigojimų neįvykdymu laikomi mokėjimų vėlavimai, siekiantys daugiau nei 90 dienų, nemokumas arba bankrotas. Originalūs reikšmingi duomenys pateikiami 17 priede.



## 23 lentelė

*Kintamųjų „įsipareigojimų nevykdymas“ ir „įmonės amžius“ statistinio reikšmingumo analizės rezultatai*

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	16,621 <sup>a</sup>	5	,005
Likelihood Ratio	12,617	5	,027
Linear-by-Linear Association	2,832	1	,092
N of Valid Cases	1012		

a. 1 cells (8,3%) have expected count less than 5. The minimum expected count is 3,42.

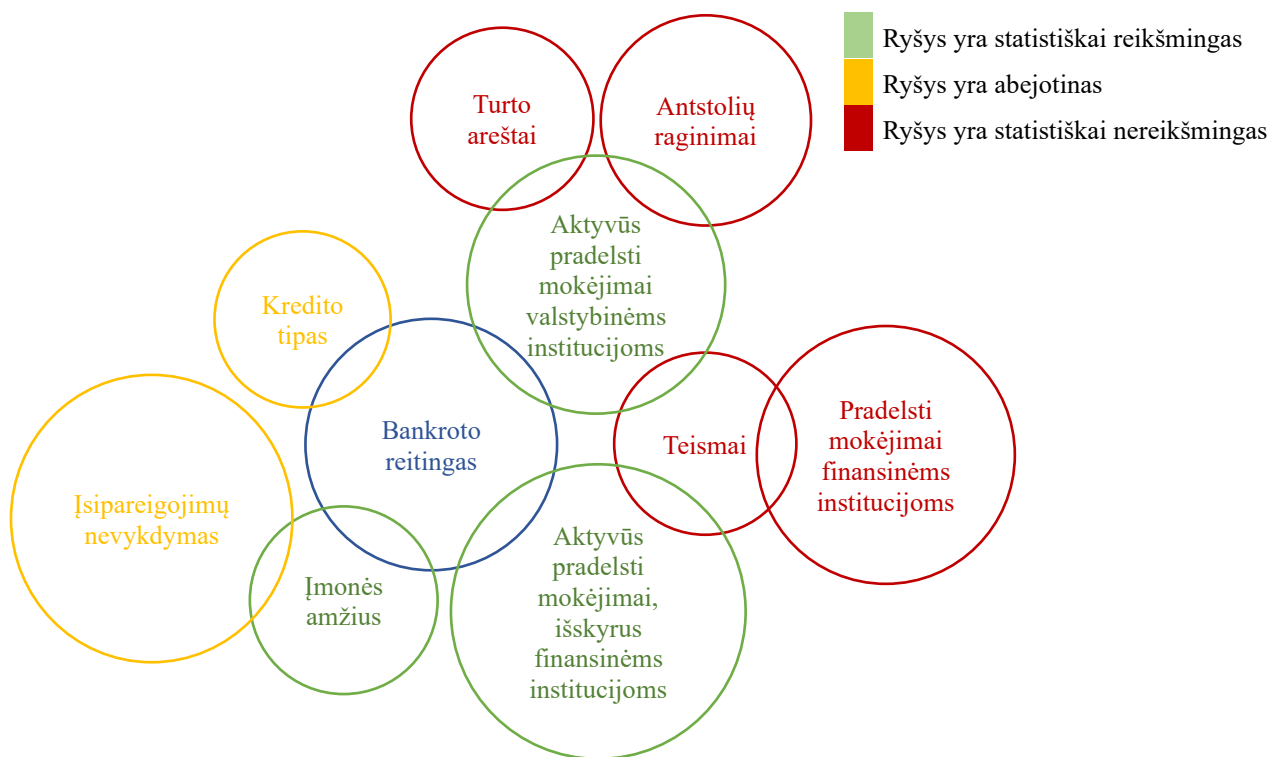
Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Su 95% pasiklovimu lygmeniu, priklausomybė tarp įsipareigojimų nevykdymo ir įmonės amžiaus kintamojo yra statistiškai nereikšminga – nulinė hipotezė yra priimama. Nors įprastai mokslinėje literatūroje nurodoma, jog tikėtinų langelių reikšmės, mažesnės nei 5, yra nepriimtinos ir gali turėti įtakos statistinės analizės patikimumui, tam tikrais atvejais, pripažįstama, jog iki 20% langelių su maža tikėtina reikšme gali būti toleruojama. Šiuo atveju, pasirenkama pripažinti, jog reikšmingas ryšys tarp nagrinėjamų kintamųjų yra abejotinas, nors tai gali būti diskutuotina. Pavyzdžiui, mažiau nei vienerius metus veikiančios smulkios įmonės, pradėjusios verslą gali gauti finansavimą verslo pradžiai ar plėtrai, tačiau, nepaisant to, kad jos gali turėti ambicingus tikslus ir perspektyvas, patirties trūkumas, galimybė pervertinti savo gebėjimus, riboti finansiniai ištekliai yra neatmestini kaip pažeidžiamumo ir galimo veiklos nutraukimo dėl finansinio stabilumo trūkumo priežastys.

Klientų segmentavimas pagal rizikingumą 3 skirtingais būdais atskleidžia, jog, nors kai kurie statistiniai ryšiai tarp klientų duomenų yra reikšmingi, tačiau kai kurie iš jų – abejotini. Taip pat, pastebimi ir statistiškai nereikšmingi požymių nepriklausomumo rezultatai.

## 18 paveikslas

*Klientų klasifikavimo statistinio reikšmingumo analizės rezultatai*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Statistiškai įvertinti požymiai negali suteikti tikslaus vaizdo, kurie kintamieji iš tikrųjų yra reikšmingi kuriant kredito rizikos vertinimo modelio, tačiau pravartu prisiminti 3.1 poskyryje atliktą paraiškų atvejo analizę, kuri suteikia pagrindą daryti prielaidą, jog juridinės informacijos, neigiamos informacijos, mokėjimų istorijos ir finansinių ataskaitų duomenų blokai teoriniu ir praktiniu požiūriu reikšmingai prisideda prie tikslesnio kredito rizikos įvertinimo. Duomenys suteikia vertinimo procesui papildomą informaciją apie pareiškėjus ir praneša apie galimus rizikos veiksnius, galinčius turėti įtakos sprendimo priėmimui. Šių prielaidų patvirtinimui papildomai atliekama 4 mėnesių monitoringo ataskaitos stebėjimų analizė. Per šį laikotarpį įmonėje registruoti 19187 pranešimai.

## 19 paveikslas

### Monitoringo pranešimų tipai pagal rizikos grupę

Juridinė informacija (9,2%)		Mokėjimų istorija (54,9%)	
Adreso (juridinio) pasikeitimas	50	Atidėta suma SODRA – dengimas	557
Akcininkų informacija / vadovo pasikeitimas	96	Atidėta suma SODRA – didėjimas / nauja	250
Išregistravimas iš PVM mokėtojų	32	Bankroto / restruktūrizacijos informacija	4
Pavadinimo pasikeitimas	5	Skola – dengimas	1288
Reikšmingas darbuotojų skaičiaus didėjimas	639	Skola – didėjimas, nauja	3806
Reikšmingas darbuotojų skaičiaus mažėjimas	879	Skola SODRA – dengimas	2791
Teisinio statuso pasikeitimas	67	Skola SODRA – didėjimas, nauja	1836
Neigiama informacija (15,6%)		Finansinių ataskaitų duomenys (14,2%)	
Areštų informacijos pasikeitimas	253	Finansinė ataskaita už ataskaitinį laikotarpį pateikta	156
Spaudos pranešimai	424	Įstatinio kapitalo pasikeitimas	16
Teismų informacija – atsakovas	1512	Pajamų didėjimas 10% ar daugiau	77
Teismų informacija – ieškovas	485	Pajamų mažėjimas 10% ar daugiau	24
Teismų informacija – trečioji šalis	9	Išorinis reitingas (13,7%)	
Vieša neigiama informacija	305	Bankroto reitingo klasės pasikeitimas	1254
Kita informacija (5,15%)	989	Vėlavimo atsiskaityti reitingo pasikeitimas	1383

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Monitoringo ataskaitos apie esamus klientus analizės rezultatai rodo, jog informacija yra dinamiška. Akcininkų bei vadovo pasikeitimo informacija, reikšmingas darbuotojų skaičiaus kitimas (juridinė informacija), pradelsti mokėjimai finansinėms, nefinansinėms ir valstybinėms institucijoms (mokėjimų istorija), turto areštai, teismai, viešai prieinama neigiama informacija (neigiama informacija), įstatinio kapitalo dydis, pajamų pokyčiai (finansinių ataskaitų duomenys), bankroto ir vėlavimo atsiskaityti reitingai (išorinis reitingas) ir kita informacija gali būti laikomi esminiais įmonės nestabilumą lemiančiais veiksniais, į kuriuos nukreiptas kreditoriaus dėmesys gali atskleisti klientų elgseną ir su ja susijusias rizikas ateityje.

Apibendrinant, „gerų“ ir „blogų“ klientų klasifikavimas pagal bankroto reitingą ir mokėjimų istoriją yra susijęs su tam tikrais statistiškai reikšmingais ryšiais. Pabrėžiama, jog šie rezultatai nėra priežastiniai, tačiau gali būti prasmingi klasifikuojant klientus pagal jų rizikos lygį. Remiantis finansų įtaigos priimtais sprendimais, galima teigti, jog 2022 m. portfelis buvo papildytas „gerais“ klientais, atsižvelgiant į žemą kredito rizikos lygį, klientus klasifikuojant pagal bankroto reitingą, mokėjimų

istoriją ir įsipareigojimų nevykdymą, tačiau svarbu pastebėti, jog toks skirstymas yra reikšmingas tik tam tikrame kontekste, todėl klientų klasifikavimas turi būti kompleksinis. Papildomai atlikta monitoringo ataskaitos analizė įrodo skirtingų duomenų integravimo poreikį.

### **3.3. Kredito rizikos vertinimo modelio formavimas ir veikimo principai**

Skirtingi pareiškėjai priskiriami skirtingiems rizikos lygmenims, o tai lemia, jog jiems gali būti pateikiamos individualiai pritaikytos kredito sąlygos. Dėl šios priežasties modelio kūrimo procese turi būti apibrėžti tam tikri apribojimai, kad būtų atsižvelgiama į šiuos skirtumus ir atitinkamai įvertinta kredito rizika. Apribojimai padeda užtikrinti, kad modelis būtų pritaikytas ne tik skirtingiems pareiškėjams vertinti, tačiau ir konkrečiam finansiniam produktui ir atspindėtų jo unikalias rizikos savybes. Šiuo požiūriu, kredito rizikos modelio mažoms ir labai mažoms įmonėms formavimas yra neatsiejamas nuo verslo aplinkos, kurioje bus taikomas. Šiame darbe modelio, orientuoto į sprendimų priėmimą, kūrimas grindžiamas atliktos literatūros analizės rezultatais, kurie nurodo, jog kiekybinių ir kokybinių duomenų atranka ir šios informacijos integravimas yra nepakeičiama proceso dalis, kuria užtikrinamas finansuotojo atžvilgiu „teisingas“ požiūris į kredito rizikos vertinimą. Kadangi rizikos suvokimas gali skirtis, modelio formavimas yra pagrįstas skolinimo įstaigos kredito rizikos politikos gairėmis, aktualia klientų informacija bei sprendimų priėmimo analize, finansuotojo suvokimu, kas yra „geras“ ir „blogas“ klientas bei monitoringo ataskaitos rezultatų visuma.

Prisitaikymas prie konkrečios aplinkos pasireiškia per duomenų prieinamumą ir informacijos suvokimą, kuriuo sprendžiamos informacijos (ne)skaidrumo problemos. Tuo tarpu, skirtingų duomenų integracija modeliuojant sprendimų priėmimą, pasitelkiant automatizuotus procesus, atitinka šią aplinką, ribodama žmogiškus šališkumo veiksnius. Remiantis anksčiau atliktos analizės rezultatų duomenimis (3.1 ir 3.2), toliau pateikiamas kliento informacijos ir pasiūlymo informacijos duomenų sudedamųjų sąrašas, kuris remiasi kredito rizikos politikos gairėmis.

## 24 lentelė

### Kliento informacijos duomenų sudedamosios dalys ir apribojimai

<b>Juridinė informacija</b>	Registracijos šalis	Tenkinama sąlyga – Lietuva
	Įmonės pavadinimas	Nuasmeninta, generuojamas unikalus kodas
	Įmonės amžius, mėnesiais	Įmonė veikia bent 12 mėnesių
	Teisinis statusas	Tenkinama sąlyga – „veikiantis subjektas“
	Ekonominės veiklos rūšis (EVRK2)	Neapribotos veiklos sektoriai
	Savininkų / akcininkų / dalyvių / steigėjų struktūra, įmonės vadovas	Juridinių asmenų dalyvių informacinėje sistemoje (JADIS) fiksuoti galutiniai naudos gavėjai ir jų pokyčiai per 12 mėnesių, skaičiuojant nuo sprendimo priėmimo dienos
	Darbuotojų skaičius	Įmonės dydis – mažos ir labai mažos įmonės
<b>Išorinis reitingas</b>	„Creditinfo Lietuva“ bankroto reitingas	1-7 – tenkinamas dydis 8-10 – netenkinamas dydis
<b>Neigiama informacija</b>	Politiškai pažeidžiami (paveikiami) <sup>16</sup> arba sankcionuoti asmenys <sup>17</sup>	Patikra, remiantis Lietuvos Respublikos pinigų plovimo ir teroristų finansavimo prevencijos įstatymu ir Lietuvos Respublikos tarptautinių sankcijų įstatymu
	Turto areštai, teismai, antstolių raginimai	12 mėnesių, skaičiuojant nuo sprendimo priėmimo dienos
	Neigiama viešai prieinama informacija	5 metai, skaičiuojant nuo sprendimo priėmimo dienos <sup>18</sup>
<b>Mokėjimų istorija</b>	Juridinio asmens, susijusių įmonių arba asmeninis bankrotas ir (ar) nemokumas	5 metai, skaičiuojant nuo sprendimo priėmimo dienos
	Pradelsti mokėjimai finansinėms, nefinansinėms ir valstybinėms institucijoms	Finansinėms institucijoms – 12 mėnesių, skaičiuojant nuo sprendimo priėmimo dienos Nefinansinėms institucijoms – aktyvūs >1 000 EUR Valstybinėms institucijoms – aktyvūs >1 000 EUR ir >30 d.
	Neigiama mokėjimų istorija	Įsipareigojimų nevykdymo patikra (esamiems klientams)
<b>Finansinių ataskaitų duomenys</b>	Pardavimo pajamos, EUR	Teigiamas dydis
	Grynasis pelnas, EUR	Įmonė veikia pelningai arba jei nuostolingai, tai nuosavas kapitalas viršija nuostolį
	Turtas, EUR	Netaikomi apribojimai
	Nuosavas kapitalas, EUR	Teigiamas dydis
	Ilgalaikiai finansiniai įsipareigojimai, EUR	Ne didesni nei pardavimo pajamos (naujausias žinomas dydis)
	EBITDA, EUR	Teigiamas dydis
	Skolos ir EBITDA santykis	Daugiau arba lygu 0, bet daugiau nei 5
	Skolos ir EBITDA santykis su naujais įsipareigojimais	Jei finansuojama suma >25 000 EUR, daugiau arba lygu 0, bet ne daugiau nei 3 Jei finansuojama suma ≤25 000 EUR, daugiau arba lygu 0, bet ne daugiau nei 5
	Nuosavybės koeficientas, %	Minimalus dydis: nuosavas kapitalas sudaro 10% balansinės turto vertės

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

<sup>16</sup> Politiškai pažeidžiami (paveikiami) asmenys – tai fiziniai asmenys, kuriems yra arba buvo patikėtos svarbios viešosios pareigos, ir jų artimieji šeimos nariai arba artimi pagalbininkai. Šaltinis: Lietuvos Respublikos Seimas, 2023

<sup>17</sup> Sankcionuoti asmenys – tai fiziniai arba juridiniai asmenys, bet kokia kita organizacija arba fizinių ar juridinių asmenų grupė ir (ar) organizacijų grupė, kuriems taikomos tarptautinės sankcijos arba Lietuvos Respublikos įstatymais nustatytos ribojamosios priemonės. Šaltinis: Lietuvos Respublikos Seimas, 2023

<sup>18</sup> Viešos neigiamos prieinamos informacijos patikros laikotarpiui netaikomas 5 metų apribojimas, jei tai susiję su finansiniais nusikaltimais ir (ar) organizuotos grupės bylomis.

## 25 lentelė

### Pasiūlymo informacijos duomenų sudedamosios dalys ir apribojimai

<b>Finansavimo pasiūlymas</b>	Kredito tipas	Tenkinama sąlyga – paskola, lizingas, faktoringas
	Įsipareigojimo terminas, mėnesiais	Maksimalus terminas: Paskola – 60 mėn. Lizingas – 36 mėn. Faktoringas – 12 mėn.
	Finansuojama suma, EUR	Negali būti didesnis nei maksimalus naujas limitas ir <=50 000 EUR
	Maksimalus naujas limitas, EUR	Jei skolos lygis su naujais įsipareigojimais yra daugiau nei 5*EBITDA, tai iš šio dydžio atimama ilgalaikių įsipareigojimų suma, bet pasiūlymas <=50 000 EUR Jei skolos lygis su naujais įsipareigojimais yra mažiau arba lygu 5*EBITDA, tai maksimalus pasiūlymas = 50 000 EUR – įsipareigojimai įstaigoje (jei esamas klientas)
	Visų įsipareigojimų likutis (įskaitant siūlomą limitą), EUR	Įsipareigojimai įstaigoje (jei esamas klientas) + finansuojama suma <=50 000EUR
	Fiksuota palūkanų norma, %	Ne mažesnė nei minimali fiksuota palūkanų norma
	Minimali fiksuota palūkanų norma, %	Priklausomybė nuo bankroto reitingo
Administracinis mokestis, EUR	Priklausomybė nuo finansavimo paraiškos sumos	
<b>Specialiosios sąlygos pagal kredito tipą</b>	<b>PASKOLA</b>	
	Atpirkimo dydis, %	>=50% (jei taikoma)
	Įkeičiamo turto vertė, EUR	Oficialus dokumentas – turto vertinimas (jei taikoma)
	Paskolos ir vertės santykis, %	<=80% (jei taikoma)
	<b>LIZINGAS</b>	
	Turto klasė <sup>19</sup>	M, N, O, Z, ST, I
	Turto kategorija	M1-M3, N1-N3, O1-O4; Z1-Z9; ST; I
	Pirmosios registracijos metai	M, N, O, Z, ST <=20 metų, I <=15 metų termino gale
	Pirkimo kaina, EUR	Maksimalus 20% nuokrypis nuo turto vertės
	Turto vertė <sup>20</sup> , EUR	Turto vertinimas arba kitų šaltinių duomenys
Pardavėjas (tiekėjas)	Juridinis / fizinis asmuo; patikimas / nepatikimas partneris	
Pradinis įnašas, %	Priklausomybė nuo turto kategorijos	
Atidėtas PVM grąžinimas, mėnesiais (jei taikoma)	Jei pardavėjas yra juridinis asmuo, klientas PVM mokėtojas ir kaina nėra „maržinė“ <sup>21</sup> , iki 6 mėn.	
<b>FAKTORINGAS</b>		
Atidėjimo terminas, dienomis	<=90 dienų	
Avansas, %	<=90%	
Valstybės programos garantijos dydis, %	>=70% (jei taikoma)	
Draudimo dydis, %	>=90% (jei taikoma)	

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

<sup>19</sup> Šiame darbe turto klasės žymimos: M, N, O – transporto priemonės, Z – žemės ūkio technika, ST – statybų technika, I – įranga.

<sup>20</sup> Turto vertė šiame darbe yra vidutinė rinkos kaina, nustatyta remiantis patikimų šaltinių duomenimis (<https://www.emprekis.lt/>) arba viešai prieinamų internetinių platformų informacija (<https://m.autoplus.lt/>, <https://www.mobile.de/>, ir kt.). Oficialių pardavėjų kainos ir pateiktos turto vertinimo ataskaitos yra nekvestionuojamos.

<sup>21</sup> Maržos schemą gali taikyti PVM mokėtojai, kurie: nuolat verčiasi naudotų automobilių tiekimu (arba tiekia, kuris į apskaitą įtrauktas kaip ilgalaikis materialusis turtas) ir tiekia be PVM Lietuvoje ar ES teritorijoje įsigytus automobilius arba tiekia iš ES valstybės įsigytus automobilius, kurie toje šalyje buvo apmokestinami taikant specialią apmokestinimo schemą (maržos schemą). Šaltinis: Valstybinė mokesčių inspekcija, 2020.

Duomenų, pateiktų 24 ir 25 lentelėse, integravimas reiškia pritaikomumą finansuotojo veikloje ir apibrėžia jo rizikos suvokimą. Modelio formavimas remiasi taisyklėmis pagrįstu metodu, t. y. kredito rizikos politikos taisyklėmis, modeliuojamomis „jeigu – tai“ principu, kurio rezultatas – sprendimo dėl kredito suteikimo priėmimas.

## 20 paveikslas

*Sąlygos ir modelio sprendimo sąveika*

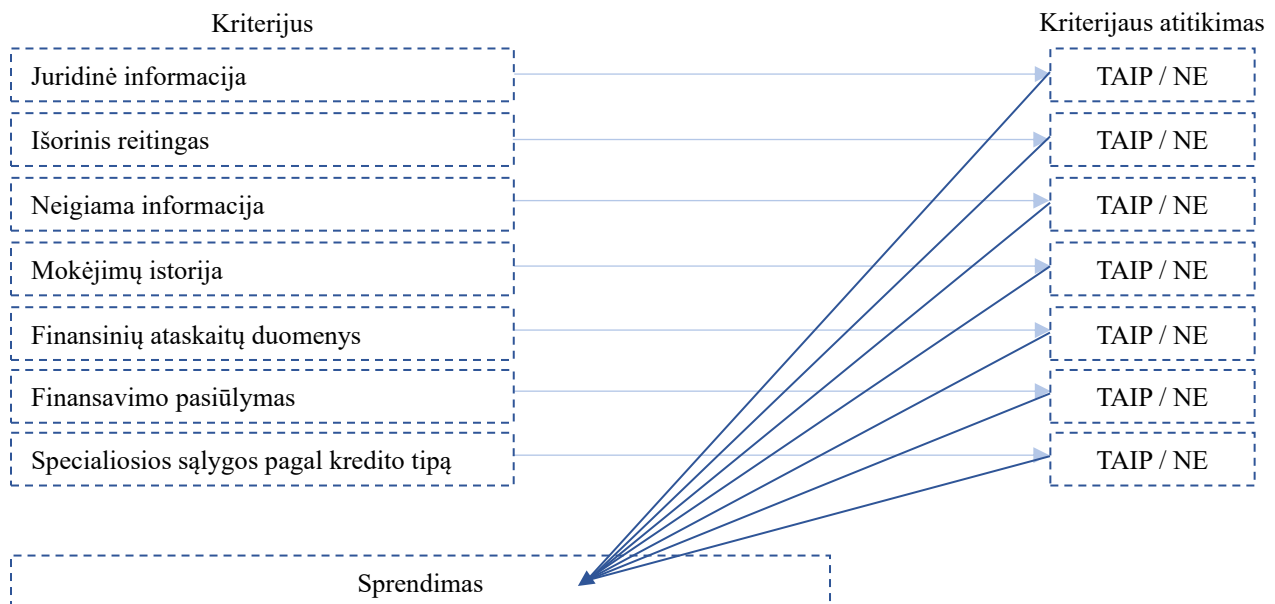


Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Duomenų segmentuose užkoduojamos „jeigu – tai“ taisyklės nurodo, ar klientą apibūdinantys kintamieji tenkina finansuotojo iškeltus tikslus, arba kitaip, sąlygas.

## 21 paveikslas

*Modelio sprendimą veikiančios sritys*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Kiekviena duomenų segmento dalis koduojama bent dvejomis taisyklėmis, kur pirmoji įtvirtina kredito rizikos politikos taisyklę, antroji – tiesiogiai nustato duomenų atitikimą nustatytos taisyklės atžvilgiu.

## 26 lentelė

*Duomenų segmentuose įgyjamos reikšmės – atitikties taisyklių rinkinys*

<b>Kliento informacija</b>	← 1	Juridinė informacija	← 9	veikiančios sritys
	← 1	Išorinis reitingas	← 1	veikiančios sritys
	← 1	Neigiama informacija	← 5	veikiančios sritys
	← 1	Mokėjimų istorija	← 6	veikiančios sritys
	← 1	Finansinių ataskaitų duomenys	← 9	veikiančios sritys
<b>Pasiūlymo informacija</b>	← 1	Finansavimo pasiūlymas	← 7	veikiančios sritys
	← 3	Specialiosios sąlygos pagal kredito tipą	← 12	veikiančių sričių

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Duomenis pagal informacijos pobūdį tiesiogiai veikia mažiausiai 9 sritys, kurios yra tiesiogiai priklausomos nuo dar mažiausiai 49 taisyklių. Kliento informaciją tiesiogiai veikia 5 segmentuose užkoduotos 30 atitikties kredito rizikos politikai taisyklių, pasiūlymo informaciją – 2 segmentuose užkoduotos 19 taisyklių.

Duomenų pagal informacijos pobūdį rezultatas klasifikuojamas į „TAIP“ ir „NE“ pagal atitikimą iškeltai sąlygai. Kiekviena duomenų segmento eilutė turi pateikti rezultatą „TAIP“, kad modelis automatiškai grąžintų teigiamą sprendimą dėl finansavimo suteikimo. Kredito rizikos vertinimo modelis formuojamas „viskas arba nieko“ principu – t. y. teigiamas sprendimas yra priimamas tik tuo atveju, jei kliento ir pasiūlymo informacija atitinka visas taisykles.

## 27 lentelė

*Kredito rizikos vertinimo modelio sprendimų priėmimo rezultatai – pavyzdys*

Kliento Nr.	Juridinė informacija	Išorinis reitingas	Neigiama informacija	Mokėjimų istorija	Finansinių ataskaitų duomenys	Finansavimo pasiūlymas	Specialiosios sąlygos	SPRENDIMAS
1	TAIP	TAIP	TAIP	TAIP	NE	NE	NE	NEIGIAMAS
2	TAIP	TAIP	TAIP	TAIP	TAIP	TAIP	TAIP	TEIGIAMAS
3	TAIP	TAIP	TAIP	TAIP	TAIP	TAIP	TAIP	TEIGIAMAS
4	TAIP	TAIP	TAIP	TAIP	NE	TAIP	TAIP	NEIGIAMAS
5	NE	TAIP	NE	TAIP	NE	TAIP	TAIP	NEIGIAMAS

Šaltinis: parengta autorės, remiantis atliktu tyrimu.




Sprendimų priėmimo dėl kredito suteikimo pavyzdys yra pateikiamas kaip šabloninė kredito rizikos vertinimo modelio, generuojančio rezultatus, versija. Kintamųjų tarpusavio ryšiai, kompleksinis modelio formavimas ir specialiųjų sąlygų pagal kredito tipą aprašymai pateikiami, atitinkamai, 18–20 prieduose.

Atsižvelgiant į tokį kredito rizikos vertinimo modelį, kurio tikslas – pateikti sprendimą dėl kredito suteikimo, galima daryti prielaidą, jog automatizuotų sprendimų modeliai pateikia teigiamą sprendimą su gana didele paklaida lyginant su žmogiškaisiais sprendimais, nes jie laikosi konkrečių taisyklių be jokių galimų nuokrypių. Kritinis modelio vertinimas formavimo procese išryškina tikimybę, jog dėl šios priežasties bus stebimas aukštas atmetamų paraiškų lygis. Kita vertus, modelio loginis įvesties-išvesties ryšio paaiškinamumas atskleidžia, jog automatizuotas modelis identifikuoja sutaptis su kredito rizikos politikos neatitikimais ir užtikrina lengvą naujų taisyklių ir (ar) jų pakeitimų integraciją, be to, yra suderinamas su žmogiškojo racionalumo veiksmu, todėl leidžia atpažinti trūkstamus duomenis ir yra veiksmingas su skirtingu duomenų kiekiu.

Suformavus kredito rizikos vertinimo modelį, jis integruojamas į automatizuotą aplinką. Šiame etape, tikrinamos automatizuotų procesų sprendimo priėmimo kontekste galimybės, o duomenų validacija atlieka esminį vaidmenį siekiant įsitikinti duomenų tikslumu, patikimumu ir tinkamumu.

## 22 paveikslas

### *Duomenų validacijos schema*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Duomenų validacija yra procesas, kuris parodo, ar duomenys yra tikslūs išskiriant klaidas ar iškraipymus, užtikrindama, kad šie atitinka numatytus reikalavimus. Šis žingsnis yra būtinas norint užtikrinti, kad modelio veikimas būtų optimizuotas ir galėtų pateikti patikimus rezultatus. Tikslui pasiekti – tikrinami automatizuotos sprendimų priėmimo sistemos išvesties rezultatų duomenys.

## 28 lentelė

*Momentinių sprendimų priėmimo modulio duomenų generavimas*

	N	
	Valid	Missing
Modelio_sprendimas	1012	0
Juridinė informacija	1012	0
Bankroto reitingas	1012	0
Neigiama informacija	1012	0
Mokėjimų istorija	1012	0
Finansinių ataskaitų duomenys	1012	0
Finansavimo pasiūlymas	1012	0
Specialiosios sąlygos pagal kredito tipą	1012	0

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Visuose duomenų segmentuose, įskaitant ir modelio sprendimų rezultatus, fiksuojama 1012 reikšmių – tai rodo atitikimą patvirtintų paraiškų kiekiui. Rezultatai analizuojami ne pavieniui, o grupuojami pagal informaciją dėl sąlyginai nedidelio duomenų rinkinio. Duomenų validacija automatizuotu procesu rodo, jog klaidų aptikimas nefiksuotas, nėra praleistų reikšmių, duomenys yra struktūrizuoti ir tinkamo formato. Svarbu pastebėti, jog duomenų validacija turėtų sekti kartu su kredito rizikos politikos atnaujinimais ir augančiu arba krentančiu kredito įstaigos rizikos „apetitu“. Kadangi modelis negali pats prisitaikyti prie rinkos pokyčių, verslo sąlygų bei kitokios naujos informacijos, būtina, jog jis būtų atidžiai prižiūrimas.

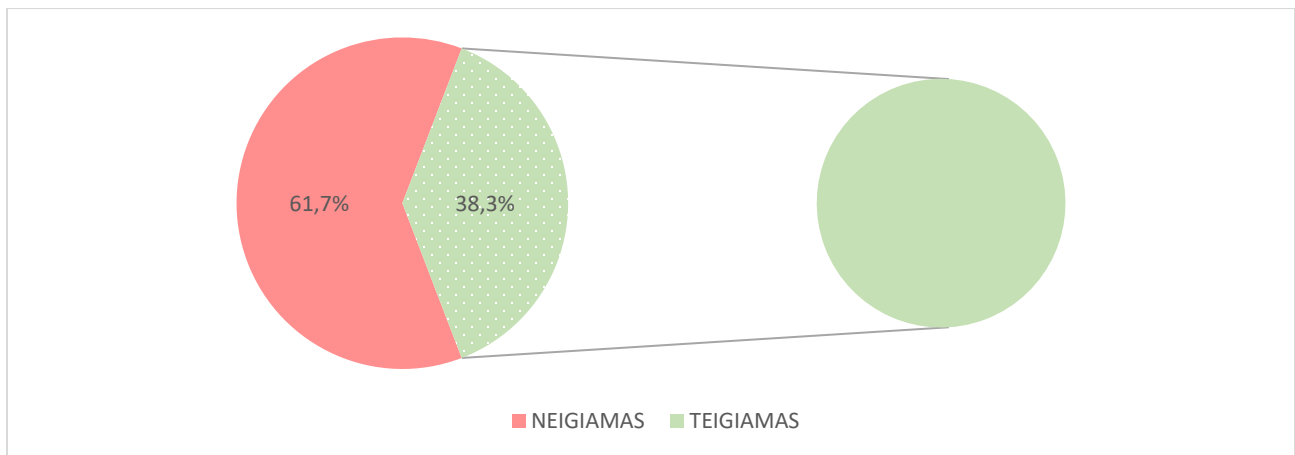
Apibendrinant, pasiektas pagrindinis darbo tikslas – mažoms ir labai mažoms įmonėms sukurtas kredito rizikos vertinimo modelis, kurio pagrindinėmis savybėmis išskiriamos individualiai pritaikytos kredito sąlygos, atsižvelgiant į pareiškėjui priskirtą rizikos lygį. Modelis grindžiamas finansuotojo kredito rizikos politikos gairėmis, kurios pagal duomenų pobūdį įtraukia kliento ir pasiūlymo informaciją. Kredito rizikos vertinimo kontekste, pasitelkiant automatizuotus procesus, momentinių sprendimų priėmimo modulis leidžia generuoti sprendimus dėl kredito suteikimo. Atlikta duomenų validacija patvirtina duomenų pasirinkimo efektyvumą ir automatizuotos sistemos pritaikomumą dinamiškoje rinkos aplinkoje, o integruotos taisyklės pagrindžia sutaptį su modelio paaiškinamumu ir nesudėtingą rezultatų interpretaciją priimamų sprendimų atžvilgiu.

### 3.4. Kredito rizikos vertinimo modelio analizė ir tyrimo rezultatų vertinimas praktinėje aplinkoje

Kredito rizikos modelis finansų sektoriuje yra nepakeičiama priemonė, skirta vertinti ir prognozuoti pareiškėjų mokumą bei su tuo susijusią riziką. Suformavus kredito rizikos vertinimo modelį, atsižvelgiant į griežtai nustatytas kredito rizikos politikos taisykles, modelio rezultatai tampa esminiu veiksniu, padedančiu įvertinti klientų kredito patikimumą. Automatizuoto kredito rizikos vertinimo modelio mažoms ir labai mažoms įmonėms rezultatų patikimumo analizė yra svarbi siekiant suprasti žmogiškųjų ir automatinių sprendimų skirtumus.

#### 23 paveikslas

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



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

23 paveiksle vaizduojami kredito rizikos vertinimo modelio pateikti sprendimai, integravus kredito rizikos politikos taisykles. Automatizuoti sprendimai, pagrįsti tiksliais taisyklėmis, praleidžia tik atvejus, atitinkančius visus reikalavimus. Iš 1012 patvirtintų atvejų, pritaikius taisykles, nustatyta, jog šis modelis atmetė 624 atvejus (61,7%).

Neatitikimų įvertinimas ir klaidų nustatymas yra analizės dalis, kuri padeda balansuoti tarp modelio teikiamų privalumų ir trūkumų. Klaidų įvertinimo tikimybė yra lemiamas kriterijus vertinant kredito rizikos modelio, nukreipto į sprendimų priėmimą, efektyvumą ir patikimumą. Ši analizė padeda suprasti modelio apribojimus. Dėl didelio modelio rezultatų neatitikimo praktikoje patvirtintų sprendimų atžvilgiu, atliekamas Chi-kvadrato testas, kuriame tikrinama hipotezė dėl sukurto modelio

sprendimo rezultatų ir įsipareigojimų nevykdymo kintamojo priklausomybės. Įsipareigojimų neįvykdymo atvejų analizė per modelio prizmę leidžia įvertinti jo specifines charakteristikas, kurios apima klasifikavimo gebėjimus, paaiškinamumo lygį ir interpretacijos galimybes.

**29 lentelė** Kintamųjų „modelio sprendimas“ ir „įsipareigojimų nevykdymas“ statistinio reikšmingumo analizės rezultatai

**Modelio\_sprendimas \* Įsipareigojimų nevykdymas Crosstabulation**

		Modelio_sprendimas				Total	
		Neigiamas		Teigiamas			
		Count	% within Modelio_sprendimas	Count	% within Modelio_sprendimas		
Įsipareigojimų nevykdymas	Ne	569	91,2%	380	97,9%	949	93,8%
	Taip	55	8,8%	8	2,1%	63	6,2%
Total		624	100,0%	388	100,0%	1012	100,0%

**Chi-Square Tests**

	Value	df	Asymptotic Significance (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	18,685 <sup>a</sup>	1	<,001		
Continuity Correction <sup>b</sup>	17,546	1	<,001		
Likelihood Ratio	21,727	1	<,001		
Fisher's Exact Test				<,001	<,001
Linear-by-Linear Association	18,666	1	<,001		
N of Valid Cases	1012				

a. 0 cells (0,0%) have expected count less than 5. The minimum expected count is 24,15.

b. Computed only for a 2x2 table

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Rezultatai rodo, kad  $p$  reikšmė su 95% pasiklovimo lygmeniu yra mažesnė už pasirinktą reikšmingumo lygį ( $\alpha = 0,05$ ), nulinė hipotezė yra atmetama. Ryšys tarp modelio sprendimo ir įsipareigojimų nevykdymo yra statistiškai reikšmingas. Šis įvertinimas yra viena stipriausių modelio savybių. Duomenų analizės lentelė rodo, jog iš 63 fiksuotų įsipareigojimų nevykdymo reikšmių, modelis atmetė 55 atvejus – tai reiškia 87,3% jautrumą, susijusį su įsipareigojimų nevykdymo atpažinimu.

Modelio rezultatų skirtumų, veikimo ir efektyvumo vertinimui naudojama klasifikavimo matricos charakteristikų analizę, kur „0“ – žymi įsipareigojimų vykdymą („geri“ klientai), „1“ – įsipareigojimų nevykdymą („blogi“ klientai).

## 24 paveikslas

*Klasifikavimo matricos rezultatai*

		Tikrosios reikšmės	
		1	0
Modelio rezultatas	1	55	569
	0	8	380

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Modelio rezultatai gana stipriai skiriasi nuo tikrųjų reikšmių, teisingai klasifikuotų klientų skaičius yra 435, klaidingai – 577. Tai patvirtinta prielaidą apie teigiamo sprendimo priėmimo apimties skirtumus tarp automatizuotos sistemos ir žmogaus priimamų sprendimų. Išsamūs klientų klasifikavimo analizės rezultatai pateikiami 30 lentelėje.

## 30 lentelė

*Modelio charakteristikos – klasifikavimo patikimumo analizės rezultatai*

Vertinamas rodiklis	Rezultatas
Efektyvumas	$CCR = 0,4298$ $MCR = 0,5702$
Klaidingo klasifikavimo rizika	$\alpha = 0,1270$ $\beta = 0,5996$
Jautrumas	$Se = 0,8730$
Specifiškumas	$Sp = 0,4004$
Įsipareigojimų nevykdymo tikslumas	$PPV = 0,0881$
Įsipareigojimų vykdymo tikslumas	$NPV = 0,9794$


Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Kredito rizikos vertinimo modelis rodo, jog klasifikavimo efektyvumas yra gana žemas, teisingai klasifikuotų klientų dalis siekia 43,0%, neteisingai klasifikuotų įmonių dalis – 57,0%. Klaidingo klasifikavimo rizikos rodikliai  $\alpha$  ir  $\beta$ , atitinkamai, skirti I ir II rūšies klaidų vertinimui, rodo, kad 12,7% įsipareigojimų nevykdančių klientų yra priskiriama „gerų“ klientų grupei, o 60,0% patikimų klientų – prie įsipareigojimų nevykdančiųjų. Modelio jautrumas ir specifiškumas yra susiję su I ir II rūšies klaidomis. Šie dydžiai vertina kaip modelio statistinio klasifikavimo pajėgumus ( $1-\alpha$ ) ir ( $1-\beta$ ). Atitinkamai, nustatyta, jog modelio jautrumas yra 87,3%, o specifiškumas – 40,0%. Įverčiai demonstruoja gana aukštas modelio galimybes vengti neteisingo „blogų“ įmonių klasifikavimo, tačiau pateikia mažiau užtikrintą rezultatą dėl klientų, kurių įsipareigojimų nevykdymo atveju finansuotojas nefiksavo. Modelis pateikia 97,9% patikimų klientų klasifikavimo tikslumą.

Klasifikavimo rezultatų efektyvumą galima paaiškinti žmogaus priimtų sprendimų nuokrypiu nuo rizikos politikos gairių. Kredito rizikos vertinimo modelio, pagrįsto taisyklėmis, neatitikimai priimtam finansavimo sprendimui, aiškinami finansavimo sprendimo „atmesti“ paraišką priežasčių analize (21 priedas).

## 25 paveikslas

*Kredito rizikos vertinimo modelio paraiškų atmetimo priežastys (proc.)*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Analizuojant atmetimą kiekviename informacijos bloke (1012 atvejų), nustatyta, kad didžiausia dalis, t. y. 41,7% neigiamą sprendimą gavusių užklausų yra susijusios su finansinių ataskaitų duomenimis. Pripažįstama, jog finansinės atskaitomybės duomenų vertinimas gali būti apgaulingas, kai įvairūs rodikliai ir skirtingi dydžiai yra vertinami atskirai, todėl finansinių kintamųjų

vertinimas reikalauja kritinio požiūrio. Antras aukščiausias atmetimo lygis – 24,3% stebimas finansavimo pasiūlymo kategorijoje. Paraiškų atmetimo priežastys gali būti paaiškinamos užstato trūkumu, kainodaros neatitikimu, finansuojamos sumos dydžiu bei maksimalaus naujo limito apribojimais, jei netenkinami finansinių rodiklių duomenys. 15,5% paraiškų neatitinka priimtino bankroto reitingo reikalavimo. 10,5% atvejų neatitinka specialiųjų sąlygų pagal kredito tipą, pavyzdžiui, lizingo atveju – pirkimo kainos ir vidutinės rinkos kainos 20% paklaida, kuri paaiškinta 3.2 poskyryje. 10,0% nepatvirtintų atvejų yra susiję su klientų mokėjimų istorija.

Gautų rezultatų kontekste galima pastebėti viena kitai prieštaraujančių prielaidų – išvadų derinį, keletas iš jų pateikiami 31 lentelėje.

### 31 lentelė

#### *Modelio rezultatų analizė ir paaiškinimo galimybės*

<b>Prielaidos dėl modelio rezultatų</b>	<b>Rezultatų paaiškinimo galimybės</b>
Modelio atmetamų paraiškų lygis gali signalizuoti apie aukštą kredito riziką, nes didelė dalis klientų neatitinka kredito rizikos politikoje numatytų reikalavimų siekiant užtikrinant saugų finansavimą	Žmogiškieji sprendimai, remiantis racionalumo faktoriumi, gali įvertinti papildomus rizikos veiksnius, individualiai parenkant papildomas įsipareigojimo užtikrinimo sąlygas
Modelis yra pernelyg konservatyvus, nes atmeta daugiau nei pusę realiai patvirtintų atvejų, finansų įstaigai kliaujantis tik modelio sprendimu, prisiimant tik užtikrintą taisyklėmis rizikos laipsnį gali kilti finansinių problemų	Modelyje nustatytos taisyklės, kurios yra grindžiamos duomenų iš patikimų informacijos šaltinių prieinamumu ir nuokrypiu nuo rizikos politikos gairių, asmeninės informacijos spragoms užpildyti reikalingas žmogaus indėlis, kad „geri“ klientai būtų aptarnaujami
Modelis yra sukurtas specialiai „idealių“ atvejų „praleidimui“, siekiant užtikrinti visišką atitikimą kredito rizikos politikos taisyklėms	Modelis negali įvertinti unikalių situacijų, pagrindinis modelio privalumas – atitiktis esminiams finansuotojo keliamiems reikalavimams

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Modelis atskleidžia prieštarigus vertinimo rezultatus, kurie demonstruoja galimą finansuotojo veiklos riziką, nustatytų taisyklių atžvilgiu, kai neįvertinami žmogiškojo racionalumo veiksniai, konservatyvumas dėl atmetų paraiškų kiekio grindžiamas patikimos informacijos prieinamumu, o visiško atitikimo išskeltiems reikalavimas nustatymas argumentuojamas nestandartinių situacijų egzistavimu. Modelis negali įvertinti, kodėl nagrinėjama atvejais buvo priimti teigiami analitiko sprendimai, tačiau tai gali būti paaiškinama informacijos, kurios neapėpia modelio vertinimo kriterijai, stygiumi. Pirmiausiai, neįtraukta informacija, kliento požiūriu, gali būti itin jautri, nes ji yra susijusi su asmeniniais duomenimis. Tai lemia į modelį įtrauktos juridinės

informacijos pasirinkimą, nes fizinių asmenų, pavyzdžiui, akcininkų ir vadovų, patikrą riboja asmens duomenų apsauga<sup>22</sup> (Lietuvos Respublikos seimas, 2023). Fizinio asmens duomenų patikrai atlikti numatomas reikalavimas gauti raštišką sutikimą dėl duomenų tikrinimo.

Kredito rizikos analitiko patvirtintų paraiškų atitikties vertinimas modelio sprendimų atžvilgiu, leidžia identifikuoti, jog papildomos užtikrinimo priemonės priimant sprendimą apėmė 78,6% visų patvirtintų paraiškų. Išsamus modelio ir žmogiškųjų sprendimo priėmimas pateikiamas 22 priede.

### 32 lentelė

#### *Papildomų įsipareigojimo užtikrinimo priemonių taikymas*

Modelio sprendimas	Įsipareigojimų nevykdymo atvejai   proc.	Įsipareigojimų vykdymo atvejai   proc.	Visos patvirtintos paraiškos   proc.
Teigiamas	37,5	53,2	52,8
Neigiamas	100,0	94,0	94,6
Iš viso:	92,1	77,7	78,6

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Nustatyta, jog sprendimų dėl kredito suteikimo priėmimo metu, įsipareigojimų nevykdymo atvejais, kai modelis suteikia paraiškai atmetimo statusą, 100,0% paraiškų buvo patvirtintos su papildomomis sąlygomis, įsipareigojimų vykdymo grupėje – 94,0%. Taigi, žmogiškojo racionalumo faktorius rodo, kad neigiamo modelio sprendimas gali būti paaiškinamas individualiai pritaikytomis kredito sąlygomis. Tokiomis sąlygomis gali būti laikomos šios priemonės: įmonės vekselis<sup>23</sup>, laidavimo sutartis<sup>24</sup>, subordinavimo sutartis<sup>25</sup> ir kitos su įsipareigojimų užtikrinimu susijusios priemonės.

<sup>22</sup> 2016 m. balandžio 27 d. Europos Parlamento ir Tarybos reglamentas (ES) 2016/679 dėl fizinių asmenų apsaugos tvarkant asmens duomenis ir dėl laisvo tokių duomenų judėjimo ir kuriuo panaikinama Direktyva 95/46/EB (Bendrasis duomenų apsaugos reglamentas) ir jo įgyvendinimo teisės aktai.

<sup>23</sup> Vekselis, kaip vertybinis popierius, – tai dokumentas, kuriuo jį išrašantis asmuo be išlygų įsipareigoja tiesiogiai ar netiesiogiai sumokėti tam tikrą pinigų sumą vekselyje nurodytam asmeniui arba kuriuo tai padaryti pavedama kitam asmeniui. Šaltinis: Lietuvos Respublikos civilinis kodeksas. Pirmoji knyga. Bendrosios nuostatos. 1.105 str.

<sup>24</sup> Laidavimo sutartimi laiduotojas už atlyginimą ar neatlygintinai įsipareigoja atsakyti kito asmens kreditoriui, jeigu tas asmuo, už kurį laiduojama, neįvykdys visos ar dalies savo prievolės. Šaltinis: Lietuvos Respublikos civilinis kodeksas. Šeštoji knyga. Prievolių teisė. 6.76 str.

<sup>25</sup> Paskolos sutartyje nustatyta, kad paskolos gavėjo likvidavimo arba bankroto atveju paskolos davėjo reikalavimas pagal paskolos sutartį bus tenkinamas tik patenkinus kitų paskolos gavėjo kreditorių reikalavimus. Šaltinis: Vainienė, R. „Ekonomikos terminų žodynas“. Verslo žinios.

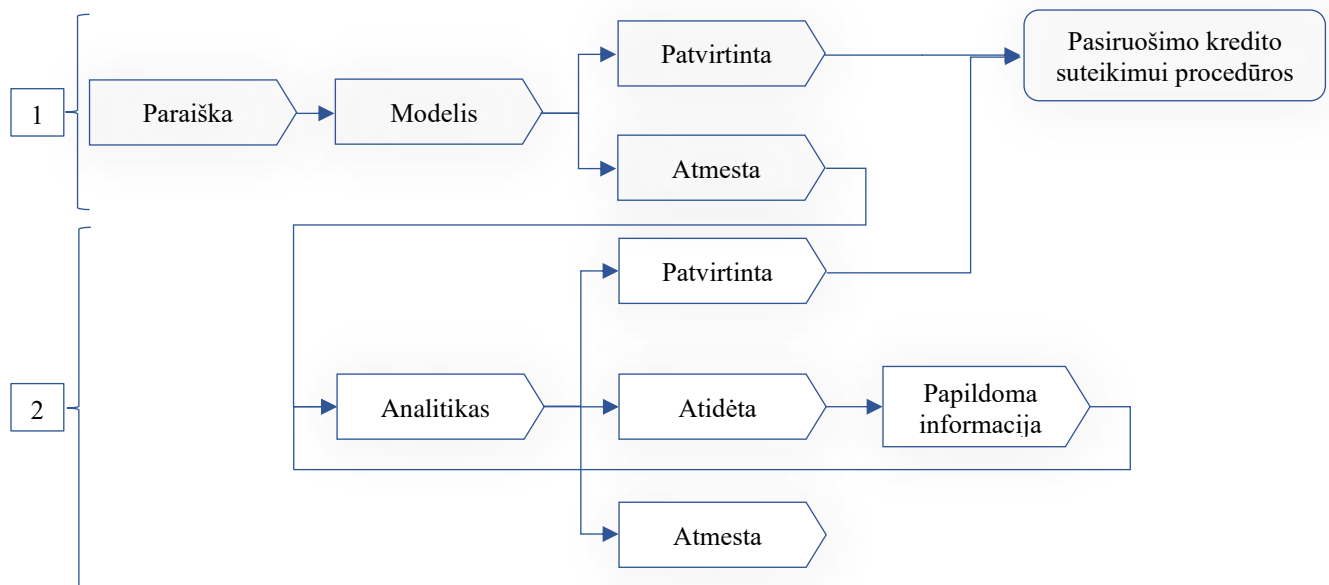


Kredito rizikos modeliai, nepaisant jų tikslingumo, turi tam tikrų ribojimų, susijusių su galimybėmis adaptuotis prie unikalių situacijų. Pritaikymo konkrečiai veiklai svarba yra nepaprastai aukšta, nes tai tiesiogiai veikia modelio veiksmingumą ir naudingumą organizacijai. Veiklos konteksto analizė padeda identifikuoti svarbiausius veiksnius ir parametrus, kurie gali būti koreguojami pagal finansinių paslaugų teikėjo poreikius.

Žmogiškųjų ir automatizuotų sprendimų skirtumų vertinimas yra būtina analizės dalis, lemianti modelio pritaikymo galimybes ir jo paskirtį finansavimo veikloje. Sprendimų priėmimas, kuris reikalauja žmogaus įsikišimo paraiškos vertinimo procese neretai susijęs su sudėtingumu ir subjektyviais vertinimo kriterijais. Automatizuotos sistemos naudojimas sprendimų priėmimo procese grindžiamas objektyviais algoritmais ir numatytomis taisyklėmis, kurios leidžia greičiau ir efektyviau priimti sprendimus, atsižvelgiant į skirtingus kriterijus. Sistema, pasižyminti objektyvumu, negali būti paveikta emocijų ar subjektyvaus vertintojo nuojautos bei visus klientus vertina vienodai, atsiribodama nuo šališkumo, remiantis kriterijais, kurie identifikuoja jiems priskirtą rizikos lygį. Atlikti analizės rezultatai rodo, jog daugiau nei 50% visų modelio atmetų paraiškų buvo patvirtintos kredito rizikos analitiko, tačiau įvertinus žmogiškojo racionalumo būtinybę, modelis laikomas įspėjamąja priemone, identifikuojančia galimus neatitikimus ir potencialius rizikos faktorius. Tai įrodo, jog modelio naudojimas finansų įstaigoje turėtų būti pirminis vertinimo šaltinis.

## 26 paveikslas

*Sprendimų priėmimo transformacija su modelio integracija alternatyvaus finansuotojo veikloje*



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

Kintamasis, kuris skiria žmogiškuosius sprendimus nuo automatinio vertinimo yra „atidėti“ sprendimą veiksny, kuris dažnu atveju kyla dėl potencialių neaiškumų, analitiko supratimu trūkstamos informacijos poreikio arba kitų priežasčių. Šis žmogiškasis vertinimas yra apribotas subjektyvumo ir individualios nuovokos, kuri gali veikti sprendimo priėmimo procesą pirminiame vertinimo etape. Automatizuotos sistemos turi pranašumų užtikrinant tikslumą, greitį bei objektyvumą, jos leidžia įvertinti atitiktį integruotoms taisyklėm ir didinti apibendrinimo galimybes. Atsižvelgiant į patikimų klientų klasifikavimo tikslumą (97,9%), pirmajame etape, pasitelkiant modelio pagalbą, patvirtinta paraiška nereikalauja žmogaus indėlio. Nors modelio jautrumo rodiklis (87,3%) demonstruoja patikimą klaidingo klasifikavimo tarp „blogų“ klientų vengimo lygį, klaidingo klasifikavimo tarp patikimų klientų rodiklis (60,0%) rodo, jog dauguma „gerų“ klientų priskiriami įsipareigojimų nevykdymo grupei, todėl automatizuota kredito rizikos vertinimo, orientuoto į sprendimų priėmimą, sistema gali būti perduota peržiūrai tais atvejais, kai sprendimas yra neigiamas. Antrasis etapas leidžia identifikuoti specifinius atvejus, kurie gali reikalauti papildomo vertinimo. Šiame etape – žmogiškasis indėlis efektyviai koordinuoja sprendimo priėmimo procesą, todėl paraiškos atmetimas modelyje gali būti laikomas įspėjamuoju signalu apie prieinamos kliento informacijos ir pasiūlymo sąlygų neatitikimus alternatyvaus finansuotojo kredito rizikos vertinimo politikai.

Apibendrinant, galima teigti, jog kredito rizikos vertinimas yra kompleksiškas kliento duomenų apdorojimas, siekiant identifikuoti visus įmanomus kredito rizikos veiksnius. Automatinį kredito rizikos vertinimo sistemų diegimas finansinių paslaugų teikėjams leidžia objektyviau valdyti potencialias rizikas ir greičiau priimti sprendimus. Kredito rizikos vertinimo aspektu, sprendimų priėmimo modelio taikymas pirmajame pareiškėjų vertinimo etape didina objektyvumo poveikį ir mažina klaidų tikimybę, o žmogiškojo vertinimo poreikis antrajame etape atsiranda dėl sudėtingesnių ir (ar) unikalių atvejų, kai vertinimui reikalingas papildomas kontekstas. Pagrindine išvada laikoma tai, jog dinamiška aplinka visapusiškai nepakeis žmogiško indėlio, tačiau toks kredito rizikos vertinimo modelis finansų įstaigoje reikšmingai prisideda prie sprendimų priėmimo kokybės gerinimo.

## IŠVADOS IR PASIŪLYMAI

Šis magistro baigiamasis darbas ir jo rezultatai, teoriniu ir praktiniu požiūriu, gali būti vertingi akademinės bendruomenės ir verslo sektoriui. Remiantis nustatytu darbo tikslu ir uždaviniais, pateikiamos pagrindinės **išvados**:

1. Kredito rizika mokslinėje literatūroje bendrai siejama su finansinių įsipareigojimų neįvykdymo rizika, galinčia reikšmingai prisidėti prie skolinimo veikla užsiimančių organizacijų patiriamų nuostolių. Nustatyta, jog pabrėžiant „gerų“ ir „blogų“ pareiškėjų atskyrimo svarbą, išryškinama klientų klasifikavimo problema, kuri lemia sprendimo dėl potencialaus kliento finansavimo priėmimą. Kredito rizikos analizė yra laikoma daugialype problema, nes daugybė rizikos formų ir didelis informacijos bei duomenų kiekis apsunkina vertinimo procesą. Įvertinta, kad kredito rizikos tyrimų rezultatai prisideda prie finansų įstaigų rizikos prevencijos ir kontrolės galimybių stiprinimo bei įsipareigojimų neįvykdymo tikimybės identifikavimo gerinimo, siekiant palaikyti stabilią finansuotojų veiklą.
2. Literatūroje, kredito rizikos vertinimo teoriniu aspektu, plačiausiai išskiriamos statistinių, struktūrinių, dirbtinio intelekto ir hibridinių modelių grupės. Modeliai, vertinantys atskirus komponentus skiriasi pagal sritis, kurias jie analizuoja. Dėl mokslo ir technologijos pažangos kredito rizikos vertinimo modeliai išlieka plačia nagrinėjimo sritimi, tačiau kiekvienas šių modelių remiasi skirtingais metodais, kurie turi privalumų ir trūkumų, todėl bendro požiūrio apie optimalią tikslų modelių kūrimo techniką nėra. Nustatyta, kad pagrindinė „gero“ modelio prielaida yra tikslumo ir rezultatų paaiškinamo derinys. Akademinėje visuomenėje vyrauja nuomonė apie konceptualios sistemos trūkumą derinant skirtingus metodus, to pasekmė – susidūrimas su dviprasmiškumu vertinant, kuris modelis pasiekė didesnę tikslumo lygį. Tai lemia svarbą atsižvelgti į modelio tikslą, pritaikymą ir rezultatų paaiškinimo galimybes.
3. Remiantis pateikta Europos Komisijos rekomendacija dėl mažų ir labai mažų įmonių sampratos, nustatyta, jog Europos Sąjungoje ir Lietuvoje smulkus verslas sudaro reikšmingą dalį ekonomikos struktūroje, kas atspindi šio verslo dominavimą. Atsižvelgiant į naujausius pastarųjų metų ekonominio poveikio veiksnius, turinčius įtakos verslo aplinkai, identifiukuota bankinio finansavimo neprieinamumo problema, kuri siejama su nemotyvuotu kredito įstaigos atsisakymu, prasta įmonės finansine būkle bei bendra ekonomine padėtimi. Įvertinta, jog, nepaisant tam tikrų sunkumų, 2021 m. ir 2022 m. Lietuvoje didėja tenkinamų finansavimo

paraiškų dalis, tačiau daugiausiai – kai sąlygos yra koreguojamos kreditoriaus. Atmetamų paraiškų mažėjimas vaizduoja didėjančią stabilumą, tačiau alternatyvių finansavimo šaltinių analizės poreikis yra būtinas dėl klientų, kuriems tradicinio finansavimo forma yra neprieinama.

4. Nustatyta, jog smulkus verslas yra svarbi socialinio ir ekonominio vystymosi sudedamoji dalis, daugiausia dėl jų indėlio skatinant verslumą, inovacijas ir užimtumą. Mokslinėje literatūroje mažos ir labai mažos įmonės vis dar daugiausiai vertinamos grupėje – kaip MVI subjektai. Nagrinėjant su kreditavimu susijusius iššūkius, pasireiškiančius smulkaus ir vidutinio verslo sektoriuje, identifikuota, jog pagrindinės kreditavimo problemų priežastys daugiausiai yra susijusios su išskirtinėmis mažų ir labai mažų įmonių savybėmis – jautrumu išoriniams aplinkos veiksniams, finansinių ataskaitų patikimumu ir verslo įrašų trūkumu. Vertinimo apribojimai lemia kreditavimo iššūkius, o tokiais atvejais finansuotojai yra linkę šias problemas spręsti taikant didesnę palūkanų normą bei aukštesnius užstato reikalavimus.
5. Vertinimo metodai, finansavimo sprendimo kontekste, yra lemiamas veiksnys dėl efektyvumo ir kredito rizikos optimizavimo. Tikima, jog didelio susidomėjimo akademinėje visuomenėje sulaukę dirbtinio intelekto modeliai gali integruotis įmonės veikloje dalinai pakeičiant kasdinių užduočių atlikimą. Nustatyta, kad pažangių technologijų vystymasis sukuria terpę automatizuoti kredito sprendimų priėmimą, tačiau tinkamų metodų pasirinkimas svarstant galimybę taikyti kredito rizikos modelius realioje finansų aplinkoje kelia abejonių dėl dirbtinio intelekto modelių formavimo ir rezultatų. Tai grindžiama skirtingais metodais, kurie ne visada veikia realiame pasaulyje. Siekiant optimalumo, privaloma integruoti skaidrias sistemas, kurių veikimas yra paaiškinamas ir nustatomas pagal konkrečius verslo poreikius, tačiau tai nereiškia, jog žmogiškojo racionalumo veiksniai turi būti visiškai pašalinti.
6. Remiantis atlikta literatūros analize, empirinio tyrimo tikslui pasiekti pasirinkta naudoti taisyklėmis pagrįstą metodą. Metodo pasirinkimas grindžiamas sutapimu su paaiškinamumu, lengvu įgyvendinimu ir priežiūra, suderinamumu su žmogiškąja patirtimi bei efektyvumu su skirtingu duomenų kiekiu. Tyrimas atliekamas naudojant alternatyvaus finansuotojo, veikiančio Lietuvoje, klientų duomenis per kalendorinius metus (2022 m.). Tyrimo eiga suskirstyta į 4 etapus, apimančius 6 vertinimo aspektus. Pasirinktiems kategoriniams kintamiesiems taikomas Chi-kvadrato testas, siekiant pagrįsti tarp kintamųjų egzistuojančius statistinius ryšius. Tyrimo pagrindiniais apribojimais išskiriama tai, jog modelis nėra

universalus, yra eksperimentinio pobūdžio ir gali reikalauti papildomo įsikišimo dėl MVI subjektyvumo.

7. Atlikus pareiškėjų atvejo analizę, nustatyta, jog skirtingi duomenys atskleidžia visapusišką informaciją apie kliento profilį. Duomenys rodo, kaip į skirtingą informaciją reaguoja sprendimus priimantis asmuo. Įvertinta, jog didžiąją dalį atmestų paraiškų lemia pradesti mokėjimai finansinėms institucijoms, su bankrotu ir (ar) nemokumu bei įregistruotais turto areštais susijusi informacija. Tarp patvirtintų paraiškų, daugiau nei pusė įsipareigojimų nevykdymo atvejų siejama su teigiamu sprendimo priėmimu, kai netinkamai įvertinta klientų mokėjimų istorija, neatsižvelgta į išorinį bankroto reitingą, neteisingai įvertinti finansinių ataskaitų duomenys.
8. Atsižvelgiant į pareiškėjų klasifikavimo analizės rezultatus, klientų skirstymas į „gerus“ ir „blogus“ galimas 3 skirtingais būdais – pagal bankroto reitingą, mokėjimų istoriją ir įsipareigojimų nevykdymo atvejus. Identifikuota, jog klientų charakteristikos, juos vertinant kaip visumą, pagal šiuos rodiklius sprendimo priėmimo dieną, rodė žemą rizikos lygį. Nustatyta, jog klientų klasifikavimo statistinio reikšmingumo rezultatai yra abejotini, o statistiškai reikšminga priklausomybė siejama su bankroto reitingo ir vieno juridinės informacijos bei dviejų mokėjimų istorijos kintamaisiais. Papildomai atlikta 4 mėnesių esamų klientų monitoringo ataskaitos analizė įrodo, jog dinamiškiausi pokyčiai pastebimi pateikiama pagal reikšmingumą seka: mokėjimų istorijos, neigiamos informacijos, finansinių ataskaitų duomenų, juridinės informacijos, išorinio reitingo ir kitos informacijos duomenų blokuose.
9. Įvertinus keliamų pagal kredito rizikos vertinimo gaires sąlygų ir sprendimų sąveiką, duomenų pagal informacijos tipą segmentams pritaikomas taisyklėmis pagrįstas metodas. „Jeigu – tai“ taisyklės nurodo kliento ir pasiūlymo informacijos atitiktį kredito rizikos politikai. Duomenų pagal informacijos pobūdį rezultatas klasifikuojamas į kategorinius, „taip“ ir „ne“ reikšmes įgyjančius, kintamuosius. Suformuotas kredito rizikos vertinimo modelis „viskas arba nieko“ principu, užtikrina loginį įvesties-išvesties ryšio paaiškinamumą, kuris reiškia kliento ir pasiūlymo informacijos charakteristikų sutaptį su visišku atitikimu finansuotojo požiūriu „tinkamai“ nustatytoms taisyklėms. Duomenų validacijos procesas užtikrina klaidų ir iškreipimų panaikinimą ir užtikrina duomenų formato atitikimus perkeltus į automatizuotą aplinką, kurioje modelis suteikia sprendimą dėl kredito suteikimo.
10. Modelio rezultatai atskleidžia, jog neatitikimų žmogiškiesiems sprendimams įvertinimas, remiantis taisyklėmis pagrįstu metodu, padeda išlaikyti balansą tarp modelio teikiamų

privalumų ir trūkumų. Modelio rezultatai 67,5% atmetamų paraiškų, išreikštų visų teigiamą sprendimo statusą įgijusių paraiškų, analitiko priimtų sprendimų atžvilgiu, procentine dalimi. Įvertintas modelio sprendimo ir įsipareigojimų nevykdymo kintamųjų statistinis ryšys leidžia identifikuoti vieną stipriausių modelio savybių – įsipareigojimų nevykdymo atvejų atpažinimą, kuris siekia 87,3%. Tai patvirtina iškeltas hipotezes, kuriose numatyta, jog žmogaus priimami teigiami sprendimai dėl kredito suteikimo savo apimtimi skiriasi nuo modelio pateiktų rezultatų, modelis geba paaiškinti sprendimą pagal skirtingas klientų charakteristikas, tačiau neatpažįsta visų įsipareigojimo nevykdymo atvejų. Pagrindine išvada laikoma tai, kad įsipareigojimų nevykdymo atpažinimo tikimybė yra aukšta, tačiau modelis atmeta daug paraiškų, kurios nefiksuoja įsipareigojimų nevykdymo atvejų.

11. Modelio charakteristikų, naudojant klientų klasifikavimo matricą, analizė parodo modelio patikimumo galimybes teisingai įvertinti paraiškų statusą. Nustatyta, jog modelio klasifikavimo efektyvumas yra žemas, teisingai klasifikuotų klientų dalis – 43,0%, klaidingai 57,0%. Priešingi dydžiai klaidingo klasifikavimo  $\alpha$  ir  $\beta$  rodikliams, kurie yra skirti I ir II rūšies klaidų identifikavimui, vertinami kaip modelio klasifikavimo jautrumas (87,3%) ir specifiškumas (40,0%), atskleidžia, jog modelis vengia neteisingo nepatikimų kliento klasifikavimo, tačiau aukšta „gerų“ klientų grupės dalis priskiriami prie įsipareigojimų nevykdymo atvejų. Modelis atskleidžia aukštą tikslumo rodiklį įsipareigojimų vykdančiųjų grupėje (97,7%).
12. Identifikuota, jog kredito rizikos vertinimo modelio neatitikimai žmogaus sprendimams yra kredito rizikos politikos taisyklių nesilaikymo rezultatas. Nustatyta, jog aukštas paraiškų atmetimo lygis, modelio konservatyvumo prielaida bei „idealių“ taisyklių nustatymas grindžiamas žmogiškojo racionalumo faktoriumi priimant sprendimus, dalinai tenkinančius finansavimo užklauso prašymą, informacijos spragų užpildymu, kad patikimi klientai būtų aptarnauti bei specifinių situacijų, kurių modelis negali įvertinti, atsiradimu. Įvertinta, jog didžiausios dalies atmetų paraiškų rezultatas – mažų ir labai mažų įmonių finansinės atskaitomybės neatitikimai (41,7%) finansuotojo rizikos „apetito“ požiūriu, kuris patvirtina teorinės analizės rezultatus dėl MVĮ finansinės atskaitomybės subjektyvumo, trūkstamų duomenų ir (ar) smulkaus verslo ekonominės galios išnykimo, kai įmonės vertinamos pavieniui.
13. Nustatyta, jog kredito rizikos vertinimo modelio, orientuoto į sprendimų priėmimą, mažoms ir labai mažoms įmonėms, neigiamo sprendimo atžvilgiu įsipareigojimų nevykdymo atvejais,

analitiko teigiamas sprendimas yra paremtas papildomų įsipareigojimo užtikrinimo priemonių taikymu visiems teisingai klasifikuotiems nepatikimiems klientams (100,0%) ir neteisingai klasifikuotų patikimų klientų (94,0%) atžvilgiu. Taisyklėmis pagrįsta sprendimų priėmimo sistema pasižymi tikslumu klasifikuojant patikimus klientus, atitiktis kredito rizikos politikai nustatymu, objektyvumu atpažįstant neatitikimus finansuotojo strategijoje, aukštomis apibendrinimo galimybės vertinant skirtingus informacijos segmentus. Kliento informacija, kuri apsiriboja teisiniais suvaržymais, integracija yra negalima, tačiau žmogiškasis indėlis yra nepakeičiamas.

14. Atliktas žmogiškųjų ir automatizuotų sprendimų skirtumų vertinimas atskleidžia, jog integracija nagrinėtoje finansų įstaigoje, remiantis pirminiu modelio sprendimu patvirtintų paraiškų kategorijoje, gali reikšmingai prisidėti prie teigiamo poveikio sprendimų priėmimui ir klaidų tikimybės mažinimo. Nustatyta, jog prižiūrint ir stebint kredito rizikos vertinimo modelį galima užtikrinti, kad jis atitiktų naujausius verslo ir finansų aplinkos pokyčius, priklausomai kuriame vertinimo etape modelis yra naudojamas.

Atsižvelgiant į darbe iškeltų teorinių ir praktinių sprendimų kontekstą, pateikiami tokie **pasiūlymai**:

*Teoriniame lygmenyje rekomenduojama:*

1. Plačiau nagrinėti kredito rizikos vertinimo duomenis, daugiau dėmesio skirti kokybinės informacijos modeliavimo svarbai ir duomenų prieinamumo šalyje klausimams. Tokia informacija gali atskleisti subtilius rizikos veiksnius, kurie gali likti nepastebėti analizuojant tik kiekybinius rodiklius.
2. Išplėsti požiūrį į išskirtinai smulkaus verslo specifiką, vengiant apibendrinimų ar jungimų į grupes. Stebint augantį labai mažų įmonių skaičių, Lietuvos kontekste šis požiūris tampa itin reikšmingas. Akcentuojant smulkaus vietinio verslo dinamiką, struktūrinius bruožus ir unikalius iššūkius gali būti skatinamas suvokimas apie verslo sąveiką su ekonominiais, socialiniais ir teisiniais veiksniais ir kokiais būdais jis gali būti optimizuojamas.
3. Skatinti išorinio finansavimo spragų analizavimą tiek nacionaliniu, tiek tarptautiniu lygiu, kad esminiai skirtumai būtų tinkamai identifikuoti. Analizuojant šias spragas, nustatyti šalies specifikos, ekonominiai bei politiniai veiksniai gali paveikti išorinio finansavimo galimybes ir sąlygas. Įvertinus tarptautinėse rinkose dominuojančius veiksnius, palyginamoji analizė galėtų prisidėti prie pozicijų stiprinimo tarptautinėje erdvėje.

4. Daugiau dėmesio skirti nebankinio finansavimo sektoriaus dalyviams. Alternatyvūs finansuotojai, papildantys tradicinės bankininkystės struktūrą, tačiau neprižiūrimi Lietuvos banko, gali turėti skirtingas kredito suteikimo praktikas ir reikalavimus, todėl kredito rizikos vertinimo kontekste, svarbu išanalizuoti su kredito sąlygomis, finansavimo suteikimu ir sprendimo priėmimu susijusias strategijas ir poveikį finansų rinkoms bei vartotojams.

*Praktiniu požiūriu rekomenduojama:*

1. Analizuoti finansų rinkos dalyvių įvairovę ir skirtumus, kas leistų praktiniais pavyzdžiais pagilinti suvokimą apie rinkos dinamiką ir veiksnius, kurie gali paveikti jų elgesį ir sprendimus. Įvertinant skirtingų dalyvių, tokių kaip bankai, nebankinės finansų institucijos strategijas, prioritetus ir rizikos toleranciją, galima atskleisti kaip skirtingi rinkos dalyviai reaguoja į pokyčius. Šių tendencijų supratimas gali padėti efektyviau prognozuoti rinkos tendencijas, identifikuoti potencialias problemas ir sukurti strategijas, kurios atitiktų skirtingų dalyvių poreikius bei tikslus.
2. Nagrinėti realias verslo tendencijas, kurios demonstruoja žmogaus sprendimų priėmimo procesą ir modelių elgsenos skirtumus. Tai įrodo, kuriais atvejais modeliai ir žmonės linke reaguoti skirtingai į panašias ar identiškąs situacijas. Remiantis šiais atvejais nauja tyrimų sritis gali tapti žmogaus patirties ir kognityvinių įpročių palyginimas. Tokie tyrimai leistų atskleisti, kokiose situacijose žmogaus sprendimai būtų nepakankami ar netinkami, palyginti su modelio sprendimais, ir kokiais būdais galima optimizuoti abiejų sąveiką siekiant geresnių rezultatų.
3. Nagrinėjamos finansų įstaigos analitikams rekomenduojama intensyviau analizuoti atmetų paraiškų vertinimą, sutelkiant dėmesį į statistinius rodiklius, lemiančius paraiškos atmetimą ir potencialius išsipareigojimų nevykdymo atvejus ateityje. Ši informacija gali būti vertinga ne tik modelio tobulinimui, tačiau gali atskleisti srities netikslumus, padėdami optimizuoti finansinius sprendimus ir gerinti bendrą rizikos vertinimo bei valdymo procesą.
4. Naudoti modelius realioje aplinkoje. Šie vertinimo įrankiai turi būti pritaikyti pagal verslo specifiką bei nustatyti, kuriame kredito rizikos vertinimo etape bus naudojami, todėl svarbu atsižvelgti į jų potencialą bei tobulinimo sritis. Modeliai, net su savo apribojimais, gali pateikti pradinę informacijos rinkinį, todėl gali būti pritaikomi tolimesnei analizei ar žmogaus intervencijai.



## LITERATŪROS IR ŠALTINIŲ SĄRAŠAS

- Abdou, H. A. & Pointon, J. (2011). Credit scoring, statistical techniques and evaluation criteria: a review of the literature. *Intelligent Systems in Accounting, Finance and Management*, 18(2-3), 59–88. Prieiga internetu: <https://doi.org/10.1002/isaf.325>
- Abraham, F., & Schmukler, S. L. (2017). Addressing the SME finance problem. *World Bank Research and Policy Briefs*. Prieiga internetu: <https://ssrn.com/abstract=3249560>
- Akwaa-Sekyi, E. K., & Moreno, G. J. (2017). *Internal controls and credit risk relationship among banks in Europe. Intangible Capital*, 13(1), 25–50. Prieiga internetu: <https://doi.org/10.3926/ic.911>
- Alam, P., Hettler, B. & Gao, H. (2020). Accounting downside risk measures and credit spreads. *Review of Accounting and Finance*, 20(1), 103–120. Prieiga internetu: <https://doi.org/10.1108/RAF-08-2020-0244>
- Arora, N. & Kaur, P. D. (2020). A Bolasso based consistent feature selection enabled random forest classification algorithm: An application to credit risk assessment. *Applied Soft Computing*, 86, 105936. Prieiga internetu: <https://doi.org/10.1016/j.asoc.2019.105936>
- Aziz, S. & Dowling, M. (2019). Machine Learning and AI for Risk Management. In T. Lynn, G. Mooney, P. Rosati, & M. Cummins (eds.), *Disrupting Finance: FinTech and Strategy in the 21st Century*, Palgrave, 33–50. Prieiga internetu: [https://doi.org/10.1007/978-3-030-02330-0\\_3](https://doi.org/10.1007/978-3-030-02330-0_3)
- Bakhtiari, S., Breunig, R. V., Magnani, L. & Zhang, J. (2020). Financial Constraints and Small and Medium Enterprises: A Review. *Economic Record*, 96(315), 506–523. Prieiga internetu: <https://doi.org/10.1111/1475-4932.12560>
- Bao, W., Lianju, N., & Yue, K. (2019). Integration of unsupervised and supervised machine learning algorithms for credit risk assessment. *Expert Systems with Applications*, 128, 301–315. Prieiga internetu: <https://doi.org/10.1016/j.eswa.2019.02.033>
- Belás, J., Smrcka, L., Gavurova, B., & Dvorský, J. (2018). The impact of social and economic factors in the credit risk management of SME. *Technological and Economic Development of Economy*, 24(3), 1215–1230. Prieiga internetu: <https://doi.org/10.3846/tede.2018.1968>
- Bhattacharya, A., Biswas, S. K., & Mandal, A. (2023). Credit risk evaluation: a comprehensive study. *Multimedia Tools and Applications*, 82, 18217–18267. Prieiga internetu: <https://doi.org/10.1007/s11042-022-13952-3>
- Błach, J., Wiczorek-Kosmala, M., & Trzęsiok, J. (2020). Innovation in SMEs and Financing Mix. *Journal of Risk and Financial Management*, 13(9), 206. Prieiga internetu: <https://doi.org/10.3390/jrfm13090206>

- Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2021). Explainable Machine Learning in *Credit Risk Management*. *Computational Economics*, 57, 203–216. Prieiga internetu: <https://doi.org/10.1007/s10614-020-10042-0>
- Carvalho, P. V., Curto, J. D., & Primor, R. (2022). Macroeconomic determinants of credit risk: Evidence from the Eurozone. *International Journal of Finance and Economics*, 27(2), 2054–2072. Prieiga internetu: <https://doi.org/10.1002/ijfe.2259>
- Chai, N., Wu, B., Yang, W., & Shi, B. (2019). A Multicriteria Approach for Modeling Small Enterprise Credit Rating: Evidence from China. *Emerging Markets Finance and Trade*, 55(11), 2523–2543. Prieiga internetu: <https://doi.org/10.1080/1540496X.2019.1577237>
- Chatterjee, S., Corbae, D., Dempsey, K., & Ríos-Rull, J. V. (2023). A Quantitative Theory of the Credit Score. *Econometrica*, 91(5), 1803–1840. Prieiga internetu: <https://doi.org/10.3982/ECTA18771>
- Chit, M. M. (2019). Financial Information Credibility, Legal Environment, and SMEs' Access to Finance. *International Journal of the Economics of Business*, 26(3), 329–354. Prieiga internetu: <https://doi.org/10.1080/13571516.2019.1645379>
- Ciampi, F., Giannozzi, A., Marzi, G. & Altman, E. I. (2021). Rethinking SME default prediction: a systematic literature review and future perspectives. *Scientometrics* 126, 2141–2188. Prieiga internetu: <https://link.springer.com/article/10.1007/s11192-020-03856-0#citeas>
- Civelek, M., Ključnikov, A., Krištofík, P., & Rozsa, Z. (2019). Barriers in financing microenterprises from the perspective of Czech and Slovak microentrepreneurs. *Journal of Business Economics and Management*, 20(2), 244–267. Prieiga internetu: <https://doi.org/10.3846/jbem.2019.8114>
- Coenen, L., Abdullah, A. K. A., & Guns, T. (2020). Probability of default estimation, with a reject option. *2020 IEEE 7th International Conference on Data Science and Advanced Analytics (DSAA)*, 439–448. Prieiga internetu: <https://doi.org/10.1109/DSAA49011.2020.00058>
- Davulis, G. (2013). Smulkusis ir vidutinis verslas Lietuvoje ir jo makroekonominis efektyvumas. *Journal of management*, 22(1), 19–29. Prieiga internetu: [https://www.ltvk.lt/file/zurnalai/03\\_Davulis.pdf](https://www.ltvk.lt/file/zurnalai/03_Davulis.pdf)
- Di Bella, L., Katsinis, A., Lagüera-González, J., Odenthal, L., Hell, M., & Lozar, B. (2023). Annual Report on European SMEs, 2022/2023. *Publications Office of the European Union, Luxemburg*. <https://doi.org/10.2760/028705>
- Doan, A. E. (2005). Type I and Type II Error. *Encyclopedia of Social Measurement*, 883–888. Prieiga internetu: <https://doi.org/10.1016/B0-12-369398-5/00110-9>
- Dolfin, M., Knopoff, D., Limosani, M., & Xibilia, M. G. (2019). Credit Risk Contagion and Systemic Risk on Networks. *Mathematics*, 7(8), 713. Prieiga internetu: <https://doi.org/10.3390/math7080713>
- dos Reis, G., Pfeuffer, M., & Smith, G. (2020). Capturing model risk and rating momentum in the estimation of probabilities of default and credit rating migrations. *Quantitative Finance*, 20(7), 1069–1083. Prieiga internetu: <https://doi.org/10.1080/14697688.2020.1726439>

- Dvorský, J., Schönfeld, J., Kotaskova, A., & Petráková, Z. (2018). Evaluation of important credit risk factors in the SME segment. *Journal of International Studies*, 11(3), 204–216. Prieiga internetu: <https://doi.org/10.14254/2071-8330.2018/11-3/17>
- Eggers, F. (2020). Masters of disasters? Challenges and opportunities for SMEs in times of crisis. *Journal of Business Research*, 116, 199–208. Prieiga internetu: <https://doi.org/10.1016/j.jbusres.2020.05.025>
- European Commission, Directorate-General for Internal Market, Industry, Entrepreneurship and SMEs. (2015). *MVĽ apibrėžties vartotojo vadovas*. Publications Office. Prieiga internetu: <https://data.europa.eu/doi/10.2873/95635>
- Eurostat. (2023a). *Business demography by size class and NACE Rev. 2 activity*. Žiūrėta 2023-09-06. Prieiga internetu: [https://ec.europa.eu/eurostat/databrowser/view/bd\\_size/default/table?lang=en&category=bsd\\_bd](https://ec.europa.eu/eurostat/databrowser/view/bd_size/default/table?lang=en&category=bsd_bd)
- Eurostat. (2023b). *Business demography by size class and NACE Rev. 2 activity (2004-2020)*. Žiūrėta 2023-09-06. Prieiga internetu: [https://ec.europa.eu/eurostat/databrowser/view/BD\\_9BD\\_SZ\\_CL\\_R2/default/table?lang=en](https://ec.europa.eu/eurostat/databrowser/view/BD_9BD_SZ_CL_R2/default/table?lang=en)
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letter*, 27(8), 861–874. Prieiga internetu: <https://doi.org/10.1016/j.patrec.2005.10.010>
- Gabbi, G., Giammarino, M., & Matthias, M. (2020). Die Hard: Probability of Default and Soft Information. *Risks*, 8(2), 46. Prieiga internetu: <https://doi.org/10.3390/risks8020046>
- Godke Veiga, M., & McCahery, J.A. (2019). The Financing of Small and Medium-Sized Enterprises: An Analysis of the Financing Gap in Brazil. *European Business Organization Law Review*, 20, 633–664. Prieiga internetu: <https://doi.org/10.1007/s40804-019-00167-7>
- Goebel, R., Chander, A., Holzinger, K., Lecue, F., Akata, Z., Stumpf, S., Kieseberg, P., & Holzinger, A. (2018). Explainable AI: The New 42?. In: Holzinger, A., Kieseberg, P., Tjoa, A., Weippl, E. (Eds.). *Machine Learning and Knowledge Extraction*. CD-MAKE 2018. Springer, Cham, 11015, 295–303. Prieiga internetu: [https://doi.org/10.1007/978-3-319-99740-7\\_21](https://doi.org/10.1007/978-3-319-99740-7_21)
- Golbayani, P., Florescu, I., & Chatterjee, R. (2020). A comparative study of forecasting Corporate Credit Ratings using Neural Networks, Support Vector Machines, and Decision Trees. *The North American Journal of Economics and Finance*, 54, 101251. Prieiga internetu: <https://doi.org/10.1016/j.najef.2020.101251>
- Gopal, M. & Schnabl, P. (2022). The Rise of Finance Companies and FinTech Lenders in Small Business Lending. *The Review of Financial Studies*, 35(11), 4859–4901. Prieiga internetu: <https://doi.org/10.1093/rfs/hhac034>
- Gorgijevska, A. & Gjorgieva–Trajkovska O. (2019). Qualitative and quantitative analysis of creditworthiness of the companies. *Journal of Economics*, 4(1), 18–26. Prieiga internetu: <https://js.ugd.edu.mk/index.php/JE/article/view/2736/2503>

- Grant, D. G., Behrends, J., & Basl, J. (2023). What we owe to decision-subjects: beyond transparency and explanation in automated decision-making. *Philosophical Studies*. Prieiga internetu: <https://doi.org/10.1007/s11098-023-02013-6>
- Huang, Y., Zhang, L., Li, Z., Qiu, H., Sun, T., & Wang, X. (2020). Fintech Credit Risk Assessment for SMEs: Evidence from China. *IMF Working Paper No. 20/193*. Prieiga internetu: <https://doi.org/10.5089/9781513557618.001>
- Investicijų ir verslo garantijos, UAB (INVEGA). (2023). *Skolinimas verslui per alternatyvius finansuotojus – „Alternatyva“*. Žiūrėta 2023-12-01. Prieiga internetu: <https://invega.lt/paslaugos/25/skolinimas-verslui-per-alternatyvius-finansuotojus-alternatyva-15#descriptionEnterpriseDeminimis>
- Istrate, L. G. & Ionescu B. S. (2017). Estimation of the probability of default based on relevant economic and financial indicators. *The Annals of the University of Oradea, Economic Sciences*, 28(1), 385–393. Prieiga internetu: <https://ideas.repec.org/a/ora/journal/v1y2017i1p385-393.html>
- Jabbouri, I. & Farooq, O. (2021). Inadequately educated workforce and financing obstacles: international evidence from SMEs in developing countries. *International Journal of Managerial Finance*, 17(1), 118–137. Prieiga internetu: <https://doi.org/10.1108/IJMF-01-2020-0002>
- Jamil, J. J. J. (2021). Modeling of corporate credit risks using actuarial techniques. *Doctoral dissertation, UKM, Bangi*.
- Jin, Y., & Zhang, S. (2019). Credit Rationing in Small and Micro Enterprises: A Theoretical Analysis. *Sustainability*, 11(5), 1330. Prieiga internetu: <https://doi.org/10.3390/su11051330>
- Jingming, L., Xuhui, L., Daoming, D., Sumei, R., & Xuhui, Z. (2020). Research on Credit Risk Measurement of Small and Micro Enterprises Based on the Integrated Algorithm of Improved GSO and ELM. *Mathematical Problems in Engineering*, 2020, 1–14. Prieiga internetu: <https://doi.org/10.1155/2020/3490536>
- Kamienas, I., Valvonis, V. (2004). Paskolų registro naudojimas kredito rizikai valdyti. *Pinigų studijos*, 1, 5–30.
- Laajimi, S. (2012). Structural Credit Risk Models: A Review. *Assurances et gestion des risques*, 80(1), 53–93. Prieiga internetu: <https://doi.org/10.7202/1091998ar>
- Lietuvos bankas. (2019, 2020, 2021, 2022). *Įmonių apklausos apžvalga*. Žiūrėta 2023-10-01. Prieiga internetu: <https://www.lb.lt/lt/apzvalgos-ir-leidiniai/category.40/series.197>
- Lietuvos bankas ir Lietuvos Respublikos konkurencijos taryba. (2021). Smulkiojo ir vidutinio verslo finansavimo galimybių tyrimas. *Dokumentas viešai konsultacijai*. Prieiga internetu: [https://www.lb.lt/uploads/consultations/docs/34217\\_bff2383bc37f0a7222f9068e1d97b6e0.pdf](https://www.lb.lt/uploads/consultations/docs/34217_bff2383bc37f0a7222f9068e1d97b6e0.pdf)

- Lietuvos Respublikos Seimas. Lietuvos Respublikos asmens duomenų teisinės apsaugos įstatymas. 1996 m. birželio 11 d. Nr. I-1374. *Galiojanti suvestinė redakcija 2021-12-01 – 2023-12-31*. Žiūrėta 2023-09-04. Prieiga internetu: <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/TAIS.29193/asr>
- Lietuvos Respublikos Seimas. Lietuvos Respublikos finansų įstaigų įstatymas. 2002 m. rugsėjo 10 d. Nr. IX-1068. *Galiojanti suvestinė redakcija nuo 2023-11-10*. Žiūrėta 2023-12-01. Prieiga internetu: <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/TAIS.183130/asr>
- Lietuvos Respublikos Seimas. Lietuvos Respublikos smulkiojo ir vidutinio verslo plėtros įstatymas. 1998 m. lapkričio 24 d. Nr. VIII-935. *Galiojanti suvestinė redakcija nuo 2022-03-31*. Žiūrėta 2023-04-05. Prieiga internetu: <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/TAIS.68516/asr>
- Lietuvos Respublikos Seimas. Lietuvos Respublikos tarptautinių sankcijų įstatymas. 2004 m. balandžio 22 d. Nr. IX-2160. *Galiojanti suvestinė redakcija nuo 2023-04-15*. Žiūrėta 2023-12-01. Prieiga internetu: <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/TAIS.232047/OBvbifZfEA>
- Lietuvos Respublikos Seimas. Lietuvos Respublikos pinigų plovimo ir teroristų finansavimo prevencijos įstatymas. 1997 m. birželio 19 d. Nr. VIII-275. *Galiojanti suvestinė redakcija 2023-11-10 – 2023-12-31*. Žiūrėta 2023-12-01. Prieiga internetu: <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/TAIS.41300/asr>
- Lietuvos statistikos departamentas. (2023). *Veikiančių įmonių skaičius metų pradžioje*. Žiūrėta 2023-09-06. Prieiga internetu: <https://osp.stat.gov.lt/statistiniu-rodikliu-analize#/>
- Lindset, A., Lund, A. C. & Persson, S.A. (2014). Credit risk and asymmetric information: A simplified approach. *Journal of Economic Dynamics & Control* 39, 98–112. Prieiga internetu: <https://doi.org/10.1016/j.jedc.2013.11.006>
- Liu, L. (2016). Research of Internet Financing Strategy of Small and Micro Enterprises. *Proceedings of 2016 5th International Conference on Social Science, Education and Humanities Research*. Prieiga internetu: <https://doi.org/10.2991/ssehr-16.2016.290>
- Liustrovaitė, J. ir Martinkutė-Kaulienė, R. (2015). Smulkaus ir vidutinio verslo kreditavimo problemos Lietuvoje. *Mokslas – Lietuvos ateitis*, 7(2), 238–245. Prieiga internetu: <https://doi.org/10.3846/mla.2015.751>
- Locatelli, R., Pepe, G., & Salis, F. (2022). Artificial Intelligence and Credit Risk. *Springer International Publishing AG*. Prieiga internetu: <https://doi.org/10.1007/978-3-031-10236-3>
- Lu, Y., Yang, L., Shi, B., Li, J. & Abedin, M. Z. (2022). A novel framework of credit risk feature selection for SMEs during industry 4.0. *Annals of Operations Research* (2022). Prieiga internetu: <https://doi.org/10.1007/s10479-022-04849-3>
- Luo, Y., & Matz, F. (2021). Explaining Outcomes of AI Systems to Consumers. Insights from the Swedish Credit Scoring Industry. KTH Royal Institute, 293, 1-88. <https://www.diva-portal.org/smash/get/diva2:1590386/FULLTEXT01.pdf>



- Malakauskas, A. & Lakštutienė, A. (2021a). Financial Distress Prediction for Small and Medium Enterprises Using Machine Learning Techniques. *Inžinerinė Ekonomika*, 32(1), 4–14. Prieiga internetu: <https://doi.org/10.5755/j01.ee.32.1.27382>
- Malakauskas, A. & Lakštutienė, A. (2021b). The Application of Artificial Intelligence Tools in Creditworthiness Modelling for SME Entities. *2021 IEEE International Conference on Technology and Entrepreneurship (ICTE)*, 2021, 1–6. Prieiga internetu: <https://doi.org/10.1109/ICTE51655.2021.9584528>
- Ma, Y., & Xu, W. (2016). Structural credit risk modelling with Hawkes jump diffusion processes. *Journal of Computational and Applied Mathematics*, 303, 69–80. Prieiga internetu: <https://doi.org/10.1016/j.cam.2016.02.032>
- Mileris, R. (2009). Statistinių kredito rizikos vertinimo modelių efektyvumo analizė. *Ekonomika ir vadyba*, 14, 1156–1162, ISSN: 1822-6515. Prieiga internetu: <https://www.lituanistika.lt/content/22398>
- Mileris, R. (2012). Įmonių finansinių išpareigojimų neįvykdymo tikimybės vertinimas nustatant kredito reitingus. *Taikomoji ekonomika: sisteminiai tyrimai*, 6(2), 127–142, ISSN: 1822-7996. Prieiga internetu: <https://doi.org/10.7220/AESR.1822.7996.2012.6.2.8>
- Misra, A. K., Rahman, M. R., & Tiwari, A. K. (2023). A risk-neutral approach to the RAROC method of loan pricing using account-level data. *Journal of Risk Finance*, 24(2), 212–225. Prieiga internetu: <https://doi.org/10.1108/JRF-09-2022-0240>
- Papouskova, M., & Hájek, P. (2019). Two-stage consumer credit risk modelling using heterogeneous ensemble learning. *Decision Support Systems*, 118, 33–45. Prieiga internetu: <https://doi.org/10.1016/j.dss.2019.01.002>
- Peškauskaitė, D., Jurevičienė, D. (2017). Įmonių kredito rizikos vertinimo metodai investiciniam sprendimui priimti. *Mokslas: Lietuvos ateitis*. 9(2), 220–229, ISSN: 2029–2341. Prieiga internetu: <https://doi.org/10.3846/mla.2017.1014>
- Prijadi, R., Wulandari, P., Desiana, P.M., Pinagara, F.A. & Novita, M. (2020). Financing needs of micro-enterprises along their evolution. *International Journal of Ethics and Systems*, 36(2), 263–284. Prieiga internetu: <https://doi.org/10.1108/IJOES-05-2018-0071>
- Qian, Q., Feng, H., & Gu, J. (2021). The influence of risk attitude on credit risk contagion—Perspective of information dissemination. *Physica A*, 582, 126226. Prieiga internetu: <https://doi.org/10.1016/j.physa.2021.126226>
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1, 206–215. Prieiga internetu: <https://doi.org/10.1038/s42256-019-0048-x>
- Sachan, S., Yang, J. B., Xu, D. L., Benavides, D. E., & Li, Y. (2020). An explainable AI decision-support-system to automate loan underwriting. *Expert Systems with Applications*, 144(15), 113100. Prieiga internetu: <https://doi.org/10.1016/j.eswa.2019.113100>

- Savickaitė, D., Valvoniš V. (2007). Įmonių reitingavimas: Lietuvos bankų patirtis. *Pinigų studijos*, 1, 86-108. Prieiga internetu: <https://www.lituanistika.lt/content/14586>
- Schäfer, R., & Koivusalo, A. F. R. (2013). Dependence of defaults and recoveries in structural credit risk models. *Economic Modelling*, 30, 1–9. Prieiga internetu: <https://doi.org/10.1016/j.econmod.2012.08.033>
- Schoeffer, J., Machowski, Y., & Kuehl, N. (2021). *A study on fairness and trust perceptions in automated decision making*. Transparency and Explanations in Smart Systems (TESS) Workshop at the 26<sup>th</sup> Annual Conference on Intelligent User Interfaces (ACM IUI '21). Prieiga internetu: <https://doi.org/10.48550/arXiv.2103.04757>
- Schotten, P. C., de Sousa Pereira, L., & Morais, D.C. (2022). Credit granting sorting model for financial organizations. *Financing Innovation*, 8(10), 1–24. Prieiga internetu: <https://doi.org/10.1186/s40854-021-00315-4>
- Shi, B., Chi, G., & Li, W. (2020). Exploring the mismatch between credit ratings and loss-given-default: A credit risk approach. *Economic Modelling*, 85, 420–428. Prieiga internetu: <https://doi.org/10.1016/j.econmod.2019.11.032>
- Soui, M., Gasmi, I., Smiti, S., & Ghédira, K. (2019). Rule-based credit risk assessment model using multi-objective evolutionary algorithms. *Expert Systems with Applications*, 126, 144–157. Prieiga internetu: <https://doi.org/10.1016/j.eswa.2019.01.078>
- Suryani, E., Hidayati, S. A. H., Putra, I. N. N. A., & Syah, D. O. (2021). Lending Relationship in the Traditional Credit Market — Implications for Credit Risk Management Strategy in Micro Credit Institutions. *Journal of International Commerce, Economics and Policy*, 12(3). Prieiga internetu: <https://doi.org/10.1142/S1793993321500125>
- Špicas, R., Nekrošiūtė, G. (2012). Įmonių kredito rizikos vertinimo modelių taikymas Lietuvos kredito unijose. *Ekonomika ir vadyba: aktualijos ir perspektyvos*, 4(28), 120–132. Prieiga internetu: <https://www.lituanistika.lt/content/44226>
- Tarashev, N. A. (2005). An Empirical Evaluation of Structural Credit Risk Models. *BIS Working Paper No. 179, Monetary and Economic Department*. Prieiga internetu: <https://doi.org/10.2139/ssrn.846304>
- Tran, C. S., Nicolau, D., Nayak, R., & Verhoeven, P. (2021). Modeling Credit Risk: A Category Theory Perspective. *Journal of Risk and Financial Management*, 14(7), 298. Prieiga internetu: <https://doi.org/10.3390/jrfm14070298>
- Ubarhande, P., Chandani, A., & McMillan, D. (eds). (2021). Elements of Credit Rating: A Hybrid Review and Future Research Agenda. *Cogent Business & Management*, 8(1), 1878977. Prieiga internetu: <https://doi.org/10.1080/23311975.2021.1878977>
- Valstybinė mokesčių inspekcija. (2020). Naudotų automobilių pardavimo apmokestinimas PVM. Mokesčių informacijos departamentas, 2020-11-15. Žiūrėta 2023-12-03. Prieiga internetu: <https://www.vmi.lt/evmi/documents/20142/390959/Naudot%C5%B3+automobili%C5%B3+pardavimo+apmokestinimas+PVM.pdf/>

- Wang, T., Liu, R., & Qi, G. (2022). Multi-classification assessment of bank personal credit risk based on multi-source information fusion. *Expert Systems with Applications*, 191, N.PAG. Prieiga internetu: <https://doi.org/10.1016/j.eswa.2021.116236>
- Wu, T. C. & Hsu, M. F. (2012). Credit risk assessment and decision making by a fusion approach. *Knowledge-Based Systems*, 35, 102–110. Prieiga internetu: <https://doi.org/10.1016/j.knosys.2012.04.025>
- Yang, L. H., Liu, J., Ye, F. F., Wang, Y. M., Nugent, C., Wang, H., & Martínez, L. (2022). Highly explainable cumulative belief rule-based system with effective rule-base modeling and inference scheme. *Knowledge-Based Systems*, 240, 107805. Prieiga internetu: <https://doi.org/10.1016/j.knosys.2021.107805>
- Yin, C., Jiang, C., Jain H. K. & Wang Z. (2020). Evaluating the credit risk of SMEs using legal judgments. *Decision Support Systems*, 136, 113364. Prieiga internetu: <https://doi.org/10.1016/j.dss.2020.113364>
- Zamore, S., Ohene Djan, K., Alon, I., & Hobdari, B. (2018). Credit Risk Research: Review and Agenda. *Emerging Markets Finance and Trade*, 54(4), 811–835. Prieiga internetu: <https://doi.org/10.1080/1540496X.2018.1433658>
- Zhang, F., Tadikamalla, P. R. & Shang, J. (2016). Corporate credit-risk evaluation system: Integrating explicit and implicit financial performances. *International Journal of Production Economics*, Elsevier, 177(C), 77–100. Prieiga internetu: <https://doi.org/10.1016/j.ijpe.2016.04.012>
- Zhu, J. (2020). Research on Risk Management and Countermeasures of Inclusive Finance – From the Perspective of Comprehensive Risk Management of Credit Insurance. *Financial Engineering and Risk Management*, 3(1), 147–155. Prieiga internetu: <https://doi.org/10.23977/ferm.2020.030121>



# MAŽŲ IR LABAI MAŽŲ ĮMONIŲ KREDITO RIZIKOS VERTINIMO MODELIS

**KAMILĖ DAILIDONYTĖ**

**Magistro baigiamasis darbas**

**Finansai ir bankininkystė**

Vilniaus universitetas, Ekonomikos ir verslo administravimo fakultetas

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

Vilnius, 2024

## SANTRAUKA

96 puslapiai, 32 lentelės, 26 paveikslai, 91 literatūros šaltiniai, 22 priedai.

Pagrindinis magistro baigiamojo darbo tikslas – sukurti ir įvertinti kredito rizikos vertinimo modelį, orientuotą į sprendimų priėmimą, mažoms ir labai mažoms įmonėms.

Darbą sudaro trys pagrindinės dalys: literatūros analizė, tyrimas ir jo rezultatai, išvados ir pasiūlymai.

Literatūros analizėje apžvelgiamos kredito rizikos teorijos, pristatomi pagrindiniai kredito rizikos modeliai, supažindinama su mažų ir labai mažų įmonių samprata, identifikuojama jų ekonominė svarba ir dėl jų ypatumų kylantys kreditavimo iššūkiai, taip pat nurodomos automatizavimo galimybės ir kritinis požiūris į kredito sprendimų priėmimo procesą pasirenkant vertinimo metodus.

Po atliktos mokslinės literatūros analizės autorė atlieka tyrimą apie kredito rizikos vertinimo modelio formavimą, atsižvelgiant į Lietuvoje veikiančio alternatyvaus finansuotojo klientų analizės rezultatus per ataskaitinį laikotarpį. Modelio kūrimui naudojamas taisyklėmis pagrįstas metodas, kuris pasinaudojus automatizacijos galimybėmis įtraukia kliento ir pasiūlymo informacijos tipus ir leidžia veikti kaip momentinė sprendimų priėmimo sistema integruota su finansuotojo kredito rizikos politikos taisyklėmis. Duomenų rinkmena remiasi kredito biuro „Creditinfo Lietuva“ pateikta informacija, vidinės duomenų bazės duomenimis bei kliento pateikta informacija. Duomenų apdorojimui naudojamas SPSS programinis paketas. Ryšiui tarp kategorinių kintamųjų nustatyti naudojamas neparametrinis kriterijus Chi-kvadratas (Pearson formulė).

Atlikto tyrimo rezultatai rodo, jog sukurtas kredito rizikos vertinimo modelis, nukreiptas į sprendimo dėl kredito suteikimo priėmimą, veikia 100% atitikimo taisyklėmis principu. Užtikrinta loginė modelio įvesties-išvesties visuma, nustatytų taisyklių atžvilgiu, leidžia paaiškinti priimtus sprendimus atskiruose informacijos segmentuose. Pagrindinės tyrimo išvados, atskleidžiančios naudą finansinių paslaugų teikėjui, yra tai, kad automatizacijos procesas, paaiškinantis žmogaus ir modelio sprendimų skirtumus, garantuoja, jog kredito vertinimo modelis, kaip pirminis vertinimo įrankis, gali prisidėti prie poveikio gerinant sprendimų priėmimą tikslumo užtikrinimo, atitikties nustatymo, objektyvumo didinimo ir apibendrinimo galimybių požiūriu.

Išvadose ir pasiūlymuose apibendrinama pagrindinės literatūros analizės koncepcija ir atlikto tyrimo rezultatai. Autorė mano, kad tyrimo rezultatai gali suteikti naudingų gairių įmonėms, ketinančioms diegti kredito rizikos vertinimo modelį ir galėtų padėti įmonei įgyvendinti šios sistemos pritaikymą realioje verslo aplinkoje.

# **CREDIT RISK ASSESSMENT MODEL FOR SMALL AND MICRO-ENTERPRISES**

**KAMILĖ DAILIDONYTĖ**

**Master Thesis**

**Finance and Banking**

Vilnius University, Faculty of Economics and Business Administration

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

Vilnius, 2024

## **SUMMARY**

96 pages, 32 tables, 26 pictures, 91 references, 22 appendices.

The main purpose of this master thesis is to develop and evaluate a credit risk assessment model focused on decision-making for small and micro enterprises.

The work consists of three main parts; the analysis of literature, the research and its results, conclusion and recommendations.

Literature analysis reviews the credit risk theories, presents the main credit risk models, introduces the concept of small and micro enterprises, identifies their economic importance and the credit challenges due to their characteristics as well as indicates the potential and critical approach of automation in the credit decision-making process in the choice of assessment methods.

After the literature analysis the author has carried out the study on the formation of a credit risk assessment model, taking into account the results of the analysis of the clients of an alternative financier operating in Lithuania during the reporting period. The model is built using a rule-based approach that incorporates client and offer information types through automation and allows it to act as an instantaneous decision-making system integrated with the financier's credit risk policy rules. The data file is based on information provided by the credit bureau 'Creditinfo Lietuva', the internal database and information provided by the client. The SPSS software package is used for data processing. The non-parametric criterion Chi-square (Pearson formula) is used to determine the relationship between categorical variables.

The results of the study show that the credit risk assessment model developed for the credit decision works on a 100% compliance basis. The logical input-output set of the model, in terms of the rules defined, is ensured and allows to explain the decisions taken in the individual information segments. The key findings of the study, which reveal the benefits for the financial services provider, are that the automation process explaining the differences between human and model decisions guarantees that the credit risk model, as a primary assessment tool, can contribute to the impact in terms of improving the accuracy of the decision-making process regarding accuracy, compliance, objectivity and generalizability.

The conclusions and recommendations summarize the main concepts of literature analysis as well as the results of the performed research. The author believes that the results of the study can provide useful guidance for companies considering the implementation of a credit risk assessment model and could help the company to implement the system in a real business environment.

# PRIEDAI

## 1 priedas. Juridinių asmenų duomenys

### 1.1 paveikslas

„Creditinfo Lietuva“ profesionalios juridinių asmenų ataskaitos pavyzdžio dalis



MES KURIAME PASITIKĖJIMA



UAB "Imonė"		Ataskaitos laikas: 2023.09.07 12:08:54				
<b>Santrauka</b>						
Vėlavimo atsisakytų reitingas	19,059% tikimybė, <b>7</b> klasė (Patenkinama rizika, stabėt)					
Bankroto reitingas	0,664% tikimybė, <b>3</b> klasė (Gera būklė)					
Tėsinis statusas	Veikiantis subjektas					
Registracijos data	2000-00-00					
Imonės kodas	111111111					
PVM kodas	LT111111111					
Veikla	000000 - Agentūrų veikla					
Institucinis sektorius	11003 - Užsienio subjektų kontroliuojamos ne finansų bendrovės					
Akcinių skaičius	1					
Nepadengti įsiskolinimai	Nėra					
Mokėjimų istorija	3 / paskutinė data: 2018-11-15   Vidutinis apmokėjimo terminas: 68 d.   Kredito biuro sistemoje pateiktų skolų apmokėjimo terminas dienomis					
Įregistruoti turto areštai	Nėra					
Teisimo posėdžių skaičius	<b>111 (49 kaip atsakovas) / paskutinė data: 2023-10-11</b>					
Vieša neįgiama informacija	Nėra					
Imonėi taikomos tarptautinės sankcijos	Nėra					
Informacija apie skolas Sodrai	Nėra					
Darbuotojų (apdraustųjų) skaičius	45 / paskutinė data: 2023-09-07					
Darbo užmokesčio vidurkis	4.557,73 EUR paskutiniai duomenys: 2023 m. 07 mėn. (moterų 4.249,00 EUR; vyrų 4.913,00 EUR.) (Atlyginimų vidurkis pateikiami tik tuo atveju, jeigu apdraustųjų įmonėje yra daugiau nei trys ir jie visi per mėnesį yra gavę pajamų. Pajamų vidurkis apskaičiuojami pagal priskaičiuotas pajamas ir pateikiami neatskačius mokesčių.)					
Pajamos	5.592.429 EUR / už 2022 metus					
Ataskaitų skaičius	2 (per 1 mėn.) / 8 (per 3 mėn.) / 19 (per 6 mėn.)					
<b>Juridinė informacija</b>						
<b>Pagrindiniai duomenys</b>						
Pavadinimas	UAB "Imonė"					
▼ <a href="#">istorinė informacija</a>						
Tėsinis statusas	Veikiantis subjektas					
▼ <a href="#">istorinė informacija</a>						
Registracijos forma	Uždaroji akcinė bendrovė					
Registracijos data	2000-00-00					
Imonės kodas	111111111					
PVM kodas	LT111111111					
Įregistruotas PVM mokėtoju	2000-00-00					
Pagrindinė veikla (EVRK2)	000000 - Agentūrų veikla					
Institucinis sektorius	11003 - Užsienio subjektų kontroliuojamos ne finansų bendrovės					
Savivaldybė	Vilniaus m. sav.					
Atstovavimas	Vienasmenis atstovavimas (Juridinio asmens vardu veikia vadovas)					
Imonės tikslai	bendrovė gali užsimiti bet kokia teisėta veikla, įskaitinai veikla, susijusia su duomenų bazėmis; verslo ir valdymo konsultacijomis; verslo informacijos paieška ir pateikimu; asmenų ar firmų kreditingumo įvertinimo veikla; skolų išieškojimo veikla; finansinėmis konsultacijomis; duomenų apdorojimu					
<b>Duomenys apie įmonės vadovą</b>						
Vadovas	Gimimo data	Data nuo				
VARDAS PAVARDE, Generalinis direktorius	1900-00-00	2020-06-03	▶ <a href="#">Vadovaujami įmoniu paieška</a>			
▼ <a href="#">istorinė informacija</a>						
<b>Imonės prekės ženklai</b>						
Ženklo vaizdas	Prekės ženklas	Statusas	Paraškos data	Registracijos data	Registracijos nr.	Galioja iki
	<b>STIPRIAUSI LIETUVOJE</b>	Registered	2021-06-08	-	-	2031-05-08
-						
-						
▼ <a href="#">Daugiau</a>						
<b>Kontaktinė informacija</b>						
Adresas	Gatvė g. 0, Vilniaus m., Vilniaus m. sav.					
▼ <a href="#">istorinė informacija</a>						

Šaltinis: UAB „Creditinfo Lietuva“, 2023.<sup>26</sup>

<sup>26</sup> Ataskaitos pavyzdys (visas): <https://lt.creditinfo.com/wp-content/uploads/sites/56/2023/09/Profesionalios-ataskaitos-pavyzdys.pdf>

## 2 priedas. Pasirašytų sutarčių charakteristikos

### 2.1 lentelė

*Pasirašytos sutartys pagal įsipareigojimų dydį ir sutarčių skaičių Lietuvoje 2022 m.*

	<b>Įsipareigojimo dydis   EUR</b>	<b>Visi įsipareigojimai   EUR</b>	<b>Visi įsipareigojimai   proc.</b>	<b>Sutarčių skaičius   vnt.</b>	<b>Sutarčių skaičius   proc.</b>
<b>Pasirašytos sutartys</b>	1 - 20 000	23 371 598	18,0	2 415	73,5
	20 001 - 50 000	15 462 881	11,9	509	15,5
	50 001 - 100 000	11 746 121	9,1	116	3,5
	100 001 - 500 000	41 005 917	31,6	200	6,1
	>500 000	38 218 548	29,4	45	1,4
	Iš viso:	129 805 065	100,0	3 285	100,0

Šaltinis: sudaryta autorės, remiantis vidiniais UAB „X“ duomenimis.

### 3 priedas. Atmestų paraiškų duomenys

#### 3.1 lentelė

*Nepatvirtintų paraiškų trūkstamos reikšmės*

	N	
	Valid	Missing
Sprendimas	1114	0
Šalis	1114	0
Įmonės pavadinimas (nuasmeninta)	1114	0
Įmonės amžius	1015	99
Teisinis statusas	1012	102
Ekonominės veiklos rūšis (pagal EVRK2)	1017	97
Pokyčiai JADIS	1020	94
Juridinio asmens dalyvių struktūra	1012	102
Žinoma >75% galutinių naudos gavėjų	1012	102
Įmonės vadovas	1012	102
Įmonės dydis	1012	102
CI bankroto reitingas	1012	102
Politiškai pažeidžiami arba sankcionuoti asmenys	1012	102
Turto areštai	1024	90
Teismai	1022	92
Antstolių raginimai	1014	100
Neigiama viešai prieinama informacija	1021	93
Bankrotas ir (ar) nemokumas	1031	83
Pradelsti mokėjimai finansinėms institucijoms	1039	75
Aktyvūs pradelsti mokėjimai, išskyrus finansinėms institucijoms	1012	102
Aktyvūs pradelsti mokėjimai valstybinėms institucijoms	1018	96
Esamų įsipareigojimų likutis kredito įstaigoje	1012	102
Neigiama mokėjimų istorija kredito įstaigoje (esamiems klientams)	1023	91
Kredito tipas	1114	0
Finansuojama suma	1114	0

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 4 priedas. Atmestos paraiškos – juridinė informacija

### 4.1 lentelė

*Nepatvirtintų paraiškų atmetimo priežasčių analizės rezultatai*

		<b>Įmonės amžius</b>			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Iki 1 metų	3	2,9	100,0	100,0
Missing	System	99	97,1		
<b>Total</b>		<b>102</b>	<b>100,0</b>		

		<b>Ekonominės veiklos rūšis (pagal EVRK2)</b>			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	0	5	4,9	100,0	100,0
Missing	System	97	95,1		
<b>Total</b>		<b>102</b>	<b>100,0</b>		

		<b>Pokyčiai JADIS</b>			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Taip	8	7,8	100,0	100,0
Missing	System	94	92,2		
<b>Total</b>		<b>102</b>	<b>100,0</b>		

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 5 priedas. Atmestos paraiškos – neigiama informacija

### 5.1 lentelė

*Nepatvirtintų paraiškų atmetimo priežasčių analizės rezultatai*

**Turto areštai**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Taip	12	11,8	100,0	100,0
Missing	System	90	88,2		
Total		102	100,0		

**Teismai**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Taip	10	9,8	100,0	100,0
Missing	System	92	90,2		
Total		102	100,0		

**Antstolių raginimai**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Taip	2	2,0	100,0	100,0
Missing	System	100	98,0		
Total		102	100,0		

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 6 priedas. Atmestos paraiškos – mokėjimų istorija

### 6.1 lentelė

*Nepatvirtintų paraiškų atmetimo priežasčių analizės rezultatai*

#### **Bankrotas ir (ar) nemokumas**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Taip	19	18,6	100,0	100,0
Missing	System	83	81,4		
Total		102	100,0		

#### **Pradelsti mokėjimai finansinėms institucijoms**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Taip	27	26,5	100,0	100,0
Missing	System	75	73,5		
Total		102	100,0		

#### **Aktyvūs pradelsti mokėjimai valstybinėms institucijoms**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Taip	6	5,9	100,0	100,0
Missing	System	96	94,1		
Total		102	100,0		

#### **Neigiama mokėjimų istorija kredito įstaigoje (esamiems klientams)**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Taip	11	10,8	100,0	100,0
Missing	System	91	89,2		
Total		102	100,0		

Šaltinis: parengta autorės, remiantis atliktu tyrimu.



## 7.1 lentelė

*Atmestų paraiškų pagal priežasčių ir atvejų skaičių rezultatai*

	<b>Atmetimo priežastis</b>	<b>Rezultatai pagal priežasčių skaičių (112)   proc.</b>	<b>Rezultatai pagal atvejų skaičių (102)   proc.</b>	<b>Paklaida   proc. punktais</b>
<b>Atmestos paraiškos</b>	Įmonės amžius	2,7	2,9	0,3
	Ekonominės veiklos rūšis (pagal EVRK2)	4,5	4,9	0,4
	Pokyčiai JADIS	7,1	7,8	0,7
	Turto areštai	10,7	11,8	1,1
	Teismai	8,9	9,8	0,9
	Antstolių raginimai	1,8	2,0	0,2
	Neigiama viešai prieinama informacija	8,0	8,8	0,8
	Bankrotas ir (ar) nemokumas	17,0	18,6	1,7
	Pradelsti mokėjimai finansinėms institucijoms	24,1	26,5	2,4
	Aktyvūs pradelsti mokėjimai valstybinėms institucijoms	5,4	5,9	0,5
	Neigiama mokėjimų istorija kredito įstaigoje	9,8	10,8	1,0

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 8 priedas. Maksimalus nuostolis

### 8.1 lentelė

*Atmestų paraiškų pagal finansuojamą sumą analizės rezultatai*

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	1 - 10 000 EUR	34	33,3	33,3	33,3
	10 001 - 20 000 EUR	45	44,1	44,1	77,5
	20 001 - 30 000 EUR	11	10,8	10,8	88,2
	30 001 - 40 000 EUR	6	5,9	5,9	94,1
	40 001 - 50 000 EUR	6	5,9	5,9	100,0
Total		102	100,0	100,0	

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 8.2 lentelė

*Konservatyvus maksimalaus nuostolio pagal paraiškos sumos dydį apskaičiavimas*

<b>Maksimalus nuostolis = maksimali paraiškos suma × atvejų skaičius</b>				
	Paraiškos suma   EUR	Maksimali suma   EUR	Atvejų skaičius   vnt.	Maksimalus nuostolis   EUR
<b>Atmestos paraiškos</b>	1 - 10 000	10 000	34	340 000
	10 001 - 20 000	20 000	45	900 000
	20 001 - 30 000	30 000	11	330 000
	30 001 - 40 000	40 000	6	240 000
	40 001 - 50 000	50 000	6	300 000
			Iš viso:	<b>2 110 000</b>

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 9 priedas. Įsipareigojimų nevykdymas

### 9.1 lentelė

*Įsipareigojimų nevykdymo atvejai 2022 m. pabaigoje*

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	949	93,8	93,8	93,8
	Taip	63	6,2	6,2	100,0
	Total	1012	100,0	100,0	

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 10 priedas. Patvirtintos paraiškos – įmonės amžius ir dydis

### 10.1 lentelė


Patvirtintų paraiškų kiekis pagal įmonės amžių ir įmonės dydį 2022 m.

Įmonės dydis			Sprendimas Patvirtinta	Total
Labai mažos įmonės	Įmonės amžius	Iki 1 metų	48	48
		Nuo 1 iki 3 metų	195	195
		Nuo 3 iki 5 metų	142	142
		Nuo 5 iki 10 metų	192	192
		Nuo 10 iki 20 metų	107	107
		20 metų ir daugiau	37	37
		Total	721	721
Mažos įmonės	Įmonės amžius	Iki 1 metų	7	7
		Nuo 1 iki 3 metų	40	40
		Nuo 3 iki 5 metų	41	41
		Nuo 5 iki 10 metų	73	73
		Nuo 10 iki 20 metų	71	71
		20 metų ir daugiau	59	59
Total	291	291		
Total	Įmonės amžius	Iki 1 metų	55	55
		Nuo 1 iki 3 metų	235	235
		Nuo 3 iki 5 metų	183	183
		Nuo 5 iki 10 metų	265	265
		Nuo 10 iki 20 metų	178	178
		20 metų ir daugiau	96	96
Total	1012	1012		

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 10.1 paveikslas

Patvirtintų paraiškų kiekis pagal įmonės amžių ir įmonės dydį 2022 m.



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 11 priedas. Patvirtintos paraiškos – kredito tipas ir įmonės dydis

### 11.1 lentelė


Patvirtintų paraiškų kiekis pagal kredito tipą ir įmonės dydį 2022 m.

Įmonės dydis		Sprendimas Patvirtinta		Total
Labai mažos įmonės	Kredito tipas	Paskola	464	464
		Lizingas	245	245
		Faktoringas	12	12
	Total		721	721
Mažos įmonės	Kredito tipas	Paskola	120	120
		Lizingas	165	165
		Faktoringas	6	6
	Total		291	291
Total	Kredito tipas	Paskola	584	584
		Lizingas	410	410
		Faktoringas	18	18
	Total		1012	1012

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 11.1 paveikslas

Patvirtintų paraiškų kiekis pagal kredito tipą ir įmonės dydį 2022 m. (proc.)



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 12 priedas. Statistiniai ryšiai – bankroto reitingas (1)

### 12.1 lentelė

*Kintamųjų „bankroto reitingas“ ir „kredito tipas“ analizės rezultatai*

**Crosstab**

		Kredito tipas			Total	
		Paskola	Lizingas	Faktoringas		
CI bankroto reitingas	8-10 (blogas)	Count	70	84	3	157
		% within CI bankroto reitingas	44,6%	53,5%	1,9%	100,0%
	1-7 (geras)	Count	514	326	15	855
		% within CI bankroto reitingas	60,1%	38,1%	1,8%	100,0%
Total	Count	584	410	18	1012	
	% within CI bankroto reitingas	57,7%	40,5%	1,8%	100,0%	

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 12.2 lentelė

*Kintamųjų „bankroto reitingas“ ir „kredito tipas“ nepriklausomumo testas*

**Chi-Square Tests**

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	13,302 <sup>a</sup>	2	,001
Likelihood Ratio	13,111	2	,001
Linear-by-Linear Association	11,562	1	<,001
N of Valid Cases	1012		

a. 1 cells (16,7%) have expected count less than 5. The minimum expected count is 2,79.

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 13 priedas. Statistiniai ryšiai – bankroto reitingas (2)

### 13.1 lentelė

*Kintamųjų „bankroto reitingas“ ir „aktyvūs pradelsti mokėjimai valstybinėms institucijoms“ analizės rezultatai*

**Crosstab**

			Aktyvūs pradelsti mokėjimai valstybinėms institucijoms		Total
			Ne	Taip	
CI bankroto reitingas	8-10 (blogas)	Count	135	22	157
		% within CI bankroto reitingas	86,0%	14,0%	100,0%
	1-7 (geras)	Count	823	32	855
		% within CI bankroto reitingas	96,3%	3,7%	100,0%
Total	Count		958	54	1012
	% within CI bankroto reitingas		94,7%	5,3%	100,0%

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 13.2 lentelė

*Kintamųjų „bankroto reitingas“ ir „aktyvūs pradelsti mokėjimai valstybinėms institucijoms“ nepriklausomumo testas*

**Chi-Square Tests**

	Value	df	Asymptotic Significance (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	27,697 <sup>a</sup>	1	<,001		
Continuity Correction <sup>b</sup>	25,701	1	<,001		
Likelihood Ratio	21,300	1	<,001		
Fisher's Exact Test				<,001	<,001
Linear-by-Linear Association	27,670	1	<,001		
N of Valid Cases	1012				

a. 0 cells (0,0%) have expected count less than 5. The minimum expected count is 8,38.

b. Computed only for a 2x2 table

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 14 priedas. Statistiniai ryšiai – bankroto reitingas (3)

### 14.1 lentelė

*Kintamųjų „bankroto reitingas“ ir „aktyvūs pradelsti mokėjimai, išskyrus finansinėms institucijoms“ analizės rezultatai*

**Crosstab**

			Aktyvūs pradelsti mokėjimai, išskyrus finansinėms institucijoms		Total
			Ne	Taip	
CI bankroto reitingas	8-10 (blogas)	Count	137	20	157
		% within CI bankroto reitingas	87,3%	12,7%	100,0%
	1-7 (geras)	Count	834	21	855
		% within CI bankroto reitingas	97,5%	2,5%	100,0%
Total	Count		971	41	1012
	% within CI bankroto reitingas		95,9%	4,1%	100,0%

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 14.2 lentelė

*Kintamųjų „bankroto reitingas“ ir „aktyvūs pradelsti mokėjimai, išskyrus finansinėms institucijoms“ nepriklausomumo testas*

**Chi-Square Tests**

	Value	df	Asymptotic Significance (2-sided)	Exact Sig. (2- sided)	Exact Sig. (1- sided)
Pearson Chi-Square	36,079 <sup>a</sup>	1	<,001		
Continuity Correction <sup>b</sup>	33,483	1	<,001		
Likelihood Ratio	26,304	1	<,001		
Fisher's Exact Test				<,001	<,001
Linear-by-Linear Association	36,044	1	<,001		
N of Valid Cases	1012				

a. 0 cells (0,0%) have expected count less than 5. The minimum expected count is 6,36.

b. Computed only for a 2x2 table

Šaltinis: parengta autorės, remiantis atliktu tyrimu.



## 15 priedas. Statistiniai ryšiai – bankroto reitingas (4)

### 15.1 lentelė

*Kintamųjų „bankroto reitingas“ ir „įmonės amžius“ analizės rezultatai*

**Crosstab**

		CI bankroto reitingas				Total	
		8-10 (blogas)		1-7 (geras)			
		Count	% within CI bankroto reitingas	Count	% within CI bankroto reitingas	Count	% within CI bankroto reitingas
Įmonės amžius	Iki 1 metų	21	13,4%	34	4,0%	55	5,4%
	Nuo 1 iki 3 metų	52	33,1%	183	21,4%	235	23,2%
	Nuo 3 iki 5 metų	25	15,9%	158	18,5%	183	18,1%
	Nuo 5 iki 10 metų	25	15,9%	240	28,1%	265	26,2%
	Nuo 10 iki 20 metų	23	14,6%	155	18,1%	178	17,6%
	20 metų ir daugiau	11	7,0%	85	9,9%	96	9,5%
Total		157	100,0%	855	100,0%	1012	100,0%

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 15.2 lentelė

*Kintamųjų „bankroto reitingas“ ir „įmonės amžius“ nepriklausomumo testas*

**Chi-Square Tests**

	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	39,475 <sup>a</sup>	5	<,001
Likelihood Ratio	34,922	5	<,001
Linear-by-Linear Association	23,100	1	<,001
N of Valid Cases	1012		

a. 0 cells (0,0%) have expected count less than 5. The minimum expected count is 8,53.

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 16 priedas. Statistiniai ryšiai – mokėjimų istorija

### 16.1 lentelė

*Kintamųjų „aktyvūs pradelsti mokėjimai valstybinėms institucijoms“ ir „teismai“ analizės rezultatai*

**Crosstab**

			Teismai		Total
			Ne	Taip	
Aktyvūs pradelsti mokėjimai valstybinėms institucijoms	Ne	Count	955	3	958
		% within Aktyvūs pradelsti mokėjimai valstybinėms institucijoms	99,7%	0,3%	100,0%
	Taip	Count	35	19	54
		% within Aktyvūs pradelsti mokėjimai valstybinėms institucijoms	64,8%	35,2%	100,0%
Total	Count	990	22	1012	
	% within Aktyvūs pradelsti mokėjimai valstybinėms institucijoms	97,8%	2,2%	100,0%	

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 16.2 lentelė

*Kintamųjų „aktyvūs pradelsti mokėjimai valstybinėms institucijoms“ ir „teismai“ nepriklausomumo testas*

**Chi-Square Tests**

	Value	df	Asymptotic Significance (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	292,305 <sup>a</sup>	1	<,001		
Continuity Correction <sup>b</sup>	276,137	1	<,001		
Likelihood Ratio	101,343	1	<,001		
Fisher's Exact Test				<,001	<,001
Linear-by-Linear Association	292,016	1	<,001		
N of Valid Cases	1012				

a. 1 cells (25,0%) have expected count less than 5. The minimum expected count is 1,17.

b. Computed only for a 2x2 table

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 17 priedas. Statistiniai ryšiai – įsipareigojimų nevykdymas

### 17.1 lentelė

*Kintamųjų „įsipareigojimų nevykdymas“ ir „įmonės amžius“ analizės rezultatai*

**Crosstab**

		Įsipareigojimų nevykdymas				Total	
		Ne		Taip			
		Count	% within Įsipareigojimų nevykdymas	Count	% within Įsipareigojimų nevykdymas	Count	% within Įsipareigojimų nevykdymas
Įmonės amžius	Iki 1 metų	45	4,7%	10	15,9%	55	5,4%
	Nuo 1 iki 3 metų	224	23,6%	11	17,5%	235	23,2%
	Nuo 3 iki 5 metų	172	18,1%	11	17,5%	183	18,1%
	Nuo 5 iki 10 metų	246	25,9%	19	30,2%	265	26,2%
	Nuo 10 iki 20 metų	171	18,0%	7	11,1%	178	17,6%
	20 metų ir daugiau	91	9,6%	5	7,9%	96	9,5%
Total		949	100,0%	63	100,0%	1012	100,0%

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 17.2 lentelė

*Kintamųjų „įsipareigojimų nevykdymas“ ir „įmonės amžius“ nepriklausomumo testas*

**Chi-Square Tests**


	Value	df	Asymptotic Significance (2-sided)
Pearson Chi-Square	16,621 <sup>a</sup>	5	,005
Likelihood Ratio	12,617	5	,027
Linear-by-Linear Association	2,832	1	,092
N of Valid Cases	1012		

a. 1 cells (8,3%) have expected count less than 5. The minimum expected count is 3,42.

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 18.1 paveikslas

### Modelio kintamieji ir jų ryšiai sprendimo priėmimo etape



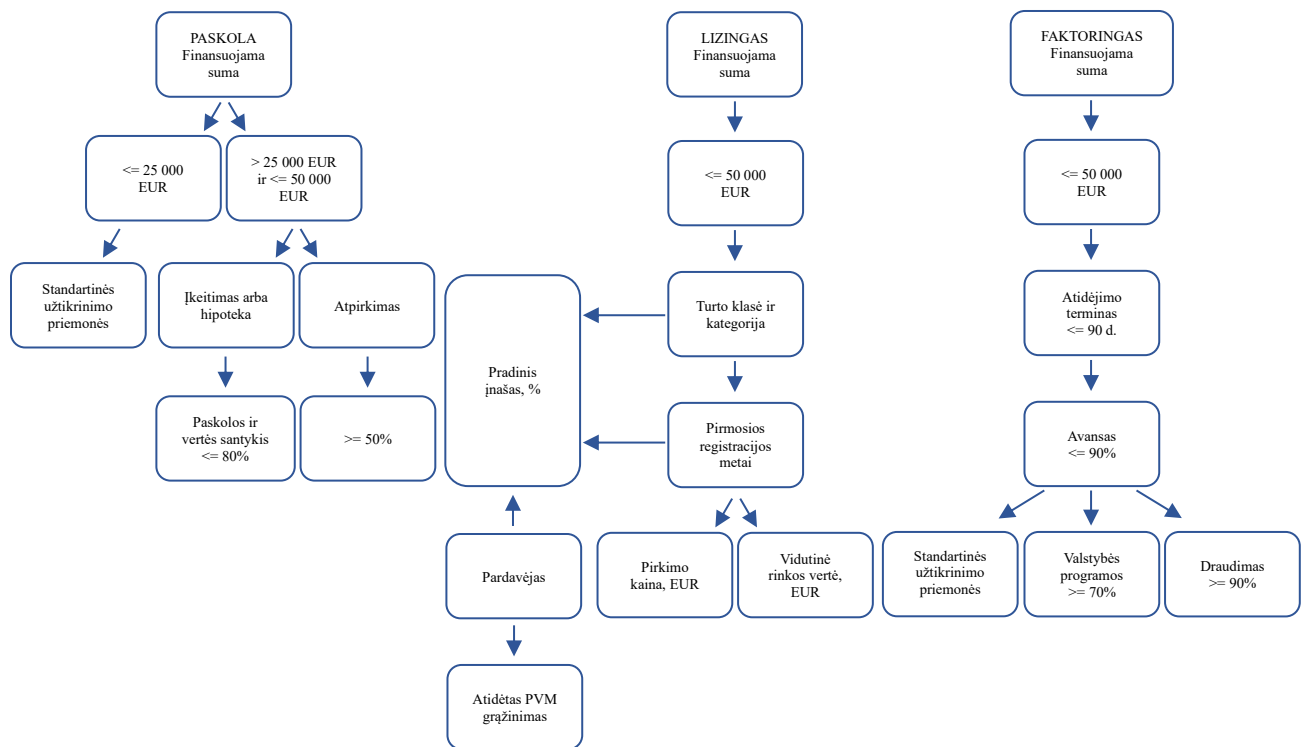
Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 19 priedas. Kompleksinis modelio formavimas

### 19.1 paveikslas

#### Modelio kintamieji pagal informacijos tipą

Juridinė informacija	Neigiama informacija	Mokėjimų istorija
Registracijos šalis Įmonės pavadinimas Įmonės amžius Teisinis statusas Ekonominės veiklos rūšis Pokyčiai JADIS Juridinio asmens dalyvių struktūra Įmonės vadovas Darbuotojų skaičius	Politškai pažeidžiami arba sankcionuoti asmenys Turto areštai Teismai Antstolių raginimai Neigiama viešai prieinama informacija	Juridinio asmens, susijusių įmonių arba asmeninis bankrotas ir (ar) nemokumas Pradelsti mokėjimai: <ul style="list-style-type: none"> <li>Finansinėms institucijoms per 12 mėnesių</li> <li>Aktyvūs &gt;1000 EUR (išskyrus finansines institucijas)</li> <li>Aktyvūs valstybinėms institucijoms &gt;1000 EUR ir &gt; 30 d.</li> </ul> Esamų įsipareigojimų likutis kredito įstaigoje Neigiama mokėjimų istorija (esamiems arba buvusiems klientams)
Finansinių ataskaitų duomenys	Finansavimo pasiūlymas (visiems kredito tipams)	Išorinis reitingas
Pardavimo pajamos, EUR Grynasis pelnas, EUR Turtas, EUR Nuosavas kapitalas, EUR Ilgalaikiai finansiniai įsipareigojimai, EUR EBITDA, EUR Skolos/EBITDA santykis Skolos/EBITDA santykis su naujais įsipareigojimais Nuosavybės koeficientas, %	Kredito tipas Įsipareigojimo terminas, mėnesiai Finansuojama suma, EUR Maksimalus naujas limitas, EUR Visas įsipareigojimų likutis (įskaitant siūlomą limitą) <= 50 000 EUR Fiksuota palūkanų norma, % Minimali palūkanų norma, % Administracinis mokestis, EUR	„Creditinfo“ Lietuva bankroto reitingas
Specialiosios sąlygos pagal kredito tipą		



Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 20 priedas. Specialiosios finansavimo sąlygos

Juridinės informacijos, bankroto reitingo, neigiamos informacijos, mokėjimų istorijos, finansinių ataskaitų bei finansavimo pasiūlymo sudedamosios dalys visiems kredito tipams yra vienodas. Specialiosios finansavimo sąlygos ir apribojimai nustatomi pagal kredito tipą.

### 20.1 lentelė

#### *Specialiųjų finansavimo sąlygų pagal kredito tipą aprašymas*

→ **Paskolos** atveju, kredito apribojimai atsiremia į finansavimo sumos be užstato rėmus (atvira pozicija  $\leq 25\,000\text{ EUR}$ ). Norint pasiskolinti didesnę sumą ( $25\,000\text{ EUR} < x \leq 50\,000\text{ EUR}$ ), klientas turi užtikrinti nedraustą paskolos dalį. Nustatytas konservatyvus paskolos ir vertės santykis demonstruoja paskolos rizikingumą, todėl klientai, neturintys arba nenorintys įkeisti turto, privalo apsiriboti 50% maksimalios finansavimo sumos dydžiu ( $\leq 50\,000\text{ EUR}$ , remiantis automatizuotu procesu). Atpirkimo atveju, taikomas minimalus 50% dydis, tokiu atveju, neužtikrintas paskolos likutis lieka lygus sumai, kurią klientas gali pasiskolinti be papildomų sąlygų ( $\leq 25\,000\text{ EUR}$ ).

→ **Lizingo** specialiųjų sąlygų pasiūlymo ( $\leq 50\,000\text{ EUR}$ ) struktūra iš pirmo žvilgsnio gali pasirodyti paini ir reikalaujanti daug informacijos, tačiau kreditorius, laikydamasis kredito rizikos politikos gairių, turi įvertinti turto likvidumą, kurį dažnu atveju nusako lizinguojamo turto pirmosios registracijos metai. Kita informacija apie turto kategoriją bei atitikimą turto klasei reikalaujama dėl vidutinės rinkos vertės įvertinimo. Kredito rizikos politika apsiriboja pirkimo kaina, kuri vertinama su 20% paklaida nuo turto vertės, kitu atveju – modelis produkto „nepraleidžia“. Praktikoje tai yra dažniausias šio kredito tipo atmetimo faktorius. Iš dalies, modelis galėtų skaičiuoti nuokrypį nuo vidutinės rinkos vertės tik tuomet, kai pirkimo kaina viršija vertę, tačiau iš kitos pusės, per žema turto kaina gali rodyti jo nelikvidumą bei neįmanomus įvertinti pažeidimus.

→ **Faktoringo** apsaugos priemonėmis laikomos valstybės programos ir draudimas. Draudimas yra standartinė faktoringo sąlyga, jei kredito įstaiga yra numačiusi maksimalų 90% sąskaitų avansavimą, tuomet ir draudimo dydis turėtų būti lygus šiam dydžiui. Siekiant apsisaugoti nuo potencialių nuostolių, valstybės programų garantijų suma turėtų būti ne mažesnė nei 70%.

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 21 priedas. Kredito rizikos vertinimo modelio rezultatai

### 21.1 lentelė

*Kredito rizikos vertinimo modelio sprendimų priėmimo pagal informacijos tipą analizės rezultatai*

**Juridinė informacija**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	85	8,4	8,4	8,4
	Taip	927	91,6	91,6	100,0
	Total	1012	100,0	100,0	

**Bankroto reitingas**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	157	15,5	15,5	15,5
	Taip	855	84,5	84,5	100,0
	Total	1012	100,0	100,0	

**Neigiama informacija**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	29	2,9	2,9	2,9
	Taip	983	97,1	97,1	100,0
	Total	1012	100,0	100,0	

**Mokėjimų istorija**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	101	10,0	10,0	10,0
	Taip	911	90,0	90,0	100,0
	Total	1012	100,0	100,0	

**Finansinių ataskaitų duomenys**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	422	41,7	41,7	41,7
	Taip	590	58,3	58,3	100,0
	Total	1012	100,0	100,0	

**Finansavimo pasiūlymas**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	246	24,3	24,3	24,3
	Taip	766	75,7	75,7	100,0
	Total	1012	100,0	100,0	

**Specialiosios sąlygos pagal kredito tipą**

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Ne	105	10,4	10,4	10,4
	Taip	907	89,6	89,6	100,0
	Total	1012	100,0	100,0	

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

## 22 priedas. Atitiktis tarp žmogiškojo sprendimo priėmimo ir kredito rizikos vertinimo modelio

### 22.1 lentelė

*Papildomų užtikrinimo priemonių taikymas – analitiko sprendimai*

<b>Žmogiškasis sprendimas</b>	<b>Įsipareigojimų nevykdymo atvejai   vnt.</b>	<b>Įsipareigojimų vykdymo atvejai   vnt.</b>	<b>Visos patvirtintos paraiškos   vnt.</b>
Teigiamas	3	202	205
Neigiamas	55	535	590
Iš viso:	58	737	795

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 22.2 lentelė

*Modelio sprendimai*

<b>Modelio sprendimas</b>	<b>Įsipareigojimų nevykdymo atvejai   vnt.</b>	<b>Įsipareigojimų vykdymo atvejai   vnt.</b>	<b>Visos patvirtintos paraiškos   vnt.</b>
Teigiamas	8	380	388
Neigiamas	55	569	624
Iš viso:	63	949	1012

Šaltinis: parengta autorės, remiantis atliktu tyrimu.

### 22.3 lentelė

*Papildomų užtikrinimo priemonių taikymas – analitiko sprendimų atitiktis modelio sprendimams*

<b>Žmogus + modelis</b>	<b>Įsipareigojimų nevykdymo atvejai   vnt.</b>	<b>Įsipareigojimų vykdymo atvejai   vnt.</b>	<b>Visos patvirtintos paraiškos   vnt.</b>
Taikomos priemonės SPRENDIMAS Teigiamas	3 iš 8	202 iš 380	205 iš 388
Taikomos priemonės SPRENDIMAS Neigiamas	<b>55 iš 55</b>	<b>535 iš 569</b>	<b>590 iš 624</b>
Iš viso:	58 iš 63	737 iš 949	795 iš 1012

Šaltinis: parengta autorės, remiantis atliktu tyrimu.