

VILNIAUS UNIVERSITETAS

RENATAS ŠPICAS

STATISTINIS MAŽŲ IR LABAI MAŽŲ ĮMONIŲ KREDITO RIZIKOS
VERTINIMO MODELIS LIETUVOS KREDITO UNIJOMS

Daktaro disertacija
Socialiniai mokslai, ekonomika (04 S)

Vilnius, 2017

Disertacija rengta 2013–2017 m. Vilniaus universitete.

Mokslinė vadovė:

prof. dr. Rasa Kanapickienė (Vilniaus universitetas, socialiniai mokslai, ekonomika – 04S).

Tekstą redagavo:

prof. dr. Gabija Bankauskaitė.

PADĖKA

Ši disertacija – ketverių metų darbo rezultatas. Kaip ir dauguma kitų disertacijų, ši negalėtų būti laikoma tik vieno žmogaus darbu. Visą šį laikotarpį mane palaikė daug aplinkinių žmonių, kuriems noriu išreikšti nuoširdžią padėką.

Pirmiausiai norėčiau padėkoti savo šeimai, kuri visą disertacijos rengimo laikotarpį mane suprato, palaikė ir toleravo mano nuolatinį užimtumą. Šiai disertacijai rengti skirtas laikas daugiausiai buvo atimtas iš jų.

Nuoširdžiai dėkoju šio darbo mokslinei vadovei prof. dr. (HP) Rasai Kanapickienei už šešerius metus bendro darbo, vertingus patarimus, mokslines diskusijas, palaikymą ir neišsenkantį optimizmą. Tik profesorės dėka ryžausi pradėti ir pabaigiau rašyti šį darbą.

Esu labai dėkingas recenzentams prof. habil. dr. Remigijui Čiegiui ir doc. dr. Eduardui Freitakui už vertingas pastabas, patarimus ir man skirtą laiką. Recenzantai ženkliai prisidėjo gerinant disertacijos kokybę, visos darbe likusios klaidos yra mano.

Už tyrimui suteiktus duomenis esu labai dėkingas UAB „Creditinfo Lietuva“ darbuotojams – Daliai Mažeikaitei ir Anatolijui Kisieliui bei Lietuvos Centrinės kredito unijos vadovui Mindaugui Vijūnui. Už skirtą laiką ir atvirumą esu labai dėkingas tyrime dalyvavusių kredito unijų darbuotojams.

Norėčiau padėkoti ir prof. dr. Gabijai Bankauskaitei už įdėmiai perskaitytą ir profesionaliai suredaguotą disertacijos tekstą.

Be abejo, labai ačiū visiems Vilniaus universiteto Kauno fakulteto kolegoms už jaukią darbo aplinką, gerą nuotaiką ir palaikymą.

Nuoširdžiai,

Renatas, 2017 m.

TURINYS

SANTRUMPOS.....	6
PAGRINDINĖS SĄVOKOS	7
LENTELIŲ SĄRAŠAS	9
PAVEIKSLŲ SĄRAŠAS	10
PRIEDŲ SĄRAŠAS	12
IVADAS	13
1. TEORINIAI KREDITO RIZIKOS VERTINIMO ASPEKTAI KREDITO UNIJOSE	26
1.1. Rizikos raiškos ypatybės kooperatinėje bankininkystėje.....	26
1.1.1. Rizikos apibrėžimas ir jos rūšys bankininkystės veikloje	26
1.1.2. Kredito rizikos ryšys su kredito unijų veiklos bruožais ir kitomis rizikos rūšimis.....	32
1.1.3. Teoriniai kredito rizikos vertinimo aspektai skirtingais kredito unijų raidos etapais	38
1.2. Teoriniai statistinio kredito rizikos vertinimo modelio sudarymo pagrindai.....	45
1.2.1. Statistinio kredito rizikos vertinimo modelio sudarymo koncepcija	45
1.2.2. Kredito rizikos vertinimo modelio kintamųjų pasirinkimo teoriniai aspektai	51
1.2.3. Teoriniai klasifikavimo metodų pagrindai.....	61
1.3. Teoriniai kredito rizikos vertinimo modelio įvertinimo pagrindai	69
2. KREDITO RIZIKOS VERTINIMO MODELIO SUDARYMO METODOLOGIJA	80
2.1. Kredito unijų sektoriaus analizės metodologija.....	82
2.2. Statistinio kredito rizikos vertinimo modelio kūrimo metodologija	89
2.2.1. Modelio kūrimo imties sudarymas.....	89
2.2.2. Nepriklausomų kintamųjų pasirinkimas ir įtraukimas į modelį.....	99
2.2.3. „Gerų“ ir „blogų“ paskolų apibrėžimai.....	106
2.2.4. Klasifikatoriaus pasirinkimas.....	110
2.2.5. Modelio patikrinimo metodai	115

2.2.6. Rangų skalės sudarymas	121
Empirinio tyrimo hipotezės.....	125
3. ĮMONIŲ KREDITO RIZIKOS VERTINIMO MODELIS LIETUVOS	
KREDITO UNIJOMS	126
3.1. Kredito rizikos vertinimo problematika Lietuvos kredito unijų sektoriuje	
.....	126
3.1.1. Kredito unijų sektoriaus struktūros ir verslo paskolų portfelio analizė ..	126
3.1.2. Kredito unijų taikomų kredito rizikos vertinimo metodų ir reikalavimų kuriamam modeliui analizė.....	132
3.1.3. Tikslinių kreditavimo segmentų ir „blogos“ paskolos apibrėžimas kredito unijų sektoriuje.....	139
3.2. Statistinis įmonių kredito rizikos vertinimo modelis Lietuvos kredito	
unijoms.....	145
3.2.1. Modelio kūrimo imties sudarymas.....	145
3.2.2. Kintamųjų atranka ir statistinio modelio sudarymas	152
3.2.3. Optimalaus lūžio taško nustatymas ir rangų skalės sudarymas	161
3.3. Sukurto modelio taikymas Lietuvos kredito unijų sektoriuje	165
3.3.1. Sukurto modelio grįžtamasis įvertinimas ir atitikimas kredito unijų poreikiams.....	165
3.3.2. Sukurto modelio taikymas ir integravimo į sprendimų paramos sistemą rekomendacijos	171
IŠVADOS.....	178
Literatūra.....	186
Priedai	208

SANTRUMPOS

ABCUL – Didžiosios Britanijos kredito unijų asociacija (angl. *Association of British Credit Unions Limited*);

AUC – plotas po gavėjų charakteristikų kreivė (angl. *area under curve*);

BCBS – Bazelio bankų priežiūros komitetas (angl. *Basel Committee on Banking Supervision*);

CAP – kaupiamojo tikslumo kreivė (angl. *cumulative accuracy profiles*);

CUNA – JAV kredito unijų asociacija (angl. *Credit Unions National Association*);

EAD – paskolos dydis įsipareigojimo neįvykdymo atveju (angl. *exposure at default*);

DPD – paskolos įmokų vėlavimas dienomis (angl. *days per due*);

EMP – maksimalaus tikėtino pelno metodas (angl. *expected maximum profit*);

ILCU – Airijos kredito unijų lyga (angl. *Irish League of Credit Unions*);

IV – informacijos vertės rodiklis (angl. *information value ratio*);

KRVM – kredito rizikos vertinimo modelis;

KU – kredito unija;

LB PT – Lietuvos banko Priežiūros tarnyba;

LCKU – Lietuvos Centrinė kredito unija;

LGD – nuostolis nemokumo atveju (angl. *loss given default*);

LKU – asociacija „Lietuvos kredito unijos“;

MAR – trūkumas esant atsitiktinumui (angl. *missing at random*);

ODF – Faktinio įsipareigojimo neįvykdymo dažnis;

PD – nemokumo tikimybė (angl. *probability of default*);

R – atviro kodo (GNU licencija) programinė aplinka statistiniams ir matematiniams skaičiavimams;

ROC – gavėjų charakteristikų kreivė (angl. *receiver operating characteristic curve*);

ROI – investicijų grąža (angl. *return on investment*);

TP, TN, FP, FN – galimi keturi binarinio klasifikavimo sprendimo tipai: teisingas teigiamas (angl. *true positive*), teisingas neigiamas (angl. *true negative*), klaidingas teigiamas (angl. *false positive*), klaidingas neigiamas (angl. *false negative*);

WOCCU – pasaulio kredito unijų asociacija (angl. *World Council of Credit Unions*);

WOE – įtakos svoris (angl. *weight of evidence*);

ŽTF – žmogiškieji, finansiniai ir technologiniai ištekliai.

PAGRINDINĖS SĄVOKOS

Bloga paskola – paskola, turinti objektyvių neveiksnios paskolos požymių, t. y. iš paskolos kylančios prievolės nėra vykdomos taip, kaip apibrėžta paskolos sutartyje. Blogos paskolos apibrėžimas dažniausiai naudojamas apibrėžiant priklausomą statistinio modelio kintamąjį (Choy, Laik, 2010; Valvonis, 2006; Dzidzevičiūtė, 2013). Apibrėžiant blogą paskolą, dažniausiai taikomas rodiklis yra 90 dienų paskolos įmokų vėlavimas (Sorokin, 2014; Nguen, 2014; Rajan ir kiti, 2010; Bloem, Freeman, 2005; Thomas, 2009, 2000; Jiménez ir kiti, 2014; Beck ir kiti, 2013; Leow, Crook, 2016, 2014; Bendendo, Bruno, 2012; Khemraj, Pasha, 2009).

Ekspertinis kredito rizikos vertinimo modelis – taisyklių pagrindu ir ekspertiniais metodais (remiantis specialistų / ekspertų nuomone) suformuota kredito rizikos vertinimo sistema, priskirianti analizuojamai paskolai kredito rizikos lygio požymį. Kreditoriai, neturintys galimybių sukurti statistinio modelio, gali pasirinkti savo veikloje taikyti ekspertinį modelį (Dzidevičiūtė, 2013; Valvonis, 2008).

Klasifikavimo matrica (angl. confusion matrix) – plačiai naudojamas binarinių modelių klasifikavimo tikslumo vertinimo metodas, parodantis modelio teisingai ir klaidingai klasifikuotų objektų skaičių. Matricos eilutės atitinka modelio prognozuotų „gerų“ ir „blogų“ skolininkų kiekius, lentelės skiltys – faktines skolininkų būkles. Atitinkamai, eilučių ir skilčių sankirtos parodo jau aptartas modelio diskriminacinės galios savybes – TP, TN, FP, FN. Iš klasifikavimo lentelės turinio išskaičiuojami rodikliai, parodantys diskriminacines modelio savybes pasirinktame lūžio taške (plačiau: Vebraken ir kiti, 2014; Mileris, 2009; Powers, 2007; Sobehart, Keenan, 2001).

Kreditavimo sprendimų priėmimo palaikymo sistema – visuma metodinių ir techninių priemonių, palaikančių sprendimų dėl kreditavimo priėmimo procesą. Dažniausiai kredito rizikos vertinimo modelis yra sprendimų priėmimo palaikymo sistemos dalis (plačiau žr. Danėnas, 2013).

Kredito unija – kooperatiniais pagrindais veikianti finansų įstaiga, teikianti paslaugas savo nariams.

Kreditoriaus verslo poreikiai – visuma kredito rizikos vertinimo modelio savybių, kurias turi atitikti kuriamas modelis, kad būtų tinkamas naudoti kreditoriaus veikloje.

Lūžio taškas (*angl. cut off point*) – skolininko PD reikšmė, kuri nepriimtina kreditoriui. Skolininkams, kurių PD yra lygi arba didesnė nei nustatytas lūžio taškas, paskolos nėra suteikiamos. Lūžio taškas nustatomas PD reikšmei arba rangui / reitingui.

Maksimalaus tikėtino pelno metodas (EMP) – Verbraken ir kiti (2014; 2013) pasiūlytas metodas, leidžiantis ekonominės naudos atžvilgiu nustatyti optimalų lūžio tašką atsižvelgiant į *apriorinę PD* (*angl. prior probability*), *tikėtiną LGD* ir *kreditavimo pelningumą (ROI)*. Metodas yra ROC/AUC metodų substitutas sprendžiant kredito rizikos vertinimo uždavinius (šis metodas išsamiai pristatomas disertacijos 2.2.6 dalyje).

Nemokumo tikimybė (*angl. probability of default*) – tikimybė, kad per nustatytą laikotarpį paskola nebus grąžinta sutartyje numatytomis sąlygomis (plačiau Valvonis, 2006; BCBS, 2004).

Socialinės kontrolės elementas (arba socialinis ryšys) – visuma subjektyvių veiksmų, padedančių kreditoriui įvertinti ir valdyti kredito riziką. Mokslinėje literatūroje, analizuojančioje kooperatinės bankininkystės klausimus, visuotinai pripažįstama, kad kredito unijoms veikiant mažose bendruomenėse (atitinka *ankstyvąją kredito unijų raidos stadiją*), socialinis kontrolės elementas (arba socialinis ryšys) padeda kredito unijoms tiksliau vertinti ir valdyti kredito riziką. Šis ryšys silpsta kredito unijoms natūraliai vystantis ir pereinant į *tranzitinę* bei *brandos* raidos stadijas (plačiau Fonteyne, 2007; MacPherson, 2007; Sibbald ir kiti 2002). Dėl šios priežasties disertacijos autorius laikosi požiūrio, kad, pereinant į *tranzitinę* ir *brandos* raidos stadijas, unijų veikloje turėtų būti taikomi statistiniai kredito rizikos vertinimo modeliai.

LENTELIŲ SĄRAŠAS

1 lentelė. Rizikos sampratos apibrėžimai.....	27
2 lentelė. Kredito unijų socialinės funkcijos atlikimui taikyti metodai	39
3 lentelė. Kredito unijų raidos etapai, jiems būdingos savybės ir kredito rizikos vertinimo ypatybės.....	42
4 lentelė. Skirtingi kredito rizikos vertinimo modelio sudarymo požiūrių pavyzdžiai	50
5 lentelė. Blogos paskolos apibrėžimai kredito rizikos vertinimo modeliuose	53
6 lentelė. Mokslinėje literatūroje minimi galutinio nepriklausomų kintamųjų rinkinio formavimo metodai.....	57
7 lentelė. Dažniausiai taikomos neurono signalo aktyvavimo funkcijos.....	66
8 lentelė. Klasifikavimo tikslumo vertinimo matrica	73
9 lentelė. Duomenų struktūros matrica	94
10 lentelė. Modelio diskriminacinių savybių tam tikrame atskyrimo taške (C) įvertinimo rodikliai	118
11 lentelė. Modelio patikimumo įvertinimo metodai	121
12 lentelė. Lietuvos kredito unijų sektoriaus verslo paskolų portfelio struktūra pagal vidutinį vėlavimo dienų kiekį ir skirtingus kredito unijų segmentus.....	130
13 lentelė. Kredito unijų verslo paskolų portfelio kokybės ir ekspertinės vertinimo įtakos analizės rezultatų apibendrinimas	134
14 lentelė. Rizikos vertinimo tikslais KU naudojami išoriniai duomenų šaltiniai ir jų svarba	138
15 lentelė. Migracijų tikimybių matrica.....	147
16 lentelė. Kuriamam modeliui keliamų reikalavimų sąvadas	153
17 lentelė. Atrinktų modelio kintamųjų ir jiems priskirtų koeficientų sąvadas	158
18 lentelė. Siūlomo modelio klasifikavimo tikslumo lentelė prie lūžio taško 0,4....	160
19 lentelė. Siūlomo modelio pagrindiniai klasifikavimo tikslumo rodikliai prie lūžio taško 0,4	161
20 lentelė. Modelio rangų skalė	163
21 lentelė. Sudaryto modelio klasifikavimo tikslumo lentelė lūžio taške T	166
22 lentelė. Sudaryto modelio pagrindiniai klasifikavimo tikslumo rodikliai lentelė lūžio taške T	167
23 lentelė. Sukurto modelio atitikimo keltiems reikalavimams sąvadas	169

PAVEIKSLŲ SĄRAŠAS

1 pav. Disertacijos struktūros ir loginės sekos schema.....	23
2 pav. Kredito unijų bruožai ir jų ryšys su tipinėmis kredito unijų veiklos rizikomis	34
3 pav. Statistinio kredito rizikos vertinimo modelio sudarymo žingsniai bei naudojama analitinė informacija.....	46
4 pav. Veiksniai, darantys įtaką modelio sudarymo metodų, naudojamų duomenų pasirinkimui ir modelio charakteristikoms	48
5 pav. Kintamųjų parinkimo metodų grupės.....	60
6 pav. Dirbtinio neurono modelis	65
7 pav. „Blogų“ ir „gerų“ skolininkų pasiskirstymas pagal modelio priskiriamus reitingus.....	72
8 pav. Ryšys tarp parametrinių modelio diskriminacinės galios vertinimo metodų...	75
9 pav. Galimi ekonominiai klaidingo ir teisingo klasifikavimo poveikiai.....	77
10 pav. Statistinio įmonių kredito rizikos vertinimo modelio kredito unijoms sudarymo eiga	80
11 pav. Kredito unijų sektoriaus tyrimo atlikimo eiga	82
12 pav. Modelio sudarymui naudojami duomenys	91
13 pav. Pasirinktą modeliavimo segmentą sudarančių duomenų struktūra	93
14 pav. Galimų naudoti nepriklausomų kintamųjų sąvado sudarymo procesas	100
15 pav. Dažniausiai naudojami santykiniai finansiniai rodikliai	102
16 pav. Dažniausiai analizuojamų finansinių santykinų rodiklių grupės	103
17 pav. Kintamųjų, naudojamų modeliui sudaryti, atrankos etapai.....	103
18 pav. „Blogo“ skolininko apibrėžimo formavimo logika.....	107
19 pav. Papildomo įmonių veiklos tęstinumo įvertinimo algoritmas	109
20 pav. Skirtingi „gerų“ ir „blogų“ skolininkų apibrėžimo formavimo variantai	109
21 pav. Modelyje taikomo klasifikatoriaus pasirinkimo logika.....	111
22 pav. Klasifikavimo metodai, jų tipai ir taikymo dažnis	113
23 pav. Klasifikatorių tikslumas pastaruosiuose moksliniuose tyrimuose	114
24 pav. Modelio įvertinimo eiga.....	115
25 pav. Dažniausiai naudojami modelio patikimumo vertinimo metodai	117
26 pav. Struktūrinis analizuotų kredito unijų pasiskirstymas pagal priskirtus požymius	127

27 pav. Taisyklių pagrindu sudaryto modelio ir faktinio sprendimų priėmimo neatitikimai kredito unijų veikloje	133
28 pav. Pagrindinės taisyklių pagrindu sudaryto modelio ir faktinio sprendimų priėmimo neatitikimų priežastys.....	136
29 pav. Veiksniai, darantys įtaką kredito rizikos vertinimo modelio sukūrimo ar tobulinimo problemiškamui Lietuvos KU sektoriuje	137
30 pav. Paskolų gavėjų segmentų pasiskirstymas kredito unijų sektoriuje pagal vertinimo metodus, priskyrimą tiksliniam segmentui ir problemiškamą kredito rizikos atžvilgiu.....	140
31 pav. Maksimalus toleruotinas paskolos mokėjimų pradelsimas Lietuvos kredito unijų sektoriuje.....	143
32 pav. Maksimalios toleruotinos paskolos įmokų pradelsimų trukmės Lietuvos kredito unijų sektoriuje, išskiriant skirtingų dydžių kredito unijų segmentus..	144
33 pav. Vidutiniai mokėjimų pradelsimai skirtingais paskolų brandos etapais Lietuvos kredito unijų sektoriuje	146
34 pav. Optimalaus stebėjimo ir imties formavimo laikotarpių nustatymas pagal vidutinį 30 dienų vėlavimo rodiklį.....	147
35 pav. Modelio kūrimo, sudarymo ir testavimo imčių formavimo eiga	151
36 pav. Individualios diskriminacinės rodiklių galios analizės rezultatai taikant IV metodą.....	155
37 pav. Koreliacinė nepriklausomų kintamųjų matrica	156
38 pav. Modelio gavėjų charakteristikos kreivė (ROC) ir modelio prognozuotų tikimybių grafikas	160
39 pav. Sudaryto modelio ir rangų skalės grafinis apibendrinimas	164
40 pav. Sudaryto modelio taikymo, vertinant Lietuvos kredito unijų verslo paskolas, rezultatai: gavėjų charakteristikų kreivė ir modelio prognozuotų tikimybių grafikas.....	166
41 pav. Dabartinis paraiškos apdorojimo procesas LKU sistemoje	174
42 pav. Rekomenduojamas paraiškos paskolai gauti apdorojimo procesas integruojant sukurtą modelį.....	175

PRIEDŲ SĄRAŠAS

- 1 priedas. Lietuvos kredito unijų apklausos anketa.
- 2 priedas. Paskolų gavėjų segmentų pasiskirstymas kredito unijų sektoriuje pagal vertinimo metodus, priskyrimą tiksliniam segmentui ir problemišumą kredito rizikos atžvilgiu, iškiriant skirtingus KU dydžius.
- 3 priedas. Kintamųjų įtraukimas į logistinės regresijos modelį.
- 4 priedas. Programavimo kodas (R): kintamųjų atranka, modelio sudarymas ir validavimas.
- 5 priedas. Apskaičiuoti kintamųjų WOE dydžiai ir jų interpretacija.
- 6 priedas. Papildomas analizuotos literatūros sąrašas.

IVADAS

Temos aktualumas. Paskolų teikimas nariams – pagrindinė kredito unijų veiklos sritis. Apibendrinus Lietuvos banko rengtas kredito unijų veiklos apžvalgas už pastaruosius penkis metus, matyti, kad palūkanos iš suteiktų paskolų generuoja didžiausią dalį šių įstaigų pajamų, o paskolos nariams sudaro didžiausią dalį kredito unijų turto (LB, 2016; 2015; 2014; 2013; 2012), todėl teisinga teigti, jog iš kreditavimo veiklos kylanti rizika yra reikšmingiausia rizika, su kuria susiduria kredito unijos vykdydamos tipinę veiklą. Suprantama, kad siekiant užtikrinti tiek pavienių kredito unijų, tiek ir viso sektoriaus veiklos tęstinumą bei stabilumą, būtina tinkamai vertinti ir valdyti prisiimamą kredito riziką.

Mokslinėje literatūroje (O’Connel, 2012; Fonteyne, 2007; MacPherson, 2007) teigiama, kad kredito unijos, veikdamos bendruomenės ribose, gali lengviau valdyti informacijos asimetriją ir tai suteikia joms galimybę efektyviai vertinti kredito riziką pasitelkus ekspertinius metodus. Literatūroje teigiama ir tai, kad augdamos kredito unijos pradeda veikti už bendruomenės ribų, tada socialinis ryšys, padedantis tiksliau vertinti kredito riziką kredito unijoms esant mažo dydžio, silpsta (O’Connel, 2012; Fonteyne, 2007; MacPherson, 2007). Fonteyne (2007) teigia, kad kredito unijų veiklos modelis buvo kurtas mažoms įstaigoms, kurios dabar tapo sudėtingais finansų konglomeratais. Šie faktai leidžia preziumuoti, kad ekspertiniai kredito rizikos vertinimo metodai veikia tik unijų ankstyvajame raidos etape ir tik tol, kol unijos turi galimybę savo veikloje naudoti socialinę kontrolės elementą informacijos asimetrijai mažinti. Dėl šios priežasties tvari kredito unijų raida negali vykti be tinkamų kredito rizikos vertinimo modelių. Kaupelytė (2007) disertacijoje teigia, kad šiuo metu Lietuvos kredito unijų sektorius yra tranzitiniame raidos etape. McKillop ir Wilson (2015; 2011) po penkerių ir vėliau, po devynerių metų, taip pat teigė, kad Lietuvos kredito unijų sektorius vis dar yra tame pačiame etape. Tad galima daryti prielaidą, kad kredito unijų

sektoriaus raida stagnuoja dėl negebėjimo tinkamai vertinti ir valdyti kredito riziką.

Lietuvos kredito unijų gebėjimą vertinti kredito riziką galima apibendrinus Lietuvos banko, kaip pagrindinės sektoriaus priežiūros institucijos, dokumentus. Išanalizavus Lietuvos banko Priežiūros tarnybos (toliau LB PT) kredito unijų sektoriuje taikytų poveikių priemonių istoriją nuo 2013 m. sausio 1 d. iki 2016 m. gegužės 1 d. (lb.lt, 2013–2016) matyti, kad per 30 mėnesių laikotarpį LB PT kredito unijoms taikė 32 poveikio priemones, iš kurių 25 buvo susijusios su netinkamu kredito rizikos vertinimu. Tai sudaro 78 % visų poveikio priemonių, taikytų sektoriuje. Lietuvos bankas metinėse ir ketvirtinėse kredito unijų ir Lietuvos Centrinės kredito unijos veiklos apžvalgose nuolatos pastebi nepakankamą kredito unijų gebėjimą tinkamai įvertinti prisiimamą kredito riziką, per didelį kredito rizikos apetitą bei nepakankamą kapitalą augantiems nuostoliams dėl neveiksnių paskolų amortizuoti (LB, 2016; 2015; 2014; 2013; 2012). Šios ir kai kurios kitos priežastys paskatino LB PT inicijuoti kredito unijų sektoriaus reformą. Realizuodamas šį tikslą, Lietuvos bankas parengė kredito unijų sektoriaus reformos projektą ir paskelbė jį dokumente viešai diskusijai. Lietuvos bankas, aprašydamas teikiamų unijų reformų kontekstą ir pagrindimą, pristatė penkis pagrindinius kredito unijų reformą lėmusius veiksnius, iš kurių trys yra susiję su netinkamu kredito rizikos vertinimu ir valdymu (LB, 2014a).

Šiuolaikinėje mokslinėje literatūroje, analizuojančioje kredito rizikos vertinimo klausimus (Dzidzevičiūtė, 2013; Valvonis, 2008; Thomas, 2009; Anderson, 2007; Siddiqi, 2006), pripažįstama, kad statistiniai kredito rizikos vertinimo modeliai atskiria patikimus ir nepatikimus skolininkus tiksliau, nei ekspertiniai modeliai. Kredito įstaigos, taikydamos tikslesnius modelius, veikia efektyviau: pirma, suteikiama mažiau paskolų nepatikimiems klientams (pirmo tipo klaida), antra, tikslesnis vertinimas leidžia suteikti daugiau paskolų patikimiems klientams (išvengiant antro tipo klaidos) ir taip didinti kredito įstaigos pajamas iš palūkanų. Statistinius metodus rekomenduojama taikyti ir

Bazelio bankų priežiūros komiteto rekomendaciniuose dokumentuose (BCBS, 2004).

Statistinio modelio tinkamumas naudoti kredito įstaigos veikloje daugiausiai priklauso nuo dviejų veiksnių tipų: pirma – tikslumo, kuris ženkliai dalimi priklauso nuo naudojamos statistinės imties kokybės ir atitikimo kredito įstaigos tikslinio kreditavimo segmentui ir antra – atitikimo kredito įstaigos verslo poreikiams. Mokslinėje literatūroje pripažįstama, kad kredito unijų veiklos modelis skiriasi nuo komercinių bankų ar kitų finansinių institucijų veiklos modelių (Fonteyne 2007). Todėl galima teigti, kad kredito rizikos vertinimo modeliai, siūlomi šiuolaikinėje mokslinėje literatūroje, nėra tinkami taikyti Lietuvos kredito unijų sektoriuje dėl skirtumų šių kredito įstaigų verslo poreikiuose ir naudotų statistinių imčių neatitikimo kredito unijų tiksliniam kreditavimo segmentui. Teoriniu požiūriu, su kredito rizika susijusiomis problemomis dažniausiai turėtų susidurti kredito unijos, esančios tranzitiniame ir brandžiam išsivystymo etape, tačiau šis klausimas iki šiol nebuvo nagrinėtas nei Lietuvos, nei užsienio tyrėjų.

Mokslinės problemos ištyrimo lygis. Visuotinai teigiama, kad šiuolaikinio statistinio kredito rizikos vertinimo pradininkas yra Altman, 1968 metais pasiūlęs diskriminantinį kredito rizikos vertinimo modelį įmonėms¹ (Altman, 1968). Po Altmano diskriminantinius modelius taip pat siūlė Martin (1977), Tafler ir Tisshaw (1977), Springate (1978), Lis (1982), Fulmer (1984) ir kiti (Mackevičius, 2007; Altman, 2000; Altman, Saunders, 1998). Logistinės regresijos modelį kredito rizikos vertinimui pirmasis 1974 metais pasiūlė Chesser, po jo vieni pirmųjų šiam tikslui logistinę regresiją taikė: Martin (1997), Ohlson (1980), Zmijewski (1984), West (1985), Koh (1991), Platt ir kiti (1991), Hopwood ir kiti (1994) (Dzidzevičiūtė, 2010; Mackevičius, Silvanavičiūtė, 2006; Lennox, 1999; Altman, Saunders, 1998). Statistiniai metodai vertinant kredito riziką yra plačiai taikomi ir naujausiuose

¹ Dėl Altman modelių pritaikymo paprastumo, nesudėtingo interpretavimo ir universalumo, autoriaus pasiūlyti modeliai sparčiai populiarėjo ir buvo plačiai taikomi moksliniuose tyrimuose. Šios disertacijos rengimo metu, anot Prado ir kiti (2016), Altman buvo labiausiai cituojamas autorius kredito rizikos vertinimo srityje.

moksliniuose tyrimuose (Fernandes, Artes, 2016; Sousa ir kiti, 2016; Petropoulos ir kiti, 2016; Sohn ir kiti, 2016; Xiao ir kiti, 2016; Lessmann ir kiti, 2015; Danėnas, Garšva, 2015; Manab ir kiti, 2015; Fei ir kiti, 2015; Florez-Lopez, Ramon-Jeronimo, 2015; Tomczak, Zięba, 2015; Harris, 2015; Van Vlasselaer ir kiti, 2015; Wang ir kiti, 2015; Bekhet, Eletter, 2014; Gupta ir kiti, 2014; Niklis ir kiti, 2014; Ju, Sohn, 2014; Verbraken ir kiti, 2014).

Dirbtinio intelekto metodus, skirtus prognozuoti nemokumą, vienas pirmųjų taikė Tam (1991). Jis sudarė neuronų tinklo modelį, skirtą prognozuoti komercinių bankų nemokumą. Be neuronų tinklų, vertinant kredito riziką plačiai taikomi ir kiti dirbtinio intelekto metodai, populiariausi yra sprendimų medžiai (Florez-Lopez, Ramon-Jeronimo, 2015; Tomczak, Zięba, 2015) ir atraminių vektorių mašinos (Cardoso ir kiti, 2016; Petropoulos ir kiti, 2016; Xiao ir kiti, 2016). Dirbtinio intelekto metodai sparčiai populiarėja, tačiau jų praktinis naudojimas kredito įstaigų veikloje yra ribotas dėl žemo rezultatų paaiškinamumo ir to nulemta nesuderinamumo su Bazelio bankų priežiūros komiteto rekomendacijomis. Dirbtinio intelekto metodų populiarumą lemia jų aukštas tikslumas ir praktinio taikymo galimybės tose finansų įstaigose, kurioms galioja kitoks teisinis reguliavimas, nei rekomenduojama Bazelio dokumentuose. Įprastai šios finansų įstaigos nepriima valstybės draustų indėlių, pvz., sutelktinio finansavimo ir tarpusavio skolinimo bendrovės, greitųjų kreditų ir lizingo paslaugų įmonės.

Vienas pirmųjų Lietuvos tyrėjų, analizavusių kredito rizikos vertinimo metodus bankroto prognozavimo kontekste, buvo Grigaravičius (2003; 2003a), taikęs logistinės regresijos modelį prognozuoti įmonių bankrotą. Pažymėtinas Valvonio (Valvonis 2004, 2006, 2006a, 2008a, 2009; Savickaitė, Valvonis, 2007; Kamienas, Valvonis, 2004; Jasevičienė, Valvonis, 2003) mokslinis įdirbis analizuojant kredito rizikos vertinimo metodų aspektus Lietuvos komercinių bankų kontekste. Disertacijoje (Valvonis, 2008) mokslininkas pateikė apibendrintą kredito rizikos vertinimo modelį, taikomą Lietuvos komerciniuose bankuose. Dzidzevičiūtė (2010; 2010a; 2013) išsamiai analizavo statistinių kredito rizikos vertinimo modelių sudarymo ir taikymo

komerciniuose bankuose metodiką. Disertacijoje (Dzidzevičiūtė, 2013) ji pasiūlė Lietuvos įmonių statistinį kredito rizikos vertinimo modelį, sudarytą logistinės regresijos pagrindu. Danėnas ir Garšva (2015; 2012; 2011; 2010; 2009) bei Danėnas ir kiti (2011) kredito rizikos vertinimui taikė atraminių vektorių mašinas ir tyrė jų veikimo tikslumą. Publikacijas kredito rizikos vertinimo tematika pastaruoju metu paskelbė šie Lietuvos tyrėjai: Butkus ir kiti (2014); Mileris (2014; 2012; 2009); Budrikienė, Paliulytė (2012); Bivainis, Garškaitė (2010); Mackevičius (2010); Vasiliauskaitė, Cvilikas (2008); Garškaitė (2008); Mackevičius, Silvanavičiūtė (2006); Merkevičius ir kiti (2004); Jasevičienė, Valvonis (2003). Lietuvoje pastaruoju metu buvo apginta nemažai disertacijų, kuriose analizuoti kredito rizikos vertinimo klausimai: Danėnas (2013), Dzidzevičiūtė (2013), Stulpinienė (2013), Mileris (2011), Pridotkienė (2009), Merkevičius (2008), Valvonis (2008), Valužis (2007), Grigaravičius (2003). Pažymėtina, kad kredito rizikos vertinimo klausimai dažniau analizuojami matematikos ir informatikos, nei ekonomikos ar vadybos mokslo kryptių disertacijose.

Kredito rizikos vertinimo klausimai mokslinėje literatūroje tapo ženkliai populiariesni nuo 2009 metų. Tai gali būti susiję su globalia finansine krize, turinčia ryšį su prastu kredito rizikos vertinimu (Prado ir kiti, 2016). Nors kredito rizikos vertinimo klausimai yra plačiai analizuoti praeityje, tačiau ir šiuo metu jie išlieka aktualūs tyrėjams. Kredito rizikos vertinimas kooperatinėje bankininkystėje buvo tirtas tik fragmentiškai. Lietuvoje kredito unijų veiklos ypatybes ir su jomis susijusias rizikas analizavo Kėdaitis, Žilinskas (2013), Kaupelytė, McCarthy (2006). Bendrai kredito unijų veiklą pastaruoju metu tyrė Jasevičienė ir kt. (2015, 2015a, 2014); Jasevičienė (2014); Dubauskas (2012); Igarytė, Ramanauskas (2011); Lukoševičius (2005); Bubnys, Kaupelytė (2004); Levišauskaitė, Kaupelytė (2003). Tačiau šiuose tyrimuose nebuvo analizuojamos įmonių kredito rizikos vertinimo problemos kredito unijose.

Užsienyje atraminių vektorių mašinų pagrindu suformuotą kredito rizikos vertinimo modelį Barbadoso kredito unijoms siūlė Harris (2013), neuronų

tinklų pagrindu kredito rizikos vertinimo modelį kredito unijų veiklai siūlė Desai ir kiti (1996). Pažymėtina, kad nors šie autoriai ir naudojo kredito unijų tikslinius segmentus atitinkančias duomenų imtis, tačiau sudarant minėtus kredito rizikos vertinimo modelius, nebuvo analizuotos kredito unijų veiklos ypatybės, problematika, išorinė aplinka bei kredito unijų verslo poreikiai ir reikalavimai kuriamiems modeliams. Be to, šie modeliai nėra tinkami naudoti Lietuvos kredito unijų sektoriuje dėl reguliacinių ir tikslinio kreditavimo segmento neatitikimų. Pažymėtina ir tai, kad Lietuvoje kredito unijų asocijuotais nariais gali būti juridiniai asmenys, atitinkantys mažų ir labai mažų įmonių apibrėžimą (Žin., 2016, XII-2567), kaip apibrėžta LR Smulkiojo ir vidutinio verslo plėtros įstatyme (Žin., 1998, 105-4689). Iki šiol šiam įmonių segmentui Lietuvoje kredito rizikos vertinimo modeliai kurti nebuvo, taip pat šio segmento kontekste nebuvo analizuoti ir kiti su kredito rizikos vertinimu susiję klausimai.

Apibendrinant galima teigti, kad apskritai mokslinėje literatūroje pasigendama tyrimų, analizuojančių kredito rizikos vertinimo klausimus kredito unijose ir kooperatinėje bankininkystėje. Iki šiol tyrėjai nėra analizavę kredito unijų verslo poreikių kredito rizikos vertinimo modeliams, nėra sudaryta ir modelių, atitinkančių kredito unijų tikslinį kreditavimo segmentą – mažas ir labai mažas įmones. Tyrėjų dėmesio pasigendama ne tik kredito rizikos analizės srityje – iki šiol kooperatinės bankininkystės kontekste buvo mažai analizuoti ir kiti bankinės rizikos tipai, pvz., operacinė, rinkos, likvidumo rizika, kt.

Mokslinis problemos apibrėžimas. Kredito unijų evoliucijos procese, joms plečiant veiklą už bendruomenės ribų, socialinės kontrolės elementas iš dalies arba pilnai nustoja veikti, todėl kredito unijos susiduria su sunkumais vertindamos kredito riziką. Atsižvelgus į tai, šiame disertaciniame tyrime sprendžiama problema yra statistinių kredito rizikos vertinimo modelių kūrimas ir taikymas kredito unijose, atsižvelgus į jų veiklos specifiškumą, verslo poreikius bei išorinę aplinką, kurioje jos veikia.

Disertacijos objektas yra įmonių kredito rizikos vertinimas kredito unijose taikant statistinius kredito rizikos vertinimo modelius.

Disertacijos tikslas – išanalizavus kredito unijų kredito rizikos vertinimo problematiką, poreikius ir reikalavimus, sukurti statistinį įmonių kredito rizikos vertinimo modelį Lietuvos kredito unijoms.

Disertacijos uždaviniai:

1. Apibrėžti rizikos sampratą ir rūšis bei teoriškai išanalizuoti skirtingų rizikos rūšių raišką kredito unijų veikloje.
2. Teoriškai išanalizuoti kredito rizikos vertinimo aspektus skirtingais kredito unijų raidos etapais.
3. Apibrėžti ir teoriškai išanalizuoti pagrindinius statistinio kredito rizikos vertinimo modelio sudarymo etapus, metodus bei veiksnius, veikiančius modelio sudarymo metodų ir naudojamų duomenų pasirinkimą.
4. Išanalizavus Lietuvos kredito unijų veiklos problematiką, nustatyti kredito unijų poreikius, lūkesčius ir reikalavimus statistiniam kredito rizikos vertinimo modeliui.
5. Atsižvelgus į nustatytus kredito unijų verslo poreikius, lūkesčius ir reikalavimus kredito rizikos vertinimo modeliui, suformuoti modelio kūrimo imtį ir parinkti tinkamus modelio sudarymo metodus.
6. Sukurti statistinį kredito rizikos vertinimo modelį Lietuvos kredito unijoms.
7. Pritaikyti sukurtą modelį analizuojant Lietuvos kredito unijų verslo paskolų portfelį bei atlikti grįžtamąjį modelio įvertinimą.

Tyrimo metodai. Rengiant šį darbą analizuota mokslinė literatūra, teisės aktai, dokumentai, juose esanti informacija abstrahuota, sisteminta bei kritiškai nagrinėta. Taikyti ir kiti bendramoksliniai tyrimo metodai.

Tiriant Lietuvos kredito unijų sektorių buvo taikomi kiekybiniai tyrimo metodai: apklausa (interviu) bei apklausa telefonu. Apklausų duomenys apibendrinti ir susisteminti suformuojant statistinę imtį. Apdorojant statistinius duomenis naudotasi MS Excel, bei R programiniais paketais. Tyrimo rezultatai pavaizduoti vizualiai pasitelkus MS Excel, R ir Circos programinius paketus.

Sudarant statistinį kredito rizikos vertinimo modelį, taikyti matematiniai ir statistiniai metodai: Markovo grandinės, duomenų vizualinio atvaizdavimo metodai, entropijos matu paremti metodai, regresinė analizė. Modelio patikimumas pamatuotas taikant binarinio klasifikavimo modelių įvertinimo metodus: gavėjų charakteristikų kreivę ir matą, parodantį plotą po šia kreive (AUC), Gini indeksą, prognozuotų tikimybių grafiką. Siekiant nustatyti optimalų lūžio tašką, taikytas Tikėtino maksimalaus pelno (EMP) apskaičiavimo metodas.

Mokslinis naujumas. Atsižvelgus į jau atliktus mokslinius tyrimus ir nustatytas fragmentiškai tirtas sritis, šios disertacijos mokslinis naujumas apibrėžiamas taip:

1. Išskirti kredito unijų veiklos bruožai bei jų priežasties ir pasekmės ryšys su specifinėmis kredito unijų veiklos rizikomis.
2. Išanalizuoti kredito rizikos vertinimo ypatumai skirtingais kredito unijų raidos etapais.
3. Nustatyti veiksniai, lemiantys kredito rizikos vertinimo metodų ir duomenų pasirinkimą kuriant kredito rizikos vertinimo modelius.
4. Atlikus išsamų Lietuvos kredito unijų sektoriaus tyrimą, nustatyti probleminiai Lietuvos kredito unijų veiklos aspektai, tiksliniai kreditavimo segmentai bei reikalavimai statistiniam kredito rizikos vertinimo modeliui.
5. Sukurta ir detalai pristatyta nauja „gerų“ ir „blogų“ įmonių apibrėžimų formavimo metodika mažų ir labai mažų įmonių segmentui.
6. Sudarytas statistinis mažų ir labai mažų įmonių kredito rizikos vertinimo modelis naudojant statistinę imtį, atitinkančią Lietuvos kredito unijų tikslinį kreditavimo segmentą bei atsižvelgus į kredito unijų reikalavimus ir poreikius.
7. Pateiktos modelio integravimo į kredito unijų sprendimų priėmimo paramos sistemą rekomendacijos leidžia į kreditavimo sprendimų priėmimo procesą įtraukti Centrinę kredito uniją. Pasiūlytas integracijos

metodas taip pat suteikia galimybę efektyviau išnaudoti plataus kredito unijų tinklo galimybes dalijantis atmestomis praraiškomis.

Pagrindiniai ginamieji teiginiai:

1. Ekspertinis kredito rizikos vertinimas kredito unijų veikloje gali būti efektyvus tik tol, kol kredito unija yra pradiniam rados etape ir turi galimybę naudoti socialinės kontrolės elementą informacijos asimetrijai mažinti.
2. Šiuolaikiniai kredito rizikos vertinimo modeliai (taip pat sudaryti ir taikomi kitų rūšių kredito įstaigose bei kredito biuruose) nėra tinkami naudoti Lietuvos kredito unijų veikloje, kadangi juos kuriant neatliekama analizė iš trijų perspektyvų: kredito įstaigos, išorės veiksmų bei homogeninės rizikos grupės.
3. Sukurtas statistinis mažų ir labai mažų įmonių kredito rizikos vertinimo modelis yra efektyvus įrankis vertinti kredito riziką kredito unijoms esant tranzitiniame ir brandos rados etapuose.

Praktinis darbo reikšmingumas. Šio darbo tyrimų rezultatai autoriui padėjo sukurti interaktyvią kredito rizikos vertinimo modeliavimo sistemą, kuri sėkmingai įdiegta skirtingų tipų kredito įstaigose Lietuvoje ir užsienyje. Šiuo metu sistema adaptuojama centrinių kredito unijų veiklai siekiant vertinti ir valdyti kredito riziką sisteminiu lygmeniu.

Pagrindinės tolimesnių tyrimų kryptys:

Sukurtą modelį pritaikyti dichotominei kredito unijų prigimčiai, įtraukiant sukuriamos socialinės vertės veiksnį.

Svarbiausios tyrimo prielaidos ir apribojimai:

1. Atliekant kredito unijų apklausą šalyje veikė 72 kredito unijos, sudariusios tyrimo populiaciją. Dėl tyrimo tikslumo buvo siekiama apklausti visą populiaciją, tačiau tyrime dalyvauti sutiko ir buvo apklaustos 56 kredito unijos.
2. Vienas iš kredito unijų nehomogeniškumo požymių yra tas, kad jos turi skirtingus tikslinius kreditavimo segmentus. Nepaisant to, apklausos duomenys generalizuoti visai populiacijai, sudarytas apibendrintas

kredito unijų verslo poreikių sąvadas, kuris panaudotas kuriant *įmonių* kredito rizikos vertinimo modelį. (Ignoruojant tai, jog kai kurie respondentai nekreditavo juridinių asmenų).


3. Kredito unijų veikla yra ribojama teritoriniu principu (Žin. 1995). Kuriant įmonių kredito rizikos vertinimo modelį, naudotasi įmonių statistine imtimi, apimančia bendroves iš skirtingų Lietuvos geografinių vietovių. Taigi buvo daroma prielaida, kad skirtingose geografinėse vietovėse veikiančios mažos ir labai mažos įmonės sudaro vieną homogeninį rizikos segmentą.
4. Sudarant modelį naudota maksimali, pagal faktines galimybes, imtis – 1252 įmonės.
5. Kadangi turimoje statistinėje imtyje nebuvo atmetų paraiškų duomenų, atitinkamai, kuriant modelį atmetų paraiškų įtraukimo problema nebuvo analizuota.

Darbo struktūra. Darbas susideda iš įvado, trijų dalių, išvadų, literatūros sąrašo ir priedų (1 pav.).

Pirmoje darbo dalyje vystoma teorinė diskusija. Šioje dalyje apibrėžiama rizikos samprata, išskiriami tipiniai kredito unijų veiklos bruožai, nurodomi jų priežasties ir pasekmės ryšiai su kredito unijų veiklos rizikomis, išanalizuoti kredito rizikos vertinimo ypatumai skirtingais kredito unijų raidos etapais. Išskirtas ekspertinių kredito rizikos vertinimo metodų ribotumas, išnagrinėti kredito rizikos vertinimo modelio sudarymo etapai ir metodai. Išanalizuota statistinio kredito rizikos vertinimo modelio sudarymo eiga bei nustatyti veiksniai, lemiantys modelio sudarymo metodus ir naudojamus duomenis. Pirmoje dalyje taip pat analizuojami pagrindiniai modelio formavimo metodai, išskiriami jų privalumai, trūkumai ir taikymo apribojimai.

Antroje darbo dalyje pateikiama modelio sudarymo metodika. Šioje dalyje formuojama kredito unijų sektoriaus tyrimo metodologija, kurią sudaro kredito unijų klasterizavimas, verslo paskolų portfelio tyrimas ir kredito unijų apklausa. Šioje dalyje taip pat pateikiama statistinio modelio sudarymo metodika ir iškeliamos tyrimo hipotezės.

Trečioje, empirinėje darbo dalyje, pateikiami tyrimo rezultatai. Pirma, pristatomi kredito unijų sektoriaus rezultatai, suteikę galimybę parinkti kredito unijoms tinkamus modelio sudarymo metodus ir duomenis. Antra, sudarytas logistinės regresijos modelis ir atliktas jo išankstinis įvertinimas. Trečia, modelis pritaikytas vertinant kredito unijų verslo paskolų portfelį bei atliktas grįžtamasis modelio įvertinimas. Ketvirta, pateikiamos modelio taikymo rekomendacijos ir pasiūlytas modelio integravimo į kredito unijų sprendimų priėmimo paramos sistemą būdas.



1 pav. Disertacijos struktūros ir loginės sekos schema

Mokslo tyrimų aprobavimas ir sklaida

Mokslinės informacijos instituto (ISI) pagrindinio sąrašo leidiniuose:

1. Špicas, R., Kanapickienė, R., Vijūnas, M., Kirka, R. (2017). Development of enterprise credit risk assessment model for Lithuanian credit unions. *Transformations in Business & Economics* (straipsnis spaudoje).

Kituose mokslinės informacijos instituto (ISI) duomenų bazėse referuojamose leidiniuose:

1. Kanapickienė, R., Špicas, R. (2016). Bankruptcy Prediction Models: Case of the Construction and Transport & Storage Sector in Lithuania. *Perspectives of Business and Entrepreneurship Development – 2016*, p. 344–357.
2. Špicas, R.; Vijūnas, M.; Kanapickienė R. (2016). Setting optimal performance period and bad loan definition for credit risk assessment model for Lithuanian credit unions. *Perspectives of Business and Entrepreneurship Development – 2016*, p. 713–728.

Kituose recenzuojamose mokslo leidiniuose:

1. Špicas, R.; Vijūnas, M. (2016). Ankstyvoji kredito unijų istorija ir veiklos modelio raida. *Ekonomika ir vadyba: aktualijos ir perspektyvos*, nr. 1 (38), p. 118–128.
2. Špicas, R.; Kanapickienė, R.; Ivaškevičiūtė, M. (2015). Filter Methods of Variable Selection for Enterprise Credit Risk Prediction. *Perspectives of Business and Entrepreneurship Development*. 15th International Conference at Brno University of Technology, Brno, p. 147–161.

Tarptautinėse mokslinėse konferencijose skaityti pranešimai

1. Konferencijoje „Ernesto Galvanausko tarptautinė mokslinė konferencija“ (Šiauliai, 2016). Pranešimo tema „Ankstyvoji kredito unijų istorija ir veiklos modelio raida“.
2. Konferencijoje “New Challenges of Economic and Business Development” (Ryga, 2016). Pranešimo tema “Setting optimal

performance period and bad loan definition for credit risk assessment model for Lithuanian credit unions”.

3. Konferencijoje “New Challenges of Economic and Business Development” (Ryga, 2016). Pranešimo tema “Bankruptcy Prediction Models: Case of the Construction and Transport & Storage Sector in Lithuania”.

1. TEORINIAI KREDITO RIZIKOS VERITINIMO ASPEKTAI KREDITO UNIJOSE

1.1. Rizikos raiškos ypatybės kooperatinėje bankininkystėje

1.1.1. Rizikos apibrėžimas ir jos rūšys bankininkystės veikloje

Etimologijos žodyne (etymonline.com), enciklopedijoje (Webster's, 1993) ir mokslinėje literatūroje, analizuojančioje angliško žodžio *risk* etimologiją (Skjong, 2005; Cline, 2004) teigiama, jog žodis *rizika* yra kilęs iš italų kalbos žodžio *risico*, *riscio*, *rischio* ir ispaniško *riesgo*². Atitinkamai šie italų ir ispanų kalbų žodžiai žodžiai kilę iš senovės graikų *ρίζικόν*, kurio pažodinis vertimas yra „šaknis, uola, akmuo“, bei *ρίζα*, verčiamo kaip „uolos papėdė“. Šie senovės graikų žodžiai metaforiškai galėtų būti suprantami ir kaip „sunkumas įveikiant jūrą“. Atitinkamai žodis *rizikuoti*, atsižvelgus į prancūzų *risquer* ir italų *risicare*, galėtų būti suprantamas kaip „laviruoti tarp uolų“ arba „įveikti jūrą“ (Skjong, 2005)³.

Vokiečių kalbos žodžio *rysigo* apibrėžimas pateikiamas 1507 m.: „verslumas, veikimas, siekimas, tikintis ekonominės naudos“ (Skjong, 2005). Anot Cline (2004), angliško žodžio *risk* reikšmė rašytine forma pirmą kartą apibrėžta 1661 m. Blount anglų kalbos žodyne kaip pavojus arba šansas⁴. Suprantama, jog turinio prasme rizikos sąvoka buvo minima ir daug anksčiau. Žmonių būtis visais laikais buvo susijusi su įvairių rūšių pavojais ir nepageidautinomis įvykių baigtimis, todėl nenuostabu, jog rizikos sąvokos įvairios formos ir sinonimai minimi seniausiuose veikaluose, pvz., Homero kūrinyje „Odiseja“ (VIII a. p. Kr.) (Skjong, 2005), Platono „Respublika“ (Cline, 2004). Toliau (žr. 1 lent.) pateikiami įvairiuose šaltiniuose aptikti šiuolaikiniai žodžio „rizika“ apibrėžimai.

² Vasmerio žodynas teigia, jog angliškas žodis *risk* yra kilęs ir iš prancūzų žodžio *risque*, tačiau kitose šaltiniuose ši informacija nėra pateikiama.

³ Platesnė etimologinė diskusija vystoma Cline (2004).

⁴ Orig. (angl.): *risk – peril, jeopardy, danger, hazard, chance* (Cline, 2004).

Nemažai tyrėjų (Gudelytė, Valužis, 2012; Rutkauskas, Stasytytė, 2011), įvairiuose kontekstuose analizuojančių rizikos sampratą, pastebi, kad vieno universalios rizikos apibrėžimo nėra. Kaplan (1997) primena, jog įsisteigus tarptautinei Rizikos vertinimo bendruomenei, buvo iškeltas tikslas apibrėžti rizikos sampratą. Šiam tikslui įgyvendinti buvo sukurta speciali darbo grupė, kuri po ketverių metų darbo pateikė kontraversišką išvadą, jog „geriau rizikos sampratos neapibrėžti“ ir rekomendavo kiekvienam tyrėjui apibrėžti rizikos sampratą savaip, priklausomai nuo tyrimo objekto ir konteksto.

1 lentelė. Rizikos sampratos apibrėžimai

Šaltinis	Apibrėžimas
Oksfordo anglų kalbos žodynas (Black ir kiti, 2009)	Netekimų, traumos, ar kitų nepageidautinų aplinkybių įvykio galimybė, šansas ar situacija, lemianti šias aplinkybes.
Crouhy ir kiti (2014)	Grąžos kintamumas, lemiantis nenumatytus nuostolius.
Coleman (2011)	Rizika – tai galimybė, jog pelno ar nuostolio rezultatai skirsis nuo planuotų. Rizika yra neapibrėžtumas ar atsitiktinumas, kuris matuojamas ateities pelno ar nuostolio nuokrypių dydžiais.
Kungwani (2014)	Rizika gali būti suprantama kaip tam tikros vertės praradimas lyginant su tam tikros vertės įgijimo ar išlaikymo galimybe. Vertė (kuri gali būti suprantama kaip sveikatos būklė, socialinis statusas, ekonominė gerovė, emocinė būklė ir pan.) prarandama, įgyjama ar išlaikoma prisiimant riziką (ne)atliekant tam tikrą veiksmą, kuris gali būti numatytas ar nenumatytas. Taip pat rizika gali būti suprantama kaip sąveika su neapibrėžtumu.
ISO 31000 (iso.org, 2016)	Rizika yra neapibrėžtumo įtaka tikslams. Įtaka suprantama kaip teigiamas ar neigiamas nuokrypis nuo laukiamo rezultato. Tikslai gali apimti skirtingas sritis: finansinius, sveikatos ir saugumo, pan. Rizika dažnai siejama su įvykiais ar jų kombinacijomis bei su tų įvykių (ar jų kombinacijų) pasekmėmis. Rizika dažnai išreiškiama kaip įvykių ir su jais susijusių pasekmių įvykimo tikimybė.
Rizikos analitikų bendruomenė (SRA, 2015)	Manoma, kad rizika analizuojama kaip galimos pasekmės arba efektas, darantis įtaką kažkam, ką žmonės vertina. Šios pasekmės arba efektas susiję su ateities įvykiu arba veikla (suprantama plačiaja prasme, siekiant apimti, pvz., gamtos reiškinius ar programinės įrangos veikimą). Pasekmės arba efektas dažnai vertinami lyginant rezultatus su planinėmis, tikslinėmis arba etaloninėmis reikšmėmis, didžiausią dėmesį skiriant neigiamiems ir/ar nepageidaujamiems pokyčiams. Vertinant riziką visais atvejais būna galimas bent vienas nepageidaujamas rezultatas. Rizika – nepageidautinos baigties galimybė. Rizika yra reiškinio pasekmė ir su tuo susijęs neapibrėžtumas. Rizika – tai neapibrėžtumas dėl reiškinio pasekmių ir jų įtakos kažkam, kas vertinama žmonių. Rizika – tai nuokrypis nuo etaloninio rezultato, susijęs su reiškinio baigties neapibrėžtumu.
Webster's, 1993	Nuostolio arba susižalojimo galimybė (<i>Possibility to loss or injury</i>).

Sudaryta autoriaus pagal lentelėje nurodytus šaltinius.

Kaip matyti iš pateiktų rizikos apibrėžimų, rizika yra glaudžiai susijusi su neapibrėžtumu ir tikimybe. Tikimybių teorija formavosi XIX amžiuje. Iš šio laikotarpio paminėtini Keynes (1920), Knight (1921), Kolmogorov (1933) darbai. Vienas pagrindinių šio laikotarpio mokslinių diskusijų objektų yra tikimybės subjektyvumas – vieni šalininkai tikimybę analizavo kaip objektyvų veiksni, kuris gali būti statistiškai išmatuojamas, kiti – kaip subjektyvų veiksni, kurio neįmanoma statistiškai išmatuoti. Kaip pastebi Rutkauskas ir Stasytė (2011), Knight (1921) pirmasis atskyrė rizikos ir neapibrėžtumo sampratą, išryškino jų skirtumus ir net apibrėžė tai kaip priešingybes. Knight (1921) išskyrė pamatuojamą ir nepamatuojamą neapibrėžtumą: pirmąjį, pamatuojamą, jis siūlo vadinti rizika, o nepamatuojamą – neapibrėžtumu.

Išanalizavus aukščiau išvardytus rizikos apibrėžimus, galima išskirti bendrus jų bruožus:

1. rizika visada yra susijusi su tam tikrais reiškiniiais, įvykiais ar veiksmiais, kurie gali nulemti rizikos atsiradimą;
rizika yra susijusi su neapibrėžtumu dėl ateities;
rizika gali lemti planuojamų rezultatų pokyčius tiek teigiamai, tiek ir neigiamai, tačiau analizuojant riziką dažniausiai akcentuojami neigiami rizikos aspektai;
analizuojant riziką bent vienas neigiamas įvykio baigties aspektas yra būtinas.

Apibendrinant galima pateikti rizikos apibrėžimą pagal šios disertacijos tyrimo kontekstą:

2. rizika – tikimybė, jog ateityje faktiniai kredito įstaigos veiklos rezultatai skirsis nuo planinių;
rizika gali būti statistiškai išmatuojama ją išreiškiant tikimybės išraiška, kuri gali būti nustatyta analizuojant veiksnius, sukeliamus kredito įstaigos veiklos ir lemiančius rizikos atsiradimą.

Mokslinėje literatūroje, analizuojančioje bankinės veiklos rizikos klausimus, aptinkamos skirtingos bankinės rizikos klasifikacijos, tačiau galima teigti, jog daugumoje šaltinių (BCBS, 2013 p. 57; Gudelytė, Valužis, 2012; Glantz, Mun, 2010; Goyal, 2010; Valvonis 2008; Altman, Hotchkiss, 2006)

išskiriamos šios pagrindinės rizikos rūšys: *operacinė, rinkos, likvidumo ir kredito*. Šios, dažniausiai išskiriamos rizikos rūšys, bus aptartos detaliau.

Operacinė rizika – tai rizika patirti tiesioginius ir netiesioginius nuostolius dėl neteisingai suprojektuotų ir (ar) nesuderintų verslo procesų, neefektyvios vidaus kontrolės, techninių gedimų, nesankcionuotų personalo veiksmų ar išorinių poveikių (Бармамов ir kiti, 2009). Lietuvos bankas valdybos nutarime „Dėl kapitalo pakankamumo skaičiavimo bendrųjų nuostatų“ operacinę riziką apibrėžia kaip riziką patirti nuostolį dėl netinkamų arba neįgyvendintų vidaus kontrolės procesų, darbuotojų klaidų ir (ar) neteisėtų veiksmų bei informacinių sistemų veiklos sutrikimų arba dėl išorės įvykių įtakos (Žin. 2006, 42-5442). Abu šie šaltiniai išskiria vadybos riziką, t. y. vidaus kontrolės riziką, apimančią darbuotojų kompetencijos pakankumą, vidaus kontrolės sistemų veiksnumą ir efektyvumą, techninių gedimų riziką. Lietuvos bankas prie operacinės rizikos priskiria ir neteisėtus veiksmus, t. y. nusikalstamos veiklos riziką bei informacinių sistemų sutrikimus, šių veiksmų pirmasis šaltinis nenumato.

Rinkos rizika bendriausiąja prasme yra netekimo rizika, kurią prisiima rinkos dalyvis dėl galimos turimų aktyvų rinkos kainos pasikeitimo. Bazelio bankų priežiūros komitetas (BCBS, 2016) rinkos riziką apibrėžia taip: rinkos rizika – tai rizika, atsirandanti dėl rinkos kainų pasikeitimo. Rinkos rizikos objektu gali tapti: nemokumo rizika, palūkanų normų rizika, nuosavo kapitalo rizika, valiutų kurso rizika, išvestinių vertybinių popierių rizika. Oksfordo ekonomikos žodyne (Black ir kiti, 2009) rinkos rizika apibrėžiama kaip kainos pasikeitimo rizika, prisiimama kiekvieno rinkos dalyvio, užimančio trumpąją ar ilgąją prekybinę poziciją bei neapsidraudusiojo išvestinėmis finansinėmis priemonėmis. Žodyne taip pat apibrėžiama rinkos rizika kaip aktyvų pabrangimo tikimybė, prisiimama rinkos dalyvio, neįsigijusio reikiamo aktyvo.

Likvidumo rizika bendrąja prasme – tai rizika, kad bendrovė nesugebės įvykdyti savo trumpalaikių įsipareigojimų (Mackevičius, 2007). Bazelio bankų priežiūros komitetas (BCBS, 2008) išskiria finansinio likvidumo (angl. *funding risk*) ir rinkos likvidumo (angl. *market risk*) rizikas. *Finansinio likvidumo*

rizika laikoma rizika, jog bankas (ar kita įstaiga, priežiūros aspektu laikoma banku, pvz., kredito unija) negalės efektyviai įvykdyti numatomų ar nenumatomų, esamų ar būsimų finansinių prievolių, neigiamai nepaveikiant kasdienės banko veiklos ar jo finansinio stabilumo. *Rinkos likvidumo rizika* – rizika, jog bendrovė nesugebės realizuoti turto rinkos kaina dėl nepakankamo rinkos gylio ar rinkos sukrėtimų (angl. *market disruption*) (BCBS, 2008).

Kredito rizika išreiškia netekimų galimybę sandorio šaliai neįvykdžius savo įsipareigojimų. Bendrąja prasme kredito rizika gali būti suprantama kaip tikimybė neatgauti skolos arba užmokesčio už į skolą parduotas prekes arba paslaugas (Mackevičius, 2007). Oksfordo finansų ir bankininkystės žodyne (Gastineau, Kritzman, 1999) kredito rizika apibrėžiama kaip rizika, kad sandorio šalis taps nemoki, atidės skolos grąžinimą arba skolos grąžinimo terminas bus pratęstas dėl prastos skolininko finansinės būklės. Lietuvos bankas valdybos nutarime „Dėl kapitalo pakankamumo skaičiavimo nuostatų“ kredito riziką apibrėžia kaip tikimybę, kad sandorio šalis nesugebės atsiskaityti sutartyje nustatyta tvarka (Žin. 2006, 42-5442). Pirmiausia, prie kredito rizikos priskiriami kreditoriaus netekimai, patiriami dėl skolininko nemokumo arba bankroto. Suteikus kreditą, kredito rizikos lygis yra būtinas duomuo skaičiuoti kredito įstaigos kapitalo pakankumą, todėl skolininko kredito reitingo sumažėjimas irgi priskiriamas prie kredito rizikos, nes jis mažina paskolos buhalterinę vertę. Prie šios rizikos taip pat priskiriami netekimai, patirti dėl skolininko išankstinio kredito grąžinimo, kuris lemia gautinų palūkanų netekimą.

Mokslinėje literatūroje (Altman, Hotchkiss, 2006; Ammann, 2001; Ganguin, Bilardello, 2004; ir kiti) kredito rizika pripažįstama kaip viena reikšmingiausių rūšių komercinių bankų veikloje. Bazelio bankų priežiūros komitetas 1997 metais „Pagrindiniuose bankininkystės priežiūros principuose“ kredito riziką taip pat nurodo kaip pagrindinę riziką, su kuria susiduria komerciniai bankai. Bendrąja prasme kredito rizika gali būti suprantama kaip tikimybė neatgauti skolos arba užmokesčio už į skolą parduotas prekes arba paslaugas (Mackevičius, 2007). Tačiau ne tik bankai ar kredito institucijos

susiduria su kredito rizika veikiant rinkos ekonomikos sąlygomis. Su kredito rizika susiduria visi rinkoje veikiantys ūkio subjektai, taip pat ir neprofesionalūs finansų rinkų dalyviai, kurių pagrindinė veikla nėra susijusi su kreditavimu.

Kredito rizika yra tiesiogiai susijusi su skolininko mokumu. Bendriausia prasme mokumas apibūdinamas kaip sugebėjimas mokėti, galimybė ar pajėgumas padengti mokestinius reikalavimus. J. Mackevičius mokumą apibūdina kaip įmonės sugebėjimą turimomis mokėjimo priemonėmis apmokėti trumpalaikius ir ilgalaikius įsipareigojimus (Mackevičius, 2007). B. Ganguin ir J. Bilardello išskiria du kredito rizikos tipus: nemokumo riziką (angl. *default risk*) ir padengimo tikimybę (angl. *recovery prospects*) (Ganguin, Bailardello, 2005). Nemokumo rizika apima riziką, susijusią su sandorio šalies noru ir galimybe vykdyti savo įsipareigojimus nustatytais terminais.

Apibendrinant galima teigti, kad mokslinėje literatūroje esama įvairių rizikos apibrėžimų, susijusių su juos formuojančiu kontekstu. Šio disertacinio tyrimo atveju rizika yra apibrėžiama kaip tikimybė, jog ateityje faktiniai kredito įstaigos veiklos rezultatai skirsis nuo planinių. Rizika gali būti statistiškai išmatuojama ją išreiškiant tikimybės išraiška, kuri gali būti nustatyta analizuojant veiksnus, sukeliamus kredito įstaigos veiklos ir lemiančius rizikos atsiradimą.

Aptartos pagrindinės rizikos rūšys: operacinė, rinkos, likvidumo ir kredito. Apžvelgti svarbiausi šių rizikos rūšių tyrimų komercinėje bankininkystėje moksliniai šaltiniai. Galima tvirtinti, kad šių rizikos rūšių analizė kooperatinės bankininkystės srityje iki šiol nagrinėta itin mažai. Be to, dėl išskirintinių kredito unijų veiklos bruožų, dėl raiškos formos šios rizikos rūšys iš esmės skiriasi nuo tradicinės komercinės bankininkystės. Todėl tolesniuose skyriuose šių rizikų raiška kredito unijų veikloje bus aptarta detaliau.

1.1.2. Kredito rizikos ryšys su kredito unijų veiklos bruožais ir kitomis rizikos rūšimis

Kooperatinės bankininkystės veikla plačiąja prasme suprantama kaip tapati komercinės bankininkystės veiklai, todėl analizuojant kooperatinę bankininkystę yra tikslinga išskirti tas pačias rizikos rūšis, kurios išskirtos šio darbo 1.1.1. skyriuje, t. y.: operacinė, rinkos, likvidumo ir kredito rizikos. Šias rizikos rūšis šiuo atveju tikslinga išskirti ir dėl to, kad jos išskiriamos Bazelio bankų priežiūros komiteto dokumentuose, kurie *mutatis mutandis* taikomi ir kitoms bankininkystės rūšims, šiuo atveju – kooperatinei bankininkystei, taip pat ir kredito unijoms. Analizuojant rizikos raiškos formas kredito unijų veikloje, neatsietina kredito unijų veiklos išskirtinumo aplinkybė. Esant specifinėms finansų įstaigoms, tradicinės rizikos rūšys kredito unijų veikloje pasireiškia sąlygojamos kitokių rizikos veiksnių bei specifinių kredito unijų veiklos bruožų. Tai įvertinus, analizę tikslinga pradėti nuo kredito unijų veiklos bruožų apibrėžimo, po to teoriškai išanalizuoti kredito unijų veiklos bruožų priežasties ir pasekmės ryšius su kredito unijų veiklai būdingais rizikos veiksniais bei specifinėmis veiklos rizikomis.


Mokslinėje literatūroje, analizuojančioje kooperatinės bankininkystės klausimus, dažniausiai išskiriami šie tipiniai kredito unijų bruožai: *kooperatinė nuosavybės struktūra, kooperatinė valdymo forma, dichotominė kredito unijų prigimtis, asociacijos ryšys, mažas organizacijos dydis ir specifinis teisinis reguliavimas* (McKillop, Wilson, 2015; Fonteyne, 2007; Kupelytė, 2007; MacPherson, 2007; Baarda, 2006; Davis, 2001; Wolf, 1983). Šių bruožų ryšys su kredito unijoms būdingomis rizikomis pavaizduotas 1 paveiksle. Nustatytos specifinės kredito unijų veiklos rizikos, sugrupuotos pagal aptartas bankininkystės rizikos rūšis: kredito, operacinę, rinkos ir likvidumo. Išskirti kredito unijų bruožai ir jų priežasties bei pasekmės ryšiai su minėtomis rizikomis bus aptarti išsamiau. Pažymėtina, kad minėti išskirti kredito unijų veiklos bruožai yra nebūdingi komerciniams bankams.

Kooperatinė nuosavybės forma. Kredito unijos savo teisine forma gali būti tik kooperatyvas (Žin. 2016, XII-2567; Fonteyne, 2007; Baarda, 2006; Davis, 2001). Tipinis kooperatyvų bruožas yra tas, kad jų savininkai yra nariai. Įvertinus kredito unijų kontekstą, nariai yra kredito unijos klientai: indėlininkai, skolininkai bei kitų paslaugų vartotojai. Kredito unijos kapitalą formuoja pajinis kapitalas, privalomieji rezervai ir kapitalas, perkainojimo rezervas ir nepaskirstytasis pelnas – nuostolis (AAT, 2016, 2 VAS). Anot McKillop, Wilson (2015) ir Taylor (1971), kredito unijos narių pajai paprastai sudaro didžiąją kredito unijų kapitalo dalį. Nustatyta, kad Lietuvoje, rengiant šią disertaciją, kredito unijų kapitalas taip pat didžiąja dalimi buvo suformuotas iš kredito unijų narių pajinių įnašų (LB, 2016, 2015, 2014, 2013, 2012). 2016 m. kredito unijų įstatymo redakcijoje (Žin. 2016, XII-2567) nurodoma, jog kredito unijos turėtų siekti, kad 9/10 kredito unijos nuosavo kapitalo sudarytų rezervinis ir atsargos kapitalas. Šiuo rodikliu apribojama ir kredito unijų teisė išmokėti nariams dividendus – dividendai negali būti mokami, kol 90 proc. unijos kapitalo neformuoja rezervinis ir atsargos kapitalas.

Šios aplinkybės, ribojančios kredito unijų galimybes išmokėti dividendus (2 pav., 1) kartu riboja ir tvaraus nuosavo kapitalo pritraukimo galimybes (2 pav., 2). Tikėtina, jog nariai gali būti finansiškai nesuinteresuoti investuoti lėšas į kredito unijos kapitalą, iš anksto žinodami, jog galimybė gauti ekonominę grąžą dividendų pavidalu yra ribota. Todėl atsiranda nuosavo kapitalo pritraukimo problematika, ribojanti kredito įstaigos plėtros perspektyvas (2 pav., 15).

Kredito unijos kaip sprendimą praktikuoja didesnio kapitalo pritraukimą iš paskolų gavėjų (2 pav., 3) (LB, 2013), tačiau tokia praktika yra ydinga ir didina nepalankaus pasirinkimo riziką (angl. *adverse selection*) (2 pav., 4): tikėtina, kad narys, sutikęs prisiimti kredito unijos veiklos riziką, yra rizikingesnis, nei tas, kuris analogiškos rizikos neprisiims, o kredito įstaiga, siekdama pritraukti daugiau nuosavo kapitalo, gali prisiimti didesnę kredito riziką, nei įprastai.

Kooperatinė valdymo forma lemia demokratinį kredito unių valdymą, kai kredito unių vadovybė, dažniausiai veikianti savanorystės pagrindais (neatlygintinai), laikantis kooperatyvuose taikomų demokratiško valdymo principų⁵, yra renkama kooperatyvo narių. Anot Fonteyne (2007), kredito unių sukuriamą ekonominę naudą yra perduodama iš kartos į kartą (angl. *intergenerational endowment*). Tai yra organizacijos be „galutinių“ savininkų, o vadovai gali būti matomi kaip tam tikros formos įgaliotiniai. Tokia organizacinė struktūra lemia *interesų persidengimą* (angl. *overlap between constituencies*), kuris atsiranda, kai unių nariai (savininkai), turintys tam tikras nario teises, yra ir kredito unių klientai, vadovai ar darbuotojai (Bauer, 2008; Fonteyne, 2007; Baarda, 2006; Davis, 2001) (2 pav., 5).



2 pav. Kredito unių bruožai ir jų ryšys su tipinėmis kredito unių veiklos rizikomis

Sudaryta autoriaus.

⁵ Vieno nario – vieno balso principas.

Ši organizacinė struktūra, anot daugelio autorių, analizavusių kredito unijų veiklos problematiką (Fonteyne, 2007; Davis, 2001), yra pagrindinis operacinės kooperatinių kredito įstaigų veiklos rizikos šaltinis. Kooperatinėje bankininkystėje plačiąja prasme operacinė rizika pasireiškia tuo, jog kooperatyvo darbuotojai ar vadovai veikia nepaisydami narių interesų. Kitaip sakant, kooperatyvų organizacinė struktūra didžiąja dalimi lemia ženklių rizikos veiksnių atsiradimą: *interesų konflikto situacijas, narių bei vadovų abejingumą ir pasyvumą bei riboto kolektyvinio veiksmo galimybes* (2 pav., 6), *ribotą vadovų pasirinkimą* (McKillop, Wilson, 2015) bei (2 pav., 7). Šie veiksniai, savo ruožtu, lemia *nepalankaus pasirinkimo riziką* (2 pav., 4) ir *moralinę riziką* (2 pav., 8) kooperatyvų veikloje⁶. Fonteyne (2007) pastebi, kad interesų konfliktai galimi ne tik kredito unijų viduje, bet ir sisteminiu lygiu – tarp kredito unijų ir jas jungiančių organizacijų⁷ (2 pav., 9).

Dichotominė kredito unijų prigimtis pasireiškia tuo, kad, viena vertus, kredito unijos yra nepelno siekiančios organizacijos, veikiančios narių asociacijos ryšio ribojamoje rinkoje, kita vertus, tai yra finansų įstaigos, veikiančios dinamiškoje, konkurencingoje ir reguliuojamoje finansų rinkoje, nuolat augančio tvaraus kapitalo poreikio kontekste. Mokslinėje literatūroje kredito unijos apibūdinamos kaip „ne pelnui, bet paslaugoms skirtos organizacijos“ (angl. *not for profit, but for service*) (McKillop, Wilson, 2015). Kredito unijų dichotominė prigimtis, veiklos tikslas ir misija yra praktinių, teisinių ir mokslinių diskusijų objektas. Worthington (2014) pastebi, jog kylantys reguliaciniai reikalavimai verčia kredito unijas maksimizuoti veiklos pelningumą.

McKillop ir Wilson (2015) pastebi, jog nepelno paskirtis neigiamai veikia kredito unijų *finansinį pajėgumą* (2 pav., 10), tai mažina kredito unijų stabilumą, *technologinį bei infrastruktūrinį išsivystymą* (2 pav., 11), *apsunkina*

⁶ Kaip pavyzdį galima nurodyti Didžiosios Britanijos statybų kooperatyvus, kurie siekia valdyti interesų konfliktų ir kolektyvinių veiksmų rizikas ribodami narių-skolininkų teises (Fonteyne, 2007).

⁷ Lietuvos atveju tokiu pavyzdžiu galėtų būti LCKU, kuris yra taip pat kooperatyvas, o jo nariai – kredito unijos, kurias LCKU prižiūri kaip antros eilės priežiūros institucija. Šiuo atveju galimas interesų konfliktas tarp prižiūrimų kredito unijų, kurios moka narystės mokestį ir yra formalūs LCKU savininkai, ir pačios LCKU.

kvalifikuoto personalo paieškas (2 pav., 7, 27), netiesiogiai mažina kredito unijos plėtros galimybes (2 pav., 12, 13, 14, 15) ir didina substituto riziką (2 pav., 26).

Asociacijos ryšys (angl. *common bond; bond of association*) – socialinis, politinis, religinis, geografinis ar kitoks ryšys, jungiantis kredito unijos narius. Asociacijos ryšys yra vienas ryškiausių kredito unijų (ir kitokio tipo kooperatyvų) bruožų, išskiriančių jas iš kitų organizacijų. Keli dažniausiai pasitaikantys asociacijos ryšio pavyzdžiai pateikiami žemiau (Worthington, 2014).

1. *Bendruomeninis*. Kredito unijos dažnai kurdavosi parapijų bendruomenių pagrindu, taigi bendras socialinis požymis, jungiantis kredito unijos narius, buvo narystė parapijoje (MacPherson, 2007; O’Connel, 2012), pvz., Vokietijoje (*Raiffeisen bankai*) ir Kanadoje (*Caisses populaires*).
2. *Darbdavio ar profesinis*. JAV populiarius asociacijos ryšys yra darbovietės požymis (MacPherson, 2007)⁸.
3. *Teritorinis*. Nuo kredito unijų steigimosi (Wolf, 1893) iki dabar vienas populiariausių asociacijos ryšių kredito unijose išlieka teritorinis požymis, jungiantis vienoje geografinėje vietovėje gyvenančius asmenis (LCKU, 2016).

Narystė kredito unijose yra ribojama. Nariais gali būti tie asmenys, kurie atitinka asociacijos ryšio reikalavimą. Viena vertus, asociacijos ryšys unijoms padeda mažinti informacijos asimetriją ir lengviau pasiekti vartotoją, kita vertus, dėl privalomo asociacijos ryšio, kredito unijose atsiranda *mažo rinkos gylio* rizika (2 pav., 16) (Fonteyn, 2007). Literatūroje teigiama, kad vykstant natūraliam kredito unijų raidos procesui, unijoms augant asociacijos ryšys silpsta, kredito unijos susiduria su rinkos gylio nepakankamumu ir pradeda taikyti platesnius asociacijos ryšio reikalavimus (McKillop, Wilson, 2015, 2011; Fonteyn, 2007; Sibbald ir kiti, 2002). JAV kredito unijų siekis taikyti

⁸ Pvz., Harvardo universiteto darbuotojų kredito unija (huecu.org).

nuosaikesnius asociacijos ryšio reikalavimus⁹ tapo mokslinių ir teisinių diskusijų objektu (PolEcon Research, 2016; ABA, 2014; ABA, 2010).

Literatūroje pastebima, kad kredito unijoms yra būdingas *mažas organizacijos dydis* (McKillop, Wilson, 2015, 2011). Tai lemia, jog dažnai negalėdamos suformuoti reikšmingos statistinės imties (2 pav., 17) kredito rizikos modeliavimui, kredito unijos savo veikloje taiko ekspertinius kredito rizikos vertinio metodus (2 pav., 18). Tai riboja kredito unijų galimybę tiksliai įvertinti prisiimamą riziką (2 pav., 19). Tikslinės rinkos gylio nepakankamumas (2 pav., 16) riboja kredito rizikos diversifikacijos galimybes (2 pav., 20) portfelio lygmeniu. Kredito unijos, veikdamos nepalankaus pasirinkimo rizikos, mažo rinkos gylio, ekspertinių kredito rizikos vertinimo metodų (2 pav., 4; 16; 18) kontekste, tikėtina, akumuliuos didesnę kredito riziką (2 pav., 20), nei tradicinės finansinės organizacijos, nesusiduriančios su paminėtais rizikos veiksniais.

Kredito unijos dėl *specifinio veiklos reguliavimo* turi ribotas likvidaus turto investavimo (2 pav., 21) ir skolinto kapitalo pritraukimo galimybes (2 pav., 22). Šie veiksniai kartu su ribota fizine ir technologine infrastruktūra neigiamai veikia kredito unijų skolinto kapitalo pritraukimo galimybes ir kainą (2 pav., 23; 24). Siekdamos pritraukti indėlius, kredito unijos turi siūlyti aukštesnes palūkanas (2 pav., 24), nei tradicinės finansinės organizacijos. Aukštesnė skolinto kapitalo savikaina lemia ir poreikį siekti aukštesnės investicijų arba kreditavimo grąžos, taip pat prisiimti aukštesnę veiklos riziką.

Apibendrinant galima teigti, kad kredito unijų veikloje, kaip ir komercinėje bankininkystėje, išskirtinos keturios pagrindinės rizikos rūšys: operacinė, kredito, rinkos ir likvidumo. Kooperatinėje bankininkystėje, kitaip nei tradicinėje, pasireiškia nepalankaus pasirinkimo, moralinė, nuosavo kapitalo prisitraukimo rizikos, kurios būdingos ir kitoms bankininkystės rūšims, tačiau kooperatinėje bankininkystėje jų raiška susijusi su šios bankininkystės rūšies bruožų ypatumais. Išskirtini ir specifiniai rizikos veiksniai: interesų persidengimas, mažas rinkos gylys, ekspertinių kredito

⁹ Pastaba – JAV kredito unijos klasifikuojamos kaip išsivysčiusios (Sibbald ir kiti, 2002).

rizikos vertinimo modelių taikymas, ribotos skolinto kapitalo pritraukimo galimybės ir aukšta skolinto kapitalo kaina. Kaip parodyta paveiksle (2 pav.), visos rizikos rūšys ir veiksniai yra susiję tarpusavyje priežasties ir pasekmės ryšiais bei daro įtaką bendrai kredito unijų veiklos rizikai.

1.1.3. Teoriniai kredito rizikos vertinimo aspektai skirtingais kredito unijų raidos etapais

Ilgą laiką kredito unijų veikla turėjo socialinės paskirties orientaciją, kuri mokslinėje literatūroje dažniausiai siejama su unijų narių finansinės atskirties ir skurdo mažinimu (McKillop, Wilson, 2015; Macdonald, Jazwinski, 2012; Birkenmaier, Curley, 2009; Jones, 2008, 2005, 2004; Westricht, Bush, 2005). Jones (2008) finansinę atskirtį apibrėžia kaip skurdo rezultatą ir negalėjimą gauti nemažai finansinių paslaugų: taupymo, banko sąskaitos, finansinių konsultacijų, draudimo bei kredito (konkurencingomis rinkos sąlygomis). Autorius pabrėžia, kad pirmosios kredito unijos Didžiojoje Britanijoje ir Airijoje buvo įkurtos būtent finansinės atskirties ir skurdo mažinimo tikslais. 2000 metais Didžiojoje Britanijoje 83 % iš daugiaž 700 kredito unijų buvo įsteigtos su vyriausybės pagalba siekiant mažinti skurdo lygį. MacPherson (2007) rašė, jog 1970-aisiais metais Kanadoje kai kurios kredito unijos buvo įsteigtos siekiant specialiai aptarnauti tuos asmenis, kurių pajamos yra itin mažos. Dėl to juos atsisakė aptarnauti ne tik tradicinės bankinės organizacijos, bet ir kitos kredito unijos. Kitos kredito unijos¹⁰ vystė specialias programas, orientuotas į paslaugų teikimą mažas pajamas gaunantiems asmenims. Šios tikslinės iniciatyvos kartojosi skirtingais laikotarpiais ir skirtingose geografinėse vietovėse (bei kito tipo kooperatyvuose). Mokslinėje literatūroje pateikiami įvairūs metodai, kuriuos taikydamos kredito unijos atliko finansinės atskirties ir skurdo mažinimo funkcijas (2 lent.). 2 lentelėje pateikiamus unijų socialinės funkcijos atlikimo metodus galima apibendrinti suskirstant juos į tris grupes. *Pirma* – finansinių paslaugų teikimas tiems asmenims, kurių nepasiekia tradicinių finansinių institucijų infrastruktūra ir / arba asmenims,

¹⁰ Šaltinyje unijos įvardijamos tiksliai.

kuriems tradicinės finansinės organizacijos nėra suinteresuotos teikti paslaugas. *Antra* – specifinių finansinių ir edukacinių paslaugų teikimas, pvz. finansinio raštingumo skatinimas, teigiamos kredito istorijos formavimas. *Trečia* – tiesioginis ekonominės vertės perdavimas skirtingais pavidalais: priiimant daugiau kredito rizikos už kitas (tradicines) finansines institucijas, paslaugų (ir paskolų) teikimas žemesnėmis kainomis ir / arba ekonominės vertės paskirstymas dividendų pavidalu.

2 lentelė. Kredito unijų socialinės funkcijos atlikimui taikyti metodai

	Borzaga, Spear (2004)	Burger, Dacin (1992)	Griffiths, Howels(1991)	Heenan McLaughlin (2002)	Jones (2008, 2005, 2001)	Lukoševičius(2005)	MacPherson(2007)	Mattern, Wilson(2013)	O'Connel(2012)	Richardson, Lennon (2001)	Ward (1995)	Westrich, Bush (2005)	Wolff (1893)
Paslaugų teikimas žemas pajamas gaunantiems asmenims.			✓		✓	✓	✓	✓	✓	✓	✓	✓	✓
Paslaugų teikimas asmenims, kuriems kiti finansiniai paslaugų tiekėjai nėra suinteresuoti teikti paslaugas.		✓	✓		✓	✓	✓	✓	✓	✓	✓		✓
Paslaugų teikimas tuose geografinėse vietovėse, kurių nepasiekia fizinė komercinių bankų infrastruktūra.					✓		✓		✓				✓
Paslaugų teikimas žemesnėmis negu rinkos kainomis ir / ar palankesnėmis sąlygomis.			✓		✓	✓	✓	✓	✓	✓	✓		✓
Neženklaus kredito suteikimas su tikslu sukurti teigiamą nario kredito istoriją.										✓			
Finansinio raštingumo skatinimas per mokymus ir / ar teikiamas finansines konsultacijas.				✓	✓		✓		✓	✓	✓	✓	✓
Ekonominės naudos paskirstymas dividendų pavidalu.											✓	✓	
Aukštesnės nei kitų pelno siekiančių organizacijų kredito rizikos tolerancija.	✓		✓				✓						
Gebėjimas tiksliau įvertinti narių kredito riziką, finansinius poreikius ir galimybes.							✓		✓		✓		
Brangiai paimtų paskolų refinansavimas.					✓				✓	✓			

Šaltinis: sudaryta autoriaus pagal lentelėje nurodytus šaltinius.

Šis, skirtingose šalyse iki 1980–2000 metų taikytas modelis literatūroje vadinamas „socialiniu“ arba „senuoju“ kredito unijų veiklos modeliu. Socialinis veiklos modelis pasižymėjo orientacija į mažas bendruomenes, savanorystės pagrindais veikiantį personalą ir socialinės paskirties filosofiją (Chambers, Ryder, 2008; Jones, 2008; Richardson, Lennon, 2001). Dauguma autorių, analizavusių kredito unijų gebėjimą atlikti socialinę funkciją, sutaria, kad kredito unijų poveikis skurdo lygio ir finansinės atskirties mažinimui yra abejotinas (Jones, 2008; Richardson ir Lennon, 2001). Jau 1990 metais Didžiosios Britanijos vyriausybė pripažino, kad investuojant į kredito unijų sektorių tikslas nebuvo pasiektas. Kredito unijos, įsteigtos mažas pajamas gaunančiose bendruomenėse, liko labai mažos bei finansiškai nestabilios (Jones, 2008). Tarptautiniai moksliniai tyrimai rodo, kad kredito unijos, siekiančios efektyviai atlikti socialines funkcijas, to pasiekti galėtų tik tuo atveju, jei savo veikloje laikytųsi komercinio požiūrio bei pačios taptų pakankamai finansiškai stabilios ir pajėgios šią funkciją atlikti (Jones, 2008; Richardson ir Lennon, 2001). Jones (2008) rašo, jog kai kurios kredito unijos žemas pajamas gaunančius asmenis pasirenka kaip tikslinį segmentą ne dėl socialinių savipagalbos paskatų, o dėl nerealių verslo prielaidų ir vadybinių įgūdžių trūkumo.

Šios aplinkybės paskatino kredito unijas bei jų asociacijas peržvelgti savo veiklos principus, segmentą, tikslus ir metodus. Didžiausios pasaulio kredito unijų asociacijos paskelbė apie naujus strateginius planus bei apie „naujo modelio“ formavimą. WOCCU siekdama stiprinti kredito unijas ir užtikrinti judėjimo tęstinumą, parengė naują kredito unijų plėtros modelį, kurio pagrindiniai bruožai yra aktyvus indėlių pritraukimas, paskolų teikimas rinkos sąlygomis, nariams mokamų dividendų maksimizavimas ir ekonomiškai pagrįstas veiklos planavimas (Chambers, Ryder, 2008; Ferguson, McKillop, 2006). Nuo 1999 m. ABCUL (angl. *Association of British Credit Unions Limited*) taip pat atsisakė kai kurių tradicinių nuostatų: griežtų reikalavimų narystės kriterijams, savanorystės pagrindais veikiančio personalas ir neformalus bendruomenės dalyvavimo veikloje. Pradėta orientuotis į

ekonomiškai pagrįstą unijų verslo planavimą, informacinių technologijų plėtrą bei profesionalių personalo darbuotojų samdymą (Jones, 2008). Panašaus turinio rekomendacijas vienijamoms kredito unijoms paskelbė ILCU (angl. *Irish League of Credit Unions*) ir CUNA (angl. *Credit Unions National Association*) (Power ir kiti, 2014; Glass ir kiti, 2014). Šios autoritetingos asociacijos rekomendavo kredito unijoms praktiškai taikyti naują, į verslą ir ekonominį racionalumą orientuotą, veiklos modelį. Kredito unijos, kurios iki šiol veikė pagal priešingas vertybes, tai sutikto prieštaringai. Vis dėlto WOCCU ir ILCU asociacijos skelbia, jog naujas modelis pasiteisino ir teigiamai paveikė kredito unijų populiarumą bei ekonominius rezultatus (Glass ir kiti, 2014; Chambers, Ryder, 2008; Jones, 2008; Ferguson, McKillop, 2006).

Naujo veiklos modelio taikymo problematika susijusi ne tik su nusistovėjusių kredito unijų vertybių, bet ir su ženkliais kredito rizikos vertinimo aplinkos pokyčiais. Mokslinėje literatūroje dažnai pastebima, jog kredito unijos turi būdingą bruožą geriau valdyti informacijos asimetriją pasitelkdamos socialinę kontrolę, nei tradicinės kredito įstaigos; tačiau socialinis ryšys silpsta unijoms augant (Power ir kiti 2014; MacPherson, 2007; Guinnane 1994; Fonteyne 2007). Pastebima ir tai, kad pati kredito unijų struktūra ir jos veikloje pasitelkiami rizikos vertinimo bei valdymo metodai buvo pritaikyti mažoms kredito įstaigoms, veikiančioms bendruomenių pagrindu (Fonteyne 2007). Naujasis kredito unijų veiklos modelis, orientuotas į ekonominį naudingumą, veiklos efektyvumą ir masto ekonomiją suponuoja neišvengiamą kredito unijų augimą bei paslaugų teikimą už bendruomenės ribų prarandant socialinį kontrolės elementą ir pranašumą valdant informacijos asimetriją. Taigi, galima teigti, kad kredito rizikos vertinimo metodai turėtų keistis priklausomai nuo kredito unijos raidos etapo.

Sibbald ir kiti (2002) išskiria tris kredito unijų raidos etapus: ankstyvasis (angl. *nascent*), tranzitinis (angl. *transition*) ir brandos (angl. *mature*). Šiems raidos etapams priskiriamos kredito unijų savybės ir kredito rizikos vertinimo ypatybės yra susistemintos 3 lentelėje.

3 lentelė. Kredito unijų raidos etapai, jiems būdingos savybės ir kredito rizikos vertinimo ypatybės

Vystymosi etapai	Ankstyvoji (angl. <i>nascent</i>)	Tranzitinė (angl. <i>transition</i>)	Brandos (angl. <i>mature</i>)
KKO savybės (1)	Mažo dydžio turtas. Stiprūs reguliaciniai ribojimai. Griežtas narystės principas (uždaro organizacijos). Priklausomybė nuo savanorystės pagrindais veikiančio personalo. Orientacija į žemas pajamas gaunančius asmenis. Mažas paslaugų asortimentas. Priklausomybė nuo išorinio finansavimo.	Didelis turto dydis. Poslinkiai teisiniame reguliavime. Liberalūs narystės kriterijai. Platesnis paslaugų asortimentas. Poslinkiai link augimo ir veiklos efektyvumo. Silpnėjanti priklausomybė nuo savanorystės pagrindais veikiančio personalo. Plėtros ir pardavimo profesionalumo poreikio pripažinimas. Paslaugų centrų vystymasis.	Didelis turto dydis. Dereguliacija ¹¹ . Technologinis išsivystymas. Efektyvūs ir sofistikuoti pardavimo kanalai. Profesionalūs vadovai. Išvystyta centralizuotų paslaugų infrastruktūra. Platus ir diversifikuotas paslaugų asortimentas. Rinkoje konkurencingi produktai ir paslaugos. Orientacija į ekonominį efektyvumą ir veiklos tęstinumą.
Kredito rizikos vertinimo aplinkybės	Dažniausiai veikia pradedama orientuojantis į tuos tikslinius segmentus, kuriuose TFO veikia neefektyviai – maža bendruomenė, finansinėje atskirtyje esantys asmenys, mažas pajamas gaunantys asmenys. Organizacijos vadovai išrenkami pagal ryšius su esamais ir potencialiais nariais ¹² . Ženklus socialinės kontrolės elementas (<i>peer review</i> , <i>Stiglitz</i>). Ženkliai dalį analitinės informacijos sudaro kokybinė informacija. Neautomatizuotas, nestandartizuotas ir lėtas sprendimų priėmimas.	Veikla plečiama už bendruomenės ribų, dažnai konkuruojama su tradicinėmis finansinėmis organizacijomis; Orientuojamasi į platesnį segmentą (taikomi nuosaikesni reikalavimai narystei), teikiamos paslaugos juridiniams asmenims (asocijuotiems nariams). Analizei naudojama tiek kokybinė, tiek kiekybinė informacija. Nepakankamas imties dydis statistinio kredito rizikos vertinimo modelio formavimui. Ribotos socialinės kontrolės elemento taikymo galimybės. Neautomatizuotas ar dalinai automatizuotas sprendimų priėmimas.	Narystės kriterijų panaikinimas ir pilnavertis konkuravimas finansų rinkoje. Pardavimo kanalų sofistifikavimas reikalauja aukšto sprendimų priėmimo automatizavimo lygio. Prarandama galimybė taikyti socialinį kontrolės elementą. Daugumą analitinės informacijos sudaro kiekybinė informacija iš išorinių šaltinių. Dėka paslaugų centrų galimas statistinės imties formavimas ir statistinių metodų taikymas.
Kredito rizikos vertinimo metodai	Ekspertiniai metodai pasitelkiant socialinės kontrolės elementą (<i>peer review</i> , <i>Stiglitz</i>)	Taikomi taisyklių pagrindu suformuoti (angl. <i>rule-based</i>) KRV derinant su ekspertiniais sprendimais. Siektina kuo greičiau pradėti taikyti statistinius kredito rizikos vertinimo modelius.	Taikomi statistiniai rizikos vertinimo metodai, leidžiantys skaičiuoti PD.

Sudaryta autoriaus pagal O'Connel (2012); McKillop, Wilson (2015; 2011); Fonteyn (2007); Ferguson, McKillop (2006); Sibbald ir kiti (2002).

¹¹ Reguliaciniai reikalavimai tampa artimi bankiniams reikalavimams.

¹² Pavyzdžiui, tam tikrų bendruomenių vadovai, gyvenviečių seniūnai, pan.

Apibendrinant galima teigti, kad veikdamos pagal naująjį veiklos modelį, siekdamos veiklos efektyvumo ir masto ekonomijos, kredito unijos privalo vystysis, kad atitiktų Sibbald ir kitų (2002) apibrėžtus raidos etapus. Skirtingais unijų raidos etapais, priklausomai nuo kredito unijų gaunamos analitinės informacijos, turimų žmogiškųjų, technologinių ir finansinių resursų, įstaigos turėtų taikyti skirtingus kredito rizikos vertinimo metodus siekdamos kuo tiksliau įvertinti potencialių paskolos gavėjų kredito riziką.

Kaip minėta, ankstyvajame raidos etape kredito unijos gali gana efektyviai vertinti kredito riziką ekspertiniais kredito rizikos vertinimo metodais, pasitelkdamos socialinės kontrolės elementą¹³. Tranzitiniame raidos etape veikla plečiama už bendruomenės ribų, socialinis kontrolės elementas silpsta, todėl privalu taikyti kiekybinius metodus pasitelkiant objektyvią analitinę informaciją. Įprastai šiame raidos etape kredito unijos dar nebūna sukaupusios pakankamo duomenų kiekio statistiniams modeliams kurti, todėl pereinamuoju laikotarpiu gali būti taikomi taisyklių pagrindu ekspertiškai suformuoti vertinimo modeliai. Tačiau siekdamos kuo tiksliau vertinti potencialių paskolos gavėjų kredito riziką, unijos turėtų siekti per kuo trumpesnę laiką pradėti taikyti statistinius kredito rizikos vertinimo modelius.

Pažymėtina, kad kredito unijoms pereinant į brandos etapą, pagal savo veiklos modelį jos negali būti tapatinamos su komerciniais bankais. Kredito unijų tikslinis segmentas ir veiklos modelis įprastai lieka nepakitęs ir skiriasi nuo komerciniu bankų pagal 1.2 dalyje išvardytus bruožus (Williams, 2010; Fonteyn, 2007). Kredito unijų perėjimą į brandos etapą gali apsunkinti teisinis reguliavimas, taip pat politiniai, socialiniai ir kitų išoriniai veiksniai. Vienos valstybės, pavyzdžiui, Prancūzija, JAV, Kanada, Australija, Pietų Korėja suteikia kredito unijoms galimybes pereiti į brandos etapą nekeičiant teisinės formos (McKillop, Wilson, 2011), kitos, pavyzdžiui, Olandija, Šveicarija, Suomija, Kinija (LB, 2014, Zuo, 2001) suteikia kredito unijoms galimybes

¹³ Pažymėtina, kad praktikoje ekspertinis kredito rizikos vertinimo metodas grynąja forma, kai sprendimai priimami remiantis subjektyviais duomenimis, šiuolaikinėje kredito unijų veikloje pasitaiko retai. Lietuvoje pagal teisės aktus kredito unijos privalo taikyti kiekybinius metodus ir remtis objektyviais duomenimis.

tapti kooperatiniais bankais. Nemažoje dalyje valstybių funkcionuoja abi teisinės formos: kooperatiniai bankai ir kredito unijos, pvz., Lenkijoje (Chyra-Rolicz, 2016), Italijoje (Catturani, Stefani, 2016). Dažnai teisinės formos pokyčiai (iš KU į kooperatinį banką) įvyksta ne dėl unijų brandos ir augimo, o dėl poreikio pertvarkyti šį sektorių po įvairių formų krizių.

Apibendrinant galima teigti, kad moksliniai tyrimai rodo, jog socialine paskirtimi grįstas kredito unijų veiklos modelis ne tik nepasiekė nustatytų tikslų, bet ir turėjo neigiamą poveikį pačiam kredito unijų judėjimui. Reaguodamos į šią situaciją, didžiausios kredito unijų asociacijos parengė naują veiklos modelį, žinomą kaip komercinį veiklos modelį, kuriame numatė į rinką orientuotą kredito unijų veiklą. Pereidamos prie naujo, komercinio veiklos modelio, kredito unijos pradėjo veikti naujoje, joms neįprastoje rinkoje, kurioje tiesiogiai konkuruojama su tradicinėmis finansinėmis organizacijomis. Naujo modelio taikymas apribojo unijų galimybes pasinaudoti iki šiol turėtais konkurenciniais pranašumais, kurie buvo galimi tik veikiant mažų bendruomenių ribose. Galima teigti, kad pagrindiniai kredito unijų iššūkiai pereinant nuo socialinio prie komercinio veiklos modelio yra susiję su naujų narių pritraukimu ir kredito rizikos vertinimu.

Išanalizavus mokslinę literatūrą, galima tvirtinti, kad kredito unijų taikomi kredito rizikos vertinimo metodai turi evoliucionuoti proporcingai pačiam kredito unijų judėjimui. Darbe pateiktas pavyzdinis kredito unijų kredito rizikos vertinimo metodų taikymas skirtingais kredito unijų išsivystymo etapais, kurie dažniausiai išskiriami analizuojant kredito unijų raidą. Disertacijos autoriaus nuomone, kredito unijoms pradedant veikti už bendruomenės ribų (tai atitinka tranzitinį kredito unijų raidos etapą), jų veikloje turėtų būti atsisakoma ekspertinių vertinimo metodų ir pereinama prie statistinių kredito rizikos vertinimo modelių taikymo.

1.2. Teoriniai statistinio kredito rizikos vertinimo modelio sudarymo pagrindai


1.2.1. Statistinio kredito rizikos vertinimo modelio sudarymo koncepcija

Modelis bendriausia prasme gali būti apibrėžiamas kaip loginis ar matematinis komponentų ir / ar funkcijų aprašymas, atspindintis reikšmingas modeliuojamo objekto ar reiškinių proceso savybes. Modelis naudojamas kaip sąlyginis apibūdinimas (forma), sudarytas siekiant supaprastinti jo tyrimą (Lopatnikov, 2003; papildyta autoriaus). *Statistinis kredito rizikos vertinimo modelis* yra kreditoriaus sprendimo priėmimo procese naudojamas techninis įrankis, kuriuo pagal potencialaus paskolos gavėjo pirminius duomenis apskaičiuojama jo nemokumo tikimybė bei priimamas sprendimas dėl paskolos suteikimo. Statistinė prasme kredito rizikos modeliavimas gali būti apibrėžiamas kaip homogeninės populiacijos identifikavimas atsižvelgus į jos ryšį su kredito rizikos veiksniais (Makuch, 2001, p. 140). Šio skyriaus tikslas – *atskleisti, jog statistinio kredito rizikos vertinimo modelio savybės reikšmingai priklauso nuo visumos aplinkybių ir veiksnių, kuriems veikiant suformuotas modelis.*

Statistinio kredito rizikos vertinimo modelio sudarymas yra kompleksinis procesas, kuris gali būti suskirstytas į šešis pagrindinius žingsnius (3 pav.). Paveiksle pavaizduotas kredito rizikos vertinimo modelio sudarymo procesas atitinka klasikinį kredito rizikos vertinimo modelių sudarymo požiūrį, kurio laikomasi mokslinėje literatūroje (Garcia ir kiti, 2015; Dzidzevičiūtė, 2013; Anderson, 2007; Siddiqi, 2006). Šis procesas yra unifikuotas ir iš esmės neturėtų skirtis nuo pasirinktos tikslinės kreditavimo grupės, kredito įstaigos, kuri taikys šį modelį, ar išorinės modelio taikymo aplinkos.

Prieš sudarant modelį, kreditoriams tenka priimti su modelio sudarymo metodika ir naudojamais duomenimis susijusius sprendimus atsakant į klausimus: kokius nepriklausomus kintamuosius pasirinkti, kokią klasifikatorių

taikyti, kaip apibrėžti priklausomą kintamąjį, kokį paskolos stebėjimo laikotarpį nustatyti ir pan. Priimant šiuos sprendimus dažnai tenka rinktis iš verslo prasme prieštaringų pozicijų, pvz., didinti kreditavimo pelningumą ir / ar pardavimus ar mažinti riziką; stiprinti asmeninį kontaktą su klientais ar mažinti pardavimo ir klientų aptarnavimo kaštus; didinti sprendimo priėmimo tikslumą ar skaidrinti sprendimo priėmimo procesą.



3 pav. Statistinio kredito rizikos vertinimo modelio sudarymo žingsniai bei naudojama analitinė informacija

Sudaryta autoriaus pagal Garcia ir kiti (2015); Anderson (2007); Siddiqi (2006).

Apibendrinus mokslinę literatūrą (Dzidzevičiūtė, 2013; Anderson, 2007; Siddiqi, 2006) galima teigti, kad sudarant kredito rizikos vertinimo modelį, **taikomi metodai ir naudojami duomenys** lemia pagrindines sudaromo **modelio charakteristikas: diskriminacinę galią analizuojamo segmento atžvilgiu, modelio rezultatų paaiškinamumą, rizikos tolerancijos lygį, atitikimą kreditoriui galiojantiems reguliaciniams reikalavimams bei kitiems kreditoriaus verslo poreikiams.**

Prieš priimant sprendimus dėl taikomų metodų ir naudotinių duomenų, tikslinga atlikti analizę iš trijų perspektyvų: *kredito įstaigos* (kuri taikys

modelį), *prognozuojamos homogeninės grupės ir išorės veiksnių perspektyvos* (3 pav., 1–3). Siekiant parodyti, kaip šios analizės rezultatai lemia tolesnius modelio sudarymo žingsnius, bei atskleisti šio proceso priežasties ir pasekmės ryšius, modelio sudarymo procesas (3 pav.) bus perteiktas kita forma (4 pav.).

Paveiksluose (3 pav.; 4 pav.) modelio sudarymo proceso žingsniai yra numeruoti (1–17). Kaip galima matyti, modelio sudarymo procesas prasideda nuo modelio sudarymo poreikių ir galimybių analizės, kuri atliekama iš trijų perspektyvų (4 pav., žingsniai 1–3). 4 paveiksle šios trys analizės perspektyvos yra pateikiamos kaip dimensijos, lemiančios tolesnių modelio sudarymo žingsnių metodus, naudojamą informaciją, taip pat viso sudaromo modelio charakteristikas. Toliau bus detaliau aptarti modelio sudarymo žingsniai.

Modelio sudarymui pasitelktą informaciją galima suskirstyti į išorinę ir vidinę. Visuotinai pripažįstama, kad bendra modeliavimui prieinamos *informacinės infrastruktūros kokybė, kaina* bei bendrovės disponuojamų *žmogiškųjų, technologinių ir finansinių išteklių* (toliau – ŽTF ištekliai) pakankamumas reikšminga dalimi lemia tai, ar įmanomas modelio sukūrimas, bei tai, ar jis bus kuriamas organizacijos viduje, ar pasitelkus trečiąsias šalis. Tuo atveju, kai kreditoriaus vidinių duomenų nepakanka sukurti modelį, duomenys ar jų dalis gali būti įgyjami iš išorės: kredito biurų, asociacijų¹⁴, kt. Tuo atveju, kai modeliui sukurti duomenų nepakanka, ar kai modelio kūrimas yra ekonomiškai neracionalus, kreditoriai gali taikyti išorinius modelius, pvz., kreditų biurų skaičiuojamus reitingus. Jei statistinio modelio sukūrimas neįmanomas ar netikslingas, o išoriniai reitingai nėra tinkami pasiekti turimus tikslus, kreditoriai gali pasirinkti taikyti ekspertinius modelius (kitai vadinamas ekspertines vertinimo sistemas arba taisyklėmis grįstus modelius¹⁵).


Kreditoriui pasirinkus tikslinį kreditavimo segmentą, būtina įsitikinti, kad segmentas homogeniškas rizikos prasme bei apibrėžti modeliuojamą *priklausomą kintamąjį*. Priklausomo kintamojo apibrėžimas dažniausiai

¹⁴ Pavyzdžiui, kai kuriose rytų Azijos valstybėse (Japonijoje, Malaizijoje, Indonezijoje ir Tailande) kredito rizikos imčių rinkimą, sisteminimą ir perteikimą finansų rinkos dalyviams vykdo specialios paskirties asociacijos (Kuwahara ir kiti, 2015).

¹⁵ Angl. *rule based model*.

siejamas su nuostolio įvykiu – neveiksnios paskolos – apibrėžimu. Dėl to depozitinės kredito įstaigos, kurioms tiesiogiai arba *mutatis mutandis* taikomi Bazelio bankų priežiūros komiteto reikalavimai, negali taikyti liberalesnio neveiksnios paskolos apibrėžimo, nei yra nustatyta teisės aktuose.

Apibrėžus priklausomą kintamąjį, nustatomas *paskolos stebėjimo laikotarpis*, kuris priklauso nuo pasirinkto tikslinio segmento elgsenos, kreditoriui taikomo reguliavimo ir kreditavimo politikos. Bazelio bankų priežiūros komitetas nurodo taikyti ne trumpesnę, kaip vienerių metų, paskolos stebėjimo laikotarpį (BCBS, 2004).



4 pav. Veiksniai, darantys įtaką modelio sudarymo metodų, naudojamų duomenų pasirinkimui ir modelio charakteristikoms

Sudaryta autoriaus.

Sutrumpinimai: DPD – pradelstų mokėjimų dienų skaičius (angl. *days per due*).

Galimi naudoti *nepriklausomi kintamieji* yra nustatomi atsižvelgus į pasirinkto kreditavimo segmento specifinę elgseną, modeliuojamą pagal priklausomą kintamąjį, vidinę ir išorinę informacinę infrastruktūrą. Svarbu užtikrinti tai, kad pasirinkti nepriklausomi kintamieji būtų kokybiškai

vienarūšiai ir vienodi turinio prasme tiek statistinėse modelio kūrimo bei grįžtamojo įvertinimo imtyse, tiek ir modelio praktinio taikymo procese¹⁶.

Modelyje *taikomas klasifikatorius* pasirenkamas atsižvelgus į kreditoriui taikomą reguliavimą, kreditavimo politiką (pvz., poreikį interpretuoti modelio atsakymus ir / ar modelio tikslumo lūkesčius), išskirtų nepriklausomų kitamųjų kiekių bei turimus ŽTF išteklius. Mokslinėje literatūroje pripažįstama, kad dirbtinio intelekto pagrindu suformuoti modeliai yra tikslesni (plačiau žr. 23 pav.), tačiau Bazelio bankų priežiūros komitetas rekomenduoja taikyti statistinius modelius, kurių veikimas gali būti detalai paaiškintas ir dokumentuotas (BCBS, 2004, p. 410). Pastebėtina, kad dirbtinio intelekto metodams būtini didesni ŽTF resursai, dėl to jie retai taikomi smulkiose kredito įstaigose.

Atliekant *išankstinį modelio įvertinimą*, analizuojama modelio diskriminacinė galia, lyginant ją su kitų modelių kiekybinėmis savybėmis (pagal turimą informaciją). Išankstinio modelio patikrinimo ir grįžtamojo įvertinimo metu turi būti atsižvelgiama ir į tai, ar sudarytas modelis atitinka prieš modelio sukūrimą iškeltus tikslus.

Lūžio taško nustatymo metodas pasirenkamas atsižvelgiant į kreditoriaus kreditavimo politiką (pvz., rizikos apetitą), pagrindines paskolų portfelio savybes (LGD, EAD) bei skolininkui būdingą specifinę elgseną. Pažymėtina, kad lūžio taško pasirinkimas daro tiesioginę įtaką finansuojamų paraiškų kiekiui¹⁷, taip pat ir kreditoriaus konkurencingumui bei patrauklumui rinkoje, todėl nustatant lūžio tašką turi būti atsižvelgiama ir į konkurencinę aplinką.

Rangų skalės sudarymas yra atliekamas laikantis kreditoriui taikomo reguliavimo bei atsižvelgus į pasirinkto tikslinio segmento elgsenos specifiką (pvz., apriorinę PD). Kredito įstaigos, kurioms tiesiogiai arba *mutatis mutandis* taikomas Bazelio bankų priežiūros reglamentavimas, turi sudaryti skalę iš ne mažiau kaip 8 rangų, iš kurių ne mažiau kaip 6 rangai, tikėtina, susiję su skolininkais, kurie vykdys įsipareigojimus, ir 2 su, tikėtina, tais, kurie jų

¹⁶ Siekiama užtikrinti, kad taikant modelį, būtų naudojami duomenys (išorinių registrų, kreditų biurų teikiamieji kiti duomenys) turinio prasme atitiktų duomenis, pasitelktus sudarant modelį.

¹⁷ Praktikoje plačiai naudojamas angliškas pavadinimas *acceptance rate*.

nevykdys (BCBS, 2001, p. 198). Rangų skalės sudarymas ir taikymo principai turi būti detalios aprašyti kreditorių vidaus dokumentuose.

Paprastai mokslinėje literatūroje kredito rizikos vertinimo modeliai yra kuriami atsižvelgus tik į homogeninę rizikos grupę, kurioje bus prognozuojamas nemokumo įvykis. Rečiau literatūroje pasitaiko tyrimų, kuriuose, nustatant kredito rizikos vertinimo modelio savybes, būtų atsižvelgiama į kreditoriaus (kuris taikys modelį) veiklos ypatybes bei į kitus išorinius veiksnius, kuriems veikiant bus taikomas modelis. Pažymėtina, jog pirmojo požiūrio besilaikantys autoriai dažniausiai analizuoja specifinius modelių sudaryme taikomus metodus, pvz., klasifikatorių taikymo (Danėnas, 2013, Mileris, 2011), arba tam tikrų specifinių homogeninių grupių elgseną (Stulpinienė, 2013). Tolesnėje lentelėje pateikiami skirtingi tokių modelių sudarymo požiūrių pavyzdžiai, pastaruoju metu sukurti Lietuvos ir užsienio autorių (4 lent.).

4 lentelė. Skirtingi kredito rizikos vertinimo modelio sudarymo požiūrių pavyzdžiai

Požiūriai	Autoriai	Klasifikatoriaus tipas	Tikslinis segmentas	Kreditoriaus tipas ir modelio taikymo vietovė***
1 požiūris*	Stulpinienė (2013)	LR	Lietuvos ūkininkų ūkiai	Nespecializuojama
	Mileris (2011)	DNT	Lietuvos įmonės	Nespecializuojama
2 požiūris**	Byanjankar (2015)	DNT	Fiziniai asmenys	Tarpusavio skolinimo platformos
	Dzidzevičiūtė (2013)	LR	Lietuvos įmonės	Lietuvos komerciniai bankai
	Harris (2013)	AVM	Fiziniai asmenys	Barbadoso kredito unijos
	Desai ir kiti (1996)	DNT	Fiziniai asmenys (DB)	Didžiosios Britanijos kredito unijos

Sudaryta autoriaus.

***1 požiūris** – modelis sudaromas neatsižvelgus į kreditoriaus verslo ypatybes ir išorinius veiksnius, kuriems veikiant jis bus taikomas.

****2 požiūris** – modelis sudaromas atsižvelgus į kreditoriaus verslo ypatybes ir išorinius veiksnius, kuriems veikiant jis bus taikomas.

***** Modelio taikymo vietovė** (dažniausiai apibrėžiama valstybė) didžiąja dalimi lemia išorinius veiksnius.

DNT – dirbtiniai neuronų tinklai; LR – logistinė regresija; AVM – atraminių vektorių mašinos.

Apibendrinant galima teigti, kad kredito unijos pasižymi išskirtiniais veiklos bruožais (žr. 1.1.2 sk., 2 pav.) bei orientuojasi į specifinį tikslinį kreditavimo segmentą, todėl jų veikloje (taip pat kaip ir kito tipo kredito įstaigose) turėtų būti taikomi skirtingi kredito rizikos vertinimo modeliai. Šie modeliai sudaromi atsižvelgiant į aplinkybes, pagal kurias planuojama juos taikyti. Būtina įvertinti ir kredito įstaigos veiklos bruožus, kurie gali būti susiję su skirtingais modelio sudarymo metodais ir/ar modelio sudarymui pasitelkiamais duomenimis. Nekorektiškai atliktos (arba neatliktos) poreikių ir galimybių analizės atveju sudaryto modelio charakteristikos gali neatitikti kreditoriaus verslo poreikių, modelio taikymo aplinkybių bei gali pasižymėti žema disriminacine galia analizuojamo segmento atžvilgiu. Tai, kad vieno universalaus kredito rizikos vertinimo modelio nėra, rašoma ir Bazelio bankų priežiūros komiteto dokumentuose (BCBS, 2004, p. 395), kuriuose pabrėžiama, kad kredito įstaigos turėtų taikyti skirtingus modelius skirtingiems tiksliniams kreditavimo segmentams. *Šio disertacinio tyrimo autorius laikosi požiūrio, kad kredito rizikos vertinimo modelio sudarymo proceso privaloma sudėtinė dalis yra modelio sudarymo poreikių ir galimybių kompleksinė analizė, į ją įtraukiant tyrimus, apimančius kreditoriaus, išorės veiksnių ir modeliuojamo segmento perspektyvas.*

Toliau darbe analizuojami teoriniai statistinių kredito rizikos vertinimo modelių kūrimo metodų aspektai.

1.2.2. Kredito rizikos vertinimo modelio kintamųjų pasirinkimo teoriniai aspektai

Priklausomo kintamojo apibrėžimas. Dažniausiai statistinio kredito rizikos vertinimo modelio priklausomas kintamasis yra kategorinis, su dviem galimomis paskolą apibūdinančiomis reikšmėmis: „gera“ ir „bloga“. Kredito įstaiga netenkina tų pareiškėjų prašymų paskolai gauti, kuriems modelis priskiria „blogos“ paskolos požymį. Todėl „blogos“ paskolos apibrėžimas yra vienas svarbiausių veiksnių, lemiančių tai, ar modelis atitiks lūkesčius ir patenkins kredito įstaigos verslo poreikius. Didžiausią įtaką apibrėžimui

formuoti daro modelio kūrimo tikslas, taikymo sritis ir kreditoriaus turimi duomenys (Choy, Laik, 2010; Dzidzevičiūtė, 2010; Valvonis, 2006). Anderson (2007) pastebi, kad „blogos“ paskolos apibrėžimas yra mažiau akivaizdus lūžio taško (angl. *cut off point*) nustatymas. Kaip ir kredito rizikos vertinimo modelis, „blogos“ paskolos apibrėžimas taikytinas vienai homogeninei paskolų grupei, pavyzdžiui, vartojimo paskoloms, būsto arba verslo paskoloms. Formuojant apibrėžimą, svarbu tiksliai charakterizuoti požymį ar požymių rinkinį, pagal kuriuos paskola yra priskiriama „blogų“ paskolų kategorijai. Nustačius per daug griežtą „blogos“ paskolos apibrėžimą, didėja tikimybė, kad mokus skolininkas bus laikomas nemokiu, o tokia situacija vadinama techniniu nemokumu (angl. *technical default*). Nustačius per daug liberalų apibrėžimą, nemokūs skolininkai gal būti priskirti prie mokių (Valvonis, 2006).

„Blogos“ paskolos apibrėžimas formuojamas iš požymių, charakterizuojančių rizikingiausius kreditoriaus aktyvus, turinčius didžiausią tikimybę virsti nuostoliu, todėl, sudarant modelius dažnai remiamasi teisės aktų ar Bazelio bankų priežiūros komiteto nustatytais neveiksnių paskolų apibrėžimais. Bazelio bankų priežiūros komiteto dokumentuose (BCBS, 2005, 2006) prie neveiksnių paskolų priskiriamos paskolos, kurių mokėjimai vėluoja daugiau kaip 90 dienų ir / ar paskolos, kurios, banko manymu, nebus pilnai gražintos bankui nesiimant specialių priemonių (pvz., užstato realizavimo). Remiantis BCBS (2005, 2006), parengtas Europos parlamento ir tarybos reglamentas „Dėl prudencinių reikalavimų kredito įstaigoms ir investicinėms įmonėms“ (Nr. 648/2012), kuriame numatomos išlygos, pagal kurias gali būti taikomas 180 dienų vėlavimas: 1) paskola yra mažmeninės paskolos grupėje, 2) užtikrinta gyvenamojo arba komercinio turto įkeitimu arba 3) suteikta viešajam sektoriui.

Mokslinėje literatūroje, analizuojančioje kredito rizikos vertinimo klausimus, „blogų“ paskolų apibrėžimui dažniausiai taikomas 90 ir daugiau dienų įmokų vėlavimo požymis (Sorokin, 2014; Nguen, 2014; Rajan ir kiti, 2010; Bloem, Freeman, 2005; Thomas, 2009, 2000; Jiménez ir kiti, 2014; Beck ir kiti, 2013; Leow, Crook, 2016, 2014; Bendendo, Bruno, 2012; Khemraj,

Pasha, 2009). Sudarant kredito rizikos vertinimo modelius, taikomi skirtingi „blogos“ paskolos ir stebėjimo laikotarpio apibrėžimai. Lentelėje (5 lent.) pateikiami pavyzdiniai „blogos“ paskolos apibrėžimai, taikyti analizuotose mokslinėse publikacijose.

Kaip matyti iš lentelės duomenų (5 lent.), sudarant kredito rizikos vertinimo duomenis, autoriai dažnai remiasi ekspertinėmis įžvalgomis, teisės aktais ar Bazelio banko priežiūros komiteto rekomendacijomis. Tačiau toks požiūris neužtikrina sąsajos su realia skolininkų elgsena bei gali daryti neigiamą įtaką modelio diskriminacinei galiai. „Blogos“ paskolos apibrėžimą nustatant kiekybiniais metodais, išskiriami du pagrindiniai žingsniai: pirmas – optimalaus stebėjimo laikotarpio nustatymas, antras – „blogos“ paskolos apibrėžimo formavimas.

5 lentelė. Blogos paskolos apibrėžimai kredito rizikos vertinimo modeliuose

Šaltinis	Homogeninė paskolų grupė	Blogos paskolos apibrėžimas	Apibrėžimo nustatymo pagrindimas
Cardoso ir kiti, 2016	Kredito kortelės	Mokėjimų pradelsimas 60 dienų iš eilės	Ekspertinis
Dzidzevičiūtė, 2010	Verslo paskolos	Bankrotas	Ekspertinis
Fernandes, Artes, 2016	Smulkaus ir vidutinio verslo paskolos	Mokėjimų pradelsimas 90 ir daugiau dienų	Brazilijos centrinio banko reikalavimas
Glennon ir kiti, 2008	Kredito kortelės	Mokėjimų pradelsimas 90 ir daugiau dienų per 24, 18 ir 12 mėn. stebėjimo laikotarpius	Ekspertinis
Kelly, O'Malley, 2016	Būsto paskolos	Mokėjimų pradelsimas 90 ir daugiau dienų	BCBS
Khandani ir kiti, 2010	Kredito kortelės	Mokėjimų pradelsimas 90 ir daugiau dienų per 3, 6 ir 12 mėn. stebėjimo laikotarpius	Ekspertinis
Koutanaei, 2015	Verslo paskolos	Mokėjimų pradelsimas 60 dienų iš eilės	Ekspertinis
Manab ir kiti 2015	Verslo paskolos	Bankrotas	Ekspertinis
Petropoulos ir kiti, 2016	Verslo paskolos	Mokėjimų pradelsimas 90 ir daugiau dienų, arba paskola pripažįstama nuostoliu pagal kitus kreditoriaus vidinius kriterijus	BCBS
Sousa ir kiti, 2016	Kredito kortelės	Mokėjimų pradelsimas 90 ir daugiau dienų per 12 mėn. stebėjimo laikotarpį	Ekspertinis

Sudaryta autoriaus pagal lentelėje nurodytus šaltinius.

Stebėjimo laikotarpio nustatymo reikšmė yra ta, jog siekiama nustatyti laikotarpį, pakankamą paskoloms „subręsti“. Stebėjimo laikotarpis pasižymi sparčiu nuostolių augimu, todėl nustačius per trumpą stebėjimo laikotarpį, neatspindintį nepriklausomų kintamųjų įtakos prognozuojamam reiškiniui, didėja tikimybė neįvertinti viso galimo nuostolio. Tokiu atveju dalis „blogų“ paskolų bus priskirta „geroms“. Ilguoju laikotarpiu skolininkų savybės, kurios buvo vertinamos paskolos suteikimo pradžioje, turi tendenciją keistis. Todėl per ilgo ar per trumpo stebėjimo laikotarpio nustatymas gali turėti neigiamos įtakos modelio kokybinėms savybėms (Thomas, 2000).

Kiekybiniam optimalaus stebėjimo laikotarpio apibrėžimo nustatymui, dažniausiai naudojama kohortų analizė (Choy, Laik, 2009; Anderson, 2007; Siddiqi, 2006). Ši analizė susideda iš kelių žingsnių. Pirma, skirtingais mėnesiais išduotos paskolos sujungiamos į homogenines grupes – kohortas. Antra, skaičiuojamas kiekvienos kohortos vidutinis vėlavimo rodiklis. Trečia, rezultatai atvaizduojami grafiškai ir analizuojami. Taikant šį metodą galimi įvairūs analizuojamų vėlavimų trukmių nustatymai (Choy, Laik, 2009; Siddiqi, 2006). Šio grafinio metodo esmė – nustatyti tokį stebėjimo laikotarpį, per kurį vidutinis vėlavimo dienų skaičius sparčiai auga. Modelio imtis formuojama iš „subrendusių“ paskolų, kurių perėjimas į „blogų“ paskolų grupę yra mažiau tikėtinas.

Kiekybiniam blogos paskolos apibrėžimui suformuoti dažniausiai taikomos Markovo migracijų matricos ir jų modifikacijos (Choy, Laik, 2009; Anderson, 2007; Siddiqi, 2006). Taikant šiuos metodus daroma prielaida, jog paskolos perėjimas iš vienos vėlavimo būsenos į kitą atitinka Markovo grandinių procesą. Ši prielaida reiškia, jog paskolų migracijos tarp būsenų vyksta homogeniškai laiko atžvilgiu. Kitaip sakant, taikant Markovo grandinių metodą, neatsižvelgiama į paskolų brandos stadiją ir traktuojama, kad migracijos tikimybė stebėjimo laikotarpiu yra vienoda. Markovo grandinė turi galimas būsenas $S=\{1,2,...,k\}$, tikimybė, jog paskolos būseną bus stadijoje j po to, kai praeitą laikotarpį buvo stadijoje i , apibrėžiama kaip P_{ij} . Hipotetinė matricos forma yra išreiškiama taip (Hadad ir kiti, 2008):

$$P = \begin{pmatrix} p_1 & p_{12} & p_{13} & \dots & p_{1k} \\ p_2 & \dots & \dots & \dots & p_{2k} \\ \vdots & & & & \vdots \\ p_{j-1,1} & p_{j-1,2} & p_{j-1,3} & \dots & p_{j-1,k} \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (1-1)$$

1-1 formulėje P – migracijų matrica, kiekvienas matricos kintamasis simbolizuoja tikimybę, kad objektas migruos iš būsenos i , esančios kairiau, į būseną j per tam tikrą nustatytą laikotarpį. Visų matricos eilučių suma lygi 1.

Apibendrinant galima teigti, kad priklausomo kintamojo apibrėžimas kredito rizikos vertinimo kontekste yra vadinamas „blogo“ skolininko apibrėžimu. Apibrėžiant „blogą“ skolininkų yra atsakoma į du klausimus: pirma, koks požymis ar požymių rinkinys galėtų charakterizuoti analizuojamą skolininką kaip „blogą“; antra, koks yra optimalus skolininko stebėjimo laikotarpis. Dažniausiai pagrindiniu „blogo“ skolininko požymiu pasirenkami įvairūs paskolos sutarties nevykdymo požymiai: bankrotas, nemokumas ar užsitęsęs mokėjimo vėlavimas. Darbe atliktos mokslinės literatūros analizė parodė, kad dažniausiai taikomas „blogos“ paskolos apibrėžimas yra mokėjimo vėlavimas 90 dienų. Toks maksimalus mokėjimo vėlavimo toleravimo terminas yra nurodomas ir Bazelio bankų priežiūros dokumentuose. Dažniausiai taikomas statistinis „blogo“ skolininko apibrėžimo metodas – Markovo migracijų matrica. Optimalaus paskolos stebėjimo laikotarpio nustatymo esmė – nustatyti tokį stebėjimo laikotarpį, per kurį vidutinis pasirinkto paskolų segmento vidutinis vėlavimo dienų skaičius sparčiai auga. Dažniausiai norint pasiekti šį tikslą taikoma kohortų analizė.

Išskirtini trys priklausomų kintamųjų atrinkimo etapai. Pirmasis – galimų naudoti kintamųjų sąvado sudarymas, kai atrenkami visi kintamieji, kurie galėtų turėti gerą diskriminacinę galią prognozuojamam reiškiniui. Antrasis – atliekama rodiklių analizė, pašalinami žemos diskriminacinės galios ir tarpusavyje susiję kintamieji. Trečiasis – sudaromas optimalus priklausomų rodiklių rinkinys, kuris įtraukiamas į galutinį modelį.

Apibrėžus priklausomąjį kintamąjį, pereinama prie kito uždavinio – šį kintamąjį charakterizuojančių nepriklausomų kintamųjų parinkimo.

Nepriklausomų kintamųjų rinkinio formavimas. Šiuolaikinės technologijos ir išsivysčiusi informacinė infrastruktūra suteikia galimybę gauti ir apdoroti didelį kiekį pirminių duomenų. Sudarius duomenų imtį, nepriklausomų kintamųjų skaičius gali nesunkiai siekti kelis šimtus¹⁸. Nežiūrint į didelį kiekį galimų nepriklausomų kintamųjų, į modelį įtraukiami tik atitinkantys modelio kūrimo tikslą, aukštos diskriminacinės galios bei analitinės informacijos turinio prasme skirtingi kintamieji. Galima sakyti, kad galutinio nepriklausomų kintamųjų rinkinio formavimo procesas susideda iš dviejų etapų: 1) *galimų naudoti nepriklausomų kintamųjų sąvado sudarymas* (nepriklausomų kintamųjų aibės suformavimas) ir 2) *į modelį įtraukiamų nepriklausomų kintamųjų atrinkimas* (iš kintamųjų aibės suformuojant poaibį).

Galutinio nepriklausomų kintamųjų rinkinio formavimo klausimas nėra naujas ir yra išsamiai išanalizuotas skirtingų mokslo šakų tyrėjų: medicinos (Thompson, 2009; Austin, Tu, 2004), informatikos (Catania, Garino, 2012), ekonomikos (Dzidzevičiūtė, 2010, 2013) ir kt. Kintamųjų pasirinkimas yra vienas iš prognozavimo modelių kūrimo etapų. Tai lemia dažną šių metodų taikymą sprendžiant tokius uždavinius: veido atpažinimas (Gu ir kiti, 2012), genų ekspresija (Lazar ir kiti, 2012), mikroorganizmų atpažinimas (Davey ir kiti, 1999). Ekonomikos moksle kintamųjų parinkimo metodai taikomi sprendžiant šiuos klausimus: bankroto prognozavimas (Tsai, 2009; Shin ir kiti, 2005), kredito rizikos vertinimas (Ioniță, Șchiopu, 2010; Hörkkö, 2010), akcijų kainų ateities tendencijų prognozavimas (Tsai, Hsiao, 2010; Lee, 2009), kt. Sprendžiant uždavinius, susiduriama su dideliais informacijos kiekiais, iš kurių reikia atrinkti kokybiškus kintamuosius, tinkančius įtraukimui į konstruojamą modelį.

Ekonomikos srities mokslinėje literatūroje, analizuojančioje sprendimų priėmimo palaikymo sistemas ir prognozavimo modelius, pasitelkiami įvairūs

¹⁸ Šiuolaikiniai kreditavimo rinkos novatoriai, kredito rizikos vertinimui naudojančys didžiulius duomenis (angl. *big data*), pasisako išskiriantys net iki 70 000 galimų reikšmingų pirminių duomenų (plačiau žr. Affirm, 2015; Pymnts.com, 2014).

metodai, skirti pasirinkti į modelį įtraukiamiems kintamiesiems (6 lent.). Kaip matyti iš lentelėje (6 lent.) pateiktų duomenų, galimų naudoti modeliui sudaryti kintamųjų sąvadą autoriai dažniausiai suformuoja remdamiesi literatūros analize arba ekspertiniu įvertinimu. Mokslinėje literatūroje dažniausiai išskiriamos šios nepriklausomų kintamųjų savybės, į kurias reikia atsižvelgti formuojant galimų rodiklių sąvadą (Finlay, 2012; Anderson, 2007; Siddiqi, 2006; Guyon, Elisseeff, 2003):

- 1) kintamojo informacijos kokybė (pvz., atliekama kintamojo informacijos patikimumo bei trūkstumų reikšmių analizė);
- 2) modelio kūrimo tikslų atitikimas;
- 3) patenkinama individuali diskriminacinė galia;
- 4) logiškumas ir unikalumas analitinės informacijos turinio prasme.

Kintamojo diskriminacinės galios įvertinimui dažniausiai taikomas informacijos vertės metodas (1-2), o kintamojo multikolinearumo – koreliacinės matricos. Tyrėjai retai naudoja kintamųjų sudarymo metodikas. Populiariausia yra principinė komponentių analizė. Beveik visuose ištirtuose darbuose parenkant optimalų galutinį kintamųjų derinį buvo taikyta šalinamoji regresija.

6 lentelė. Mokslinėje literatūroje minimi galutinio nepriklausomų kintamųjų rinkinio formavimo metodai

Šaltinis	Sritis	Kintamųjų parinkimo metodai	Kintamųjų svarbos vertinimo metodai	Kintamųjų sudarymo metodai	Optimalios kintamųjų subaibės formavimo metodai	Klasifikatorius
Atiya (2001)	Kredito rizikos vertinimas balais	Mokslinės literatūros analizė	IV; CM	Netaikyta	Netaikyta	DNT
Shin et al. (2005)	Bankroto prognozavimas	Nenurod.	T-T	Netaikyta	Šalinamoji regresija	AVM
Roobaert, Karakoulas (2006)	Kredito rizikos vertinimas balais	Nenurod.	IV, CM, Indukcija	Netaikyta	Netaikyta	AVM
Tsai (2009)	Bankroto prognozavimas	Ekspertinis vertinimas	CM; T-T	PCA	Šalinamoji regresija	DNT
Enke, Thawornwong (2009)	Akcijų gražos prognozavimas	Ekspertinis vertinimas	IV	Netaikyta	Šalinamoji regresija	DNT
Lee (2009)	Akcijų kainų kitimo trendo nustatymas	Ekspertinis vertinimas	F-T	Netaikyta	Šalinamoji regresija	AVM

Šaltinis	Sritis	Kintamųjų parinkimo metodai	Kintamųjų svarbos vertinimo metodai	Kintamųjų sudarymo metodai	Optimalios kintamųjų subaibės formavimo metodai	Klasifikatorius
Hörkkö (2010)	Kredito rizikos vertinimas balais	Mokslinės literatūros analizė; ekspertinis vertinimas	IV; LLR; CHSQT	Netaikyta	Šalinamoji regresija; kaupiamoji regresija; Aikakės informacijos kriterijus	LR
Ioniță I., Șchiopu D. (2010)	Kredito rizikos vertinimas balais	Nenurod.	CM	PCA	Netaikyta	NI
Tsai, Hsiao (2010)	Akcijų kainų prognozavimas	Mokslinės literatūros analizė	NU	PCA	Netaikyta	DNT
Dzidzevičiūtė (2013)	Kredito rizikos vertinimas balais	Ekspertinis vertinimas	IV	Netaikyta	Šalinamoji regresija	LR
Oreski, Oreski, (2014)	Kredito rizikos vertinimas balais	Nenurod.	IV, SCC, GINI, GR	Netaikyta	Hibridinis euristicinis – dirbtinio intelekto modelis	NI

Sudaryta autoriaus pagal lentelėje nurodytus šaltinius.

Santrumpos:

Kintamųjų svarbos vertinimo metodai: A-t – Adekvatumo testas; IV – Informacijos vertės testas; CM – koreliacinės matricos; SCC – Spearmen koreliacijos koeficientas; ULR – vienfaktorinė regresija; Wald – Valdo testas; GR – Gain Ratio; F-T – F testas; LLR – log likelihood ratio testas; CHSQT – Chi kvadratu testas; P-c – dalinė koreliacija; T-T – Stjudento testas.

Kintamųjų sudarymo metodai: PCA – principinių komponentų analizė.

Klasifikatorius: AVM – atraminių vektorių mašina; LR – logistinė regresija; DNT – dirbtiniai neuronų tinklai; NI – netaikyta.

Filtrai yra metodų tipas, pagrįstas individualių kintamųjų savybių vertinimu. Procesą galima išskaidyti į du etapus: diskriminacinės galios įvertinimas ir multikolinearumo įvertinimas.

Siekiant įvertinti individualias kintamųjų diskriminacines savybes dvifaktorinėje analizėje dažniausiai taikomas informacijos vertės metodas (1-2 formulė) (Bolton, 2009), rečiau X^2 (Chi kvadratu testas). Ryšys tarp kintamųjų įvertinamas dažniausiai taikant Spearmen koreliacijos koeficientą (Cateni ir kiti, 2013; Finlay, 2012; Dzidzevičiūtė, 2010; Anderson, 2007).

$$IV_j = \sum_{i=1}^n \left(\left(\frac{G_i}{\sum_{i=1}^n G_i} - \frac{B_i}{\sum_{i=1}^n B_i} \right) \cdot WOE_i \right) \quad (1-2)$$

Formulėje IV – informacijos vertės rodiklis, B – „blogų“ skolininkų kiekis, G – „gerų“ skolininkų kiekis, n – vertintų skolininkų kiekis, i – vertinamo skolininko indeksas, WOE_i – i-tojo skolininko įtakos svoris (angl. *weight of evidence*)¹⁹.


Filtravimo metodai yra patrauklūs dėl realizavimo paprastumo bei galimybės nesudėtingai interpretuoti gautus rezultatus. Filtravimo metodų trūkumas – jų atskirtis nuo klasifikatorių. Tai gali turėti neigiamą įtaką modelio tikslumui.

Šiurkščios jėgos ir įkomponuotieji algoritmai yra pagrįsti „šiurkščios jėgos“ principu – algoritmas parenka kintamųjų pogrupį, sudaro modelį, po to vertinamos gauto modelio charakteristikos, jei gaunami nepatenkinami rezultatai, tada procesas kartojamas (5 pav.). Šiurkščios jėgos algoritmų pranašumas yra jų gebėjimas įvertinti kintamųjų pogrupio diskriminacines savybes, kurios gali skirtis nuo pavienių kintamųjų savybių (Tan, 2007). Pagrindinis šios metodų grupės trūkumas yra tas, kad gautų rezultatų neįmanoma interpretuoti, nors tyrėjai išskiria šiai grupei priskiriamus metodus kaip tiksliausius (Khushaba ir kiti, 2008; Tan, 2007). Kaip galima matyti iš 6 lentelės, vienas dažniausiai naudojamų šiurkščios jėgos algoritmų – *šalinamoji regresija*.

Įprastai šiurkščios jėgos algoritmai yra imlūs kompiuteriniams resursams ir praktiškai jų gali būti neįmanoma taikyti dėl didesnio pradinių kintamųjų skaičiaus. Galima išeiti – jie gali būti taikomi kartu su kitais optimizavimo metodais, pvz., filtrų metodais. Tokiu atveju filtro metodas atitiktų paruošiamąjį etapą ir būtų pateikti jau atrinkti kintamieji, pašalinus perteklinius ir netinkamus, o šiurkščios jėgos algoritmas parinktų geriausią galimą pogrupį (rinkinį). Tokius mišrius kintamųjų pasirinkimo modelius savo publikacijose siūlė Sanchez-Marono ir kiti (2007), taip pat Oreski ir Oreski (2014). Kai kurie

¹⁹ WOE apskaičiavimo metodika detalai aprašoma šio darbo metodinėje dalyje.

autoriai atkreipia dėmesį į prisitaikymo prie imties (angl. *curse dimensionality*) problemą, kuri yra tipinė šiurkščios jėgos algoritmų modeliams ir atsiranda dėl modelių sąsajos su klasifikatoriumi. Ši problema lemia tai, kad modelis patikimai veikia tik apmokymo imtyje (Bolon-Canedo ir kiti 2013; Cateni ir kiti 2013; Tan, 2007; Guyon, Elisseeff).



5 pav. Kintamųjų parinkimo metodų grupės

Sudaryta autoriaus pagal Bolon-Canedo ir kiti (2013); Cateni ir kiti (2013).

Mokslinėje literatūroje visuotinai sutariama dėl teigiamos kintamųjų pasirinkimo metodų taikymo įtakos modelių kokybei (Cateni ir kiti, 2012; Finlay, 2012; Mileris, 2011; Ioniță, Șchiopu, 2010; Mays, Lynas, 2010; Yang, Duan, 2008; Anderson, 2007; Siddiqi, 2006; Guyon, Elisseeff, 2003). Dažniausiai siūloma taikyti filtrų metodus, o pradinių kintamųjų rinkinį formuoti ekspertiškai, atsižvelgus į modelio sukūrimo tikslą bei tikslinį segmentą (Finlay, 2012; Dzidzevičiūtė, 2010; Mays, Lynas, 2010; Anderson,

2007; Siddiqi, 2006). Kai kurie autoriai pabrėžia ypatingą ekspertų kompetencijos svarbą bei tai, kad kartais sprendimą įtraukti kintamuosius į galutinį modelį gali priimti ir modelį kuriančios kredito įstaigos vadovai (Finlay, 2012; Siddiqi, 2006). Toks požiūris suprantamas, nes kintamųjų įtraukimas daro tiesioginę įtaką modelio diskriminacinei galiai, taip pat ir kredito įstaigos pelningumui bei konkurencingumui.

1.2.3. Teoriniai klasifikavimo metodų pagrindai

Nežiūrint į tai, kad kredito rizikos vertinimo modelius sudaro ne tik klasifikavimo etapas, klasifikatoriaus tipas dažnu atveju lemia ir paties modelio pavadinimą. Esama skirtingų kredito rizikos vertinimo modelių grupavimų. Mackevičius ir Silvanavičiūtė (2006) modelius skirsto į klasikinius ir dirbtinio intelekto. Prie klasikinių autoriai priskiria logistinės regresijos ir diskriminantinius, prie dirbtinio intelekto – neuronų tinklų ir sprendimų medžių modelius. Valvonis (2006) pateikia išsamesnę klasifikaciją, kredito rizikos vertinimo modelius skirsto į penkias grupes:

- 1) vertinimo balais modeliai: tiesiniai tikimybiniai, logit, probit, sprendimų medžių, neuroninių tinklų, diskriminantiniai;
- 2) kredito maržos: Jonkhart (1979), Iben-Litterman (1989);
- 3) mirtingumo (aktuariniai): Altman (1989); Millins-Wolff (1989);
- 4) redukuotieji (intensyvumo): Lando (1998), Duffie-Silgelton (1997), (Turnbull ir kiti (1997, 1995);
- 5) struktūriniai (įmonės turto rinkos vertės): Longstaff-Schwartz (1995), Geske-Johnston (1984), Merton (1973).

Šiame disertaciniame tyrime analizuojami tik kredito rizikos *vertinimo balais* modeliai, prie kurių priskiriami tokie metodai: diskriminantinė analizė, logistinė regresija, dirbtiniai neuronų tinklai, sprendimų medžiai ir atraminių vektorių mašinos (Dzidzevičiūtė, 2013). Literatūroje yra aprašyti ir kiti modelių grupavimo metodai (Karalevičienė, Bužinskienė, 2011). Šio skyriaus tikslas – išanalizuoti populiariausių klasifikatorių, taikomų kredito rizikos vertinimo modeliuose, teorinius pagrindus. Toliau šiame skyriuje analizuojami

šie klasifikavimo metodai: diskriminantinė analizė, logistinė regresija, dirbtiniai neuronų tinklai ir sprendimų medžiai.

Diskriminantiniai modeliai yra vieni populiariausių kredito rizikos vertinimo ir bankroto prognozavimo modelių. Jie populiarūs dėl modelio rezultatų paaiškinamumo ir taikymo paprastumo. Plačiausiai mokslinėje literatūroje analizuotas diskriminantinis modelis yra E. I. Altmano modelis „Z“ (Altman, 1968). Pristačius šį modelį leidinyje „*The Journal of Finance*“ 1968 metais, diskriminantinė analizė kuriam laikui tapo pačia populiariausia kredito rizikos vertinimo ir bankroto prognozavimo metodika. Altmano „Z“ modeliui buvo sukurtos adaptuotos versijos skirtingų rūšių įmonėms: kotiruojamoms vertybinių popierių biržoje, nekotiruojamoms ir individualioms bei paslaugų įmonėms. Diskriminantinius modelius taip pat pasiūlė: Martin (1977), Tafler ir Tisshaw (1977), Springate (1978), Lis (1982), Fulmer (1984) ir kiti (Mackevičius, 2007; Altman, 2000; Altman, Saunders, 1998).

Diskriminantinėje analizėje yra siekiama sudaryti tiesinę lygtį, kuri išskirtų potencialius skolininkus į dvi grupes: mokius ir nemokius (Altman, Saunders, 1998). Norint pasiekti tikslą, analizuojamos kintamųjų aibės, parenkami kintamieji, pasižymintys maksimaliomis diskriminantinėmis savybėmis, kartu išlaikoma minimali koreliacija tarp pačių kintamųjų. Toliau pateikiama diskriminantinės funkcijos lygtis (Altman, 1968):

$$Z = v_1x_1 + v_2x_2 + \dots + v_nx_n \quad (1-3)$$

Lygtyje: $v_1, v_2, \dots, v_n$ – diskriminantiniai koeficientai, $x_1, x_2, \dots, x_n$ – nepriklausomi kintamieji, Z – rezultatinis kintamasis.

Diskriminantinę analizę galima taikyti tada, kai tenkinamos šios sąlygos (Čekanavičius, Murauskas, 2002):

- 1) normalusis pasiskirstymas; daroma prielaida, kad nepriklausomi kintamieji yra išrinkti iš daugiamačio normaliojo skirstinio;

- 2) variacijų / kovariacijų matricų homogeniškumas; daroma prielaida, kad grupių kovariacijų matricos nesiskiria, norint patikrinti, dažniausiai pasitelkiamas Bokso kriterijus;
- 3) multikolinearumas; jei vienas kintamasis stipriai koreliuoja su kitu ir (arba) yra kitų tiesinė daugdara – šis kintamasis neturės diskriminantinių savybių.

Diskriminantinių modelių populiarumas pradėjo mažėti atsiradus regresiniams modeliams (Dzidzevičiūtė, 2010; Altman, Saunders, 1998). Vienas pagrindinių diskriminantinių modelių trūkumų yra tas, kad juose neapskaičiuojamas PD. Diskriminantiniai modeliai taip pat yra reiklūs duomenų kokybei, pvz., svarbus normalus kintamųjų pasiskirstymas (Akkoç, 2012). Esant PD apskaičiavimo poreikiui ar susidūrus su duomenų pasiskirstymo problema, gera diskriminantinių modelių alternatyva yra regresiniai modeliai.

Logistinė regresija yra tikimybinės klasifikacijos metodas, naudojantis tiesinę faktorinių kintamųjų funkciją kaip diskriminantinę įrankį ir logistinę funkciją, paverčiančią tiesinę priklausomybę tarp faktorinių ir rezultatinio kintamųjų į logistinę. Logistinės regresijos modeliuose regresoriai gali būti tiek kiekybiniai, tiek kokybiniai (Mestiri, Hamdi, 2012; Wang ir kiti, 2011). Šio tipo regresijoje daroma prielaida, kad skolininko nemokumo tikimybė yra logistiškai pasiskirsčiusi (angl. *logistically distributed*) tarp reikšmių $[0;1]$ (Mester, 1997). Logistinę regresiją, siekdamas įvertinti kredito riziką, pirmą kartą pritaikė D. L. Chesser, 1974 metais. Vėliau norėdami pasiekti šį tikslą, ją taikė: Martin (1997), Ohlson (1980), Zmijewski (1984), West (1985), Koh (1991), Platt ir kiti (1991), Hopwood ir kiti (1994) (žr. Dzidzevičiūtė, 2010; Mackevičius, Silvanavičiūtė, 2006; Lennox, 1999; Altman, Saunders, 1998). Lietuvoje logistinės regresijos modelį, prognozuodamas bankroto tikimybę, 2003 metais taikė S. Grigaravičius. Logistinė regresija buvo pradėta taikyti vėliau už diskriminantinę ir yra vienas populiariausių bankinės praktikos metodų (Dzidzevičiūtė, 2010; Kamienas, Valvonis, 2004). Logistinės regresijos formulė yra loginio sigmoido funkcija:

$$P = \frac{1}{1 + e^{-(\beta_1 + \beta_1 X_{1i} \dots \beta_n X_{ni})}} \quad (1-4)$$

Formulėje: P – priklausomas kintamasis, šiuo atveju – skolininko nemokumo tikimybė, kurios galimų reikšmių sklaida logistiškai pasiskirsčiusi tarp 0 ir 1, $\beta_1, \dots, \beta_n$ – faktoriai kintamieji, o $X_1, \dots, X_{ni}$ – faktorių kintamųjų koeficientai (svoriai).


Logistinės regresijos populiarumą lėmė keli svarbūs faktoriai. Pirmiausia – universalios taikymo galimybės: faktoriai kintamieji, o $X_1, \dots, X_{ni}$ nebūtinai turi būti normalieji, nereikalaujama normaliai pasiskirsčiusių paklaidų, nekalbama apie priklausomo kintamojo homoskedatiškumą (Čekanavičius, Murauskas, 2002). Antra, logistinė regresija iš kitų regresinių modelių išsiskiria sąlyginiu matematinio taikymo paprastumu (Gujarati, Porter, 2009), tai suteikia galimybę jį nesunkiai taikyti praktikoje nesinaudojant specialia programine įranga. Tačiau modelis gali netikti prognozei dėl kintamųjų multikolinearumo arba dėl sudėtingesnės kintamųjų tarpusavio priklausomybės (Čekanavičius, Murauskas, 2002).

Nors logistinės regresijos modeliuose nebūtinai turi būti atsižvelgiama į diskriminantinės analizės modeliuose taikomus duomenų kokybės reikalavimus, kai kurie autoriai pritaria nuomonei, kad logistinės regresijos modelių tikslumas gali prilygti diskriminantiniams tik tada, kai išpildomi duomenų normalumo reikalavimai (Akkoç, 2012; Harrel, Lee, 1985).

Dirbtiniai neuronų tinklai. Dirbtinio intelekto sukūrimo galimybės patraukė mokslininkų dėmesį dar XIX amžiuje. Nuo 1930 iki 1960 metų įvairių sričių mokslininkai – filosofai, matematikai, elektrotechnikai, biologai siūlė įvairius smegenų funkcionavimo modelius (Hay, 1960; MacKay, 1954; Culberstone, 1950; Hebb, 1949; McCulloch, 1943; Rashevsky, 1938; Shannon, 1956; Neumann, 1956 ir kiti). Smegenų veikimo modelis yra suprantamas kaip bet kuri teorinė sistema, kurioje siekiama paaiškinti fiziologines smegenų funkcijas pasitelkus žinomus fizikos ir matematikos dėsnius, taip pat

neuroanatomijos ir neurofiziologijos faktus. Viena iš smegenų veikimo modelių koncepcijų yra perceptronai. Perceptroną pirmą kartą aprašė F. Rozenblatas 1957 metais. Tuo metu pagrindinis mokslininko susidomėjimo objektas buvo atminties mechanizmo veikimo principai biologinėse sistemose (Rozenblatt, 1962). Pastarasis darbas sukėlė didelį susidomėjimą ir daug lūkesčių, tačiau išsiaiškinus vienasluoksnių perceptronų galimybių ribas, susidomėjimas sumenko. Tyrėjų dėmesys vėl buvo atkreiptas atradus daugiasluoksnius perceptronus (Packaitė, 2004). Lietuvoje dirbtinius neuronų tinklus (DNT) vertindamas kredito riziką taikė Mileris (2012). Kėdaitis ir Žilinskas (2013) taikė DNT ir sprendimų medžių metodus vertindami kredito unijų veiklos riziką.

Smulkiausia DNT dalis yra dirbtinis neuronas (6 pav.).



6 pav. Dirbtinio neurono modelis

Sudaryta autoriaus remiantis Ringienė (2014), Medvedev (2007), Packaitė (2004).

Dirbtinio neurono modelį sudaro šios pagrindinės sudedamosios dalys (Ringienė, 2014):




- 1) **Iėjimai**, per kuriuos yra perduodama įėjimų aibė: $x_1, x_2 \dots x_n$ – dažniausiai tai būna realūs skaičiai. Kiekvienas įėjimas turi savo perdavimo koeficientą. Šalia įėjimų yra sinapsiniai koeficientai (svoriai) $w_1, w_2 \dots w_n$, kurie nurodo sustiprinti arba pasilpninti signalą.

Sumatorius $\sum_{i=1}^p w_i x_i$, kuris apskaičiuoja svorinių neurono įeities duomenų sumą.

Išeities signalas y , kuris perduodamas aktyvavus neuroną. Neurono aktyvavimo funkcijų yra įvairių, svarbu pažymėti, kad įvairiuose sluoksniuose gali būti naudojamos skirtingos aktyvavimo funkcijos (Kėdaitis, Žilinskas, 2013). Dažniausios aktyvavimo funkcijos (Ringienė, 2014; Yilmaz, Ozer,

2009; Medvedev, 2007; Vengrovskij, 2007; Packaitė, 2004) pateikiamos lentelėje (7 lent.).

7 lentelė. Dažniausiai taikomos neurono signalo aktyvavimo funkcijos

Perdavimo funkcijos tipas	Grafikas	Formulė	Reikšmių diapazonas
<i>Slenkstinė arba šuolinė</i>		$\begin{cases} y = 1, \text{ kai } x \geq 0 \\ y = 0 \text{ kitais atvejais} \end{cases}$	[0;1]
<i>Loginis sigmoidas</i>		$f(x) = \frac{1}{1 + e^{-x}}$	[0;1]
<i>Tangento sigmoidas</i>		$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	[-1;1]

Sudaryta autoriaus remiantis: Ringienė (2014), Angelini ir kiti (2008), Medvedev (2007), Packaitė (2004).

Pagal neuronų tinklų sujungimą vienas su kitu DNT yra skirstomi į (Ringienė, 2014):

1. Tiesioginio sklidimo DNT:
 - a. vienasluoksnis perceptronas (VP);
 - b. daugiasluoksnis perceptronas (DP);
 - c. radialinių bazinių funkcijų (RBF).
2. Grįžtamojo ryšio arba rekurentinius:
 - a. konkurenciniai neuroniniai tinklai (KNT);
 - b. saviorganizuojantys neuroniniai tinklai (SONT);
 - c. hopfieldo neuroniniai tinklai (HNT);
 - d. adaptyviojo rezonanso teorija paremti modeliai (ARNT).

Reikšmingiausia DNT savybė, nulėmusi šio metodo populiarumą, yra gebėjimas DNT mokytis. DNT architektūros apmokamos skirtingais algoritmais, kurie gali būti skirstomi į tris etapus (Kėdaitis, Žilinskas, 2013): pradinių svorių nustatymas, mokymas ir mokymo stabdymas. Mokymosi procese yra nustatomi sinapsiniai koeficientai ir neurono signalo aktyvavimo poslinkiai.

Kredito rizikos ir verslo sprendimų priėmimo procesuose dažniausiai taikoma DNT architektūra yra daugiasluoksnis perceptronas (DP) (Lahsasna ir kiti, 2010; West, 2000; Vellido ir kiti, 1999). Pastaruoju metu DNT vertindami kredito riziką taikė Akkoç (2012), Mileris (2012), Oreski ir kiti (2012), Salehi, Mansoury (2011), Angelina ir kiti (2008); Lee, Chen (2005); Lee ir kiti (2002), Fadlala, Lin (2001) ir kiti tyrėjai.

Sprendimų medžiai – tai duomenų gavybos (angl. *data mining*) modelis, kuriame užkuoduotas populiacijos paskirstymas į klases pagal predikatų atributus. Tai medžio formos kryptingas, acikliškas grafas. Pradinis mazgas (angl. *root node*) neturi jokio įėjimo, kiekvienas kitas mazgas turi tikslų vieną įėjimą ir nulį ar daugiau išėjimų. Jei mazgas n neturi išėjimų, jis vadinamas n lapu, kitu atveju – n vidiniu mazgu. Kiekvienas lapas žymimas kaip klasė, kiekvienas vidinis mazgas žymimas vienu predikatu (atributu), vadinamu padalinimo atributu (Twala, 2010).

Sprendimų medis sudaro objekto klasifikavimo taisyklių ir sąlygų rinkinį (Landwehr ir kiti, 2005). Šiai segmentacinei metodų grupei priklausančys modeliai gali būti pasitelkti analizuoti potencialius paskolų gavėjus, juos įvertinti ir klasifikuoti į homogenines grupes pagal kredito rizikos lygį. Siddiqi (2005) skirsto segmentacinius modelius į ekspertinius ir statistinius (Bijak, Thomas, 2012). Sprendimų medžiai pasižymi aiškumu ir skaidrumu (Landwehr ir kiti, 2005), todėl ekspertiniai sprendimų medžių modeliai dažnai taikomi vadybos srityje, pvz., priimant sprendimus. Statistiniai sprendimų medžių modeliai dažniausiai naudojami marketingo srityje (Yanping, 2012). Vertinant kredito riziką, sprendimų medžiai pasitelkiami rečiau, tačiau jie sparčiai

populiarėja, ypač hibridiniuose modeliuose, derinant juos su kitais, pvz., neuronų tinklais.

Sprendimų medžiuose taip pat, kaip ir kituose analizuotose modeliuose, yra priežastiniai ir rezultatiniai kintamieji. Modelyje analizuojamas kiekvienas priežastinis kintamasis, jis padalijamas į dvi subklases siekiant išlaikyti kuo didesnę grynumą, t. y. norima, kad į vieną subklasę įeitų, pagal galimybę, reikšmės, priklausančios tik tai subklasei, t. y. ją diskriminuojančiai maksimaliai tiksliai. Kiekviena subklase vėl dalijama analogišku metodu, išlaikant maksimalų subklasių grynumą. Šis pasikartojantis klasifikavimo procesas yra vadinamas rekursiniu padalinimo algoritmu (angl. *Recursive Partitioning Algorithm*) (Crook ir kiti, 2007). Dalijimas į subklases baigiamas tada, kai pasiekiamas maksimalus klasių grynumas, kai medžio dydis ir struktūra užtikrina efektyvų objektų aibės klasifikavimą, o tolimesnis dalijimas nebetenka statistinės reikšmės (Landwehr ir kiti, 2005). Siekiant įvertinti klasių grynumą (vienodumui), taikomi įvairūs statistiniai metodai, populiariausi yra Gini ir indeksas ir entropijos matas (Kėdaitis, 2009).

Dažnu atveju pirmame etape sudaromas didelis medis įvykdamas didžiausią klasių pasidalijimo skaičių. Vėliau medis optimizuojamas pašalinant dalį subklasių. Šis procesas vadinamas medžio genėjimu ir optimalaus medžio sudarymu (Kėdaitis, 2009; Landwehr ir kiti, 2005).

Esama daug skirtingų medžio auginimo, genėjimo ir optimizavimo bei apmokymo metodikų. Dažniausiai naudojami tokie sprendimų medžių tipai: CART (*Classification and Regression Trees*), CHAID (*Chi-squared Automatic Interaction Detection*), LOTUS (*Logistic Trees with Unbiased Selection*), C4.5, QUEST (*Quick, Unbiased and Efficient Statistical Tree*) ir kiti, populiariausi yra CART ir CHAID.

Binarinis rekursinio padalinimo metodas taikomas viename populiariausių sprendimų medžių modelių – CART, apimančiame klasifikavimo ir tikimybės skaičiavimo metodus. CART modelį pasiūlė L. Breiman su bendraautorais 1984 metais (Breiman ir kiti, 1984). CART metodas yra neparametrinis statistinio modeliavimo metodas, pasitelkiamas

prognozuoti kintamojo reikšmę atsižvelgus į kitų kintamųjų reikšmes. Sprendimų medis, naudojamas objektams klasifikuoti, vadinamas klasifikacijos medžiu, o sprendimų medis, naudojamas prognozei – regresijos medžiu (Kėdaitis, Žilinskas, 2013). CHAID metodas – tai rekursinio dalijimo metodas, padedantis įvertinti, ar mazgo dalijimas padidina reikšmingumą (Kėdaitis, Žilinskas, 2013). CHAID 1980 metais pasiūlė buvo Gordonas V. Kaasu (Ritschard, 2010).

Pastaruoju metu vertindami kredito riziką sprendimų medžių modelius taikė: Yanping ir kiti (2012), Zurada ir Kunene (2011) ir Finlay (2011)²⁰.

1.3. Teoriniai kredito rizikos vertinimo modelio įvertinimo pagrindai

Kredito rizikos vertinio modelio kokybės įvertinimas yra vienas svarbiausių modelio sudarymo etapų. Nekokybiškas modelis skatina *suboptimalų* (angl. *suboptimal*) kredito įstaigos kapitalo paskirstymą ir atitinkamą rezultatą – nuostolingą veiklą. Bazelio bankų priežiūros komitetui paskelbus antrąjį konsultacinį dokumentą, kuriame buvo pristatytas vidiniu reitingu pagrįstas kapitalo perskaičiavimo metodas (plačiai žinomas, kaip Bazelis II) (Engelmann, 2003; BCBS, 2001), išaugo poreikis taikyti tikslesnius modelių įvertinimo metodus. Bazelio bankų priežiūros komiteto dokumentuose kredito rizikos vertinimo modelių tinkamumo naudoti analizė apibrėžiama kaip procesų ir veiksmų visuma, nukreipta įvertinti, ar modelio priskiriami reitingai tinkamai diferencijuoja analizuojamus subjektus ir ar išskiriami rizikos komponentai atspindi realią riziką (BCBS, 2005).

Bazelio dokumentuose nurodomi šie svarbiausi reikalavimai vertinant modelių tinkamumą:

- 1) Bankai²¹ privalo turėti patikimą modelių tinkamumo įvertinimo sistemą, leidžiančią įvertinti vertinimo tikslumą, nuoseklumą, procesus bei rizikos

²⁰ Esama ir komercinės kredito rizikos vertinimo aplikacijų, sudarytų naudojant sprendimų medžių metodus: bendrovė „Vantage Score“, įkurta trijų didžiausių kreditų biurų „Equifax“, „Experian“ ir „Trans Union“, taiko modifikuotą daugiapakopį sprendimų medžių modelį (VantageScore, 2014; Bijak, 2012).

veiksnius. Bankas privalo gebėti įrodyti priežiūros institucijai, kad vidinio vertinimo modelio rezultatai yra tikslūs ir prasmingi (BCBS, 2001; p. 500);

- 2) Vidinių vertinimo modelių įvertinimo objektas yra modelių diskriminacinė galia ir modelių priskirtų reitingų ²² taikymas kredituojant (BCBS, 2005, Principle 1);
- 3) Vidinių vertinimo modelių įvertinimas yra bankų pareiga (BCBS, 2005, Principle 2);
- 4) Įvertinimas yra tęstinis procesas (BCBS, 2005, Principle 3);
- 5) Nėra vieno universalaus įvertinimo metodo (BCBS, 2005, Principle 4);
- 6) Įvertinimas turi apimti kiekybinius ir kokybinius metodus (BCBS, 2005, Principle 5);
- 7) Įvertinimo rezultatai yra nepriklausomo įvertinimo objektas (BCBS, 2005, Principle 6).

Bazelio bankų priežiūros komiteto parengtoje vidinių reitingo sistemų tinkamumo įvertinimo studijoje (BCBS, 2005a) išskiriamos dvi nemokumo tikimybės vertinimo modelių analizės sritys – modelio diskriminacinės galios analizė ir modelio kalibravimo (lūžio taško nustatymo) tikslumo įvertinimas. Analizuojant abi sritis rekomenduojama taikyti šiuos abu metodus (BCBS, 2005a):

- grįžtamąjį patikrinimą (angl. *backtesting*) – modelio patikrinimą su kita arba ta pačia duomenų imtimi;
- lyginamąją analizę (angl. *benchmarking*) – modelio charakteristikų palyginimą su kitais modeliais.

Modelio diskriminacinės galios matavimas. Pagal analitinės informacijos turinį binarinių modelių diskriminacinės galios įvertinimo metodai gali būti išskirti į du tipus: 1) metodai, parodantys modelio diskriminacines savybes tam tikrame pasirinktame lūžio taške ir 2) metodai,

²¹ Darbe cituojamas Bazelio bankų priežiūros komiteto dokumentas, kurio nuostatos *mutatis mutandis* taikomos kredito unijoms.

²² Daugiausia dėmesio skiriama nustatant lūžio tašką ir PD priskyrimą reitingams.

parodantys bendras modelio diskriminacines savybes neatsižvelgus į pasirinktą lūžio tašką. Toliau šie du įvertinimo metodų tipai analizuojami atskirai.


Modelio diskriminacinės galios vertinimas pasirinktame lūžio taške.

Tarkime, kad potencialūs paskolų gavėjai yra vertinami kredito rizikos vertinimo modeliu prognozuojant jų mokumą apibrėžtam ateities periodui. Modelis kiekvienam interesantui priskiria reitingą R , sutarkime, kad kuo šis reitingas didesnis, tuo didesnė tikimybė, jog skolininkas bankrutuos per prognozuojamą laikotarpį. Binarinio klasifikavimo atveju, siekiant suskirstyti skolininkus į „gerų“ ir „blogų“ skolininkų kategorijas, nustatomas atskyrimo taškas C . Manytina, kad skolininkai, kurių $R \geq C$, per prognozuojamą laikotarpį bankrutuos, ir priešingai, skolininkai, kurių $R < C$, išliks mokūs. Idealiu atveju modelis visiems bankrutuosiantiems paskolų gavėjams priskirs $R \geq C$, ir priešingai, mokiems $R < C$. Tačiau praktikoje idealūs modeliai reti, tad dalį faktiškai mokių klientų modelis priskirs nemokiems, ir priešingai. Kitaip tariant, taikant modelį ir pasirinkus atskyrimo tašką C , galimi keturių tipų atsakymai (7 pav.):

- 1) pareiškėjai, kuriems modelis priskyrė $R \geq C$ ir per prognozuojamą laikotarpį jie bankrutavo, laikomi teisingai klasifikuotais „blogais“ pareiškėjais (angl. *true negative, TN*);
- 2) pareiškėjai, kurie buvo priskirti „blogiems“, $R \geq C$, tačiau jie per prognozuojamą laikotarpį nebankrutavo, tad laikomi klaidingai priskirtais prie „blogų“ (angl. *false negative, FN*). Ši modelio klaida dar vadinama pirmo tipo klaida.
- 3) pareiškėjai, kuriems modelis priskyrė $R < C$, tačiau jie per prognozuojamą laikotarpį bankrutavo, vadinami klaidingai teigiamai klasifikuotais klientais (angl. *false positive, FP*). Ši modelio klaida vadinama antro tipo klaida ir traktuojama, kad dėl jos kredito įstaigos patiria daugiausiai nuostolių.

Paveiksle (7 pav.) pavaizduoti du hipotetiniai skolininkų skirstiniai – atitinkamai, pradedant iš kairės – „gerų“ ir „blogų“. Ašis x rodo modelio priskiriamo reitingo skalę, y skolininkų pasiskirstymo dažnį. Paveiksle

atskyrimo tašką (C) pasirinkus ties 5, matomos teisingai ir klaidingai klasifikuotus klientus simbolizuojančios skirstinių dalys. Rodyklė D simbolizuoja analizuojamą modelių diskriminacinę galią, kuriai kintant, keistųsi ir teisingai klasifikuotų klientų dalis. Iš 8 paveikslo yra akivaizdu, kad, keisdami C taško reikšmę, galime mažinti FP ar FN klaidų proporcijas, tačiau dažniausiai tai būtų daroma priešingos klaidos sąskaita, t. y. nustačius konservatyvesnį C taško dydį, pvz., 4, sumažėtų neteisingai klasifikuotų nemokių klientų dalis, tačiau būtų prarasta didesnė mokių klientų dalis (Sobehart, Keenan, 2001).



7 pav. „Blogų“ ir „gerų“ skolininkų pasiskirstymas pagal modelio priskiriamus reitingus

Sudaryta autoriaus pagal Verbaken ir kiti (2014); Sobehart, Keenan (2001).

Sutrumpinimai:

TP – modelio teisingai klasifikuoti „geri“ skolininkai; TN – modelio teisingai klasifikuoti „blogi“ skolininkai; FN – modelio klaidingai klasifikuoti „blogi“ skolininkai (pirmo tipo klaida); FP – modelio klaidingai klasifikuoti „geri“ skolininkai (antro tipo klaida), C – lūžio taškas (angl. *cut off point*), D – modelio diskriminacinė galia.

Toliau, analizuojant modelio savybes, siekiant paprastumo, paveikslą (7 pav.) galima transformuoti į klasifikavimo matricos formą (8 lent.), kuri yra plačiai taikoma mokslinėje literatūroje analizuojant binarinio klasifikavimo problemas.

8 lentelė. Klasifikavimo tikslumo vertinimo matrica

		Faktas	
		„Geras“	„Blogas“
Modelio prognozė	„Geras“	TP	FP (II-o tipo klaida)
	„Blogas“	FN (I-o tipo klaida)	TN

Sudaryta autoriaus pagal Mileris (2009); Powers (2007).

Lentelės (8 lent.) eilutės atitinka modelio prognozuotų „gerų“ ir „blogų“ skolininkų kiekius, lentelės skiltys – faktinės skolininkų būklės. Atitinkamai, eilučių ir skilčių sankirtos parodo jau aptartas modelio diskriminacinės galios savybes – TP, TN, FP, FN. Klasifikavimo lentelės turinys leidžia sudėlioti rodiklius, parodančius diskriminacines modelio savybes pasirinktame lūžio taške. Šie rodikliai detalai analizuojami šio darbo 2.2.5. skyriuje.

Modelio diskriminacinės galios įvertinimas neatsižvelgiant į pasirinktą lūžio tašką. Gavėjų veiklos charakteristikų kreivė (angl. *receiver operation characteristic curve*), labiau žinoma kaip ROC (toliau – ROC) kreivė sudaroma kiekvienam galimam atskyrimo taškui C nustatant: 1) kokią patikimų klientų dalį teisingai klasifikavo modelis, t. y. modelio specifiškumas, kurį charakterizuoja X ašies dydis; ir 2) kokią dalį nepatikimų klientų modelis identifikavo teisingai, t. y. modelio jautrumas, šis dydis nurodomas grafiko Y ašyje. Taip grafikas parodo apibendrintas modelio diskriminacines savybes pirmo ir antro tipo klaidų atžvilgiu kiekvienam galimam atskyrimo taškui C (8 pav., A).

Kuo ROC kreivė yra arčiau kairiojo viršutinio kampo, tuo modelis traktuojamas kaip kokybiškesnis, ir priešingai – kuo kreivė yra arčiau grafiko diagonalės tiesės (8 pav., A grafikas, punktyrinė tiesė), tuo mažiau diskriminacinės galios turi modelis. Modelis, kurio ROC kreivė yra artima diagonalei tiesei, laikytinas naiviu (beverčiu).

Kiekybiškai modelio diskriminacines savybes apibendrina plotas po ROC kreive – AUC (angl. *area under curve*, toliau – AUC). AUC dydis svyruoja nuo 0 iki 1, kuo modelio AUC artimesnė 1, tuo jis laikomas patikimesniu. Kitaip sakant, jei modelio AUC=1, tai toks modelis mokius ir nemokius


klientus klasifikuoja 100 procentų tikslumu. Kaip minėta, praktikoje tokie modeliai yra neįmanomi.

Kaupiamojo tikslumo kreivė (angl. *cummulative accuracy curve*), labiau žinoma, kaip CAP kreivė (toliau – CAP), taip pat vadinama Gini kreive, Lorenzo kreive arba galios kreive (angl. *power curve*). Sudarant CAP kreivę, pirmiausia skolininkai išrikiuojami pagal modelio priskiriamą reitingą nuo rizikingiausių iki mažiausiai rizikingų. Atskyrimo tašku laikomas modelio priskirtas reitingas. Grafiko y ašis rodo modelio jautrumą (Se), o x – kaupiamąją skolininkų dalį (Irwin, Irwin, 2012; Dzidzevičiūtė, 2013) (8 pav., B dalis).

Apibendrinant galima teigti, kad analizuoti parametriniai modelio diskriminacinės galios vertinimo metodai ROC ir CAP kreivės, AUC, AR rodikliai, Pietra indeksas ir teisingo klasifikavimo rodikliai yra susiję tiesiniais ryšiais. Šį ryšį iliustruoja paveikslas (8 pav.).

1. 10 paveikslo A dalyje vaizduojama ROC kreivė, plotas po jos kreive – AUC ir atstumas nuo diagonalės, rodančios naivųjį modelį ir vertinamo modelio ROC kreivės – Pietra indeksas.
2. 10 paveikslo B dalyje vaizduojama CAP kreivė, plotas po ja – A_R , plotas po tobulo modelio kreivės – A_P , naiviojo modelio CAP kreivės – įstrižainė punktyrinė linija.
3. Tarp ROC ir CAP grafikų (A ir B paveikslo dalys) pateikiama formulė, parodanti tiesinį ryšį tarp šių dviejų metodų.
4. ROC grafike (10 paveikslo dalis A) vaizduojamas hipotetinis atskyrimo taškas C, kuris turi savo „blogų“ ir „gerų“ subjektų klasifikavimo skirstinius (10 paveikslo dalis D), teisingai ir klaidingai klasifikuotų subjektų dalis, kurios gali būti transformuotos į klasifikavimo matricą (paveikslo dalis E), bei iš matricos išskaičiuoti teisingo klasifikavimo rodikliai (10 paveikslo dalis F²³).

²³ Klasifikavimo tikslumo rodikliai išsamiai analizuojami šio darbo 2.2.5. dalyje.



8 pav. Ryšys tarp parametrinių modelio diskriminacinės galios vertinimo metodų

Sudaryta autoriaus pagal Mileris (2009); Pranckevičiūtė (2007); Engelmann ir kiti (2003).

Sutrumpinimai:

Kreivės: CAP – kaupiamojo tikslumo kreivė (angl. *cumulative accuracy profile curve*); ROC – gavėjų veiklos charakteristikų kreivė (angl. *receiver operating characteristic curve*); A_p – plotas po tobulo modelio kreivės CAP grafike; A_r – plotas po analizuojamo modelio kreivės CAP grafike; AUC – plotas po analizuojamo modelio kreivės ROC grafike; Gini – Gini indeksas; atskyrimo taškas C (angl. *cut off point*).

Klasifikavimo matrica: TP – modelio teisingai klasifikuoti „geri“ skolininkai; TN – modelio teisingai klasifikuoti „blogi“ skolininkai; FN – modelio klaidingai klasifikuoti „blogi“ skolininkai (pirmo tipo klaida); FP – modelio klaidingai klasifikuoti „geri“ skolininkai (antro tipo klaida).

Modelio klasifikavimo tikslumo įvertinimo rodikliai: Ar – bendro tikslumo rodiklis (angl. *accuracy rate*); CCR – teisingo klasifikavimo rodiklis (angl. *correct classification rate*); MCR – klaidingo klasifikavimo rodiklis (angl. *misclassification rate*); α – klaidingo neigiamo klasifikavimo paklaidos santykis (angl. *false negative rate*); β – klaidingo teigiamo klasifikavimo paklaidos santykis (angl. *false positive rate*); Se – jautrumas (angl. *sensitivity*); Sp – specifiškumas (angl. *specificity*); PPV – teisingo teigiamo klasifikavimo dalis teigiamose klasifikacijose (angl. *positive predictive value*); NPV – teisingo neigiamo klasifikavimo dalis neigiamose klasifikacijose (angl. *negative predictive value*); F – F rodiklis (angl. *F value*).


Mokslinėje literatūroje analizuoti modelio įvertinimo metodai dažniausiai taikomi dviem etapais: pirma, atliekamas išankstinis modelio įvertinimas, antra – grįžtamasis modelio patikrinimas (angl. *backtesting*). Vertinant taikomi

tie patys šiame skyriuje aptarti metodai. Skirtumas yra tas, kad atliekant išankstinį modelio įvertinimą, lūžio taškas nustatomas ekspertiniu būdu (dažniausiai nustatant jį ties 0,5) o modelio savybės vertinamos testine imtimi, kuri formuojama iš pradinės turimos imties. Atliekant grįžtamąjį patikrinimą, modelis testuojamas „gamybinėje aplinkoje“, t. y. taikomas realiomis sąlygomis (pvz., imituojant modelio taikymą kredito įstaigoje, kuriai jis kuriamas), naudojant kredito įstaigos turimus duomenis bei kiekybiniais metodais nustatant lūžio tašką. Toliau darbe analizuojami pagrindiniai lūžio taško nustatymo principai.

Lūžio taško nustatymo metodai. Mokslinėje literatūroje yra išskiriamos dvi metodų rūšys, skirtos nustatyti optimalų atskyrimo tašką (Verbraken ir kiti, 2014; Bravo ir kiti 2013;): 1) pagrįsti klasifikavimo tikslumo analize ir 2) pagrįsti ekonominės²⁴ naudos optimizavimo analize. Pastarųjų metų moksliniai tyrimai rodo, kad kredito rizikos vertinimo atveju pastarasis metodas yra efektyvesnis (Verbraken ir kiti 2014; 2013; Bravo ir kiti 2013; Hand, 2009; Dompuos ir kiti, 2002; West, 2000).

Ekonominės naudos maksimizavimo būdų efektyvumą lemia nuostolių dydžio skirtumas dėl pirmo ir antro tipo klasifikavimo klaidų, t. y. kreditorius patiria didesnę nuostolį suteikęs „blogą“ paskolą, nei nesuteikęs „geros“: suteikęs paskolą nepatikimam klientui (II tipo klasifikavimo klaida) kreditorius praranda visą ar dalį paskolos, o nesuteikęs paskolą patikimam potencialiam klientui (I tipo klasifikavimo klaida), kreditorius praranda galimybę uždirbti pajamas. Dr. Hoffmanas, pateikęs visuomenei naudoti plačiai analizuojamą Vokietijos paskolų duomenų imtį (orig. *German credit data*), teigė, kad šioje imtyje nuostolių dėl klaidingo pirmo ir antro tipo klasifikavimo santykis yra 5:1 (žr. West, 2000), tačiau pasitaiko ir kitokios proporcijos (Frydman ir kiti, 1985). Bendrąja ekonomine prasme galima išskirti šiuos klasifikavimo poveikius (9 pav.).

²⁴ Sudarant modelius nepelno siekiančioms organizacijoms gali būti analizuojama ir neekonominė nauda. Pvz., Bravo ir kiti (2013) į optimalaus atskyrimo taško nustatymo metodiką įtraukė kintamąjį, atspindintį suteiktos paskolos sukuriamą socialinę gerovę.



9 pav. Galimi ekonominiai klaidingo ir teisingo klasifikavimo poveikiai

Sudaryta autoriaus.

Vienas pirmųjų mokslo darbų, kuriame buvo analizuotas klaidingos klasifikacijos kainos nustatymo klausimas kredito rizikos vertinimo srityje, yra Frydman ir kiti (1985) publikacija. Autoriai apibrėžė pagrindinius veiksnius, darančius įtaką klasifikacijos klaidų kainai: apriorinė tikimybė (angl. *prior probability*), kad objektas bus priskirtas vienai iš klaidingų klasifikavimo grupių (finansuotas nemokus ar atmestas mokus), pirmo ir antro tipo klaidų kaina. Autoriai pasitelkė klasifikavimo klaidos kainą kaip vieną iš sprendimų medžio apmokymo argumentų. West (2000), norėdamas apskaičiuoti klaidingo klasifikavimo kainą, pasiūlė tokią formulę (1-5):

$$Cost = C_{12}\pi_2 \frac{n_2}{N_2} + C_{21}\pi_1 \frac{n_1}{N_1} \quad (1-5)$$

Kur: Cost – klasifikavimo klaidos kaina; C_{12} ; C_{21} – II ir I tipo klaidų kainos²⁵; π_1 ir π_2 – apriorinės FP ir FN klaidų tikimybės.

Šiuo atveju FP ir FN klaidų apriorines tikimybes West (2000) apskaičiavo kaip santykį tarp rinkoje nurašomų paskolų koeficiento ir modelio sudarymo imties vidutinės klaidos; $\frac{n_2}{N_2}$ – FP; $\frac{n_1}{N_1}$ – FN.

²⁵ West (2000) tyrime remiamasi Hoffman pasiūlytomis FP ir FN kainomis, atitinkamai traktuota, kad $C_{12}=5$ ir $C_{21}=1$.

Šio disertacinio tyrimo autorius laikosi požiūrio, kad lūžio taškas kredito rizikos vertinimo modeliuose turėtų būti nustatomas laikantis ekonominio naudingumo principų. Vienas naujausių šiuos principus atitinkančių metodų – EMP metodas (tikėtino maksimalaus pelno metodas, angl. *expected maximum profit*) pagal Verbraken ir kiti (2014; 2013). Detaliai šis metodas analizuojamas šio darbo 2.2.6 dalyje.

1 intarpas. Tikėtinos klasifikavimo klaidos kainos apskaičiavimo pavyzdys pagal West (2000)

Traktuokime, kad vertinamas kredito rizikos vertinimo modelis (hipotetinis modelis) binarinio klasifikavimo tikslumą pasitelkus 2400 potencialių paskolų gavėjų duomenų imtį. Modelio prognozių tikslumas pateikiamas klasifikavimo matricos forma (I.1 lent.).

I.1 lentelė. Analizuojamo hipotetinio modelio binarinio prognozavimo tikslumo duomenys

		Faktas		Viso
		Blogas	Geras	
Modelio prognozė	Blogas	1000	300	2400
	Geras	100	1000	
Viso:		2400		

Remiantis Hoffman tyrimo duomenimis (žr. West, 2000) keliama prielaida, kad rinkoje santykiniai nuostoliai dėl „blogos“ paskolos suteikimo (II tipo klaida) ir „geros“ paskolos nesuteikimo yra 5:1. Kitaip tariant, suteikus „blogą“ paskolą, bus patirtas 5 kartus didesnis nuostolis, nei nesuteikus „geros“ paskolos (galima pasakyti ir kitaip: tam, kad atsipirktų „blogos“ paskolos nuostoliai, vidutiniškai reikia suteikti 5 „geras“ paskolas).

Tarkime, yra duomenų, kad kreditavimo rinkoje vidutinis nurašomų neveiksnių paskolų rodiklis (π_1) yra 10 %. Darytina prielaida, kad įprastai kreditoriai yra racionalūs ir konservatyvūs bei linkę labiau nesuteikti „geros“ paskolos, nei suteikti „blogą“ (tiek ekspertinio vertinimo atvejais, tiek ir statistinio modelio sudarymo atžvilgiu), todėl galima manyti, kad „geros“ paskolos turi dvigubai didesnę tikimybę būti nesuteiktos, nei suteiktos „blogos“ paskolos. Kitaip tariant, traktuosime, kad $\pi_1 = 2 \cdot \pi_2$. Atliksime skaičiavimus.

1. I tipo klaidos tikimybė:

$$\alpha = \frac{1000}{1000 + 300} = 0,23$$

2. II tipo klaidos tikimybė:

$$\beta = \frac{1000}{1000 + 300} = 0,09$$

3. *I tipo klaidos kaina:*

$$Cost_I = 0,23 * 0,2 * 1 = 0,046$$

4. *II tipo klaidos kaina:*

$$Cost_{II} = 0,09 * 0,1 * 2 * 5 = 0,09$$

5. *Klaidingo klasifikavimo kaina:*

$$Cost = 0,046 + 0,09 = \mathbf{0,136}$$

2. KREDITO RIZIKOS VERTINIMO MODELIO SUDARYMO METODOLOGIJA

Šios disertacijos pirmoje dalyje atlikta teorinė analizė leidžia sudaryti statistinį įmonių kredito rizikos vertinimo modelį, atsižvelgus į specifinius kredito unijų veiklos bruožus, tikslinį segmentą bei išorinius veiksnius. Siekiant sudaryti statistinį įmonių kredito rizikos vertinimo modelį kredito unijoms, atliktas tyrimas, susidedantis iš keturių tyrimo etapų (10 pav.).

I tyrimo etapas - Lietuvos kredito unijų sektoriaus tyrimas			II tyrimo etapas - modelio kūrimo imties sudarymas		
Tyrimo objektas	Tyrimo metodai	Tyrimo tikslai	Tyrimo objektas	Tyrimo metodai	Tyrimo tikslai
Lietuvos KU ir jų suteiktos verslo paskolos	K-vidurkių metodas, cirkuliarinės diagramos	KU sektoriaus struktūra ^[1-3]	I tyrimo etapo rezultatai, mažų ir labai mažų Lietuvos įmonių imtis	Bendramoksliniai tyrimo metodai	Modelio sudarymo ir testavimo imčių formavimas ^[4-6]
Lietuvos kredito unijos	Kohortos	Kredito rizikos vertinimo problematikos ir ją sąlygojančių veiksnių analizė KU sektoriuje ^[1-3]	I etapo tyrimo rezultatai, KU suteiktos verslo paskolos	Markovo grandinės ir kohortų analizė	Priklausomo modelio kintamojo ir paskolos stebėjimo laikotarpio apibrėžimas ^[7-8]
	Interviu, apklausa telefonu	Kredito unijų naudojamo modelio, jo taikymo problematikos ir ribotumo analizė ^[1]	I etapo tyrimo rezultatai, mokslinė, teisinė ir profesinė literatūra	Bendramoksliniai tyrimo metodai	Galimų modelio nepriklausomų kintamųjų sąvado sudarymas ^[9]
		KU lūkesčių ir reikalavimų analizė modelio veikimo paaiškinamumui ir diskriminacinei galiai ^[1]	I tyrimo etapo rezultatai, mažų ir labai mažų Lietuvos įmonių imtis	Informacijos vertės metodas, koreliacijos analizė, šalinamoji regresija	I modelį įtraukiamų nepriklausomų kintamųjų rinkinio formavimas ^[10-11]
		KU išorinės informacinės infrastruktūros ir svarbių nepriklausomų kintamųjų analizė ^[1-3]			
		Tikslinio modeliavimo segmento ir tikslo apibrėžimas ^[1-3]			
		„Blogo“ skolininko apibrėžimas KU sektoriuje ^[1]			
III tyrimo etapas - modelio sudarymas ir išankstinis patikrinimas			IV tyrimo etapas - modelio taikymas ir grįžtamasis patikrinimas		
Tyrimo objektas	Tyrimo metodai	Tyrimo tikslai	Tyrimo objektas	Tyrimo metodai	Tyrimo tikslai
I etapo tyrimo rezultatai, mokslinė, teisinė ir profesinė literatūra	Bendramoksliniai tyrimo metodai	Modelio klasifikatoriaus pasirinkimas ^[12]	III tyrimo etapo rezultatai, KU suteiktų paskolų imtis	Modelio taikymas	Sudaryto modelio taikymas kredito unijų veikloje ^[17]
II tyrimo etapo rezultatai, modelio sudarymo imtis (mažų ir labai mažų Lietuvos įmonių imtis)	Logistinė regresija, Voldo krit., įvairių statistinių rodiklių analizė	Įmonių kredito rizikos vertinimo modelio sudarymas logistinės regresijos pagrindu ^[13]	III tyrimo etapo rezultatai, KU suteiktų paskolų imtis	Modelio diskriminacinės galios įvertinimo rodikliai (tiek pasirinktame lūžio taške, tiek ir modelio bendrai)	Sudaryto modelio grįžtamasis patikrinimas ^[18]
Sudarytas modelis, modelio testavimo imtis (mažų ir labai mažų Lietuvos įmonių imtis)	Modelio diskriminacinės galios įvertinimo rodikliai (tiek pasirinktame lūžio taške, tiek ir modelio bendrai)	Išankstinis modelio patikrinimas ^[14]			
Mažų ir labai mažų Lietuvos įmonių imtis	EMP metodas (Verbraken ir kiti, 2014, 2013).	Optimalaus lūžio taško nustatymas apriorinio pelno atžvilgiu ^[15]			
	Rangų skalės sudarymo principai (Dzidzevičiūtė, 2013)	Rangų skalės sudarymas, atsižvelgiant į nustatytą optimalų lūžio tašką ^[16]			

10 pav. Statistinio įmonių kredito rizikos vertinimo modelio kredito unijoms sudarymo eiga

Sudaryta autoriaus.

Santrumpos: EMP – tikėtinas maksimalus pelnas (angl. *expected maximum profit*); KU – kredito unijos.

Pirmame tyrimo etape atlikta išsami Lietuvos kredito unijų sektoriaus analizė. *Pirmiausia* išanalizuotas Lietuvos kredito unijų sektorius, jo struktūra bei kredito unijų verslo paskolų portfelis, identifikuotos problemos, su kuriomis susiduria kredito unijos vertinant juridinių asmenų kredito riziką. *Antra*, atlikta kredito unijų apklausa. Apklausos metu nustatyti kredito unijų reikalavimai bendroms kredito rizikos vertinimo modelio savybėms bei išanalizuoti sunkumai, su kuriais susiduriama tobulinant esamą ir / ar kuriant naują kredito rizikos vertinimo modelį. *Pagrindinis šio tyrimo etapo uždavinys* – atsižvelgus į kredito unijų veiklos ypatumus, tikslinį segmentą ir išorinius veiksnius, kuriems veikiant bus taikomas kuriamas modelis, tinkamai nustatyti modelio sukūrimo metodus bei parinkti duomenis sudaromam modeliui.

Antrame tyrimo etape suformuotos modelio sudarymo ir testavimo imtys. Šalia bendramokslinių tyrimo metodų buvo taikytas Markovo grandinių metodas ir atlikta grafinė kohortų analizė. Apibrėžiant modelio priklausomą kintamąjį, pasitelkta LCKU verslo paskolų imtis. Modelio sudarymo ir testavimo imtys buvo suformuotos iš mažų ir labai mažų Lietuvos įmonių statistinės imties, kurią šiam tyrimui suteikė kreditų biuras UAB „Creditinfo Lietuva“.


Trečiame tyrimo etape, pasitelkus antrame tyrimo etape suformuotas imtis, logistinės regresijos pagrindu sudarytas statistinis modelis bei atliktas išankstinis modelio patikrinimas. Modelis sudarytas naudojantis R programiniu statistiniu paketu. Atliekant išankstinį modelio patikrinimą, analizuoti įvairūs statistiniai rodikliai, taip pat atlikti modelio distriminacinės galios patikrinimai – ir viso modelio bendrai, ir pasirinktame lūžio taške. Taikant Verbraken ir kiti (2014, 2013) pasiūlytą EMP metodą, nustatytas optimalus lūžio taškas. Atsižvelgus į nustatytą lūžio tašką, suformuota 10 rangų skalė, kiekvienam rangui priskiriant apriorinį PD.

Ketvirtame tyrimo etape sudarytas modelis pritaikytas vertinant LCKU verslo paskolų paraiškas bei atliktas grįžtamasis modelio įvertinimas – įvertintos modelio diskriminacinės savybės ir nustatytame lūžio taške, ir bendrai viso modelio.

Toliau šioje disertacinio tyrimo dalyje pristatoma empirinio tyrimo metodologija bei suformuluotos tyrimo hipotezės. Tyrimo metodai aptariami laikantis tyrimo atlikimo chronologijos, pavaizduotos paveiksle (10 pav.).

2.1. Kredito unių sektoriaus analizės metodologija

Kaip jau minėta šio disertacinio tyrimo 1.2.1. dalyje, prieš kuriant statistinį kredito rizikos vertinimo modelį, būtina apibrėžti taikomus metodus modeliui sukurti bei parinkti tinkamus duomenis. Siekiant, kad sudaryto modelio charakteristikos atitiktų kredito unių verslo poreikius, atliktas išsamus Lietuvos kredito unių sektoriaus tyrimas. Kredito unių sektoriaus tyrimą sudarė trys dalys: kredito unių sektoriaus apklausa, klasterizavimas ir paskolų portfelio tyrimas. Siekiant atlikti kredito unių klasterizavimą, papildomai atliktas kredito unių rinkos dydžių tyrimas (11 pav.).



11 pav. Kredito unių sektoriaus tyrimo atlikimo eiga

Sudaryta autoriaus.

Atliekant tyrimą, iškelti tokie uždaviniai:

1. Nustatyti, kiek ir kokių tikslinių kreditavimo segmentų išskiria kredito unijos bei kurie iš šių segmentų kredito rizikos vertinimo atžvilgiu kredito unijų laikytini probleminiais (4 pav., žingsnis 1A). Uždavinys svarbus tuo, jog probleminių segmentų identifikavimas leidžia tiksliai apibrėžti modeliojamą segmentą, modelio sudarymo tikslą, įvertinti imties ir modelio sudarymo galimybes, identifikuoti galimus nepriklausomus kintamuosius (4 pav., žingsniai 3, 4, 9).
2. Išanalizuoti paskolų įmokų vėlavimo dinamiką iškiriant skirtingus kredito unijų struktūrinius segmentus (4 pav., žingsnis 1E). Pirma, šis uždavinys svarbus todėl, kad kredito unijų sektoriaus struktūros ir paskolų portfelio analizės rezultatai leidžia geriau suprasti kredito rizikos vertinimo problematiką analizuojant ją iš kredito unijos perspektyvos (4 pav., žingsnis 1). Kredito rizikos problematikos suvokimas, savo ruožtu, suteikia galimybę sukurti kredito rizikos vertinimo modelį, orientuotą į svarbiausių kredito unijų sektoriaus problemų sprendimą. Antra, analizės rezultatai naudojami nustatant optimalų paskolos stebėjimo laikotarpį (4 pav., žingsnis 8).
3. Išanalizuoti vidinę ir išorinę informacinę infrastruktūrą (4 pav., žingsnis 1B, 2A). Ši informacija yra svarbi formuojant galimų nepriklausomų kintamųjų sąvadą (4 pav., žingsnis 9).
4. Išanalizavus kredito unijų kreditavimo politiką (4 pav., žingsnis 1D), nustatyti:
5. „blogo“ skolininko apibrėžimo požymius kredito unijose. Šios analizės rezultatai leidžia suformuoti priklausomo kintamojo apibrėžimą (4 pav., žingsnis 7) atsižvelgus į kredito unijų rizikos toleranciją ir kreditavimo politiką.
6. Nustatyti kredito unijų keliamus modelio veikimo paaiškinamumo reikalavimus. Šios analizės rezultatai yra svarbūs pasirenkant modelyje taikomą klasifikatorių (4 pav., žingsnis 1D).

7. Apibrėžti kredito unijų išskiriamus svarbiausius nepriklausomus kintamuosius.
8. Išanalizuoti kredito unijų disponuojamus ŽTF išteklius (4 pav., žingsnis 1C). Ši informacija yra svarbi nustatant modelio metodų sudėtingumo lygį (4 pav., žingsniai 4, 12).

Tyrimo lygis. Tyrimas atliekamas šalies (nacionaliniu) lygmeniu, kredito unijų sektoriuje. Atliekant apklausą, kredito unijos nebuvo diskriminuotos pagal (ne)priklausomybę kredito unijų asociacijoms ar LCKU.

Tyrimo metodai. Analizuojant kredito unijų sektorį, taikyti šie metodai:

1. Kredito unijų segmentavimui ir struktūrinei analizei taikyti *k-vidurkių* ir *cirkuliarinių diagramų* metodai.
2. Sprendžiant 1, 3, 4, 5 uždavinius, taikytas *apklausos metodas*. Metodas pasirinktas atsižvelgus į tai, kad iškelti klausimai susiję su konfidencialiais kredito unijų veiklos aspektais, ir tai, kad klausimų turinį gali tekti aiškinti.
3. Sprendžiant 2 uždavinį, taikytas grafinės analizės metodas – *kohortos*.
4. Taikyti bendramoksliniai tyrimo metodai.

Toliau detalai analizuojama kiekvienos tyrimo dalies metodologija laikantis paveiksle (11 pav.) pristatyto eiliškumo: pirma – analizuojama Lietuvos kredito unijų sektoriaus apklausa, antra – kredito unijų klasterizavimas ir trečia – kredito unijų verslo paskolų portfelio tyrimas.

Kredito unijų apklausa. Tyrimo atlikimo metu Lietuvoje veikė 74 kredito unijos ir Lietuvos Centrinė kredito unija (LB, 2015). Tyrimo rezultatai kiekvienoje kredito unijoje gali priklausyti nuo daugelio veiksnių ir galimų jų kombinacijų, pvz.: unijos turto dydis, galima veiklos teritorija, (ne)priklausomybė įvairioms asociacijoms ir / ar LCKU, nuosavo kapitalo dydis, riziką ribojančių normatyvų dydžiai, paskolų portfelio struktūra, taikomi pardavimo kanalai, organizacinė struktūra ir pan. Atsižvelgus į šias populiacijos savybes, galima teigti, kad kredito unijų populiacija tyrimo uždavinių atžvilgiu nėra homogeniška. Dėl šios priežasties, taip pat siekiant, kad tyrimo rezultatai atspindėtų realias populiacijos savybes, buvo iškeltas tikslas pagal galimybę apklausti visą populiaciją. Apklausti pavyko 56 kredito

unijas, iš kurių 28 buvo apklaustos interviu būdu (susitikimo metu), o likusios – telefonu.

Atrankinio tyrimo rezultatai visada turi didesnę ar mažesnę neapibrėžtumą. Didinant atrankos apimtį, jis mažėja, atitinkamai didėja išvadų tikslumas. Išvadų tikslumą galima įvertinti pasitelkus minimalaus atrankos dydžio $n_{\min}$ apskaičiavimo formulę (2-1) (Martišius, 1997; Schutt, 2011):

$$n_{\min} = \frac{z_{\alpha}^2 N p (1 - p)}{(\Delta p)^2 (N - 1) + z_{\alpha}^2 p (1 - p)} \quad (2-1)$$

Formulės dydžiai:

N – populiacijos dydis; darbe tiriamos Lietuvoje tyrimo metu veikusios 74 kredito unijos ir Lietuvos Centrinė kredito unija;

P – požymio tikimybė; ji dažniausiai nežinoma; kadangi nėra kitų žinių apie p dydį, galima imti $p=0,5$;

z_{α} – normaliojo skirstinio koeficientas; šiame tyrime traktuotina, kad visi rezultatai bus gauti su 95 % tikimybe, tada normaliojo skirstinio koeficientas $z_{\alpha}=1,96$;

$n_{\min}$ = tyrime apklaustos 56 kredito unijos;

Δp – požymio dalies paklaida, kurią galima paskaičiuoti iš formulės (2-2).

$$\Delta p = \sqrt{\frac{z_{\alpha}^2 p (1 - p) (N - n_{\min})}{n_{\min} (N - 1)}} \quad (2-2)$$

Duomenis surinkus iš 56 kredito unijų, rezultatai buvo gauti su 95 % tikimybe ir 6,5 % paklaida. Kredito unijų apklausa vyko nuo 2015 m. birželio 3 d. iki 2015 m. rugsėjo 15 d.²⁶. Apklausiai sudaryta anketa (1 priedas), kurią pokalbių su respondentais metu pildė autorius. Apklaustos rezultatai analizuojami šio darbo 3.1 dalyje. Laikantis respondentų pageidavimų, apklaustos rezultatai pateikti išlaikant respondentų anonimiškumą.

²⁶ Pirmos ir paskutinės apklaustos datos

Kredito unijų klasterizavimas. *Pirma, atliekamas kredito unijų potencialių rinkos dydžių apskaičiavimas.* Kredito unijos veikia teritoriniu principu ir gali teikti paslaugas nariams, kurie dirba, mokosi arba gyvena kredito unijos registracijos vietos savivaldybėje arba tose savivaldybėse, kurios ribojasi su registracijos savivaldybe (LR Kredito unijų įstatymas, Žin. 1995, 26-578, 12 str., 1 p.). Siekiant nustatyti rinkos, kurioje veikia kredito unija, dydį, buvo vertinamas gyventojų kiekis (LRSD, 2015, 2011). Vertintos tos gyvenvietės, kuriose analizuojama kredito unija registruota bei kuriose LCKU duomenimis (LCKU, 2015) veikė analizuojamos unijos nutolusios kasos²⁷. Potencialus kiekvienos unijos rinkos dydis nustatytas pagal formulę (2-3):

$$KURD_n = PKUB + \sum_{i=1}^k PKUNK_i \quad (2-3)$$

Formulėje:

– n -tosios kredito unijos veiklos teritorijos registruotas gyventojų skaičius;

$PKUB$ – gyvenvietės, kurioje registruota KU buveinė, gyventojų skaičius;

$PKUNK_i$ – gyvenvietės, kurioje veikia kredito unijos nutolusi kasa, gyventojų skaičius.

Antra, atliekamas kredito unijų klasterizavimas pagal priskirtus požymius. Be duomenų, gautų apklausos metu, kredito unijoms priskirti papildomi požymiai – rinkos, kurioje veikia kredito unija dydis, turto dydis ir paskolų portfelio dydis. Pasirinkta šiuos požymius suskirstyti į tris tipus – didelį, vidutinį ir mažą. Siekiant tiriamų objektų suskirstymo pagal pasirinktus požymius tikslumo, nutarta atsisakyti ekspertinio skirstymo ir taikyti statistinį klasterizavimo metodą. Klasterizuotos visos Lietuvos kredito unijos, nepriklausomai nuo to, ar jos dalyvavo apklausoje.

²⁷ Kai kurios kredito unijos vis dar turi nutolusias kasy tose teritorijose, kuriose neturi teisės teikti paslaugas. Tokios nutolusios kasy į tyrimą nebuvo įtrauktos.

Klasterinės analizės tikslas – suskirstyti objektus į panašių objektų grupes. Vienas populiariausių klasterinės analizės metodų, tinkamų taikyti, kai norimas klasterių kiekis nustatomas iš anksto, – k-vidurkių metodas (Paulauskienė, 2013). Šiuo metodu objektai suskirstomi į klasterius taip, kad skirtumai tarp objektų klasterio viduje būtų kuo mažesni, o tarp klasterių – kuo didesni.

Pirma, visoms šalyje veikusioms (74) kredito unijoms buvo priskirtas požymio rinkinys $x_1, x_2, x_3 \dots x_p$, pagal kurį jos turėjo būti suskirstytos į tris klasterius. Antra, atsitiktiniu būdu buvo parinkti trys objektai, kurie laikyti etalonais, jiems priskirti eilės numeriai, kurie buvo ir klasterių numeriai. Trečia, iš likusių (71) objektų buvo išskirtas taškas X_i , kurio koordinatės yra $x_{i1}, x_{i2}, x_{i3} \dots x_{ip}$, bei pasitelkus Euklido metriką, patikrinta, kurio etalono (centro) jis buvo arčiausiai. Analizuojamas objektas prijungtas prie etalono, kuriam atitiko $\min d_{il} (l = 1, \dots, k)$. Ketvirta, etalonas pakeistas nauju, perskaičiuotu pagal įvertintą tašką. Procedūra kartota visiems objektams, taip visos kredito unijos priskirtos vienam iš trijų klasterių (Mileris, Glinskienė, 2007). Pasitelkus k-vidurkio klasterizavimo metodą, unijoms buvo priskirti rinkos dydžio, turto dydžio ir paskolų portfelio dydžio požymiai.

Trečia, atliekama kredito unijų sektoriaus struktūros analizė. Siekiant atskleisti unijoms priskirtų požymių tarpusavio ryšius ir kredito unijų sektoriaus struktūrą, pasirinkta taikyti cirkuliarinių diagramų metodą, kuris suteikia galimybę grafiškai pavaizduoti tiriamų objektų požymių pasiskirstymo struktūrą. Šis metodas kartu su specialia atviro kodo programine įranga Circos buvo pasiūlytas autorių Krzywinski, Schein, Birol ir kt. (2009) ir yra plačiai naudojamas genų inžinerijos ir bioinformatikos mokslų srityse (Darzentas, 2010; Schnable, Ware, Fulton ir kt. 2009)²⁸. Nors cirkuliarinės diagramos metodas yra populiariausias gamtos moksluose, jis gali būti taikomas ir kitose mokslinių tyrimų srityse, kuriose siekiama pavaizduoti reiškinių tarpusavio ryšius cirkuliarine forma.

²⁸ Išsamus mokslinių publikacijų, kuriose taikomas cirkuliarinių diagramų grafinis atvaizdavimo metodas, sąrašas yra patalpintas autorių tinklapyje: <http://circos.ca/images/published/>.

Kredito unijų sektoriaus verslo paskolų portfelio analizė. Pasitelkus Lietuvos Centrinės kredito unijos LCKU sistemai priklausančių kredito unijų verslo paskolų portfelių duomenis, atliktas paskolų portfelio kokybės tyrimas. Duomenų imtį sudarė 4339 verslo paskolų duomenys. Jos buvo suteikiamos nuo 2010 sausio 5 d. iki 2015 gruodžio 30 d. ir sudarė visas LCKU vienijamų kredito unijų suteiktas verslo paskolas.

Tyrimas buvo atliekamas tokia seka. *Pirma*, kiekvienai paskolai priskirti ją suteikusių kredito unijos požymiai: turto, paskolų portfelio ir tikslinės rinkos dydžiai. *Antra*, paskolos suskirstytos į kohortas K_m , kur m – kohortos eilės numeris. Kiekviena kohorta formuota iš tą patį mėnesį suteiktų paskolų. Taikytas stebėjimo laikotarpis – 40 mėn. Kadangi paskolos buvo suteikiamos skirtingais laikotarpiais, ne visos kohortos padengė pilną stebėjimo laikotarpį. Hipotetinė tyrimo duomenų struktūros forma gali būti pavaizduota taip:

$$\begin{array}{cccccc}
 & t_1 & t_2 & t_3 & t_k & t_{40} \\
 K_1 & pv_{1,1,40} & pv_{1,2,40} & \cdots & \cdots & pv_{1,40,40} \\
 & pv_{2,1,40} & \cdots & \cdots & \cdots & \vdots \\
 & \vdots & \cdots & \cdots & \cdots & \vdots \\
 K_2 & pv_{1,1,40} & \cdots & \cdots & \cdots & pv_{1,40,40} \\
 \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\
 K_m & \vdots & \vdots & \vdots & \vdots & \vdots \\
 & pv_{i,n,k} & \cdots & \cdots & pv_{i,n,k} &
 \end{array} \quad (2-4)$$

Formulėje:

K_m – kohorta m ;

pv – paskolos vėlavimo dienų skaičius;

i – paskolos numeris kohortoje K_n ;

n – paskolos būvimo portfelyje trukmė;

k – kohortos stebėjimo trukmė.

Pavyzdžiui, kohortoje K_5 įrašas $10_{2,7,36}$, reikštų, kad paskola, esanti antra pagal eiliškumą (i) penktoje kohortoje (m), septintą mėnesį po paskolos suteikimo (n) pasižymėjo dešimties dienų mokėjimo pradelsimu (pv) ir iš viso ši paskola tyrimo metu buvo stebima 36 mėnesius (k).

Trečia, suskaičiuoti vidutiniai kiekvieno paskolų mėnesio vėluojančių paskolų rodikliai išskiriant 30, 60, 90 ir 120 d. vėlavimus. Ketvirta, apskaičiuoti kiekvieno unijų segmento rodikliai.

$$avg_pv_{n,vds,s} = \frac{1}{l} \sum_{i=1}^l pv_i \quad (2-5)$$

Čia:

avg_pv – vidutinio paskolos mokėjimo pradelsimo dienomis rodiklis;

n – paskolos būvimo portfelyje trukmė;

vds – analizuojamas vėlavimo dienomis kiekis (30, 60, 90, 120 d.);

s – analizuojamas kredito unijų segmentas;

l – n -tajį mėnesį stebėtų paskolų (visose kohortose) kiekis.

Taip buvo sudarytos LCKU verslo paskolų vėlavimo kohortos, kurios detalai analizuojamos šio darbo 3.1.2 skyriuje.

2.2. Statistinio kredito rizikos vertinimo modelio kūrimo metodologija

2.2.1. Modelio kūrimo imties sudarymas

Kaip jau minėta, modelio kokybinės savybės tiesiogiai priklauso nuo duomenų imties pakankamumo ir kokybės, todėl duomenų paruošimas gali padidinti arba pamažinti galutinį modelio veikimo efektyvumą. Literatūroje, analizuojančioje statistinių kredito rizikos vertinimo modelių sudarymą, dažnai nurodoma, kad įprastai norint suformuoti modelį, reikia ne mažiau kaip 1000 ar 2000 „gerų“ ir „blogų“ paskolų duomenų, t. y. iš viso nuo 2000 iki 4000 (Finlay, 2012; Siddiqi, 2006). Anderson (2007) taip pat rekomenduoja naudoti ne mažiau kaip 1000, o Siddiqi (2006) – ne mažiau kaip 2000 atmestų paraiškų duomenų. Minimalių galimų naudoti imčių klausimu skirtingų autorių nuomonės skiriasi, pvz., Mays, Lynas (2010) nurodo, kad minimalus galimas

įrašų skaičius imtyje gali sudaryti po 300 kiekvienai skolininkų grupei (iš viso 900); Anderson (2007) siūlo naudoti modeliui sudaryti ne mažiau kaip 400 „blogų“ paskolų duomenis.


Norint sudaryti modelį, duomenų kiekio didinimas modelio kokybei turi teigiamą įtaką, tačiau pastebima, kad ribinis imties įrašų kiekio padidėjimas daro vis silpnesnę įtaką modelio kokybei. Finlay (2012) pateikia pavyzdį, kai imties padidėjimas nuo 2000 iki 5000 įrašų daro didesnę įtaką modelio diskriminacinei galiai, nei imties padidėjimas nuo 5000 iki 50000 įrašų. Anderson (2007) rekomenduoja nenaudoti modeliui sudaryti daugiau nei 5000 „blogų“ paskolų įrašų. Pasak cituotų autorių, šie skaičiai paremti praktine patirtimi sudarant kokybiškus modelius. Papildomai norint nustatyti imties dydį gali būti taikoma įprastinė statistinė imties dydžio nustatymo formulė (žr. 2-1 formulę) (Shutt, 2011; Dzidzevičiūtė, 2010; Martišius, 1997). Papildomai, siekiant užtikrinti didesnę modelio tikslumą, Dzidzevičiūtė (2010) optimaliam skolininkų skaičiui pasirinkti siūlo taikyti Neyman-Pearson optimalaus pasiskirstymo algoritmą, po to atitinkamai padidinti arba sumažinti imties dydį.

Įprastai kredito įstaigoms sunkiausia yra gauti „blogų“ paskolų duomenis, nes jų dalis paskolų portfelyje yra mažiausia. Siekdami suformuoti reikiamą „blogų“ paskolų imtį, kreditoriai sujungia iš skirtingų šaltinių gautus duomenis, po to dažniausiai „gerų“ ir „blogų“ paskolų proporcijos nebeatitinka kreditoriaus portfelyje esančios proporcijos. Taip susiduriama su „gerų“ ir „blogų“ skolininkų santykio problema. Siddiqi (2006) rekomenduoja išlaikyti natūralią portfelyje esančią „gerų“ ir „blogų“ skolininkų proporciją ir daro prielaidą, kad portfelio struktūra yra reprezentatyvi segmento populiacijos struktūrai, tačiau praktikoje tai pasiteisina ne visada. Galima alternatyva: kai kreditoriaus portfelis ar modeliuojamas portfelio segmentas yra mažas, kreditoriai gali remtis ir kitais išoriniais šaltiniais, pvz., kreditų biurais. Tokiu atveju turėtų būti tinkamai suformuota segmento imtis išorinio duomenų tiekėjo duomenų bazėje.

Ne visada natūrali „gerų“ ir „blogų“ paskolų duomenų proporcija tinka pasirinktam klasifikatoriaus tipui. Čekanavičius ir Murauskas (2004) sudarant logistinės regresijos modelį nurodo naudoti ne mažiau kaip 20 ir ne daugiau kaip 80 proc. „blogų“ skolininkų. Norint pagal poreikį pakoreguoti „gerų“ ir „blogų“ skolininkų proporcijas, galima mažinti arba didinti „blogų“ skolininkų skaičių taip pasiekiant norimą proporciją. Įrodyta, kad naudojant imtį su subalansuota „gerų“ ir „blogų“ skolininkų proporcija, pasiekiami geresni modelių tikslumo rezultatai (Finlay, 2012).

Suformavus imtį su tinkamu „gerų“, „blogų“ ir atmestų paskolų santykiu, ji išskaidoma į dvi: apmokymo ir testavimo. Idealiu atveju įrašai iš imties sudarymo laikotarpio yra paskirstomi atsitiktine tvarka į vieną ir kitą imtis, jei duomenų trūksta – iš apmokymo imties atsitiktine tvarka išrenkami įrašai ir iš jų suformuojama testavimo imtis.

Atliekant grįžtamąjį modelio patikrinimą, testuojant patartina naudoti įrašus ne vien iš apmokymo imties sudarymo laikotarpio (12 pav.). Paveiksle raidėmis A žymimi laikotarpiai, kurių duomenys yra naudojami testuoti modelį kitu, nei apmokymo, laikotarpiu; įprastai naudojami vėlesnio laikotarpio duomenys (Anderson, 2007).



12 pav. Modelio sudarymui naudojami duomenys

Sudaryta autoriaus pagal Anderson (2007).

Nuo modelio apmokymo imties sudarymo iki modelio formavimo gali būti praėję nemažai laiko, todėl atliekant grįžtamąjį modelio patikrinimą, siekiant modelį išbandyti su aktualiais duomenimis, jis papildomai gali būti testuojamas su pastaruoju laiku analizuotomis paskolomis (12 pav., B). Tiesa, remiantis pastarojo laikotarpio duomenimis, modelio tikslumo įvertinti greičiausiai nepavyks, nes nėra praėjęs jų stebėjimo laikotarpis, tačiau taip

patikrinamas modelio veikimo stabilumas, tai ypač aktualu taikant aukšto automatizavimo lygio modelius, kuriuose tiesiogiai naudojami vertinimo duomenys iš išorinių duomenų bazių.

Įrašų su praleistais stebėjimais įtraukimas į imtį. Visais atvejais sudarant imtį, keliama prielaida, kad imtis bus reprezentatyvi pasirinktai populiacijai. Kaip jau minėta, į imties sudarymą dažniausiai autoriai siūlo įtraukti „geras“, „blogas“ ir atmestas paskolas, taigi susiduriama su dilema: prie kurių „gerų“ ar „blogų“, paskolų reikia priskirti atmestas paraiškas ir paskolas, kurių suteikimui buvo pritarta, tačiau jos nebuvo išduotos dėl kitų priežasčių, pvz., paskolos gavėjas persigalvojo, pasiskolino iš kito kreditoriaus ir pan. Atmestų paraiškų įtraukimo (angl. *reject inference*) aktualumas priklauso nuo pasirinktos imties sudarymo konteksto. Didesnę įtaką modelio kokybiniam rodikliams atmestų paraiškų įtraukimas turės tose imtyse, kurios sudarytos esant žemam rizikos tolerancijos lygiui (angl. *high cut off point*), pasirinktų segmentų populiacijos narių rizika yra heterogeninė, paraiškų ir kredito rizikos vertinimo procesai yra efektyvūs (Anderson, 2007).


Tarkime, kredito įstaiga gavo n kredito paraiškų, kiekviena turi $X_1, X_2, X_3, \dots, X_n$ nepriklausomų kintamųjų, sudarančių vektorių X . Kredito kokybė („Gera“ / „Bloga“) charakterizuojama Y ir kartais yra nežinoma, t. y. $Y=?$. Kredito įstaiga kiekvienai paraiškai priskiria kredito rizikos koeficientą k , $S_k = f(X_k)$. Kredito rizikos tolerancijos riba yra h , kreditas suteikiamas, jei $S_k \geq h$, kitu atveju paraiška atmetama ir kreditas nėra teikiamas. Kredito (ne)suteikimo duomuo a yra lygus 1, jei kreditas suteikiamas ir $a=0$, jei kreditas neteikiamas. Kredito kokybė $Y=1$, kai paskola yra „gera“ ir $Y=0$, kai „bloga“ (Chen, Astebro, 2003; papildyta autoriaus).

Padarius prielaidas, kad kreditoriai veikia tobulos konkurencijos sąlygomis, vartotojų elgsena yra racionali, palūkanų normą visais atvejais priklauso nuo prisiimamos kredito rizikos, paklausa nėra elastinga, o pasirinkto segmento rizikos homogeniškumas niekada nebus idealus, galima teigti, jog *ceteris paribus* trūkstami duomenys susidarys ne tik iš atmestų paraiškų klasių. Nors įprastai kreditoriaus rizikos tolerancija galėtų būti apibrėžta kaip $S_k < h$,

tokia išraiška neturėtų būti apibūdinama duomenų trūkumo tendencija. Kreditoriaus turimi duomenys susidarys iš šių kelių grupių (13 pav.).

Kaip matyti iš paveikslo (13 pav.), kreditoriaus turimi duomenys susidarys iš kelių duomenų grupių:

1. Pareiškėjų grupė A, atitinkanti kreditoriaus reikalavimus, tačiau galinti rinkoje pasiskolinti palankesnėmis sąlygomis: $h > S_k < r$, kur r – kreditoriaus konkurencingumo riba. Jei tokie asmenys kreiptųsi į kreditorių, didelė tikimybė, kad gavę kreditoriaus pasiūlymą, jie atsisakytų sudaryti su juo paskolos sutartį. Tokiu atveju vektoriaus X nariai kreditoriui yra žinomi, paskolos klasė Y – ne.
2. Pareiškėjų grupė B, kuriems išduotos paskolos, jų $h > S_k > r$. Šioje grupėje nėra trūkstamų duomenų, tiek nepriklausomi kintamieji, tiek ir paskolų klasės yra žinomi.
3. Pareiškėjų grupė C – atmestos paraiškos, tai grupė paraiškų, kurių $h < S_k$. Kreditoriui yra žinomi nepriklausomieji kintamieji, tačiau nežinoma paskolos klasė. Šios grupės trūkstamų duomenų įtraukimas yra labiausiai ištirtas ir aprašytas tyrėjų ir praktikų.



13 pav. Pasirinktą modeliavimo segmentą sudarančių duomenų struktūra

Sudaryta autoriaus.

Pagal aprašytus duomenis galima suformuoti matricą (9 lentelė):

9 lentelė. Duomenų struktūros matrica

	X_1	X_2	.	.	.	X_n	S	Y	a
1	X_{11}	X_{12}	X_{13}	X_{14}	X_{15}	X_{16}	S_{max}	?	0
2	.	.	.	.	.	.	.	?	0
3	.	.	.	.	.	.	r	G/B	1
4	X_{41}	X_{42}	.	.	.	X_{4n}	.	.	1
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	h	G/B	1
.	.	.	.	.	.	.	$h-1$	?	0
.	.	.	.	.	.	.	.	?	0
.	.	.	.	.	.	.	.	.	.
n	X_{n1}	X_{n2}	.	.	.	X_{nn}	S_{min}	?	0

Sudaryta autoriaus pagal Chen, Astebro, 2003; papildyta autoriaus.

Iš matricos galima matyti, kad kintamasis objektas turi trūkstamų duomenų, kai $h > S_k < r$ arba $S < h$, visi kiti duomenys, tiek $a=1$, tiek ir $a=0$ objektų yra žinomi. Čia a gali būti apibrėžiamas kaip antraeilis (papildomas) duomenų trūkumui įtaką darantis veiksnys, turintis savo skirstinį (Chen, Astebro, 2003), kuris turi poveikį duomenų poaibio Y_{mis} trūkumui, tik vienu atveju tai siejama su kreditoriaus rizikos tolerancijos riba, kitu – su paskolos gavėjo pasirinkimu. Toks duomenų trūkumo kontekstas, anot Rubin (1976), yra laikomas neatsitiktiniu (angl. *not missed at random*, *NMAR*).

Rubin (1976) nustatė tris kontekstus, kuriems esant gali būti analizuojami įrašai su praleistais stebėjimais (Mok, 2009; Anderson, 2007; Banasik, Crook, 2004; Feelders, 2003; Pigott, 2001; Heitan, Basu, 1996; Little, Rubin, 1989; Little, 1988; Rubin, 1976):

Pirmas. Trūkumas esant pilnam atsitiktinumui (*missing completely at random*, **MCAR**) – situacija, kai duomenų trūkumas yra nepriklausomas tiek nuo priklausomo, tiek ir nuo nepriklausomų kintamųjų, t. y. duomenų trūkumas yra visiškai atsitiktinis:

$$P(A) = P(Y|X, y_{obs}) = P(Y|X, y_{mis}) \quad (2-6)$$

MCAR situacija susidarytų tada, jei paskolos būtų išduodamos atsitiktine tvarka. Suprantama, kad tokia situacija praktikoje yra reta. Kredito įstaigos galėtų išduoti kelias aukštesnės rizikos, nei priimtina, paskolas ir taip „nusipirkti patirtį“, toks metodas dar vadinamas atsitiktiniu papildymu (angl. *random supplementation*) (Anderson, 2007; Feelders, 2003). Kaip pastebi autoriai Chen ir Astebro (2012), toks „patirties pirkimas“ būtų imlus investicijoms norint suformuoti reprezentatyvią imtį²⁹.

Antras. Trūkumas esant atsitiktinumui (angl. *missing at random, MAR*) – situacija, kai duomenų trūkumas priklauso tik nuo duomenų, t. y. nuo nepriklausomų kintamųjų, bet ne nuo rezultatinio kintamojo:

$$P(Y|X) = P(Y|X, y_{obs}) = P(Y|X, y_{mis}) \quad (2-7)$$

Trečias. Tokia situacija yra praktiškai įmanoma tais atvejais, kai kreditoriai priiminėja sprendimus remdamiesi formaliais kriterijais, pvz., ekspertiniais modeliais. Tuo atveju Y analizuojama tik tada, kai funkcija g kintamųjų X , viršija toleruotina reikšmę, $g(X) \geq h$, kur h yra konstanta, rizikos tolerancijos riba (Feelders, 2003).

Trūkumas beatsitiktinumo (angl. *not missing at random, NMAR*) – situacija, kai duomenų trūkumas priklauso tiek nuo nepriklausomų kintamųjų, tiek ir nuo rezultatinio kintamojo:

$$P(Y|X) \neq P(Y|X, y_{obs}) \neq P(Y|X, y_{mis}) \quad (2-8)$$

Ši situacija praktiškai yra labiausiai tikėtina, remiantis prielaida, jog tai, kad kreditorius paraišką atmetė, turi ryšį su tuo, kad paskola greičiausiai taptų „bloga“.

²⁹ Autoriaus žiniomis, toks „patirties pirkimas“ taikytas kreditorių praktikoje šio tyrimo atlikimo metu.

Informacijos trūkumo konteksto prielaida yra reikšminga. MCAR ir MAR kontekstų atveju atmestų paraiškų problemos sprendimas yra ženkliai supaprastinamas. MCAR atveju atmestų paraiškų klausimas gali būti ignoruojamas ir modelis sudaromas remiantis tik išduotų paskolų informacija (Mok, 2009; Anderson, 2007; Banasik, Crook, 2004; Chen, Astebro, 2003; Feelders, 2003; Pigott, 2001; Weldon, 1999; Schafer, 1997; Heitan, Basu, 1996). Norint įtraukti įrašus su praleistais stebėjimais į modelio kūrimo imtį, plačiai taikomi augmentacijos ir ekstrapoliacijos metodai.

Augmentacija. Augmentacijos metodo taikymą galima suskirstyti į du etapus: klasių perskirstymą ir persvėrimą. Pirmiausia pasirenkamas matas, pagal kurį nustatoma tikimybė, kad patvirtintos paraiškos taps „blogos“ ar „geros“. Tokiu matu gali tapti išorinis, vidinis reitingas ar specialus rodiklis. Vėliau pagal pasirinktą matą sudaromi režiai, juose nustatomas patvirtintų paraiškų lygis, paskirstomos tiek patvirtintos, tiek atmestos paraiškos. Atras metodo etapas, persvėrimas, skirtas charakterizuoti įrašus su praleistais stebėjimais. Nors šio metodo taikymas gali pasirodyti patrauklus dėl savo paprastumo, jis turėtų būti pasitelkiamas atsargiai, atsižvelgus į daromas svarias prielaidas, kurioms esant jis galioja (Anderson, 2007; Banasik, Crook, 2004; Weldon, 1999, papildyta autoriaus):

- MAR kontekstas;
- pasirinktas vertinimo matas bus reprezentatyvus;
- bus prieinama vienoda tiek patvirtintų, tiek ir atmestų paskolų informacija.

Ekstrapoliacija. Kita MAR aplinkoje taikoma technika yra ekstrapoliacija, dar vadinama parceliavimu (angl. *parcelling*). Ji taip pat, kaip ir augmentacija, priskiria žinomus rezultatus nežinomiems, atsižvelgdama į jų rizikos savybes ir pasitelkdama išorinį ar vidinį reitingą, rodiklį ar jų rinkinį, parodantį nemokumo tikimybę. Šiam metodui galioja tos pačios prielaidos, kaip ir augmentacijai. Pagrindinis skirtumas tarp augmentacijos ir ekstrapoliacijos yra tas, kad ekstrapoliacijos metodas numato tariamą visų

objektų perkėlimą į patvirtintų paraiškų grupę, kurioje paskolai priskiriamas „geros“ arba „blogos“ paskolos statusas.

Mokslinėje literatūroje dažnai keliamas klausimas dėl augmentacijos ir ekstrapoliacijos metodų efektyvumo ir įtakos modelio diskriminacinei galiai (Anderson, 2007; Banasik, Crook, 2004; Weldon, 1999). Banasik ir Crook (2004), ištyrę augmentacijos šio metodo įtaką galutiniam modelio efektyvumui, padarė išvadą, jog esant aukštesniam rizikos tolerancijos laipsniui, metodo įtaka yra neženkliai, o esant žemai rizikos tolerancijai, metodo taikymas daro neigiamą įtaką modelio diskriminacinei galiai. Autoriai taip pat pastebi, kad taikant augmentacijos metodą atsiranda rizika suformuluoti pernelyg optimistines prognozes apie „gerų“ ir „blogų“ skolininkų pasiskirstymą atmetų paraiškų imtyje. Tyrėjai, analizavę ekstrapoliacijos metodo efektyvumą (Banasik, Crook, 2004; Weldon, 1999), priėjo prie išvados, kad metodas nepasižymi aukštu tikslumu ir jo taikyti nerekomendavo. Tokios autorių įžvalgos gali būti paaiškinamos tuo, jog tiek ekstrapoliacijos, tiek ir augmentacijos metodai taikomi darant prielaidą dėl MAR konteksto, tačiau tobula MAR aplinka praktikoje pasitaiko retai. Net ir tais atvejais, kai kreditoriai sprendimui priimti pasitelkia ekspertinius modelius ir formalias taisyklių sistemas, jos vis vien turi savybę atskirti „gerus“ ir „blogus“ skolininkus (kitu atveju būtų galima paskolas išdavinėti atsitiktinai, tai privestų prie MCAR konteksto). Kuo griežtesnes paskolų išdavimo taisykles nusistato kredito įstaiga, tuo, tikėtina, „blogų“ paskolų dalis išduotose paskolose bus mažesnė, o tai gali turėti įtakos ir pasirinkto mato reprezentatyvumui. Pažymėtina, kad tiek ekstrapoliacijos, tiek ir augmentacijos metoduose pasirinktas kategorizavimo matas gali neapimti visų rizikos veiksnių. Nežiūrint į aibę trūkumų, augmentacijos ir ekstrapoliacijos metodai praktikoje taikomi dažniausiai (Anderson, 2007; Banasik, Crook, 2004).

Praktikoje analizuojamai problemai spręsti taikomi ir kiti metodai. Kredito įstaiga, siekdama išsiaiškinti, ar atmetas skolininkas taptų „geru“ ar „blogu“, gali tikrinti jo duomenis išoriniuose šaltiniuose ir, jei tas skolininkas yra gavęs paskolą kitoje kredito įstaigoje, remtis jo dabartine kredito istorija

(Ash, Meester, 2002). Tačiau toks metodas turi trūkumų.– Pirma, jis gali būti netikslus: paskolos gavėjas gali būti gavęs ne tos pačios sumos paskolą, jam gali būti taikoma kita palūkanų norma, nei būtų taikoma modelį sudarančioje kredito įstaigoje, gali skirtis paskolos terminas ir pan. Šie veiksniai turi įtaką mėnesinėms įmokoms ir skolininko galimybėms vykdyti įsipareigojimus. Antra, šis metodas yra imlus kaštams ir gali ženkliai padidinti modelio sudarymo savikainą. Tuo atveju, jei skolininkas yra gavęs kitą paskolą toje pačioje kredito įstaigoje, paraiškai gali būti priskiriamas tos paskolos statusas (Dzidzevičiūtė, 2010). Visos atmestos paraiškos taip pat gali būti priskiriamos prie „blogų“ paskolų, tačiau tai gali turėti neigiamą įtaką modelio tikslumui.

Imties sudarymo tikslas yra charakterizuoti pasirinkto tikslinio modeliavimo segmento populiaciją remiantis kreditoriaus turimais duomenimis. Kiekvienas kreditorius turi savitą rinkos poziciją ir rizikos tolerancijos ribas, atitinkamai jie formuoja marketingo strategiją ir kreditoriaus pozicionavimą rinkoje. Šios aplinkybės lemia tai, kad kreditorius turi skirtingo rizikingumo paskolos gavėjų paraiškų, tačiau jų pasiskirstymas pagal riziką yra netolydus. Dėl to kai kurie rizikos segmentai gali nebūti padengti paraiškomis, t. y. nežinomieji bus tiek nepriklausomi kintamieji vektoriaus X nariai, tiek ir klasės Y . Kreditoriai su šia problema gali susidurti norėdami mažinti rizikos toleranciją.

Apibendrinant galima teigti, kad objektų su praleistais stebėjimais įtraukimas į imtį yra diskusijų objektas tiek mokslinėje, tiek ir praktinėje srityje – tyrėjai neturi vieningos nuomonės dėl siūlomų statistinių metodų praktinio efektyvumo. Mokslinėje literatūroje dažnai siūloma atmestas paraiškas laikyti „blogomis“ keliant prielaidą, kad jos būtų „blogos“, tačiau darbe atliktas teorinis tyrimas rodo, kad toks požiūris būtų ribotas. Nefinansuotos paraiškos ne visada būna nefinansuojamos dėl nepriimtinos kredito rizikos lygio. Ypač kredito unijų srityje ženkliai dalį nefinansuotų paskolų gali sudaryti persigalvojusių paskolų gavėjų dalis, kurie gali gauti paskolas geresnėmis sąlygomis. Atsižvelgdamas į tai, autorius siūlo neįtraukti

atmestų paraiškų į statistinę imtį, išskyrus atvejį, kai duomenys apie jų faktinį mokumą gali būti gaunami iš trečiųjų šalių, pvz., kreditų biurų.

Vienas iš šio disertacinio tyrimo apribojimų – modelio sudarymo, taikymo ir grįžtamojo patikrinimo imtyse nėra įrašų su praleistais stebėjimais (t. y. žinomos visų įrašų klasės). Dėl šios priežasties disertacijos autorius neturėjo galimybės pristatytus metodus pritaikyti praktiškai šio tyrimo metu. Tačiau, autoriaus nuomone, šiame poskyryje pristatytos teorinės įžvalgos ir metodai yra svarbūs sprendžiant įrašų su praleistais stebėjimais įtraukimo į modelio kūrimo imtį, problemas, sudarant kredito rizikos vertinimo modelius kredito unijų sektoriuje.

2.2.2. Nepriklausomų kintamųjų pasirinkimas ir įtraukimas į modelį


Nepriklausomai nuo pasirinkto modelio tipo, sudarant kredito rizikos vertinimo modelį būtina apibrėžti, kokie kintamieji įeis į modelį. Įprastai kintamųjų atrinkimas, atsižvelgus į jų diskriminacinę galią ir ekonominę logiką priklausomojo kintamojo atžvilgiu, yra atliekamas iš pradinio galimų kintamųjų sąvado, į kurį pagal galimybę įtraukiami visi galimi nepriklausomi analizuojamo reiškinių kintamieji.

Analizuojant nepriklausomų kintamųjų atrinkimą įmonių kredito rizikos vertinimo kontekste, pažymėtina, kad tyrėjai į modelius dažniausiai įtraukia finansinius ir nefinansinius kintamuosius. Dažniausiai analizuojami finansiniai kintamieji – santykiniai finansiniai rodikliai, apskaičiuojami iš įmonių finansinių ataskaitų rinkinių duomenų. Anot Mackevičiaus (2007), kai kurie autoriai išskiria iki 300 skirtingų santykinų finansinių rodiklių. Nefinansiniai kintamieji – rodikliai, parodantys įmonės mokumo potencialą analizuojant nefinansinius šaltinius: tai kredito istorijos, bylinėjimosi, taikomų laikinųjų poveikio priemonių, elgsenos socialiniuose tinkluose rodikliai ir kita reikšminga informacija. Parenkant galimus finansinius rodiklius, yra atsižvelgiama į analizei prieinamą finansinę informaciją³⁰. Kadangi finansinės

³⁰ Pavyzdžiui, vertinant mažų ir labai mažų įmonių kredito riziką, netikslinga pasitelkti rodiklius, kurie apskaičiuojami pastelkus pinigų srautų ataskaitos duomenis.

ataskaitos yra standartizuotos, tad galimų finansinių rodiklių sąvadą tikslinga rengti analizuojant mokslinėje ir profesinėje literatūroje naudojamus rodiklius. Svarbu tai, kad į galutinį modelio finansinių rodiklių rinkinį įėtų rodikliai, analizuojantys skirtingas įmonių veiklos sritis ir būtų skirtingi ekonominės informacijos turinio prasme. Nefinansinių rodiklių naudojimas tiesiogiai priklauso nuo išorinių veiksnių – informacinės infrastruktūros, dėl to šių rodiklių naudojimo galimybės ženkliai skiriasi skirtingose šalyse. Dėl šių priežasčių nefinansiniai rodikliai yra parenkami atsižvelgus į modelio sudarymui galimus naudoti duomenis ir išorinę informacinę infrastruktūrą.

Šiame disertaciniame tyrime galimų naudoti nepriklausomų kintamųjų sąvadas buvo sudaromas dviem etapais (14 pav.). Pirma, atlikus išsamią mokslinės ir profesinės literatūros analizę, sudarytas santykinų finansinių rodiklių sąvadas. Į sąvadą išrinkti tik tie rodikliai, kuriuos įmanoma apskaičiuoti pagal Lietuvos Respublikos verslo apskaitos standartus. Finansinių rodiklių atrinkimo procesas yra išsamiai aprašytas šiame skyriuje. Nefinansinių rodiklių sąvadas yra sudarytas remiantis Lietuvos kredito unijų sektoriaus apklausos rezultatais ir aprašomas 3 dalyje.




14 pav. Galimų naudoti nepriklausomų kintamųjų sąvado sudarymo procesas

Sudaryta autoriaus.

Žymėjimai: 1 – atliekama lyginamoji analizė; KRV – kredito rizikos vertinimas.

Finansinių rodiklių sąvado sudarymas. Siekiant suformuoti dažniausiai taikomų santykinų finansinių rodiklių sąvadą, iš kurio vėlesniuose modelio sukūrimo etapuose atrenkami santykiniai finansiniai rodikliai, buvo atlikta išsami mokslinės literatūros analizė, išanalizuoti 40 autorių darbai, iš viso 101 skirtingas kredito rizikos vertinimo ir bankroto prognozavimo modelis (Altman, 1968; Altman, Sabato, 2007; Angelini ir kiti, 2008; Bužius ir kiti, 2010; Chen, Du, 2009; Cubiles-De-La-Vega ir kiti, 2013; Danėnas ir kiti, 2011; De Andres ir kiti 2011; Dimitras ir kiti, 1999; Dzidzevičiūtė ir kiti 2010; Frydman ir kiti, 1985; Fulmer, 1984; Grigaravičius, 2003; Gurny, Gurny, 2013; Huang ir kiti, 2004; Lin, 2009; Lorca ir kiti, 2013; Mileris, 2012; Min, Jeong, 2009; Min, Lee, 2005; Mori, Yasushi, 2007; Nikolic, 2013; Ohlson, 1980; Olson, 2012; Pacelli, Azzollini, 2011; Pompe, Feelders, 1997; Ryser, Denzler, 2009; Springate, 1978; Tafler, Tisshaw, 1977; Tseng, Hu, 2001; Tseng, Hu, 2010; Varetto, 1998; Vasiliauskaitė, Cvilikas, 2008; Wang ir kiti, 2005; Wang, Ma, 2012; Wu, Hsu, 2012; Zhang, Hardle, 2008; Zhou, Tian, 2006; Zmijevski, 1984; Zopoudinis, Doumpos, 1999). Analizuotoje literatūroje autoriai taikė 218 skirtingų santykinų finansinių rodiklių.

Atlikus analizę nustatyta, kad analizuotose darbuose dažniausiai taikomi šie santykiniai finansiniai rodikliai: trumpalaikio mokumo koeficientas, nepaskirstyto pelno ir turto santykis, pardavimo pajamų ir turto santykis, pelno prieš palūkanas, mokesčius, nusidėvėjimo ir amortizacijos ir turto santykis, apyvartinio kapitalo ir turto santykis. Išplėstinė, tačiau nepilna dažniausiai taikomų rodiklių ir jų naudojimo dažnumo suvestinė pateikta 15 paveiksle. Visi santykiniai finansiniai rodikliai, atrinkti į finansinių rodiklių sąvadą, pateikti 3 priede.




15 pav. Dažniausiai naudojami santykiniai finansiniai rodikliai

Sudaryta autoriaus pagal 6 priede nurodytus šaltinius.

Rodiklių trumpiniai: A – atsargos; AK – apyvartinis kapitalas; BP – bendrasis pelnas; EBIT – pelnas prieš palūkanas ir mokesčius; EBITDA – pelnas prieš palūkanas, mokesčius, nusidėvėjimą ir amortizaciją; GP – grynasis pelnas; Įsip. Indeks – įsipareigojimų pokyčio indeksas; MAT – materialiojo turto rinkos vertė; MT – materialusis turtas; NK – nuosavas kapitalas; NP – nepaskirstytas pelnas; PA – pardavimai; PPE – pinigai ir pinigų ekvivalentai; PS – pardavimų savikaina; PVPS – pagrindinės veiklos pinigų srautas; PVPSPOK – pagrindinės veiklos pinigų srauto pokytis; ROE – nuosavybės grąžos rodiklis (GP/NK); T – turtas; TI – trumpalaikiai įsipareigojimai; TT – trumpalaikis turtas; I – įsipareigojimai.

Siekiant geriau suprasti bendrą santykinų finansinių rodiklių taikymo tendencingumą, toliau esančiame paveiksle rodikliai sugrupuoti išskiriant trumpalaikio ir ilgalaikio mokumo, pelningumo, turto struktūros, veiklos efektyvumo, pinigų srautų, augimo dinamikos, rinkos vertės, IMT (ilgalaikio materialiojo turto panaudojimo rodiklius), kapitalo rinkos bei „kitą“ rodiklių grupę, į kurią pateko niekur nepriskirti rodikliai (16 pav.). Galutinis modelyje naudojamas rodiklių rinkinys turėtų „apimti“ dažniausiai analizuojamas įmonių veiklos sritis.




16 pav. Dažniausiai analizuojamų finansinių santykinų rodiklių grupės

Sudaryta autoriaus.

Analizuotose darbuose dažniausiai taikyti tokie rodikliai: pelningumo rodikliai (15,29 proc.), trumpalaikio mokumo rodikliai (13,53 proc.), išlaidų lygio rodikliai (13,53 proc.), turto struktūros rodikliai (10,59 proc.), ilgalaikio mokumo rodikliai (10 proc.), turto apyvartumo (10 proc.). Rečiausiai taikyti buvo ilgalaikio materialiojo turto pokyčių rodikliai (1,79 proc.) ir kapitalo rinkos rodikliai (1,18 proc.).

Suformavus galimų naudoti nepriklausomų kintamųjų sąvadą, atlikta galutinių kintamųjų, įtaukiamų į modelį, atranka, kuri vykdyta 6 etapais (17 pav.).



17 pav. Kintamųjų, naudojamų modeliui sudaryti, atrankos etapai

Sudaryta autoriaus.

Pirma, iš tolimesnio tyrimo šalinami tie nepriklausomi kintamieji, kurie turi tiesioginį ryšį su suformuotu „bloga“ skolininko apibrėžimu arba akivaizdžiai parodo įmonės ūkinės-komercinės veiklos sutrikimus. Pavyzdžiui,

požymiai, kad įmonė turi reikšmingų nepadengtų skolų, (nors ir pagal pasirinktus „blogo“ skolininko apibrėžimą tokia įmonė ir nėra laikoma „bloga“), jau signalizuoja apie tai, kad įmonė kitais metais gali tapti „bloga“ (pagal suformuluotą apibrėžimą). Autoriaus nuomone, tokie požymiai galėtų būti įtraukti į kredito unijų kreditavimo taisyklių rinkinius, o įmonės, atitinkančios šiuos požymius, neturėtų būti kredituojamos. Pažymėtina ir tai, kad dažnu atveju kintamųjų, tiesiogiai susijusių su „blogo“ skolininko apibrėžimu, diskriminacinė galia, vertinant informacijos vertės (IV) metodu, būna įtartinaai didelė (>1), tai taip pat rodo galimą tiesioginį ryšį su priklausomu kintamuoju.

Antra, atliekama trūkstamų reikšmių analizė. Analizuojamas kiekvieno nepriklausomo kintamojo trūkstamų reikšmių kiekis bei priežastys, kodėl rodiklis negalėjo būti apskaičiuotas. Tais atvejais, kai rodiklis negalėjo būti apskaičiuotas dėl to, kad reikšmingos įmonių dalies finansinėse ataskaitose nebuvo duomenų, būtinų apskaičiuoti analizuojamą rodiklį, buvo sprendžiamas klausimas dėl tokio rodiklio šalinimo. Rodiklis šalinamas tuo atveju, jei galimybės jį apskaičiuoti (ne)buvimas akivaizdžiai neindikavo tikimybės, kad įmonė taps „bloga“.

Pavyzdžiui, rodikliai, kurių vardikliuose naudojamos atsargos, gali būti šalinami iš imties, o rodikliai, kurių rodikliuose naudojamos pardavimo pajamos – paliekami. Šis požiūris paaiškinamas tokia logika: faktas, kad įmonė neturi atsargų, nebūtinai parodo, kad įmonės veikla yra sutrikusi, ir priešingai – jei įmonė per analizuojamą laikotarpį negavo pardavimo pajamų, tai parodo, kad įmonės ūkinės-komercinės veiklos efektyvumas yra labai abejotinas. Papildomai, prieš priimant sprendimą šalinti rodiklius su trūkstamomis reikšmėmis, buvo analizuojama „blogų“ įmonių dalis (ODF) su ir be trūkstamų konkretaus rodiklio reikšmėmis. Rodiklis nešalintas tuo atveju, jei įmonių ODF reikšmingai ($\pm 5\%$) skyrėsi rodiklio su / be trūkstamų reikšmių imtyse.

Trečia, vertinama kintamųjų individuali diskriminacinė galia, tam pasirinktas informacijos vertės metodas (toliau – IV). Analizė atlikta

kienkvienam kintamajam apskaičiuojant IV rodiklį pagal (1-2) formulę (Bolton, 2009).

Ketvirtame rodiklių atrankos etape analizuojama koreliacija tarp finansinių rodiklių siekiant, kad galutinėje imtyje likę rodikliai neturėtų stiprios tarpusavio priklausomybės ir turinio prasme apimtų skirtingą įmonių veiklos analitinę informaciją. Siekiant šio tikslo, sudaryta koreliacinė matrica.

Penktame rodiklių atrankos etape, sprendžiant išskirčių problemą ir siekiant geresnės modelio diskriminacinės galios, finansinių rodiklių rezultatai transformuojami perteikiant juos įtakos svoriais (angl. *weight of evidence*, toliau *WOE*). WOE svoris apskaičiuojamas pagal formulę (2-9) (Bolton, 2009):

$$WOE_i = \ln \left(\left(\frac{G_i}{\sum_{i=1}^n G_i} \right) / \left(\frac{B_i}{\sum_{i=1}^n B_i} \right) \right) \quad (2-9)$$


Formulėje, B – „blogų“ skolininkų kiekis, G – „gerų“ skolininkų kiekis, n – vertintų skolininkų kiekis, i – vertinamo rodiklio indeksas. Įtakos svoriai nustatomi suskirstant WOE reikšmes į intervalus, išskiriant nuo 3 iki 7 intervalų. Pasirenkant WOE intervalų kiekį atsižvelgiama į įtakos svorių ekonominę logiką, į įmonių kiekį kiekviename išskirtame intervale (tiek bendrą įmonių, tiek ir „gerų“ / „blogų“ įmonių kiekį) bei į rodiklio WOE svorių pasiskirstymą intervaluose. Kaip pastebi Dzidzevičiūtė (2013), WOE svoriai intervaluose turi pasiskirstyti logiškai – gali didėti, mažėti arba atitikti U ar S formą. Tais atvejais, kai intervalo WOE reikšmės neatitinka ekonominės logikos, ar intervalo įmonių kiekis akivaizdžiai per mažas, toks intervalas sujungiamas su gretimu. Rodikliai, kurių įtakos svoriai neatitinka ekonominės logikos ar „gerų“ / „blogų“ įmonių kiekis nepakankamas patikimam WOE nustatymui, pašalinami iš imties.

Šeštame etape formuojant galutinį kintamųjų rinkinį taikoma šalinamoji regresija (angl. *backward stepwise regression*).

2.2.3. „Gerų“ ir „blogų“ paskolų apibrėžimai

Siekiant suformuoti „blogo“ skolininko apibrėžimą, atlikta analizė, susidedanti iš trijų dalių. *Pirma*, analizuoti kredito unijų apklausos rezultatai, siekta nustatyti, kaip kredito unijos suvokia „blogą“ skolininką. Ši analizės dalis yra svarbi siekiant įvertinti kredito unijų rizikos tolerancijos lygį bei užtikrinti, kad suformuotas priklausomo kintamojo apibrėžimas atitiks kredito unijų verslo požiūrį ir rizikos tolerancijos lygį. *Antra*, taikant Markovo grandines ir sudarant paskolų vėlavimo kohortas, analizuotas LCKU verslo paskolų portfelis. Ši analizės dalis yra svarbi formuojant statistinį „blogo“ skolininko ir paskolos stebėjimo laikotarpio apibrėžimus. *Trečia*, analizuoti reguliaciniai reikalavimai ir geroji finansų rinkos praktika. Ši analizės dalis yra svarbi, kad suformuotas galutinis apibrėžimas atitiktų galiojančią teisinę reguliavimą.

Šių trijų analizės dalių rezultatai sisteminti, lyginti, analizuoti, abstrahuoti, galiausiai suformuoti tarpiniai „gerų“ ir „blogų“ skolininkų apibrėžimai (18 pav.). Įprastai formuojant modelio sudarymo imtį, tos įmonės, kurios neatitinka „blogo“ skolininko apibrėžimo, yra laikomos „geromis“. Šio tyrimo kontekste formuojant modelio sudarymo imtį pritariant tradiciniam požiūriui „geromis“ būtų laikomos tos įmonės, kurios per stebėjimo laikotarpį neatitiko nustatyto „blogos“ paskolos apibrėžimo. Kaip matyti iš 1.2.2 dalyje atlikto teorinio tyrimo, dažniausiai taikomi „blogos“ paskolos požymiai yra bankroto ar finansinio nemokumo rodikliai. Tačiau bankroto bylos iškėlimas nėra vienintelis įmonės veiklos nutraukimo būdas – įmonės veikla taip pat gali būti stabdoma atleidus visus darbuotojus ir tiesiog nepratęsus veiklos. Įmonių įsiskolinimai kreditoriams esant nedideliems veiklos mastams gali būti dengiami įmonių savininkų lėšomis tiek dėl ekonominių, tiek ir dėl reputacinių veiksnių.



18 pav. „Blogo“ skolininko apibrėžimo formavimo logika

Sudaryta autoriaus.

Taigi, pritariant tradiciniam požiūriui bei laikant visas nebankrutavusias ir finansinių įsiskolinimų neturinčias įmones „geromis“, „gerų“ įmonių imtį sudarys ir nesėkmingai veikiančios įmonės, neturinčios ilgalaikių veiklos perspektyvų. Turint omenyje pasirinkto tikslinio segmento – mažų ir labai mažų įmonių – veiklos specifiškumą, galima kelti prielaidą, kad veiklos stabdymas, neskelbiant įmonės bankroto, šiame tiksliniame segmente gali būti dažnesnis nei vidutinių ir didelių įmonių segmentuose. Atsižvelgus į tai, kad vertinant juridinių asmenų kredito riziką, akcininkų galimybės grąžinti paskolą įmonės veiklos nutraukimo atveju yra vertinamos tik fragmentiškai ir dažniausiai tais atvejais, kai akcininkų yra prašoma laiduoti už paskolą, manytina, kad nutrūkusią įmonės veiklą būtų tikslinga priskirti prie „blogo“ skolininko požymio.


Siekiant patikrinti šios prielaidos pagrįstumą bei galimą įtaką galutinio modelio savybėms, nutarta papildomai patikrinti visų įmonių, neatitinkančių suformuotų tarpinių „blogos“ paskolos požymių būklės šio tyrimo metu – 2015 m.³¹ (18 pav., 4 dalis). Siekta nustatyti, ar visos „blogomis“ nelaikomos įmonės analizuojamu metu vykdė veiklą ir neturėjo reikšmingų veiklos sutrikimo požymių. Realizuojant tikslą analizuoti keli veiksniai: darbuotojų skaičius, įsiskolinimai VSDF ir įmonės pardavimai. Pagal analizės rezultatus įmonėms priskirti papildomi požymiai:

- a) **veikianti įmonė** – požymis priskirtas įmonėms, kurios 2016 m. tęsė veiklą ir neturėjo veiklos sutrikimo požymių;
- b) **neveikianti įmonė** – požymis priskirtas įmonėms, kurios 2016 m. nevykdė veiklos;
- c) **veikianti, tačiau įsiskolinimų turinti įmonė** – požymis priskirtas įmonėms, kurios 2016 m. vykdė veiklą, tačiau turėjo ženklių nepadengtų skolų VSDF³²;
- d) **ekspertinio įvertinimo reikalaujanti įmonė** – požymis priskirtas įmonėms, kurios nepriskirtos nei vienai iš šių grupių. Norint įvertinti šias įmones, reikia gauti daugiau duomenų, kurie išorinio vertinimo metu nėra prieinami.

Šie požymiai priskirti pagal vertinimo logiką, pavaizduotą 19 paveiksle.

³¹ Šio tyrimo imtyje nebuvo duomenų, leidžiančių stebėjimo laikotarpiu (2011–2012 m.) įvertinti įmonių veiklos aktyvumą, todėl papildomas vertinimas buvo atliktas šio tyrimo atlikimo metu 2016 m. Papildomam įvertinimui būtini duomenys buvo surinkti iš viešai šiuos duomenis teikiančio portalo rekvizitai.vz.lt.


³² Įsiskolinimų reikšmingumą autorius vertino ekspertiškai, remdamasis savo patirtimi ir žiniomis. Vertinimas atliktas atsižvelgus į įsiskolinimo sumą ir pokyčių dinamiką.



19 pav. Papildomo įmonių veiklos testinimo įvertinimo algoritmas

Sudaryta autoriaus.

Taigi, formuojant kredito rizikos vertinimo modelio sudarymo imtį, galimi skirtingi alternatyvūs „gerų“ ir „blogų“ skolininkų apibrėžimai (20 pav.):



20 pav. Skirtingi „gerų“ ir „blogų“ skolininkų apibrėžimo formavimo variantai

Sudaryta autoriaus.

Pastaba: reikšmingomis skolomis laikomos tos skolos, kurios atitinka paskolos vėlavimo sąvoką (pagal paskolos sumą ir vėlavimo terminą), nurodomą „blogos“ paskolos apibrėžime.

Apibrėžiant „blogą“ skolininką, galima pritarti tradiciniam požiūriui ir įmonės bankrotą (20 pav., pav., B1) arba paskolos vėlavimą pagal pasirinktą vėlavimo trukmę (20 pav., B2) vertinti kaip pagrindinius „blogos“ paskolos požymius. Atlikus papildomą veiklos tęstinumo patikrinimą, formuojant imtį, įmanoma įtraukti papildomus „blogos“ paskolos požymius – veiklos nutraukimą arba įsisikolinimą po kontrolinio laikotarpio.

Analogiškai formuojamas „geros“ paskolos apibrėžimas: (20 pav.) G1 ir G2 pasirinkimai atitiktų tradicinį požiūrį ir atitinkamus B1 ir B2 požymius „blogos“ paskolos apibrėžimui. G3 ir G4 požymiai indikuoja įmonės veiklos tęstinumą kontroliniu laikotarpiu.

Sudarant modelį „blogo“ ir „gero“ skolininko apibrėžimai formuojami atsižvelgus į:


2) kredito unijų sektoriaus apklausos rezultatus;
LKU suteiktų verslo paskolų portfelio statistinius tyrimų rezultatus;
papildomo įmonių veiklos tęstinumo tyrimo rezultatus.

2.2.4. Klasifikatoriaus pasirinkimas

Kaip minėta, nuo modelyje taikomo klasifikatoriaus pasirinkimo ženkliai priklauso sudaromo modelio kiekybinės ir kokybinės savybės bei galimi modelio taikymo apribojimai. Atsižvelgus į tai, šiame tyrime klasifikatoriaus pasirinkimas atliekamas analizuojant modelio sudarymo kontekstą skirtingomis perspektyvomis, kaip tai numatyta 1.2.1 dalyje (4 pav.).

Klasifikatoriaus pasirinkimas darytas atlikus analizę, susidedančią iš penkių dalių (21 pav.). *Pirma*, atlikus kredito unijų apklausą ir išanalizavus jų kreditavimo politiką, suformuotas kredito unijų kiekybinių ir kokybinių reikalavimų sudaromam modeliui sąvadas (kreditoriaus perspektyva). *Antra*, atlikta išsami literatūros analizė ir parengtas galimų taikyti klasifikatorių bei jų

kiekybinių ir kokybinių sąvybių sąvadas³³ (analizuojamos homogeninės rizikos grupės perspektyva).



21 pav. Modelyje taikomo klasifikatoriaus pasirinkimo logika

Sudaryta autoriaus.


Trečia, analizuota teisinė literatūra ir apibrėžti reguliaciniai reikalavimai sudaromiems modeliams (išorinių veiksnių perspektyva). Šių trijų dalių tarpiniai tyrimo rezultatai analizuoti, gauti rezultatai apibendrinti suformuojant bendrą reikalavimų modeliams sąvadą. *Ketvirtoje* klasifikatorių analizės dalyje, pasitelkus klasifikatorių kiekybinių ir kokybinių sąvybių sąvadą, atlikta pirminė atranka, kurios metu siekta nustatyti:

³³ Analizuoti tik tie tyrimai, kuriuose taikyti statistiniai vertinimo balais modeliai, tinkantys fizinių asmenų bei vertybinių popierių biržoje nekotiruojamų juridinių asmenų kredito rizikos vertinimui.

- 1) ar analizuojamas klasifikatorius atitinka kredito unijų kreditavimo politiką ir leidžia sudaryti modelį, atitinkantį kredito unijų keliamus reikalavimus;
- 2) ar klasifikatoriaus taikymas leidžia sudaryti aukšto tikslumo modelį;
- 3) ar klasifikatoriaus taikymas leidžia sudaryti modelį, atitinkanti kredito unijoms taikomus reguliacinius reikalavimus bei gerą finansų rinkos praktiką.

Tie klasifikatoriai, kurie neatitiko šių analitinių kriterijų, pašalinti iš tolimesnės analizės. Reikalavimus tenkinę klasifikatoriai toliau ekspertiškai analizuoti autoriaus *penktoje* analizės dalyje, kurioje priimtas sprendimas dėl klasifikatoriaus taikymo.

Klasifikatorių tipų, jų taikymo dažnio ir tikslumo analizė. Šio darbo 1.2.4. dalyje atlikta analizė parodo, kad autoriai skirtingai klasifikuoja modelius pagal juose taikomų klasifikatorių tipus. Šio tyrimo autorius kredito rizikos vertinimo modelius pagal juose taikomus klasifikatorius skirsto į tris tipus: statistinius, dirbtinio intelekto ir kitus metodus. Statistiniams modeliams priskiriami modeliai, kuriuose taikomi regresinių ir diskriminantinių tipų klasifikatoriai. Dirbtinio intelekto metodams – modeliai, kuriuose taikyti neuronų tinklų, sprendimų medžių, ansamblinio mokymosi, Naiviojo Bajeso, evoliucinio programavimo, atraminių vektorių mašinų, artimiausio kaimyno tipų klasifikatoriai. Pagal šį grupavimą 22 paveiksle apibendrinama pastaruoju laiku mokslinėje ir profesinėje literatūroje nagrinėtų modelių analizė. Tyrimai apžvelgti pagal taikytą klasifikavimo metodą, metodo tipą bei taikymo dažnį. Pažymėtina, kad moksliniuose tyrimuose minimi ir kiti klasifikavimo metodai. Siekdami didesnio modelio tikslumo, praktinio taikymo patogumo, tyrėjai nuolat bando taikyti įvairius kitus klasifikavimo metodus, pavyzdžiui, imuninės sistemos ir kitus, retesnius metodus (plačiau žr. Leung ir kiti, 2007; Lessman ir kiti, 2003; Michie ir kiti, 1993; Hand, Hendley, 1997).




22 pav. Klasifikavimo metodai, jų tipai ir taikymo dažnis

Sudaryta autoriaus pagal 6 priede nurodytus šaltinius.

Paveikslo santrumpos: LR – logistinė regresija; PR – probit regresija; CR – Cox regresija; MARS – daugiamatė adaptvyvioji regresija; RLR – logistinė regresija su reguliarizacija; LLR – Lasso logistinė regresija; TDA – tiesinė diskriminantinė analizė; KDA – kvadratinė diskriminantinė analizė; DNT – dirbtinis neuronų tinklas; KSZ – Kohoneno saviorganizuojantys žemėlapiai; CART – klasifikacijos ir regresijos medis; CHAID – sprendimų medis, rekursinio dalijimo metodas; C4.5; C5; LOTUS – sprendimų medžių rūšys; AM – atsitiktiniai miškai; AD – atsitiktinės džunglės; NB – Naiviojo Bajeso metodas; GP – genetinis programavimas; AVM – atraminių vektorių mašinos; KNN – artimiausio kaimyno metodas; Mišr. – mišrūs metodai.

Viena pagrindinių modelio taikymo užduočių – minimizuoti nuostolius dėl blogų paskolų išdavimo (II tipo klaida) ir neuždirbtas pajamas dėl patikimų skolininkų priskyrimo nepatikimiams (I tipo klaida). Todėl suprantama, kad pagrindinė savybė, lemianti modelio klasifikatoriaus pasirinkimą, yra jo tikslumas. Skirtingi autoriai, taikydami tuos pačius klasifikavimo metodus, gauna nevienareikšmius rezultatus. Norint apibendrinti atliktus tyrimus ir nustatyti, kurie klasifikavimo metodai pasižymi didesniu tikslumu, 22 paveiksle nagrinėti modeliai ištirti analizuojant jų tikslumą. Į modelių klasifikatorių tikslumo tyrimą įtraukti tik tie modeliai, kurių tikslumas tyrimuose išreikštas Gini, AUC ar AR koeficientais, nes jie yra susiję tiesiniais

ryšiais³⁴. Tai leidžia konvertuoti tikslumo rezultatus išreikšiant juos vienu matu. Klasifikatorių tikslumą apibendrinantys tyrimo rezultatai pateikiami 23 paveiksle.



23 pav. Klasifikatorių tikslumas pastaruosiuose moksliniuose tyrimuose

Sudaryta autoriaus pagal 6 priede nurodytus šaltinius.


Paveikslo santrumpos: DNT – dirbtinis neuronų tinklas; LR – logistinė regresija; PR – probit regresija; GP – genetinis programavimas; SM – sprendimų medžiai (visų rūšių); AM – atsitiktiniai miškai; DA – tiesinė diskriminantinė analizė; MARS – daugiamačė adaptyvioji regresija; AVM – atraminių vektorių mašinos; KNN – artimiausio kaimyno metodas; NB – Naiviojo Bajeso metodas; Mišr. – mišrūs metodai.

Paveiksle (23 pav.) modelių tikslumas išreiškiamas AUC rodikliu. Vidutinė objektų linija rodo modelių tikslumo vidurkį, stačiakampių kraštai – standartinę nuokrypį nuo vidurkio, o linijų viršūnės – minimalias ir maksimalias modelių klasifikavimo tikslumo reikšmes. Kaip matyti, skirtinguose tyrimuose, taikant tuos pačius klasifikavimo metodus, gauti nevienareikšmiai tyrimų rezultatai.

³⁴ Pastaba: į klasifikatorių tikslumo tyrimą neįtraukti kai kurie klasifikatoriai, kurių tikslumą įvertinti analizuotuose tyrimuose trūko duomenų. Vertinant sujungti visi sprendimų medžių tipai. Atkreiptinas dėmesys ir į tai, kad modelių tikslumas priklauso ne tik nuo taikomo klasifikatoriaus, bet ir nuo kitų veiksnių, todėl atlikto tyrimo rezultatai turėtų būti vertinami tik atsižvelgus į bendrą klasifikatorių taikymo tendenciją, lūkesčių pagrindimą, o tolimesnėje tyrimo eigoje – į kuriamo modelio diskriminacinės galios interpretavimą.

2.2.5. Modelio patikrinimo metodai

Sukurto modelio įvertinimas atliekamas taikant du patikrinimo etapus. *Pirmiausia*, sukūrus modelį, atliekamas išankstinis modelio įvertinimas. Šiame etape analizė yra atliekama testinėje imtyje, kuri yra suformuojama iš modelio kūrimo imties. Patikrinimas atliekamas apskaičiuojant modelio įvertinimo rodiklius ir atliekant lyginamąją rodiklių rezultatų analizę. Atlikus lyginamąją analizę, apskaičiuotos modelio veikimo savybės lyginamos su analizuotais moksliniais tyrimais, kuriuose taikyti tokio paties tipo klasifikatoriai, kaip ir sukurtame modelyje (žr. 23). Tuo atveju, jei analizuojamos modelio savybės neatitinka lūkesčių, modelis atmetamas, jei atitinka – pereinama prie antro įvertinimo etapo (24 pav.). Pirmo modelio patikrinimo etapo tikslas – preliminariai įvertinti diskriminacines modelio savybes, todėl šiame etape modelio diskriminacinės galios patikrinimas lūžio taške yra atliekamas parenkant lūžio taško reikšmę ekspertiniu būdu.



24 pav. Modelio įvertinimo eiga

Sudaryta autoriaus.


Antrame modelio patikrinimo etape atliekamas grįžtamasis modelio patikrinimas. Šio patikrinimo tikslas – įvertinti modelio veikimą „gamybinėje aplinkoje“, t. y. analizuojant faktiškai suteiktų verslo paskolų duomenis, gautus iš kredito unių veikloje naudojamų išorinių duomenų šaltinių, bei taikant

sukurtą modelį, kiekybiniais metodais nustatytą modelio lūžio tašką ir sudarytą rangų skalę. Atliekant grįžtamąjį modelio įvertinimą, analizė atlikta LCKU verslo paskolų imtyje tiriant verslo paskolas, suteiktas 2009–2012 metais. Duomenys tyrimui surinkti iš dviejų šaltinių:

1. Pirma, iš LCKU suteiktos verslo paskolų imties atrenkamos tos įmonės, kurios pagal turimus paskolų grąžinimo duomenis atitiko nustatytą „blogo“ skolininko apibrėžimą bei kurioms nuo paskolos suteikimo yra praėjęs nustatytas paskolos stebėjimo laikotarpis.
2. Antra, pagal atrinktų įmonių kodus, iš kreditų biuro „Creditinfo Lietuva“ gauti vertinimui reikalingi duomenys. Vertinami šių laikotarpių duomenys:
 - kredito istorijos ir nefinansiniai duomenys yra vertinami paskolos suteikimo datai;
 - finansiniai duomenys (balansas ir pelno–nuostolių ataskaita) yra vertinami praėito ataskaitinio laikotarpio datai, skaičiuojant nuo paskolos suteikimo datos.
3. Duomenų imtys sujungtos suformuojant modelio grįžtamojo patirinio imtį.

Atliekant grįžtamąjį modelio patikrinimą pasitelktas kiekybiniais metodais nustatytas lūžio taškas bei modelio rangų skalė. Naudojant istorinius įmonių duomenis ir taikant sukurtą modelį apskaičiuojamas įmonės PD, modelio priskirtas rangas bei pakartotinai apskaičiuojami modelio įvertinimo rodikliai.

Metodai, skirti įvertinti modelį. Siekiant išanalizuoti, kokie diskriminacinės galios vertinimo metodai dažniausiai naudojami praktikoje, atrinktos pastarųjų 10 metų (2005 sausio 1 d.– 2016 m. kovo 1 d.) mokslinės publikacijos, iš viso 97, kuriose išskirti 23 modelių patikimumo vertinimo metodai (25 pav.).



25 pav. Dažniausiai naudojami modelio patikimumo vertinimo metodai

Sudaryta autoriaus pagal 6 priede nurodytus šaltinius.

Metodų santrumpos: TKM – teisingo klasifikavimo matrica; BTR – binarinio klasifikavimo tikslumo vertinimo rodikliai; TKKM – tikėtinos klaidos kainos metodas; MKK – Matthews koreliacijos koeficientas; IVR – informacijos vertės metodas; TKR – teisingo klasifikavimo rodiklis; SIE – savitarpio informacijos entropija; AKM – apytikslės koreliacijos metodas; BKT – Bajeso klaidos tikimybė; DTPR – didžiausio tikėtino pelno metodas; PVR – pridėtinės vertės rodiklis (angl. *value added measure*); AUC – plotas po ROC kreive; KS – Kolmogorovo-Smirnovo testas; Gini – Gini indeksas; AR – Klasifikavimo tikslumo rodiklis; CAP – kaupiamojo tikslumo kreivė; HR – H rodiklis; BBM – Briero balų metodas; CKR – Coheno Kappa rodiklis; DGI – Dalinis Gini indeksas (angl. *partial Gini index*); AIK – Akaikės informacijos kriterijus; SIK – Švarco informacijos kriterijus.

Kaip galima matyti iš analizės rezultatų (25 pav.), pastarojo dešimtmečio mokslinėje literatūroje modelių patikimumo vertinimui dažniausiai naudojamos klasifikavimo matricos ir iš jos duomenų išskaičiuojami klasifikavimo tikslumo rodikliai. Jų skaičiavimo formulės yra pateiktos žemiau esančioje lentelėje (10 lent.)³⁵. Be tradicinių klasifikavimo tikslumo įvertinimo rodiklių, vertinant modelio diskriminacines savybes, pasitelkiami ir koreliacijos rodikliai. Dažnai taikomas grafinės analizės metodas – ROC kreivės ir jos rezultatus kiekybiškai apibendrinantis AUC rodiklis, rodantis plotą po ROC kreive.

³⁵ Literatūroje minimi ir kiti, retesni rodikliai, išskaičiuojami iš klasifikavimo matricos duomenų, pvz., Saberi ir kiti (2013).

10 lentelė. Modelio diskriminacinių savybių tam tikrame atskyrimo taške (C) įvertinimo rodikliai

Rodiklis	Formulė	Paaškinimas	Rodiklis	Formulė	Paaškinimas
<i>Ar</i>	$\frac{TP + TN}{P + N}$	Bendro tikslumo rodiklis (angl. <i>accuracy rate</i>). Parodo, kokia dalis iš analizuotų subjektų buvo klasifikuota teisingai ³⁶ .	<i>NPV</i>	$\frac{TN}{TN + FN}$	NPV – teisingo neigiamo klasifikavimo dalis neigiamose klasifikacijose (angl. <i>negative predictive value</i>)
<i>CCR</i>	$\frac{TP + TN}{N}$	CCR – teisingo klasifikavimo rodiklis (angl. <i>correct classification rate</i>). Parodo teisingai klasifikuotų ir nemokiems priskirtų subjektų santykį.	α	$\frac{FN}{FN + FP}$	α – klaidingo neigiamo klasifikavimo paklaidos santykis (angl. <i>false negative rate</i>), pirmo tipo klaidos rodiklis.
<i>MCR</i>	$\frac{FP + FN}{N}$	Klaidingo klasifikavimo rodiklis (angl. <i>misclassification rate</i>). Parodo neteisingai klasifikuotų ir nemokiems priskirtų subjektų santykį.	β	$\frac{FP}{FP + TN}$	β – klaidingo teigiamo klasifikavimo paklaidos santykis (angl. <i>false positive rate</i>), antro tipo klaidos rodiklis.
<i>Se</i>	$\frac{TP}{TP + FN}$	<i>Se</i> – jautrumas (angl. <i>sensitivity</i>), dar vadinamas pataikymo rodikliu (angl. <i>hit ratio</i>). Rodiklis parodo, kokia dalis nepatikimų klientų buvo teisingai klasifikuota.	<i>F</i>	$\frac{2 * PPV * Se}{PPV + Se}$	<i>F</i> rodiklis (angl. <i>F value</i>) – harmoninis jautrumo ir specifiškumo vidurkis.
<i>Sp</i>	$\frac{TN}{TN + FP}$	<i>Sp</i> – specifiškumas (angl. <i>specificity</i>), dar vadinamas neteisingo pavojaus signalo rodikliu (angl. <i>false alarm ratio</i>). Rodiklis parodo, kokia patikimų klientų dalis buvo teisingai klasifikuota.	<i>BAC</i>	$\frac{Se + Sp}{2}$	Rodiklis parodo apibendrintą modelio tikslumą ir tinka naudoti imtyse su mažomis blogų subjektų proporcijomis (Harris, 2015).

³⁶ Bendro tikslumo rodiklis literatūroje taikomas dažnai, tačiau įvardijamas skirtingai, pvz., Burset ir Guigo (1996) šį rodiklį vadina paprastojo sutapimo koeficientu (angl. *simple matching coefficient*), Wu, Hsu (2012) – viso teisingo klasifikavimo rodikliu (angl. *total correct prediction ratio*, *TCP*) ir pan.

Rodiklis	Formulė	Paaiškinimas	Rodiklis	Formulė	Paaiškinimas
PPV	$\frac{TP}{TP + FP}$	PPV – teisingo teigiamo klasifikavimo dalis teigiamose klasifikacijose (angl. <i>positive predictive value</i>).	G-vidurkis	$\sqrt{\frac{TP}{TP + FN} + \frac{TN}{TN + FP}}$	Rodiklis rodo modelio jautrumo ir specifiškumo subalansuotumą (Tomczak, Zięba, 2015).

Sudaryta autorių pagal Cardoso ir kiti (2016); Harris (2015); Tomczak, Zięba, (2015); Cheng, Li, 2014; Mileris (2009).

TP – modelio teisingai klasifikuoti „geri“ skolininkai; TN – modelio teisingai klasifikuoti „blogi“ skolininkai; FN – modelio klaidingai klasifikuoti „blogi“ skolininkai (pirmo tipo klaida); FP – modelio klaidingai klasifikuoti „geri“ skolininkai (antro tipo klaida).

Vertinant binarinio klasifikavimo tikslumą pasitelkus klasifikavimo matricas, kaip specializuotas Pearsono koreliacijos koeficiento substitutas literatūroje dažnai taikomas Matthews koreliacijos koeficientas (Louzada ir kiti, 2012; Derelioğlu, G., Gürgen, 2011; Powers, 2007):

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP) * (TP + FN) * (TN + FP) * (TN + FN)}} \quad (2-10)$$

Burset ir Guigó (1996), atsižvelgę į Mathews koreliacijos rodiklio trūkumą, kai viena iš MCC formulės vardiklyje esančių sumų lygi 0, pasiūlė apytikslės koreliacijos koeficientą AC (angl. *approximate correlation*), kuris išskaičiuojamas nustatius vidutinę būklės tikimybę (angl. *average conditional probability*) ACP:

$$ACP = \frac{1}{4} \left(\frac{TP}{TP + FN} + \frac{TP}{TP + FP} + \frac{TN}{TN + FP} + \frac{TN}{TN + FN} \right) \quad (2-11)$$

Nemokumo prognozavimo kontekste³⁷ ACP rodiklis parodo tikimybę, kad analizuojamas subjektas bus mokus ar nemokus, neatsižvelgiant į tai, ar tai yra faktinė būklė, ar modelio prognozė. Kadangi ACP yra tikimybė, tad galima rodiklio reikšmė yra rėžyje [0;1]. Apskaičiavus ACP, koreliacija AC nustatoma pagal formulę:

³⁷ Burset ir Guigó (1996) pristatė ACP ir AC rodiklių taikymą medicinos srityje.

$$AC = 2 * (ACP - 0,5) \quad (2-12)$$

Anot Buset ir Guigó (1996), AC pagal savo reikšmę yra artimas koreliacijai ir jo reikšmės yra interpretuojamos analogiškai: 1 – kai koreliacija yra labai stipri, 0 – koreliacijos nėra ir -1, kai ryšys atvirkštinis. AC rodiklis, kaip alternatyvus koreliacijos matas, taikomas ir vertinant kredito rizikos vertinimo modelius (Louzada ir kiti, 2012).

Svarbu atkreipti dėmesį į tai, kad tiek klasifikavimo matrica, tiek pateikti diskriminacinių modelio savybių analizės rodikliai (14 lentelė) charakterizuoja modelio savybes tik tam tikrame atskyrimo taške C. Norint apibendrinti modelio diskriminacines savybes, dažniausiai taikomi grafinės analizės metodai: ROC ir CAP kreivės, kurios apibendrina modelio tikslumą visuose C taškuose.

Kiekybiškai CAP savybes apibendrina tikslumo rodiklis AR (angl. *accuracy ratio*):

$$AR = \frac{A_R}{A_P} = Gini \quad (2-13)$$

Formulėje AR – tikslumo rodiklis, A_R – plotas po CAP kreive, A_P – plotas po tobulo modelio kreive, AR rodiklis yra lygus Gini indeksui (Pranckevičiūtė, 2007). Kaip galima pastebėti iš pateiktų apibrėžimų, tarp AR ir AUC rodiklių egzistuoja tiesinis ryšys, matematiškai jį būtų galima išreikšti taip (Engelmann ir kiti, 2003):

$$AR = 2 * AUC - 1 \quad (2-14)$$

Kitas su su ROC kreivių metodu susijęs statistinis metodas yra Pietra indeksas. Šis indeksas parodo maksimalų atstumą nuo naiviojo modelio

diagonalės iki analizuojamo modelio ROC kreivės (10 pav., A). Statistinė prasme šis indeksas yra ekvivalentus Kolmogorovo-Smirnov (toliau – KS) testui, kuriuo analizuojama, ar dvi populiacijos gali būti iš to paties skirstinio (Engelmann ir kiti, 2003). Naiviojo modelio atveju Pietra indeksas būtų lygus 0. Svarbu pažymėti, kad tiek Pietra indeksas, tiek ir KS rodiklis analizuoja tik didžiausią galimą atstumą tarp diagonalės ir ROC kreivės.

Šiame tyrime, siekiant patikrinti sudaromo modelio patikimumą, buvo pasirinkti tokie metodai (11 lentelė):

11 lentelė. Modelio patikimumo įvertinimo metodai

Metodai lūžio taške	Metodai neatsižvelgiant į lūžio tašką
Teisingo klasifikavimo matrica	AUC
Matthews koreliacijos koeficientas	ROC
Klasifikavimo tikslumo rodikliai: Ar, CCR, MCR, Se, Sp, BAC, MCC (=AC), PPV, NPV, α , β , F, G-vidurkis, ACP	Aikakės kriterijus
	Prognozuotų tikimybių grafikas
	Gini indeksas

Sudaryta autoriaus.

Modelio įvertinimo metodai pasirinkti atsižvelgus į jų analitinį turinį bei praktinio taikymo dažnumą kredito rizikos vertinimo srityje. Pasirinkti metodai taikyti tiek modelio išankstinio, tiek ir grįžtamojo patikrinimų etapuose. Modelio įvertinimo rodiklių analitiniai kriterijai ekspertiškai nustatomi autoriaus, atsižvelgus į mokslinėje literatūroje pateikiamus modelių įvertinimo kriterijus, jų interpretavimą bei geriausią kreditavimo rinkos praktiką.

2.2.6. Rangų skalės sudarymas

Rangų skalės sudarymas dažniausiai atliekamas ekspertiniais metodais, analizuojant galimus PD režius bei rangų kiekius (Dzidzevičiūtė, 2013; Anderson, 2007; Siddiqi, 2006). Šiame disertaciniame tyrime rangų skalė sudaryta tokia tvarka:

- *pirma*, nustatomas optimalus lūžio taškas – PD dydis, nuo kurio paskolų paraiškos turėtų būti atmetamos;
- *antra*, atsižvelgus į nustatytą lūžio tašką bei laikantis Bazelio dokumentuose pateikiamų rekomendacijų, formuojami rangų režiai

išskiriant ne mažiau, kaip 6 rangus, tikėtina, įsipareigojimus vykdysiantiems skolininkams, ir ne mažiau, kaip 2 rangus, tikėtina, nevykdysiantiems skolininkams (BCBS, 2001, p. 198);

- *trečia*, kiekvienam rangui priskiriamas vidutinis rango PD.

Ekonominiu naudingumu pagrįstas lūžio taško nustatymas. Siekiant nustatyti optimalų atskyrimo tašką, atsižvelgus į klasifikavimo klaidos kainą bei tikėtiną ekonominę naudą, Verbraken ir kiti (2014; 2013) pasiūlė alternatyvą AUC, numatomo didžiausio pelno rodiklį (toliau – EMP, angl. *Expected Maximum Profit*). Autorių pasiūlytas metodas leidžia, nustatant optimalią skolininkų atmetimo proporciją, apskaičiuoti optimalų atskyrimo tašką ir didžiausią galimą pelną taikant analizuojamą modelį.

Pagal Verbraken ir kiti (2014; 2013) ekonominė nauda, gaunama teisingai klasifikuojant skolininką b_0 (TP atvejis), dar suprantama kaip paskolos dalis, kuri, tikėtina, bus prarasta skolininkui tapus nemokiu:

$$b_0 = \frac{LGD \cdot EAD}{A} = \lambda \quad (2-15)$$

Formulėje $\lambda \in [0,1]$, A – paskolos suma, LGD – nuostolis įsipareigojimo neįvykdymo atveju (angl. *loss given default*) ir EAD – paskolos dydis įsipareigojimo neįvykdymo atveju (angl. *exposure at default*).

Dėl skirtingų LGD , EAD ir A dydžių skirtingose kredito įstaigose bei paskolų pozicijose, tiksliai nustatyti λ yra sudėtinga, todėl keliama prielaida, kad dažniausiai pasitaiko atvejai, kai $\lambda = 0$ ir $\lambda = 1$, kurie formuoja du koncentruotus tikimybių masyvus (angl. *probability masses*), atitinkamai p_0 ir p_1 , tarp kurių λ pasiskirsčiusi pagal diskretųjį skirstinį (angl. *uniform distribution*) tarp 0 ir 1: $h(\lambda) = 1 - p_0 - p_1$, kaip matyti, parametrai p_0 ir p_1 nusako $h(\lambda)$.

Ekonominė nauda, kuri prarandama klaidingai identifikavus blogą skolininką c_1 (FN atvejis), dar gali būti suprantama kaip investicijų grąža ROI (angl. *return on investment*). Bet kuriai paskolai, žinant paskolos įmoką p ,

terminą M , sumą A ir palūkanų normą r , visa investicinė grąža I (angl. *total interest*) ir ROI apskaičiuojama pagal formules:

$$I = p \cdot M - A \quad (2-16)$$

$$p = \frac{A \cdot r}{1 - (1 + r)^M} \quad (2-17)$$

$$c_1 = ROI = \frac{I}{A} = \frac{r \cdot M}{1 - (1 + r)^M} - 1 \quad (2-18)$$

Svarbu pastebėti, kad šiuo atveju skaičiuojant $c_1(ROI)$, r vertinama ne kaip paskolos palūkanų norma, bet kaip marža, kuri apskaičiuojama iš palūkanų normos skolinto kapitalo kainos C .

Tarkime, kad π_0 ir π_1 – apriorinės tikimybės, jog skolininkai bus, atitinkamai, „blogi“ ir „geri“, t – lūžio taškas, c^* – paskolos išdavimo veiksmo kaina (angl. *cost of action*), F_0 ir F_1 – sukaupto „blogų“ ir „gerų“, atitinkamai, skolininkų pasiskirstymo tankio funkcijos (angl. *cumulative density function*). Tada vidutinis vienam skolininkui tenkantis pelnas P (angl. *average classification profit per borrower*), taikant modelį, išreiškiamas taip (Verbranken ir kiti 2014; 2013):

$$P(t, b_0, c_1, c^*) = (b_0 - c^*)\pi_0 F_0(t) - (c_1 + c^*)\pi_1 F_1(t) \quad (2-19)$$

Siekiant optimizuoti vidutinį pelną, kuris priklauso nuo lūžio taško t , apskaičiuojamas maksimalaus pelno rodiklis MP (angl. *maximum profit measure*):

$$MP = \max_{\forall t} P(t, b_0, c_1, c^*) = P(T, b_0, c_1, c^*) \quad (2-20)$$

Čia T – optimalus lūžio taškas šiomis aplinkybėmis:

$$P = \operatorname{argmax}_{\forall t} P(t, b_0, c_1, c^*) = P(T, b_0, c_1, c^*) \quad (2-21)$$

Optimalus lūžio taškas nustatomas pirmame taške, tenkinančiame šią sąlygą:

$$\frac{f_0(T)}{f_1(T)} = \frac{\pi_1(c_1 + c^*)}{\pi_0(b_0 - c^*)} \quad (2-22)$$

Nustačius lūžio tašką, jis naudojamas kaip išeities taškas sudarant rangų skalę.

Empirinio tyrimo hipotezės

Keliamos tokios empirinio tyrimo hipotezės:

H1 Mažose rinkose veikiančių kredito unijų verslo paskolų portfeliai yra kokybiškesni, nei didžiosiose rinkose veikiančių kredito unijų.

Autorius preziumuoja, kad kredito unijose, veikiančiose mažose rinkose, veikia socialinis kontrolės elementas, būdingas mažų bendruomenių pagrindu veikiančioms kredito unijoms. Šis veiksnys lemia tai, kad mažose rinkose veikiančiose kredito unijose neveiksnių paskolų dalis visame paskolų portfelyje yra mažesnė. Hipotezės patvirtinimas suteiktų reikšmingą pagrindą teiginiui, kad kredito unijoms veikiant už bendruomenės ribų, socialinis kontrolės elementas silpsta ir kyla statistinių kredito rizikos vertinimo modelių poreikis.

H2 Dažniausiai kredito unijos susiduria su kredito rizikos vertinimo problemomis vertindamos verslo paskolų ir vartojimo paskolų kredito riziką.

Autorius daro prielaidą, kad kredito unijoms kredito rizikos vertinimo aspektu problemiškesni yra tie segmentai, kuriuos įvertinti įprastai yra taikomi statistiniai kredito rizikos vertinimo metodai. Patvirtinus hipotezę, būtų galima teigti, kad statistinių kredito rizikos vertinimo modelių taikymas galimai palengvintų kredito unijų veiklą ir supaprastintų paskolų teikimo procesą.

H3 Reikšminga įmonių dalis, kurioms kredito unijų suteiktos paskolos tampa neveiksniomis, nebankrutuoja.

Autorius preziumuoja, kad reikšminga mažo ir labai mažo dydžio įmonių dalis, susidūrusi su finansiniais sunkumais, nebankrutuoja. Toks reiškinys galėtų būti paaiškintas dvejopai: *pirma*, kai, veikiant ekonominiams, moraliniams ir socialiniams veiksniams, įmonių savininkai yra linkę sumokėti įmonės skolas asmeninėmis lėšomis ir, *antra*, kreditoriai nėra linkę bylinėtis dėl nereikšmingo dydžio skolų išieškojimo. Hipotezei patvirtinus, sudarant statistinius modelius, skirtus vertinti mažų ir labai mažų įmonių kredito riziką, būtų tikslinga formuoti modifikuotą „blogos“ paskolos apibrėžimą įtraukiant įmonės veiklos tęstinumo požymius per apibrėžtą stebėjimo laikotarpį.

H4 Sudarytas statistinis mažų ir labai mažų įmonių kredito rizikos vertinimo modelis leis tiksliau įvertinti kredito unijų teikiamų verslo paskolų kredito riziką.

Autorius preziumuoja, kad taikant kuriamą modelį kredito unijų veikloje, neveiksnių paskolų dalis bendrame kredito unijų paskolų portfelyje būtų mažesnė. Patvirtinus hipotezę, sukurtą modelį būtų galima pasiūlyti kredito unijų asociacijoms. Sukurto modelio taikymas teigiamai veiktų kredito unijų sektoriaus stabilumą ir kredito unijų veiklos efektyvumą.

3. ĮMONIŲ KREDITO RIZIKOS VERTINIMO MODELIS LIETUVOS KREDITO UNIJOMS

3.1. Kredito rizikos vertinimo problematika Lietuvos kredito unijų sektoriuje


Šiame disertacinio tyrimo skyriuje pristatomi Lietuvos kredito unijų sektoriaus tyrimo rezultatai. Atliekant tyrimą, taikyti 2.1. skyriuje pristatyti ir pagrįsti tyrimo metodai: apklausa, k-vidurkiai, kohortos, cirkuliarinės diagramos ir bendramoksliniai tyrimo metodai. Atliekant tyrimą siekta atsakyti į 2.1. skyriuje iškeltus uždavinius.

3.1.1. Kredito unijų sektoriaus struktūros ir verslo paskolų portfelio analizė

Kredito unijų sektoriaus struktūros analizė. Siekiant geriau suprasti Lietuvos kredito unijų sektoriaus struktūrą, jo dalyvių savybes bei sunkumus, su kuriais susiduria kredito unijos vertindamos kredito riziką, kredito unijoms priskirti papildomi požymiai: turto dydžio, paskolų portfelio dydžio ir potencialaus rinkos dydžio. Kredito unijų potencialus rinkos dydis apskaičiuotas pagal (2-3) formulę, duomenys skaičiavimams paimti iš LRSD (LRSD, 2015, 2011). Kredito unijų paskolų portfelių ir balansinio turto dydžiai gauti iš Lietuvos banko priežiūros tarnybos ataskaitų³⁸, atskleidžiančių Lietuvos kredito unijų finansinę padėtį už 2015 ataskaitinius metus (LB, 2016). Surinkti duomenys išanalizuoti, sujungti su apklausos rezultatų duomenimis bei susisteminti suformuojant kredito unijų sektoriaus tyrimo imtį. Kredito unijos klasiterizuotos pagal priskirtus požymius suformuojant devynis klasterius – kiekvienam požymiui priskiriant mažas, vidutines ir dideles kredito

³⁸Pagrindiniai Lietuvos KU sektoriaus dalyvių rodikliai yra skelbiami internete kas ketvirtį: http://www.lb.lt/pagrindiniai_kredito_uniju_sektoriaus_veiklos_rodikliai.

unijas³⁹. Siekiant atskleisti Lietuvos kredito unijų sektoriaus, kuriame atliktas tyrimas, struktūrą, atlikto klasterizavimo rezultatai pateikiami cirkuliariinių diagramų forma (26 pav.)⁴⁰.



26 pav. Struktūrinis analizuotų kredito unijų pasiskirstymas pagal priskirtus požymius

Sudaryta autoriaus pagal Krzywinski ir kiti (2009).

26 paveikslas susideda iš trijų diagramų. Kiekviena diagrama parodo analizuojamų kredito unijų struktūrą pagal du požymius. Diagrama A – pagal rinkos, kurioje veikia kredito unija, dydį ir unijos turto dydį, diagrama B – pagal rinkos, kurioje veikia kredito unija, dydį ir paskolų portfelio dydį, diagrama C – pagal turto dydį ir paskolų portfelio dydį. Diagramos susideda iš atskirų struktūrinių dalių, kurios atitinka minėtus priskirtus požymius ir jiems priskirtas reikšmes: didelis, vidutinis ir mažas. Tokio porinio požymių analizės atveju, cirkuliarinės diagramos jungtys sujungia vieno kategorinio požymio reikšmes, kurias atitinka skirtingos diagramos struktūrinės dalys su kito analizuojamo požymio reikšmėmis, taip parodomas požymių reikšmių pasiskirstymas analizuojamoje imtyje. Jungčių plotis rodo proporcijas, vizualiai pavaizduojama, kokia dalis objektų, atitinkančių vieną požymio reikšmę, atitinka kito požymio reikšmę. Taip vaizduojama požymių

³⁹ Skaičiavimai atlikti naudojant R atviro kodo programinės įrangos paketą (R Core Team, 2015).

⁴⁰ Paveikslas suformuotas naudojant Circos atviro kodo programinės įrangos paketą (Krzywinski ir kiti, 2009).

pasiskirstymo struktūra imtyje. Siekiant diagramas interpretuoti paprasčiau, vieno iš analizuojamų požymių reikšmėms priskiriamos skirtingos spalvos, o diagramos išorėje pateiktos matavimo skalės. Pirmoji skalė, esanti arčiau diagramos centro, rodo kiekvienos struktūrinės diagramos dalies unijų kiekį vienetais. Antroji skalė, labiau atitolusi nuo diagramos centro, rodo kiekvienos struktūrinės diagramos dalies proporcijas procentais. Diagramos išorėje nurodoma, kurią požymio reikšmę atitinka kiekviena iš diagramos struktūrinių dalių.

Kaip matyti iš paveikslo (26 pav.) diagramų, dauguma kredito unijų veikia mažose rinkose, yra mažo dydžio (pagal turto ir paskolų portfelio dydį). Tokios unijos sudarė 50 proc. respondentų. Iš viso mažose rinkose veikiančios kredito unijos sudarė 73 proc., mažo dydžio (pagal turtą) unijos – 68 proc., o mažą portfelį valdančios unijos – 64 proc. analizuotų respondentų. Diagrama A parodo ženklių ryšį tarp kredito unijų rinkos dydžio ir turto dydžio: 55 proc. mažose rinkose veikiančių kredito unijų turtas yra mažas, 13 proc. vidutinis ir 5 proc. didelis. Diagramos A ir B beveik identiškos, tai parodo stiprią turto ir portfelio dydžių priklausomybę, kuri yra logiška – įprastai paskolų portfelis sudaro tam tikrą proporcingą turto dalį. Tačiau yra ir išimčių – diagramoje C matyti, kad viena kredito unija, kurios turtas priskiriamas vidutiniam, valdo mažą paskolų portfelį; dvi kredito unijos, turinčios didelius paskolų portfelius, yra vidutinio dydžio; trys vidutinio dydžio (pagal turtą) kredito unijos valdo mažus, o dvi – didelius portfelius. Šios išimtys atskleidžia kredito unijų turto struktūrų ir veiklos strategijų skirtumus – kai kurios kredito unijos yra linkusios didžiąją dalį turto laikyti paskolų pavidalu, kitos – kitokiomis turto formomis (pvz., skolos vertybiniais popieriais).

Remiantis respondentų klasterizavimo pagal požymius rezultatais, galima daryti dvi išvadas. Pirma – kredito unijos yra nehomogeniškos, matyti ženklūs skirtumai – jos veikia skirtingų dydžių rinkose, turi skirtingą turto struktūrą, laikosi skirtingų turto valdymo strategijų bei ženkliai skiriasi jų dydžiai – tiek paskolų portfelį, tiek bendrai turto. Antra, didžioji dalis Lietuvos kredito unijų yra mažos pagal savo valdomo turto ir paskolų portfelio dydžius. Nors

dauguma kredito unijų veikia mažose rinkose, o kredito unijos Lietuvoje veikia laikydamosios teritorinio principo, matyti, kad tai nėra pagrindinis veiksnys, trukdantis vystytis kredito unijoms – ženkli dalis vidutinio dydžio ir didelėse rinkose veikiančių kredito unijų taip pat yra mažos (tiek turto, tiek valdomų paskolų portfelio prasme, žr. 1 pav.). Tokia situacija Lietuvos kredito unijų sektoriuje leidžia daryti prielaidą, kad kredito unijos susiduria su sunkumais pereidamos nuo socialiai orientuoto prie verslo veiklos modelio⁴¹.

Kredito unijų verslo paskolų portfelio analizė. Siekiant patikrinti H1 hipotezę, kad mažose rinkose veikiančių kredito unijų verslo paskolų portfeliai yra kokybiškesni, bei siekiant geriau suprasti Lietuvos kredito unijų sektoriaus problemas, susijusias su kredito rizikos vertinimu, šiame skyriuje atliekama kredito unijų sektoriaus verslo paskolų vėlavimo dinamikos analizė. Siekiant atskleisti skirtingų kredito unijų segmentų specifiškumą, atliekant šią analizę kredito unijos segmentuojamos pagal 3.1.1. poskyryje priskirtus požymius. Analizei taikomas kohortų metodas, detalai pristatytas šio disertacinio tyrimo metodinėje dalyje, 2.1.3. poskyryje. Pirma, paskoloms priskiriami jų suteikusių kredito unijos požymiai. Antra, suformuojamos paskolų kohortos, trečia, suskaičiuojami vidutiniai vėlavimo rodikliai, išskiriant 30, 60, 90 ir 120 dienų vėlavimo rodiklius, ketvirta, rezultatai pavaizduojami grafiškai. Tyrimui pasitelkti Lietuvos Centrinės kredito unijos paskolų juridiniams asmenims duomenys, nuo 2010 sausio 1 d. iki 2015 rugsėjo 12 d., iš viso – 1955 mėnesinės paskolų grąžinimo istorijos.

Analizės rezultatai pateikti 12 lentelėje. Lentelės langeliuose esantys paveikslai vaizduoja kredito unijų verslo paskolų portfelio struktūrą pagal vėlavimo dienų kiekį. Paveikslų y ašys – santykinės portfelio dalys, x ašys – paskolos buvimo portfelyje trukmė mėnesiais, nuo 1 iki 40 mėn. Lentelės skiltys nurodo kredito unijų segmentus pagal klasterizavimo rezultatus (s), atitinkamai, pagal paskolų portfelio, turto ir tikslinės rinkos dydžius. Lentelės

⁴¹ Plačiau apie kredito unijų veiklos problematiką pereinant nuo socialiai orientuoto veiklos modelio prie komercinio – publikacijoje „Ankstyvoji kredito unijų istorija ir veiklos modelio raida“ (Špicas, Vijūnas, 2016).

eilutės nurodo paskolų vėlavimo trukmes (n), atitinkamai, 30, 60, 90 ir 120 dienų.

Kaip matyti pagal pateiktą lentelę (12 lent.), turto ir paskolų portfelio prasme didelės kredito unijos valdo žymiai kokybiškesnius paskolų portfelius, nei mažos ir vidutinės kredito unijos. Tokia tendencija rodo, kad unijos, valdančios didelius paskolų portfelius ir / ar vertinamos kaip didelės turto prasme, kredito riziką vertina efektyviau, nei mažesnės kredito unijos.

12 lentelė. Lietuvos kredito unijų sektoriaus verslo paskolų portfelio struktūra pagal vidutinį vėlavimo dienų kiekį ir skirtingus kredito unijų segmentus



* Paveiksluose Did. – didelės, Vid. – vidutinės, Maž. – mažos kredito unijos

Autoriaus skaičiavimai.

Kitokią tendenciją galima matyti trečiojoje lentelės skiltyje, kurioje kredito unijos yra segmentuotos pagal potencialios rinkos dydį – mažose rinkose veikiančios kredito unijos valdo kokybiškesnius paskolų portfelius. Tokia prieštaringa tendencija gali būti paaiškinama tuo, kad mažose rinkose

veikiančiose kredito unijose veikia socialinės kontrolės elementas ir tai suteikia kredito unijoms reikšmingą pranašumą vertinant ir valdant kredito riziką, palyginus su didesnėse rinkose veikiančiomis kredito unijomis. Kitaip tariant, tyrimo duomenys rodo, kad kredito unijų veiklai plečiantis už mažos rinkos ribų, jos susiduria su sunkumais vertinant įmonių kredito riziką.

Apibendrinant galima teigti, kad su didžiausiais sunkumais vertinant riziką susiduria vidutinio dydžio ir didžiosiose rinkose veikiančios kredito unijos. Tokia tendencija gali būti paaiškinta dvejopai. **Viena vertus**, yra moksliskai įrodyta, kad mažesnė konkurencija lemia žemesnį rizikos apetitą (žr. Jiménez ir kiti, 2014, 2007). **Kita vertus**, mokslinėje literatūroje, analizuojančioje kredito unijų veiklą iš jų raidos perspektyvos (Wilson 2015; 2011; O’Connel 2012; Fonteyn 2007, Ferguson, McKillop, D. 2006; Sibbald ir kiti 2002), akcentuojant vyraujančio požiūrio į socialinės kontrolės elemento vaidmenį vertinant kredito riziką, galima teigti, kad šis elementas daro reikšmingą teigiamą įtaką mažose rinkose veikiančių kredito unijų gebėjimui įvertinti ir valdyti verslo paskolų kredito riziką. Šiame disertaciniame tyrime laikomasi pastarojo požiūrio, tačiau pažymėtina, kad šie du įvardyti požiūriai vienas kitam neprieštarauja.

Šiame skyriuje atliktos kredito unijų verslo paskolų vėlavimo dinamikos analizės rezultatai leidžia patvirtinti H1 hipotezę. Iš analizės rezultatų matyti, kad mažose rinkose veikiančių kredito unijų paskolų portfeliai yra ženkliai kokybiškesni, nei vidutinėse ir didelėse rinkose. Šie rezultatai leidžia teigti, jog mažose rinkose socialinis kontrolės elementas veikia efektyviau, o veiklai plečiantis už bendruomenės ribų, jis silpsta. Tai patvirtina statistinių kredito rizikos vertinimo modelių poreikį kredito unijoms plečiant veiklą už bendruomenės ribų. Pažymėtina, kad šio tyrimo rezultatai atitinka mokslinėje literatūroje išskiriamų kredito unijų raidos etapų savitumą (3 lentelė) bei šiuolaikinį tyrėjų požiūrį į socialinio kontrolės elemento vaidmenį vertinant kredito riziką bei kredito unijų evoliuciją apskritai.

3.1.2. Kredito unijų taikomų kredito rizikos vertinimo metodų ir reikalavimų kuriamam modeliui analizė

Šiame disertacinio tyrimo poskyryje analizuojamas tyrimo metu kredito unijų veikloje taikytas kredito rizikos vertinimo modelis bei jo taikymo, koregavimo ir / ar naujo modelio sukūrimo problematika. Šiame poskyryje siekama dviejų tikslų. *Pirma*, išanalizuoti kredito unijų naudojamą modelį atskleidžiant jo taikymo ribotumą bei tinkamumą naudoti kredito unijų veikloje. *Antra* – nustatyti kredito unijų lūkesčius ir reikalavimus kredito rizikos vertinimo modelio diskriminacinei galiai, modelio rezultatų paaiškinamumui bei naudotiniams nepriklausomiems modelio kintamiesiems. Šiai analizei atlikti pasirinktas apklausos metodas. Kredito unijų naudojamo modelio analizės rezultatai sujungiami su kredito unijų verslo paskolų portfelio analizės rezultatais. Iškeltų uždavinių svarba kuriant kredito rizikos vertinimo modelį bei taikomas tyrimo metodas yra aptarti ir pagrįsti šio disertacinio tyrimo metodinėje dalyje (2.1. skyrius).

Tyrimo metu kredito unijų taikytas kredito rizikos vertinimo modelis.

Tyrimo metu nustatyta, kad visos apklaustos kredito unijos savo veikloje taiko standartizuotą taisyklių pagrindų veikiantį ekspertinio tipo (angl. *rule-based expert system*) kredito rizikos vertinimo modelį (toliau – kredito unijų naudojamas modelis), kuris priskiria pareiškėjams vieną iš penkių galimų balų. Penktas balas atspindi didžiausią riziką ir atitinka lūžio tašką.

Didžioji dalis apklaustų kredito unijų pripažino poreikį tobulinti turimą vertinimo sistemą, 55 % respondentų apibūdino modelio tobulinimo poreikį kaip aktualų arba labai aktualų, 12,5 % kaip nei aktualų, nei neaktualų, likę 32,5 % – kaip neaktualų. Pažymėtina, kad 65 % respondentų, atsakiusių, jog esamos rizikos vertinimo metodikos tobulinimas yra neaktualus, veikia mažose rinkose bei atitiko mažo turto ir mažo paskolų portfelio segmentus. Dauguma respondentų paaiškino savo požiūrį tuo, kad pageidauja taikyti ekspertinius kredito rizikos vertinimo ir sprendimų priėmimo metodus dėl reikšmingo socialinės kontrolės veiksnio jų veikloje.

Siekiant atskleisti kredito unijų naudojamo modelio taikymo ribotumą, nutarta įvertinti ekspertinio vertinimo įtaką kreditavimo sprendimų priėmimo procese. Respondentų paklausus, ar dažnai praktikoje taikomas jų naudojamas kredito rizikos vertinimo modelis, vertinimo modelio rezultatai skyrėsi nuo faktinio sprendimų priėmimo⁴². Nustatyta, kad paskolų portfelio ir turto atžvilgiu mažose kredito unijose modelio rezultatų ir faktinių sprendimų neatitikimai yra dažnesni, nei vidutinio ir didelio dydžio kredito unijose. Priešinga tendencija matyti tikslinės rinkos dydžio segmentuose – modelio rezultatų ir sprendimo priėmimo neatitikimai dažnesni didesnėse rinkose veikiančiose kredito unijose (27 pav.).

		Priskirti papildomi požymiai		KU kiekis	Dabartinio KRV modelio rezultatų ir faktinių sprendimų priėmimo neatitikimų dažnis (absoliutus ir santykinis)			Tendencija
Apklaustos kredito unijos	Turtas	Did.	6	Visuomet/Dažniausiai	0	0%	—	
				Dažnai	1	16,7%		
				Retai / Itin retai	5	83,3%		
		Vid.	12	Visuomet/Dažniausiai	2	16,7%	↓	
				Dažnai	2	16,7%		
				Retai / Itin retai	8	66,7%		
		Maž.	37	Visuomet/Dažniausiai	7	18,9%	=	
				Dažnai	9	24,3%		
				Retai / Itin retai	21	56,8%		
	Paskolų portfelis	Did.	6	Visuomet/Dažniausiai	0	0%	↓	
				Dažnai	1	16,7%		
				Retai / Itin retai	5	83,3%		
		Vid.	14	Visuomet/Dažniausiai	2	14,3%	↓	
				Dažnai	3	21,4%		
				Retai / Itin retai	9	64,3%		
		Maž.	36	Visuomet/Dažniausiai	7	19,4%	=	
				Dažnai	8	22,2%		
				Retai / Itin retai	21	58,3%		
	Tikslinė rinka	Did.	10	Visuomet/Dažniausiai	4	40%	↑	
				Dažnai	0	0%		
				Retai / Itin retai	6	60%		
		Vid.	5	Visuomet/Dažniausiai	1	20%	↑	
				Dažnai	1	20%		
				Retai / Itin retai	3	60%		
		Maž.	41	Visuomet/Dažniausiai	4	9,8%	=	
				Dažnai	11	26,8%		
				Retai / Itin retai	26	63,4%		

27 pav. Taisyklių pagrindu sudaryto modelio ir faktinio sprendimų priėmimo neatitikimai kredito unijų veikloje

Sudaryta autoriaus.

⁴² Pavyzdžiui, jei apskaičiuota pagal dabartinį modelį kredito rizika nesuteikia galimybės išduoti paskolą, tačiau ekspertinio vertinimo metu paskolą nutariama išduoti, arba priešingai.

Atliktos analizės rezultatai rodo, kad ekspertinė vertinimo įtaka yra mažesnė turto ir paskolų portfelio atžvilgiu didelėse ir vidutinio dydžio kredito unijose. Priešinga tendencija matyti kredito unijas segmentuojant pagal tikslinės rinkos dydžius – didelėse ir vidutinėse kredito unijose ekspertinė įtaka yra labai didelė arba didelė, o mažose – vidutinė⁴³.

Ekspertinės įtakos analizės rezultatus sujungus su kredito unijų verslo paskolų portfelio analizės rezultatais (13 lent.), galima matyti tendenciją, kad verslo paskolų portfelio kokybė priklauso nuo ekspertinės įtakos kredito rizikos vertinimo procese. Tuose kredito unijų segmentuose, kuriuose ekspertinė įtaka yra didelė arba vidutinė, paskolų portfelio kokybė yra blogesnė (13 lent., 2, 3, 5, 6, 7, 8 skiltys), nei tuose, kuriuose ekspertinė vertinimo įtaka mažesnė (13 lent., 1, 4, 9 skiltys). Šios tendencijos išimtį galime matyti 9 lentelės skiltyje – ekspertinei įtakai esant vidutinio dydžio, verslo paskolų portfelio kokybė yra gera. Ši išimtis pilnai paaiškinama socialinės kontrolės elemento veikimu mažo tikslinio dydžio kredito unijų rinkose.

13 lentelė. Kredito unijų verslo paskolų portfelio kokybės ir ekspertinės vertinimo įtakos analizės rezultatų apibendrinimas

Analizuojamas KU segmentas	Turtas			Paskolų portfelis			Rinka		
	1	2	3	4	5	6	7	8	9
Priskirti papildomi požymiai	Did.	Vid.	Maž.	Did.	Vid.	Maž.	Did.	Vid.	Maž.
Paskolų portfelio kokybė	Gera	Bloga	Bloga	Gera	Bloga	Bloga	Bloga	Labai bloga	Gera
Ekspertinė įtaka	Maža	Vidutinė	Didelė	Maža	Vidutinė	Didelė	Labai didelė	Didelė	Vidutinė
							Probleminis KU sektoriaus segmentas	Veikia soc. kontrolės elementas	

Sudaryta autoriaus.

⁴³ Įtakų reikšmingumus disertacijos autorius priskyrė ekspertiškai, atsižvelgdamas į tyrimo rezultatus.


Kaip galima matyti iš atliktos analizės rezultatų, kredito unijas segmentuojant pagal tikslinės rinkos dydį, atsiskleidžia probleminis kredito unijų segmentas (13 lentelė, 7–8 skiltys). Tai kredito unijos, veikiančios vidutinėse ir didelėse tikslinėse rinkose, kurių kredito rizikos vertinimo ir sprendimų priėmimui reikšmingą įtaką daro ekspertinis veiksnys. Šių kredito unijų verslo paskolų portfelio kokybė yra ženkliai blogesnė, nei mažose rinkose veikiančiose kredito unijose (13 lentelė, 9 skiltis). Šios analizės rezultatai leidžia pagrįstai teigti, kad dabartinis verslo paskolų kredito rizikos vertinimo modelis nėra tinkamas didelėse ir vidutinėse rinkose veikiančioms kredito unijoms, tačiau mažose rinkose veikiančios kredito unijos jį sėkmingai taiko papildydamos ekspertiniu įvertinimu socialinės kontrolės elemento veikimo kontekste. Šios analizės rezultatai papildo atliktos verslo paskolų portfelio analizės rezultatus ir pakartotinai pagrindžia H1 hipotezės patvirtinimą.

Siekiant geriau suprasti analizuojamo reiškinių priežastingumą, papildomai analizuotos modelio rezultatų ir faktinio sprendimų priėmimo neatitikimų priežastys. Respondentų klausta, kokie veiksniai lemia neatitikimus (atviro tipo klausimas). Respondentų atsakymai analizuoti, sisteminti ir sugrupuoti pateikiant pagrindines neatitikimų priežastis (28 pav.).

Analizuojant nustatyta, kad viena pagrindinių neatitikimo priežasčių yra tai, jog kredito unijų sprendimų priėmimo logika skiriasi nuo taikomo modelio veikimo logikos. Respondentai paaiškino, kad sprendimus dažniausiai priima remdamiesi kitais kriterijais, o ne analizuojamais taikomame modelyje, dažniausiai tai būna subjektyviu požiūriu, t. y. ekspertinio įvertinimo metu pasitelkiami kriterijai. Kaip matyti iš atliktos ekspertinės įtakos ir paskolų portfelio kokybės analizės, toks požiūris efektyvus tik mažose tikslinėse rinkose veikiančiose kredito unijose. Taip pat reikšmingi neatitikimų veiksniai yra subjektyvių⁴⁴ duomenų įtaka, faktinių ir oficialių duomenų nesutapimai, ir

⁴⁴ Respondentai paaiškino, kad veikiant benduomenių pagrindu ir pažįstant potencialius klientus (narius), vertinimo procese dažnai vertinami turimi subjektyvūs duomenys.


kiti, nurodyti paveiksle (28 pav.). Respondentai pažymėjo, kad dabartinio modelio keitimo procedūra yra sudėtinga ir imli darbei bei kaštams.



28 pav. Pagrindinės taisyklių pagrindu sudaryto modelio ir faktinio sprendimų priėmimo neatitikimų priežastys

Autoriaus skaičiavimai remiantis apklausos rezultatais.

Siekiant nustatyti pagrindines kliūtis, su kuriomis susiduria kredito unijos kurdamos ar tobulindamos kredito rizikos vertinimo modelį, bei nustatyti kredito unijų disponuojamus ŽTF, respondentų buvo paprašyta pažymėti šiuos veiksnius (uždaro tipo klausimas) nurodant, ar jie yra svarbūs. Atlikus tyrimą nustatyta, kad Lietuvos kredito unijos kaip reikšmingiausius veiksnius, trukdančius sukurti naują ar tobulinti dabartinį kredito rizikos vertinimo modelį nurodo modelio sudarymo kaštus, personalo trūkumą ir modelio sudarymui būtinos informacijos (imties) nebuvimą. Kaip didžiausią trūkumą respondentai pažymėjo personalo statistikos ir informacinių technologijų srities žinias, taip pat nurodė, kad kompetentingų darbuotojų negali priimti į darbą dėl jau minėto veiksnio – ribotų finansinių pajėgumų.



29 pav. Veiksniai, darantys įtaką kredito rizikos vertinimo modelio sukūrimo ar tobulinimo problemiškamumui Lietuvos KU sektoriuje

Autoriaus skaičiavimai remiantis apklausos rezultatais.

Tyrimo metu taip pat paaiškėjo, kad reikšmingas trukdis tobulinti taikomos kredito rizikos vertinimo metodiką yra ir politinės valios stoka. 36 respondentai nurodė kredito unijų valdymo organų pasyvumą ir politinės valios stoką kaip labai svarbų veiksnių, trukdanti diegti pažangius kredito rizikos vertinimo metodus.

Kredito unijų reikalavimai kuriamo kredito rizikos vertinimo modeliui charakteristikoms. Siekiant nustatyti kredito unijų reikalavimus kuriamam modeliui, respondentų klausta, kurios modelio savybės yra svarbiausios (atviro tipo klausimas). Visi respondentai teigė tai, kad nors viena svarbiausių modelio savybių yra gera diskriminacinė galia, jie būtų linkę pasirinkti modelį su žemesne diskriminacine galia, tačiau tokį, kurio rezultatus būtų galima nesudėtingai interpretuoti, o ne „juodos dėžės“ tipo modelį su labai aukšta diskriminacine galia.

Respondentų klausta, ar modelio (ir sprendimų priėmimo proceso) automatizavimas yra svarbus veiksnys jų veikloje (atviro tipo klausimas). 51,7 proc. respondentų pabrėžė modelio automatinį arba pusiau automatinį veikimą kaip svarbią arba labai svarbią modelio savybę. Respondentai teigė, jog šiuo metu vertinimo procesas yra atliekamas rankiniu būdu, tam sugaištama daug

laiko bei yra pasitaikę vertinimo klaidų – tiek techninio tipo, tiek ir atsirandančių dėl nesąžiningumo (operacinės rizikos elementai).

Svarbūs nepriklausomi kintamieji. Siekiant identifikuoti kredito unijoms svarbius nepriklausomus kintamuosius, respondentų klausta, kuriuos kredito rizikos veiksnius jie laiko svarbiais. Visi respondentai teigė, kad jiems būtų svarbu į modelio nepriklausomus kintamuosius įtraukti tiek finansinius, tiek ir nefinansinius rodiklius. Kaip techninio modelio išpildymo reikalavimą respondentai nurodė išorinių duomenų bazių integravimo poreikį, nes šiuo metu informaciją iš išorinių duomenų šaltinių suvendant rankomis sugaištama daug laiko.

Respondentų nuomonės dėl naudojamų duomenų vertinant kredito riziką reikšmingai nesiskyrė. Galima sakyti, kad visi respondentai nurodė, jog į modelį reikia įtraukti aukštą diskriminacinę galią turinčius nepriklausomus kintamuosius, kuriuos kredito unijos gali gauti iš duomenų registrų. Visi apklausti respondentai vertinant juridinių asmenų kredito riziką naudoja lentelėje nurodytus išorinius šaltinius (14 lent.).

14 lentelė. Rizikos vertinimo tikslais KU naudojami išoriniai duomenų šaltiniai ir jų svarba

Registro pavadinimas	VĮ Registrų centras (JAR)	VĮ Registrų centras (NTR)	SODRA	Centrinė hipotekos įstaiga	UAB "Creditinfo Lietuva"	Bankroto registras	LB PRDB
Analitinė informacija	Finansinių ataskaitų rinkiniai	Nekilnojam. turto registras	Darbuotojų skaičiaus ir skolų SODRAI duomenys	Laikinosios apsaugos priemonės	Skolų registras (kredito istorija) Turimų finansinių įsipareig. registras	Bankroto informacija	Turimų finan. įsip. ir mokėj. vėlav. registr.
Registro analitinės informacijos svarba	Labai svarbi inform.	Vidutiniškai svarbi informacija	Vidutiniškai svarbi inform.	Labai svarbi inform.	Labai svarbi inform.	Labai svarbi inform.	Labai svarbi inform.

Sudaryta autoriaus.

Iš lentelės duomenų matyti, kad kredito unijos savo veikloje naudoja finansinės atskaitomybės, kredito istorijos ir taikomų laikinų apsaugos priemonių (areštų) duomenis. Toliau šiame tyrime, atsižvelgus į rezultatus,

formuojant galimų naudoti kintamųjų sąvadą, siekiama pagal galimybę įtraukti kintamuosius, kuriuos sudaryti kredito unijos turi pakankamai duomenų.

*Apibendrinant poskyrį, galima teigti, kad: **pirma**, nustatytas kredito unijų naudojamo kredito rizikos vertinimo modelio ribotumas – modelis nėra tinkamas naudoti vidutinio ir didelio dydžio rinkose veikiančių kredito unijų veikloje. Pažymėtina tai, kad kredito unijų naudojamas modelis neatitinka Bazelio bankų priežiūros komiteto rekomendacijų dėl išskirtino rangų kiekio skalėje⁴⁵. Tobulindamos naudojamą ir / ar kurdamos naują modelį, kredito unijos daugiausiai sunkumų patiria dėl ribotų ŽTF išteklių ir valdymo organų politinės valios stokos. **Antra**, nustatyti kredito unijų reikalavimai ir lūkesčiai kuriamam modeliui: aukšta diskriminacinė galia, modelio rezultatų paaiškinamumas ir prieinamos išorinės informacijos įtraukimas (nepriklausomų kintamųjų forma) į modelio sudarymą, įtraukiant finansinę ir nefinansinę informaciją.*


3.1.3. Tikslinių kreditavimo segmentų ir „blogos“ paskolos apibrėžimas kredito unijų sektoriuje

Kredito unijų tikslinių kreditavimo segmentų analizė. Siekiant patikrinti H2 hipotezę bei motyvuotai nustatyti modeliuojamą homogeninę skolininkų grupę, atliekama kredito unijų tikslinių kreditavimo segmentų ir jų problemiško analizė. Analizei pasirinktas 2.1.1. poskyryje aprašytas ir pagrįstas apklausos metodas.

Atliekant tyrimą, respondentų klausta: kokios homogeninės skolininkų grupės yra išskiriamos taikant vertinimo metodus ir / ar modelius; kurias iš šių grupių jos išskiria kaip tikslines ir prioritетines vykdant veiklą; kurios iš jų galėtų būti apibūdinamos kaip probleminės kredito rizikos vertinimo atžvilgiu. Analizuojant nustatyta, kad vertindamos kredito riziką, kredito unijos įprastai išskiria penkias homogenines grupes, kurioms yra taikomi modeliai,

⁴⁵ Kaip minėta, kredito unijos išskiria 5 rangus – 4, tikėtina, įsipareigojimus vykdysiantiems ir vieną, tikėtina, nevykdysiantiems (bei faktiškai nemokiems skolininkams). Bazelio bankų priežiūros komiteto dokumentuose rekomenduojama išskirti mažiausiai 9 rangus: 6, tikėtina, įsipareigojimus vykdysiantiems ir 3 nevykdysiantiems skolininkams.

išskiriantys– fizinius asmenis, juridinius asmenis, žemės ūkio subjektus ir fizinius komercinius asmenis. Tolesniame paveiksle (30 pav.) pateikta struktūrinė analizės rezultatų schema.



30 pav. Paskolų gavėjų segmentų pasiskirstymas kredito unijų sektoriuje pagal vertinimo metodus, priskyrimą tiksliniam segmentui ir problemiškumą kredito rizikos atžvilgiu

Sudaryta autoriaus.

Paveiksle: FA – fiziniai asmenys; JA – juridiniai asmenys; FKA – fiziniai komerciniai asmenys; ŽŪ – žemės ūkio subjektai; Taiko – parodo, kokia dalis kredito unijų išskiria atskirą vertinimo metodiką šiam pareiškėjų segmentui; Tikslinė / Netikslinė – parodo, kokia santykinė dalis KU laiko šį segmentą savo tiksliniu segmentu; Probleminė / Neprobleminė – parodo, kokia dalis kredito unijų laiko šį segmentą probleminiu grupuojant pagal (ne)orientaciją į segmentą kaip į tikslinį.

Analizė parodė, kad problemiškesni kredito rizikos vertinimo atžvilgiu yra fizinių ir juridinių asmenų segmentai. Juos kaip probleminius įvardijo iš viso 42,86 % ir 67,86 % respondentų. Pažymėtina, kad unijos, kurioms šie segmentai yra tiksliniai, dažniau vertino juos kaip probleminius. Kredito unijų sunkumai prognozuojant fizinių ir juridinių asmenų mokumą galimai yra susiję su kredito rizikos vertinimo metodais – priešingai nei yra rekomenduojama

(Valvonis, 2006), unijos, vertindamos šiuos segmentus, taiko ekspertinius metodus vietoje statistinių. Kaip mažiau problemiškus segmentus unijos vertina fizinius komercinius asmenis ir žemės ūkio subjektus. 1,8 % ir 3,57 % respondentų šiuos segmentus apibūdino kaip probleminius.

Į problemiškesnį laikomą juridinių asmenų segmentą dažniausiai orientuojasi didžiuosiuose ir vidutinėse rinkose veikiančios kredito unijos. Atitinkamai 70 % ir 100 % respondentų apibūdino šį segmentą kaip tikslinį, o mažose rinkose orientacija į įmonių finansavimą yra mažesnė – 29,27 %. Fizinių asmenų segmentas yra populiariausias tarp vidutinėse ir didžiuosiuose rinkose veikiančių kredito unijų (atitinkamai 70 % ir 80 %). Tik 56,1 % mažosiose rinkose veikiančių unijų šį segmentą įvardijo kaip tikslinį, jose populiariausias žemės ūkio segmentas – 85,4 %. Pažymėtina, kad nei vienas respondentas nenurodė fizinių komercinių asmenų segmento kaip tikslinio.

Respondentų klausta, kodėl (ir kaip) jie pasirenka jų įvardytus tikslinius segmentus. Pasirinkimus kredito unijos dažniausiai pagrįsdavo dviejų tipų argumentais: a) rinkos – galimybės rasti potencialių paskolos gavėjų bei konkuruoti rinkoje su kitais finansinių paslaugų tiekėjais ir b) rizikos – gebėjimu tiksliai įvertinti potencialaus paskolos gavėjo kredito rizikos lygį. Vidutinėse ir mažose rinkose veikiančios kredito unijos savo pasirinkimą orientuoti į žemės ūkio sektorių dažniausiai pagrindžia „socialinės kontrolės elementu“ – kredito unijos darbuotojai ir valdymo organai teigia asmeniškai pažįstantys daugumą paskolų gavėjų bei dažnu atveju turi geresnes sąlygas kontroliuoti paskolos panaudojimą ir valdyti riziką⁴⁶. Šią tendenciją patvirtina ir tai, kad mažose ir vidutinio dydžio rinkose veikiančios kredito unijos yra labiau linkusios įtraukti į unijos veiklą asmenis iš vietovių, priskirtinų prie unijos veiklos teritorijos⁴⁷. 46,34 % mažose rinkose veikiančių respondentų asmens gyvenamąją vietą vertina kaip svarbų faktorių renkant asmenis į unijos

⁴⁶ Vienos kredito unijos vadovė sakė: „Rizika? Pažiūrėkite per langą. Matote, auga mūsų nario derlius, vadinasi viskas gerai. Šį derlių auginantis ūkininkas yra mūsų narys nuo įsikūrimo, kasmet skolinasi. Jis ir vienas mūsų unijos valdymo organų bei seniūnijos tarybos narys. Tokia ir rizika, jam gėda būtų neatiduoti, juk viename kaime gyvename, vienas kitą žinome“.

⁴⁷ Pagal teritorinį kredito unijų veiklos principą.

valdymo organus, vidutinio dydžio rinkose šis rodiklis lygus nuliui, didelėse rinkose – 20 %.

Orientacija į fizinių ir juridinių asmenų segmentus vidutinėse ir mažose rinkose yra mažesnė dėl demografinių ir ekonominių veiksnių bei dėl blogos kredito unijų patirties kredituojant šiuos segmentus. Šie respondentai išskiria dvi su kredito rizika susijusias priežastis, lėmusias jų neigiamą kreditavimo praktiką šiuose segmentuose: **pirma**, dėl demografinių pokyčių ir emigracijos tendencijų jų veiklos teritorijose šie segmentai tapo mažais ir rizikingais, **antra**, taikomi rizikos vertinimo įrankiai yra neefektyvūs ir jų taikymas skolinant nedideles sumas užima neproporcingai daug laiko.


Respondentų prašyta apibūdinti jurinius asmenis, atitinkančius jų tikslinį kreditavimo segmentą (klausta tais atvejais, kai respondentas nurodė šį segmentą kaip tikslinį), išskiriant įmonės turto ir pardavimo pajamų dydį, darbuotojų skaičių ar kitus įmonės požymius. Apklausos metu nustatyta, jog atsižvelgiant į kredito unijų veiklos specifiškumą ir reguliavimą, kredito unijų tikslinį kreditavimo segmentą tikslinga apibrėžti kaip mažas ir labai mažas įmones pagal LR Smulkiojo ir vidutinio verslo plėtros įstatymą (1998, Nr. 109-2993).

*Apibendrinant analizę, galima teigti, kad: **pirma**, atliktos kredito unijų tikslinių kreditavimo segmentų bei jų problemiško analizės rezultatai leidžia patvirtinti H2 hipotezę. Iš analizės rezultatų matyti, jog didžiausius sunkumus vertindamos kredito riziką, kredito unijos patiria analizuodamos fizinių asmenų ir verslo subjektų paskolų paraiškas. Šie rezultatai leidžia numanyti, kad statistinio kredito rizikos vertinimo modelio naudojimas kredito unijų veikloje supaprastintų paraiškų analizės procesą bei darytų teigiamą įtaką kredito unijų veiklos efektyvumui. **Antra**, kredito unijų tikslinių kreditavimo segmentų analizės rezultatai leidžia motyvuotai apibrėžti tikslinį modeliavimo segmentą – mažas ir labai mažas įmones pagal LT Smulkiojo ir vidutinio verslo plėtros įstatymą (1998, Nr. 109-2993).*

„Blogo“ skolininko apibrėžimo nustatymas kredito unijų sektoriuje. Siekiant nustatyti vyraujančią „blogo“ skolininko apibrėžimą Lietuvos kredito

unijų sektoriuje, šio darbo metodinėje dalyje aprašytas ir pagrįstas taikytas apklausos metodas. Apklausos metu respondentų prašyta nurodyti kriterijus, galinčius apibrėži „blogą“ skolininką jų kredito unijoje. Kaip pagrindinis rodiklis, apibrėžiantis „blogą“ skolininką, pasirinktas paskolos įmokų mokėjimo vėlavimo dienomis skaičius. Kreditoriams siūlyta pasirinkti vieną iš penkių maksimaliai toleruotinų vėlavimų dienomis trukmių, nuo vieno mėnesio iki metų.

Analizės metu nustatyta, kad, priešingai nei rekomenduojama mokslinėje literatūroje (Anderson, 2007; Siddiqi, 2006), apklausti kreditoriai neišskiria skirtingų toleruotinų vėlavimo kriterijų skirtingiems paskolų segmentams⁴⁸. Tačiau kai kurie kreditoriai teigė, jog sutiktų toleruoti ilgesnius įmokų pradelsimus, jei paskola pilna apimtimi būtų užtikrinta likvidaus nekilnojamojo turto įkeitimu, tačiau tokie atvejai į tyrimą įtraukti nebuvo. Toliau pateikiami tyrimo rezultatai (31 pav).



31 pav. Maksimalus toleruotinas paskolos mokėjimų pradelsimas Lietuvos kredito unijų sektoriuje


Autoriaus skaičiavimai.

Santrumpos: NA – neatsakyta; DPD – vėlavimo dienomis skaičius.

Paveiksle (31 pav.) matyti, kad didžiausia dalis respondentų (38 %) pagrindiniu „blogos“ paskolos požymiu laiko 90 dienų mokėjimo vėlavimą. Kiek mažiau respondentų (34 %) toleruoja vėlavimą iki 60 dienų, o 17 % – iki

⁴⁸ Iš dalies tai galima paaiškinti tuo, kad apklausti respondentai netaiko statistinių kredito rizikos vertinimo metodų.

30 dienų. Tik 7 % respondentų apibrėždami „blogas“ paskolas, pasitelkė LR teisės aktuose nurodytą neveiksnių paskolų kriterijų – 180 d. vėlavimą (LB, 2009). Tolesniame paveiksle (32 pav.) pavaizduota skirtingų dydžių rinkose veikiančių kredito unijų struktūra pagal maksimalius toleruotinus mokėjimų pradelsimų dydžius.



32 pav. Maksimalios toleruotinos paskolos įmokų pradelsimų trukmės Lietuvos kredito unijų sektoriuje, išskiriant skirtingų dydžių kredito unijų segmentus

Autoriaus skaičiavimai.

Santrumpos: NA – neatsakyta; DPD – vėlavimo dienomis skaičius; Big market – didelė tikslinė rinka; Average market – vidutinio dydžio tikslinė rinka; Small market – mažo dydžio tikslinė rinka.

Anderson (2007) teigia, kad „blogas“ skolininko apibrėžimas yra rizikos tolerancijos požymis. Iš pateiktų paveikslų (31–32 pav.) matyti kredito unijų nehomogeniškumas kredito rizikos tolerancijos atžvilgiu. Kredito unijos, veikiančios mažose ir vidutinio tikslinio dydžio rinkose, linkusios toleruoti ilgesnius vėlavimo pradelsimus labiau, nei unijos, veikiančios didelėse rinkose. Matyti ir tai, jog kai kurios kredito unijos teigia toleruosiančios ilgesnius nei 180 d. mokėjimų vėlavimus. Tokį požiūrį šie respondentai argumentavo tuo, kad veidamos mažose rinkose (dažniausiai mažose gyvenvietėse ar bendruomenėse), jos atlieka ir socialinę funkciją siekdamos mažinti finansinę narių atskirtį bei taiko socialinės kontrolės elementą vertindamos bei valdydamos kredito riziką. Pažymėtina, kad mokslinėje literatūroje kredito unijų gebėjimas atlikti socialinę funkciją mažinant narių finansinę atskirtį vertinamas rezervuotai (Jones, 2008; Richardson ir Lennon, 2001). Jones (2008) rašo, kad kai kurios kredito unijos žemas pajamas gaunančius asmenis


pasirenka kaip tikslinį segmentą ne dėl socialinių savipagalbos paskatų, o dėl nerealių verslo prielaidų ir vadybos įgūdžių trūkumo.

Apibendrinant atliktą analizę galima teigti, kad daugiausiai respondentų (38 %) laiko 90 dienų mokėjimo vėlavimą pagrindiniu „blogos“ paskolos požymiu. Toks „blogos“ skolininko apibrėžimas sutampa su dažniausiai mokslinėje ir profesinėje literatūroje naudojamu apibrėžimu, ES teisės aktais ir Bazelio bankų priežiūros komiteto rekomendacijomis (plačiau šis klausimas analizuotas 1.2.2. poskyryje). Kiek mažiau respondentų (34 %) toleruoja vėlavimą iki 60 dienų, o 17 % – iki 30 dienų. Tik 7 % respondentų, apibrėždamos „blogas“ paskolas, pasitelkė LR teisės aktuose nurodytą neveiksnių paskolų kriterijų – 180 d. Tyrimas taip pat parodė, kad kredito unijos, veikiančios mažose ir vidutinio dydžio rinkose, yra linkusios toleruoti ilgesnius vėlavimo pradelsimus, nei unijos, veikiančios didelėse rinkose. Atsižvelgus į tai, kad tiriamas kredito unijų segmentas pasirodė esąs nehomogeniškas, jo dalyvių veikla pasižymi specifiškumu, bei tai, jog apklausti respondentai laikėsi skirtingų požiūrių į „blogos“ skolininko apibrėžimą, papildomas tyrimas vertintinas kaip teisingas nustatant priklausomo kintamojo apibrėžimą statistiniais metodais, aptartais šio darbo 1.2. skyriuje.

3.2. Statistinis įmonių kredito rizikos vertinimo modelis Lietuvos kredito unijoms

3.2.1. Modelio kūrimo imties sudarymas

Priklausomo kintamojo apibrėžimas formuojant modelio kūrimo imtį. Siekiant kiekybiškai nustatyti „blogos“ skolininko apibrėžimą, tyrimui pasitelkti Lietuvos Centrinės kredito unijos verslo paskolų portfelio duomenys nuo 2010 sausio 1 d. iki 2015 rugsėjo 12 d., iš viso – 1955 paskolų mėnesinė gražinimo istorija. Pirmiausia, suformavus skirtingais mėnesiais suteiktų paskolų kohortas, pavaizduoti bent kartą suvėlavusių paskolų rodikliai, išskiriant 30, 60, 90, 120 ir 180 dienų vėlavimus (33 pav.). Siekiant perteikti pilnesnį paskolų brandos ciklą paveikslą, imtas ketverių metų laikotarpis.




33 pav. Vidutiniai mokėjimų pradelsimai skirtingais paskolų brandos etapais Lietuvos kredito unių sektoriuje

Autoriaus skaičiavimai.

Ever DPD ratio – mokėjimo vėlavimo (bent vieną kartą) rodiklis; Month on book – laikotarpis nuo paskolos suteikimo.

Paveiksle (33 pav.) atskleistas paskolų brandos ciklas –matyti laikotarpiai, kuriais apskaičiuotų mokėjimų vėlavimo rodiklių kreivės turi aiškiai išreikštą augimo potencialą. Pasitelkus šią grafinę informaciją, ekspertiniu būdu nustatomas stebėjimo laikotarpis. Šiuo atveju, autoriaus nuomone, tikslinga jį nustatyti ties 25 mėn. (34 pav.). Pažymėtina, kad mokslinėje literatūroje (Choy, Laik, 2009; Anderson, 2007; Siddiqi, 2006), taikant kohortų metodą, pasirenkami nevienodi pradelsimų rodikliai, dažniausiai 30, 60 arba 90 dienų vėlavimo rodikliai. Šiame tyrime, pavaizdavus penkis skirtingus pradelsimų rodiklius, autorius pasirinko 30 dienų vėlavimo rodiklį kaip pavyzdį, tačiau, kaip matyti iš paveikslo, pasirinkus kitus rodiklius, rezultatas skirtųsi nežymiai⁴⁹. Toliau tyrime, atsižvelgus į modelio kūrimo imties informacinę struktūrą, nustatytas stebėjimo laikotarpis yra suapvalintas iki 24 mėn., t. y. dviejų metų.

⁴⁹ Šio tyrimo kontekste 120 ir 180 dienų vėlavimo rodiklių kreivės pateiktos dėl informatyvumo, siekiant parodyti bendrą kredito unių portfelio ODF – 10 %. Atsižvelgus į galiojantį reguliavimą, juo gali būti laikomas 180 d. vėlavimo rodiklis. Jis reiškia, kad 10 % juridiniams asmenims suteiktų paskolų bent kartą per 48 mėn. nuo paskolos suteikimo dienos vėlavo sumokėti paskolos įmoką 180 d.



34 pav. Optimalaus stebėjimo ir imties formavimo laikotarpių nustatymas pagal vidutinį 30 dienų vėlavimo rodiklį

Sudaryta autoriaus.

Nustačius optimalų stebėjimo laikotarpį, tolimesniam tyrimui pasirinktas metinis migracijos laikotarpis. Į tyrimą įtrauktos tik tos paskolos, kurių trukmė nuo paskolos suteikimo buvo ne trumpesnė, nei nustatytas optimalus stebėjimo laikotarpis (24 mėn.). Šio tyrimo atveju tokios paskolos tyrimo imtyje sudarė 1383 paskolas. Atliekant tyrimą, vertintas kiekvienos paskolos pasiektas didžiausias mokėjimo pradelimas pirmaisiais ir antraisiais metais. Sudaryta Markovo migracijų tikimybių matrica (15 lentelė):

15 lentelė. Migracijų tikimybių matrica

	Vėlavimo nėra	30+ DPD	60+ DPD	90+ DPD	120+ DPD	Paskola nurašoma
Vėlavimo nėra	92,1 %	4,1 %	1,1 %	0,9 %	1,3 %	0,4 %
30+ DPD	36,8 %	21,5 %	16,0 %	8,3 %	9,7 %	7,6 %
60+ DPD	27,1 %	6,8 %	15,3 %	20,3 %	17,0 %	13,6 %
90+ DPD	28,6 %	2,4 %	2,4 %	7,1 %	33,3 %	26,2 %
120+ DPD	36,1 %	0,0 %	0,0 %	0,0 %	13,9 %	50,0 %
Paskola nurašoma						100 %

Autoriaus skaičiavimai.

Santrumpos: DPD – *days past due*.

Suformavus Markovo migracijų tikimybių matricą, matyti, kad paskolos, kurios per pirmuosius metus pasiekia 60 ir daugiau dienų vėlavimą, turi 15,3 % tikimybę likti toje pačioje būsenoje ir 50,9 % tikimybę migruoti į blogesnes būsenas, taip pat ir 13,6 % tikimybę, jog paskola virs neveiksnia. 30 ir daugiau dienų per pirmus metus vėlavusios paskolos turi 41,7 % tikimybę migruoti į blogesnes grupes, taip pat ir 7,6 % tikimybę tapti nuostolingomis. Autoriaus nuomone, šio tyrimo kontekste formuojant modelį „blogos“ paskolos apibrėžimu galėtų būti laikomas tiek 60, tiek ir 90 dienų vėlavimas. Gautus tyrimo rezultatus palyginus su naujausių mokslinių tyrimų rezultatais (5 lent.), matyti, kad 60 dienų vėlavimas retai pasirenkamas kaip pagrindinis „blogos“ paskolos indikatorius ir įprastai toks trumpas vėlavimo laikotarpis nelaikomas reikšmingu (Finlay, 2012). Gautus rezultatus palyginus su kredito unijų apklausos rezultatais, matyti, kad kiekybiniu ir ekspertiniu būdu nustatomi „blogo“ skolininko apibrėžimai ženkliai skiriasi: tik 17 % respondentų nurodė 30 dienų vėlavimą kaip maksimaliai toleruotiną, o 45 % respondentų nurodė 90 ir daugiau vėlavimo dienų pradelsimus, kaip pagrindinį „blogos“ paskolos požymį. Siekiant, kad sudarytas modelis kuo labiau atitiktų apklausos metu nustatytą ekspertinį „blogos“ paskolos apibrėžimą kredito unijų sektoriuje, disertacijos autorius kaip pagrindinį „blogos“ paskolos požymį nutarė naudoti 24 mėn. stebėjimo laikotarpį ir 90 dienų mokėjimo pradelsimą.

Nors atliktas tyrimas parodė, kad geriausiai „blogą“ skolininką apibrėžia 90 d. mokėjimo pradelsimas, tačiau analizuojant turimą įmonių imtį atliktos korekcijos. Pirma, buvo papildytas „blogos“ įmonės apibrėžimas. Pastebėta, jog imtyje svari įrašų dalis apie ilgesnių nei 90 dienų vėlavimus gali būti nereikšmingi⁵⁰. Priklausomas kintamasis, kuriuo buvo papildyta pradinė tyrimo imtis, suformuotas pagal šį apibrėžimą:

„Blogu“ skolininku laikoma įmonė, kuri per 24 mėnesių stebėjimo laikotarpį bankrutavo arba kuriam nors kreditoriui (pagal turimus duomenis) vėlavo sumokėti ilgiau nei 90 kalendorinių dienų. Toks priklausomo kintamojo

⁵⁰ Pavyzdžiui, autoriaus nuomone, nereikšmingu gali būti laikomas įrašas apie 2000 dienų vėlavimą sumokėti 30 Eur. Tikėtina, jog toks įrašas yra techninė klaida.

apibrėžimas atitinka galiojančius ES ir LR teisės aktus bei Bazelio dokumentų reikalavimus.

Modelio sudarymo ir testavimo imčių formavimas. Šiame disertacinio tyrimo poskyryje siekiama dviejų tikslų. *Pirma*, iš pradinių tyrimo duomenų suformuoti modelio kūrimo, sudarymo ir testavimo imtis. *Antra*, siekiama preliminariai patikrinti H3 hipotezę, kad reikšminga įmonių dalis, kurioms kredito unių suteiktos paskolos tampa neveiksniomis, nebankrutuoja.

Kaip minėta 3.1.4 poskyryje, remiantis LR Kredito unių įstatymu (Žin., 2008, Nr. 76-3003), buvo atlikta Lietuvos kredito unių apklausa. Atsižvelgus į maksimalią galimą vienos paskolos sumą, kurią kredito unijos gali suteikti vienam nariui, galima motyvuotai teigti, kad Lietuvoje veikiančios kredito unijos, finansuodamos juridinius asmenis, labiausiai orientuojasi į mažas ir labai mažas įmones. Šio tyrimo kontekste mažos ir labai mažos įmonės suprantamos taip, kaip jos yra apibrėžtos LR Smulkiojo ir vidutinio verslo plėtros įstatyme (1998, Nr. 109-2993). Atsižvelgus į tyrimo rezultatus, siekiant sukurti įmonių kredito rizikos vertinimo modelį, atitinkantį Lietuvos kredito unių tikslinį kreditavimo segmentą, buvo sudaryta tyrimo imtis⁵¹. Į imtį atrinktos įmonės, atitinkančios bent vieną iš šių sąlygų:

- balansinio turto vertė neviršija 5 mln. Eur;
- metinėje pelno (nuostolių) ataskaitoje pajamos neviršija 7 mln. Eur;
- pašalintos įmonės, kuriose analizuojamu laikotarpiu dirbo 50 ir daugiau darbuotojų;
- pašalintos valstybės ir savivaldybių įmonės.

Siekiant, kad imtis būtų suformuota tik iš realių ūkinę-komercinę veiklą vykdančių įmonių, iš imties pašalintos tos įmonės, kurios atitiko bent vieną iš šių kriterijų:

- pagal VSDF duomenis, įmonėje dirba du ar mažiau darbuotojų;
- metinės pardavimo pajamos nesiekia 10000 Eur;
- balansinio turto vertė nesiekia 5000 Eur.

⁵¹ Disertacijos autorius dėkoja UAB „Creditinfo Lietuva“ darbuotojams už suteiktą mažų ir labai mažų įmonių statistinę imtį. Be suteiktų duomenų šio tyrimo nebūtų buvę įmanoma atlikti.

Analizuojamu laikotarpiu Lietuvoje veikė 28580 šiuos kriterijus atitinkančių įmonių⁵². Šiam tyrimui atsitiktinės atrankos būdu sudaryta imtis apėmė finansinius ir nefinansinius įmonių 2010–2012 metų laikotarpio duomenis, iš viso tyrimo imtį sudarė 2150 įrašų ir 65 kintamieji. Finansiniai duomenys apėmė įmonių balanso ir pelno (nuostolių) ataskaitų straipsnių duomenis, nefinansiniai – duomenis apie įmonėms taikytus turto areštus, kredito istoriją, darbuotojų skaičių.

Siekiant iš tyrimo duomenų pašalinti netikslius ir tikrovės neatitinkančius duomenis, iš imties išimti tų įmonių įrašai, kurių finansiniai duomenys atitiko bent vieną iš kriterijų:


- finansinių ataskaitų duomenys neatitinko pagrindinių apskaitos principų;
- balanse nurodyto turto vertė arba pelno (nuostolių) ataskaitoje nurodytos pardavimo pajamos turėjo neigiamas reikšmes;
- nepateikti privalomi finansiniai duomenys (pvz., turtas arba pardavimo pajamos).

Pašalinus šiuos kriterijus atitinkančias įmones, imtyje liko 1799 įrašai.

Nepriklausomų kintamųjų rinkinys suformuotas iš pradinių įmonių duomenų. Iš imtyje esančių finansinių duomenų apskaičiuoti 53 finansiniai rodikliai, dažniausiai naudojami kredito rizikos vertinimo srityje. Pradiniai nefinansinius duomenis aprašantys kintamieji transformuoti: pavertus šiuos rodiklius kategoriniais, išvesti nauji pseudokintamieji, kuriais papildyta turima imtis. Šią transformaciją nutarta atlikti ekspertiniu būdu. Iš viso išskirti 65 nepriklausomi kintamieji. Kintamiesiems priskirti pavadinimų trumpiniai ir jų įtraukimo į galutinį modelį eiliškumas bei kriterijai pateikti 3 priede.

Koreguotas „geros“ įmonės apibrėžimas. Pradinė modelio kūrimo imtis susidėjo iš 1799 įmonių, iš jų 650 (atitinka 20 pav., B1) per 24 mėn. stebėjimo laikotarpį bankrutavo arba tapo bankrutuojančios, o 48 (atitinka 20 pav., B2-B1) turėjo reikšmingų įsiskolinimų. Atitinkamai, įmonių, neatitikusių B2 kriterijų, imtis sudarė 1101 įmonių (atitinka 20 pav., G2).

⁵² UAB „Creditinfo Lietuva“ duomenys.



35 pav. Modelio kūrimo, sudarymo ir testavimo imčių formavimo eiga

Sudaryta autoriaus.

G2 apibrėžimas atitiktų klasikinį „geros“ įmonės apibrėžimą sudarant imtį. Tačiau atlikus papildomą įmonių veiklos testavimo patikrinimą ir laikantis autoriaus pasiūlyto papildomos patikros algoritmo (žr. 19 pav.) 2016 m., paaiškėjo, kad daug G2 įmonių imties neturėtų būti laikoma „geromis“, nes 34 % tokiomis laikytų įmonių veiklos nevykdė, turėjo reikšmingų įsiskolinimų VSDf arba kitų veiklos sutrikimų. Šie tyrimo duomenys leidžia teigti, jog tikėtina, kad iškelta H3 hipotezė yra teisinga. Todėl šiame tyrimo etape, preliminarus hipotezės patikrinimo metu ji nėra atmetama ir bus pakartotinai tikrinama modelio grįžtamojo patikrinimo imtyje, kai bus priimamas galutinis sprendimas dėl jos patvirtinimo ar atmetimo.

35 paveiksle pavaizduoti skirtingi galimi „blogų“ ir „gerų“ įmonių apibrėžimo nustatymo būdai, kurie gali būti taikomi sudarant modelius

skirtingiems tiksliniams segmentams, atsižvelgiant į segmento specifiškumą, turimus duomenis ir modeliujamo homogeninio segmento ypatumus. Toliau šiame tyrime „blogomis“ laikomos B2 o „geromis“ – G4 kriterijus atitinkančios įmonės. Iš tolimesnio tyrimo pašalintos įmonės, neatitikusios B2 ir G4 kriterijų, t. y. 2015 metais nevykdžiusios veiklos, turėjusios įsiskolinimų VSDF bei įmonės, kurios nebuvo priskirtos nei prie vienos iš grupių.

Iš tyrimo pašalintos ir įmonės, 2010 m. atitikusios „blogos“ įmonės apibrėžimą⁵³. Likusią imtį sudarė 1252 įmonės, iš kurių 525 buvo „blogos“ ir 727 „geros“. Ši imtis toliau tyrime naudota vertinant ir atrenkant nepriklausomus kintamuosius bei nustatant jų įtakos svorius (WOE). Atsitiktine tvarka padalijus šią tyrimo imtį, gautos modelio sudarymo ir testavimo imtys. Nutarta daugumą „blogų“ įmonių (275 įrašai) skirti testavimui, o likusias (250 įrašų) – modelio sudarymo imčiai formuoti; 352 „geras“ įmones skirti modelio testavimo, o likusias 375 „geras“ – formuoti modelio sudarymo imtį. Taip buvo gauta modelio sudarymo imtis, susidedanti iš 625 įmonių, ir modelio testavimo imtis, susidedanti iš 627 įmonių (35 pav.).

Kaip rekomenduojama mokslinėje literatūroje, suformuotoje modelio sudarymo imtyje nei viena iš priklausomo kintamojo reikšmių nėra vyraujanti, o prognozuojamo įvykio požymių atitinkančių įrašų kiekis sudarė 40 % ir gali būti laikoma pakankamu (Čekanavičius, 2011). Apskaičiuota, kad suformuota modelio sudarymo imtis leidžia prognozuoti PD su 95 % tikimybe ir 7 % paklaida.

3.2.2. Kintamųjų atranka ir statistinio modelio sudarymas

Šiame disertacinio tyrimo poskyryje logistinės regresijos pagrindu sudaromas statistinis kredito rizikos vertinimo modelis. Pirmiausia, laikantis metodinėje dalyje pristatyto eiliškumo, pasirenkamas modelyje naudotinas klasifikatorius. Antra, atrenkami nepriklausomi kintamieji. Trečia, sudaromas modelis. Ketvirta, atliekamas išankstinis modelio įvertinimas.

⁵³ Pritariant logikai, kad įmonė jau analizės metu atitinka suformuotą „blogos“ paskolos apibrėžimą, nėra būtina skaičiuoti tikimybės, kad ji taps „bloga“ per ateinančius dvejus metus.

Modelio klasifikatoriaus pasirinkimas. Pirmiausia, pasirinkus klasifikatorių, formuojamas bendras reikalavimų modeliui sąvadas. Reikalavimai į sąvadą atrenkami atsižvelgus į kredito unijų kreditavimo politikos tyrimo (atliktas KU apklausos metu), klasifikavimo metodų taikymo dažnumo ir tikslumo tyrimo rezultatus bei į svarbiausius reguliacinius reikalavimus taikant kredito rizikos vetinimo modelius. Taigi, atsižvelgus į minėtus veiksnius, šis sąvadas suformuotas iš keturių pagrindinių reikalavimų, keliamų modelio charakteristikoms (16 lent.).

16 lentelė. Kuriamam modeliui keliamų reikalavimų sąvadas

Nr.	Reikalavimas	Reikalavimo pagrindimas
1.	Modelis turi pasižymėti aukšta diskriminacine galia, AUC rodiklis neturėtų būti žemesnis nei 75.	KU sektoriaus apklausos metu nustatyta, kad modelio tikslumą respondentai traktuoja kaip svarbiausią modelio charakteristiką. Minimalus AUC nustatytas atsižvelgus į atliktą modelių klasifikatorių tikslumo ir taikymo dažnumo analizę (plačiau žr. 23 pav.).
2.	Aukštas modelio rezultatų paaiškinamumas.	Pirma, KU sektoriaus apklausos metu nustatyta, kad modelio rezultato paaiškinamumas yra vienas svarbiausių respondentų įvardytų modelio charakteristikų. Antra, Bazelio bankų priežiūros komitetas rekomenduoja taikyti statistinius modelius, kurių veikimas gali būti detalai paaiškintas ir dokumentuotas (BCBS, 2004, p. 410).
3.	Modelio taikymas, periodinis patikrinimas, kalibravimas ir modelio rezultatų interpretavimas neturėtų būti susijęs su statistikos ir informacinių technologijų sričių specialių žinių poreikiu.	KU sektoriaus apklausos metu nustatyta, kad kredito unijų ŽTF ištekliai, skirti kurti, palaikyti ir taikyti kredito rizikos vertinimo modelį, yra itin riboti. Respondentai pažymėjo, kad itin stokojama žmoniškųjų išteklių bei kompetencijų statistikos ir informacinių technologijų srityse (plačiau žr. 3.1.3 poskyrį).
4.	Modelis turi būti tikimybinis, t. y. modelio atsakymas turi būti PD – tikimybė, kad skolininkas taps nemokus per nustatytą laiko tarpą.	Statistinius metodus rekomenduojama taikyti ir Bazelio bankų priežiūros komiteto rekomendaciniuose dokumentuose. Paskolų ir portfelio nemokumo tikimybė (PD) yra vienas svarbiausių rodiklių, kurį rekomenduojama skaičiuoti bankininkystės veikloje (BCBS, 2004).

Sudaryta autoriaus.

Galimų naudoti klasifikatorių tipai nustatyti atlikus išsamią mokslinės ir profesinės literatūros analizę, kurios metu įvertintas 21 klasifikatoriaus tipo

taikymo dažnis ir tikslumas (22–23 pav.). Vertintos visų analizuotų klasifikatorių taikymo galimybės kuriant modelį. Klasifikatoriaus pasirinkimas vykdytas keliais etapais. *Pirma*, vertintas vidutinis klasifikatorių tikslumas (23 pav.). Nustatyta, kad analizuotų metodų vidutinis tikslumas atitiko nustatytą minimalų tikslumo reikalavimą (16 lent., nr. 1). *Antra*, dėl ribotų rezultato interpretacijos galimybių (neatitiko reguliacinių reikalavimų ir KU kreditavimo politikos, 16 lent., nr. 2) iš tolimesnio tyrimo pašalinti dirbtinio intelekto metodai: dirbtiniai neuronų tinklų, genetinio programavimo, sprendimų medžių, atraminių vektorių ir ansamblinio mokymo tipo klasifikavimo metodai. *Trečia*, dėl reto naudojimo mokslinėje ir profesinėje literatūroje bei dėl modelio taikymo, modifikavimo ir kalibravimo sudėtingumo (atsižvelgus į itin ribotus kredito unijų ŽTF resursus, 16 lent., nr. 3) iš tolimesnės atrankos pašalinti: NB, PR, CR, MARS, RLR ir LLR klasifikatoriai⁵⁴. *Ketvirta*, pašalinti diskriminantiniai klasifikavimo metodai siekiant palikti tik nemokumo tikimybę nustatančius klasifikavimo metodus (16 lent., nr. 4). Pažymėtina, kad diskriminantiniai klasifikavimo metodai taip pat atmestini dėl jų reiklumo duomenų normalumui (Čekanavičius, 2011). Taigi, į tarpinių pasirinkimų sąvadą įtraukta logistinė regresija (LR) ir artimiausio kaimyno metodas (KNN).

Iš šių dviejų metodų pasirinkta logistinė regresija dėl didesnio jos tikslumo, kuris įvertintas atsižvelgus į atliktą išsamią mokslinės ir praktinės literatūros analizę (žr. 23 pav.).


Nepriklausomų kintamųjų atranka ir logistinės regresijos modelio sudarymas. Į modelį įtraukiamų nepriklausomų kintamųjų atranka atlikta iš metodinėje šio darbo dalyje suformuoto galimų naudoti nepriklausomų kintamųjų sąvado bei laikantis šio disertacinio tyrimo metodinėje dalyje pristatyto ir pagrįsto eiliškumo bei atrankos metodų (plačiau žr. 2.2.2 poskyrį). Skaičiavimai atlikti naudojant R atviro kodo programinės įrangos paketą (R Core Team, 2015). Programavimo (R) kodas pateiktas šio darbo 5 priede. Visi analizuoti nepriklausomi kintamieji, jiems priskirti sutrumpinti pavadinimai bei

⁵⁴ Santrumpų paaiškinimus žr. darbo pradžioje.

atrankos metu atlikti detalūs skaičiavimo rezultatai yra pateikti šio darbo 4 priede.

Pirma, pašalinti kintamieji, turintys tiesioginį ryšį su priklausomu kintamuoju. Iš viso šiame etape iš imties pašalinti 4 kintamieji. *Antra*, atlikta trūkstamų reikšmių analizė. Šiame analizės etape pašalinti 7 kintamieji (žr. 4 priedą).

Trečia, atlikta nepriklausomų kintamųjų individualios diskriminacinės galios analizė. Analizė atlikta kiekvienam kintamajam apskaičiuojant IV rodiklį pagal (1-2) formulę (Bolton, 2009). Analizės rezultatai pateikti 36 paveiksle perteikiant IV tyrimo rezultatą. Paveiksle esančio grafiko abscisės ašyje (x) pateikti analizuojami nepriklausomi kintamieji, ordinatės (y) – jų apskaičiuotas IV rodiklis.



36 pav. Individualios diskriminacinės rodiklių galios analizės rezultatai taikant IV metodą

Autoriaus skaičiavimai.

Analizuotų nepriklausomų kintamųjų santrumpų reikšmės pateiktos 4 priede.

Paveiksle (36 pav.) rodikliai surikiuoti nuo turinčio stipriausią diskriminacinę galią iki silpniausio. Tamsesnė mėlyna spalva žymima didesnė IV reikšmė, šviesesnė – mažesnė. Matyti, kad didžiausią diskriminacinę galią turi turto struktūros rodikliai, analizuojantys skolinto ir nuosavo kapitalo

santykį. Testas parodė, kad iš analizuotų rodiklių 4 pasižymi įtartinai stipria diskriminacine galia, 23 – labai stipria, 13 – stipria, 3 vidutine ir 11 – silpna diskriminacine galia. Nors nefinansinių rodiklių $IV < 0,3$, t. y. rodikliai, pasirodę esantys silpnos diskriminacinės galios; tačiau iš tolimesnio proceso nutarta pašalinti tik vieną nefinansinį rodiklį – užklausų skaičių. Iš viso šiame analizės etape iš tolimesnio tyrimo pašalinta 11 rodiklių, tolimesnei analizei pasirinkti 43 rodikliai (3 priedas).

Ketvirta, sudaryta koreliacinė matrica (37 pav.).

	GP_TA	CL_CA_TA	TL_TA	EBIT_TA	NP_TA	EBT_TA	S_TA	NSSK_KAT	NSVVT_KAT	NP_EQ	EBT_EQ	NSSUM_KAT	PSSK_KAT	PSVVT_KAT	EBT_EQ_CL	PSSUM_KAT	CL_S	EQ_S	WC_EQ	CA_EQ	AR_TL_CA	CL_TL_CA	EQ_EQ_LTL	CUA_INV_CL	CUA_TL_CA	CA_INV_CL	LTA_EQ	AR_TL	EBIT_S	NP_S	EBT_S	WC_S	EQ_TL	CUA_TL	CA_TL	CA_CL	EBIT_CL	A	CA_TA	RE_TA	EQ_TA	WC_TA									
GP_TA	1	1	1	0.67	0.66	0.66	0.45	0.03	0.03	0.04	0.03	0.02	0.02	0.01	0.03	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.02	-0.04	-0.01	-0.07	-1	-1							
CL_CA_TA	1	1	1	0.64	0.64	0.64	0.47	0.04	0.03	0.03	0.02	0.02	0.02	0.02	0.03	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.02	-0.04	0	-0.09	-1	-1					
TL_TA	1	1	1	0.64	0.64	0.64	0.47	0.04	0.04	0.03	0.03	0.02	0.02	0.02	0.03	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.02	-0.04	0	-0.09	-1	-1				
EBIT_TA	0.67	0.64	0.64	1	1	1	-0.37	0.02	0.02	0.04	0.04	0.02	0.03	0.03	0.03	0.04	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0	0	0.01	0	0	0	0	0	0	0	-0.02	-0.04	-0.15	0.11	-0.64	-0.64				
NP_TA	0.66	0.64	0.64	1	1	1	-0.37	0.02	0.02	0.04	0.04	0.02	0.03	0.03	0.03	0.04	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0	0	0.01	0	0	0	0	0	0	0	0	-0.02	-0.04	-0.15	0.11	-0.64	-0.64			
EBT_TA	0.66	0.64	0.64	1	1	1	-0.37	0.02	0.02	0.04	0.04	0.02	0.03	0.03	0.03	0.04	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0	0	0	0	0.01	0	0	0	0	0	0	0	0	0	-0.02	-0.04	-0.15	0.11	-0.64	-0.64		
S_TA	0.45	0.47	0.47	-0.37	-0.37	-0.37	1	0.01	0.01	-0.01	-0.01	0	-0.02	-0.02	-0.01	-0.04	0	0	0	0	0	0	0	0	0	0	0	-0.01	0	0	0	0	0	-0.01	-0.01	0	0	0	0	-0.01	0.17	-0.96	-0.47	-0.47							
NSSK_KAT	0.03	0.04	0.04	0.02	0.02	0.02	0.01	1	0.81	0	0	0.67	0.4	0.35	0.04	0.38	0.02	0.01	0.06	-0.09	-0.01	-0.02	-0.03	-0.01	-0.03	0	-0.03	0.01	-0.08	-0.02	-0.03	-0.03	-0.02	-0.08	-0.07	-0.07	-0.07	-0.03	0.27	-0.1	-0.02	-0.04	-0.03								
NSVVT_KAT	0.03	0.03	0.04	0.02	0.02	0.02	0.01	0.81	1	0	-0.01	0.67	0.32	0.4	0.05	0.33	0.04	0.02	0.05	-0.04	-0.03	-0.03	-0.03	0	-0.05	0	-0.01	-0.01	-0.07	-0.04	-0.04	-0.04	-0.04	-0.07	-0.07	-0.06	-0.06	-0.04	0.21	-0.06	-0.02	-0.03	-0.03								
NP_EQ	0.04	0.03	0.03	0.04	0.04	0.04	-0.01	0	0	1	1	0.04	0	0	0.01	0.02	0	0	0	0	0.13	0	0	0	0	0	0	-0.23	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.03	-0.02	0	-0.03	-0.03					
EBT_EQ	0.03	0.03	0.03	0.04	0.04	0.04	-0.01	0	-0.01	1	1	0.04	0	0	0.01	0.02	0	0	-0.02	0.14	0	0	0	0	0	0	0	-0.22	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.03	-0.02	0	-0.03	-0.03					
NSSUM_KAT	0.02	0.02	0.02	0.02	0.02	0.02	0	0.67	0.67	0.04	0.04	1	0.37	0.33	0.01	0.45	0.03	0.01	0.04	-0.04	0	-0.02	-0.02	-0.02	-0.05	0	-0.03	-0.02	-0.07	-0.03	-0.04	-0.04	-0.03	-0.06	-0.06	-0.06	-0.06	-0.01	0.28	-0.12	-0.01	-0.02	-0.02								
PSSK_KAT	0.02	0.02	0.02	0.03	0.03	0.03	-0.02	0.4	0.32	0	0	0.37	1	0.42	1	0.05	0.42	0.05	0.04	0.02	-0.05	0	-0.01	0.01	-0.04	-0.04	-0.03	-0.06	-0.05	-0.05	-0.05	-0.08	-0.07	-0.07	-0.07	-0.09	0.09	0	0.34	-0.21	0.01	-0.02	-0.02								
PSVVT_KAT	0.01	0.02	0.02	0.03	0.03	0.03	-0.02	0.35	0.4	0	0	0.33	0.42	1	0.05	0.42	0.05	0.04	0	-0.05	0.02	0.05	0.05	0.05	0.02	-0.02	-0.06	0.01	-0.07	-0.05	-0.05	-0.05	-0.08	-0.07	-0.07	-0.07	0.02	0.25	-0.1	0.01	-0.02	-0.02									
EBT_EQ_CL	0.03	0.03	0.03	0.03	0.03	0.03	-0.01	0.04	0.05	0.01	0.01	0.01	0	0.05	1	-0.02	0	0	0	0.01	0.01	0.03	0	0	0.02	0.01	-0.01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.01	0.03	0	-0.03	-0.03					
PSSUM_KAT	0	0	0	0.04	0.04	0.04	-0.04	0.38	0.33	0.02	0.02	0.45	0.81	0.42	-0.02	1	0.04	0.03	0.01	-0.03	0.02	-0.01	-0.01	-0.05	-0.02	-0.04	-0.06	0.02	-0.06	-0.04	-0.04	-0.04	-0.06	-0.06	-0.09	-0.09	0	0.34	-0.24	0.03	0	0	0								
CL_S	0	0	0	0	0	0	0	0.02	0.04	0	0	0.03	0.05	0.05	0	0.04	1	0.37	-0.01	0	0	0	0	0	0	0	0	-0.01	-1	-1	-1	-1	0	0	0	0	0	0	0	-0.02	-0.02	0	0	0							
EQ_S	0	0	0	0	0	0	0	0.01	0.02	0	0	0.01	0.04	0.04	0	0.03	0.37	1	-0.01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0.01	-0,03	-0,01	0	0						
WC_EQ	0	0	0	0	0	0	0	0.06	0,05	0	0	-0,02	0,04	0,02	0	0	0,01	-0,01	-0,01	1	-0,05	0	0	0	0	0	0	0	0,02	0	-0,33	0,01	0,01	0,01	0,01	0	0	0	0	0	0	0	-0,04	-0,02	0	0					
CA_EQ	0	0	0	0	0	0	0	-0,09	-0,04	0,13	0,14	-0,04	-0,05	-0,05	0,01	-0,03	0	-0,05	1	0	0	0,02	0	0	0,01	0	0,01	0,08	0,01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0,06	-0,06	0	0				
AR_TL_CA	0	0	0	0	0	0	0	-0,01	-0,03	0	0	0	0,02	0,01	0,02	0	0	0	0	1	0,09	0	-0,02	0,42	0,02	-0,02	0	-0,11	0	0	0	0	0	0	0	0	0	0	0	0	0	-0,05	-0,05	-0,01	-0,01	-0,03	-0,02	0	0		
CL_TL_CA	0	0	0	0	0	0	0	-0,02	-0,03	0	0	-0,02	-0,01	0,05	0,03	-0,01	0	0	0	0,02	0,09	1	0	-0,01	0,67	0	-0,01	0	-0,02	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-0,01	-0,01	0	0	0		
EQ_EQ_LTL	0	0	0	0	0	0	0	-0,03	-0,03	0	0	-0,02	0,01	0,05	0	-0,01	0	0	0	0	0	0	1	0	0	0	0	0	0,02	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0			
CUA_INV_CL	0	0	0	0	0	0	0	-0,01	0	0	0	-0,02	-0,04	-0,05	0	-0,05	0,01	0	0	0	-0,02	-0,01	1	-0,03	0,1	0,95	0	0,21	0	0	0	0	0,01	0,35	0,35	0,35	0,36	-0,84	0,01	0,06	0	0	0	0	0	0	0				
CUA_TL_CA	0	0	0	0	0	0	0	-0,03	-0,05	0	0	-0,05	-0,04	0,02	0,02	-0,02	0	0	0	0,01	0,42	0,67	0	-0,03	1	0,04	-0,04	-0,04	0	0	0	0	-0,06	-0,07	0	0	0	0	0	0	0	-0,01	0,01	-0,01	0	0	0	0			
CA_INV_CL	0	0	0	0	0	0	0	0	0	0	0	0	-0,03	-0,02	0,01	-0,04	0	0,02	0	0,02	0	0	0	0,1	0,04	1	-0,08	0	0,11	0	0	0	0	0	0	0	0	0	0	0	0,27	0,27	-0,1	-0,03	0,19	0	0	0			
CUA_CL	0	0	0	0	0	0	0	-0,03	-0,01	0	0	-0,03	-0,06	-0,06	-0,01	-0,06	0,01	0	0,01	-0,02	-0,01	0	0,95	-0,04	-0,08	1	0	0,24	0	0	0	0,01	0,56	0,57	0,53	0,53	-0,67	0	0,06	0	0	0	0	0	0	0	0	0			
LTA_EQ	0	0	0	0	0	0	0	0,01	-0,01	-0,23	-0,22	-0,02	0,03	0,01	0	0,02	0	0,01	-0,33	0,08	0	0	0	0	0	0	0	0	0	0	0	0	0	-0,01	-0,01	-0,01	-0,01	0	0	0	0	0	0	0	0	0	0	0			
AR_TL	0	0	0	0.01	0.01	0.01	-0.01	-0.08	-0.07	0	0	-0.07	-0.06	-0.07	0	-0.06	-0.01	0	0.01	0.01	-0.11	-0.02	0.02	0.21	-0.04	0.11	0.24	-0.01	1	0.01	0.01	0.01	0.01	0.47	0.41	0.3	0.3	0.02	-0.06	0.07	0.01	0	0	0	0						
EBIT_S	0	0	0	0	0	0	0	-0.02	-0.04	0	0	-0.03	-0.05	-0.05	0	-0.04	-1	-0.97	0.01	0	0	0	0	0	0	0	0	0	0.01	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0				
NP_S	0	0	0	0	0	0	0	-0.03	-0.04	0	0	-0.04	-0.05	-0.05	0	-0.04	-1	-0.96	0.01	0	0	0	0	0	0	0	0	0	0.01	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0							

etapo pašalinti 22 rodikliai ir liko 21 kintamasis: 4 nefinansiniai ir 17 finansiniai (žr. 3 priedą).

Penkta, apskaičiuoti ir analizuoti kintamųjų WOE svoriai. Kiekvienam analizuotam nepriklausomam kintamajam apskaičiuoti WOE įtakos svoriai pagal (2-9) formulę (Bolton, 2009). Rodikliams priskirtų WOE reikšmių apskaičiavimo rezultatai bei tinkamumas naudoti sudarant modelį pateiktas 5 priede. Šiame etape pašalinti 6 nepriklausomi kintamieji. Tų kintamųjų, kuriuos nutarta palikti tolimesnei analizei, originalios reikšmės pakeistos apskaičiuotomis WOE reikšmėmis⁵⁵.

Šešta, taikyta šalinamoji regresija (angl. *backward stepwise regression*).

Septinta, apskaičiavus pasirinktų nepriklausomų kintamųjų koeficientus (17 lentelė) suformuotas logistinės regresijos modelis.

Pagal sudarytą modelį įmonių nemokumo tikimybė (PD) apskaičiuojama taip:

$$PD = \frac{1}{1 + e^{-z}} \quad (3-1)$$

$$z = -1,241 - 0,627 \cdot EQ_TA - 0,326 \cdot CA_EQ + 0,669 \cdot CUA_TL_CA - 0,229 \cdot WC_S - 0,679 \cdot NP_TA + n^* + k^{**} \quad (3-2)$$

* jei NSVVT > 4, n=0,885; jei ne – 0;

** jei A > 0, k=0,939; jei ne – 0.

Išankstinis modelio įvertinimas. Sudarius modelį, atliktas jo išankstinis įvertinimas.

1. Iš pateiktos lentelės (17 lent.) matyti, kad į modelį atrinkti finansiniai rodikliai padengia pagrindines finansines įmonių veiklos analizės sritis: ilgalaikio mokumo ir turto struktūros, trumpalaikio mokumo ir pelningumo. Modelio nefinansiniai rodikliai analizuoja kredito istoriją ir kitus svarbius

⁵⁵ Skaiciavimams naudoti R programinio paketo plėtiniai „WOE“ (Sudarson, 2015) ir „riv“ (Cohen-Freue ir kiti, 2015).

rizikos veiksnius. Galima sakyti, jog modelio regresoriai atitinka ekonominę logiką ir padengia pagrindines įmonių veiklos sritis, kurios turėtų būti analizuojamos nustatant nemokumo tikimybę.

17 lentelė. Atrinktų modelio kintamųjų ir jiems priskirtų koeficientų sąvadas

Ti- pas	Rodiklių grupė	Pilnas pavadinimas	Trumpinys	IV	Priskirtos koef. reikšmės	Galim. sant. (angl. <i>log odds</i>)	Voldo krit.	Regresorių ir jiems priskirtų koeficientų reikšmių įtakos nemokumo tikimybei paaiškinimas
Laisvasis narys			C	–	-1,241	0,29	<0,00 1	
Finansiniai rodikliai	Ilgalaikio mokumo rodikliai ir turto struktūros rodikliai	Nuosavas kapitalas / Turtas	EQ_TA	1,15	-0,627	0,53	<0,00 1	Didėjant nuosavo kapitalo daliai turte, PD mažėja.
		Pinigai ir pinigų ekvivalentai / Nuosavas kapitalas	CA_EQ	1,044	-0,326	0,72	0,017	Didėjant PPE daliai nuosavam kapitale, nemokumo tikimybė mažėja.
		Trumpalaikis turtas / (Mokėtinų sumų ir įsipareigojimų – Pinigai ir pinigų ekvivalentai)	CUA_TL_C A	0,333	0,669	1,95	0,05	Didėjant trumpalaikio turto ir įsipareigojimų santykiui, nemokumo tikimybė didėja.
	Trumpa- laikio mokumo rodikliai	Apyvartinis kapitalas / Pardavimo pajamos	WC_S	0,647	-0,229	0,8	0,07	Kuo didesnis apyvartinis kapitalas, tuo nemokumo tikimybė mažesnė.
	Pelnin- gumo rodikliai	Grynasis pelnas / Turtas	NP_TA	0,978	-0,679	0,51	<0,00 1	Kuo efektyviau ir pelningiau veikia įmonė, tuo mažesnis PD.
Nefinansiniai rodikliai	Kredito istorijos ir kiti rodikliai	Nesumokėtų skolų vidutinis vėlavimo terminas	NSVVT (II)*	0,054	0,885	2,42	<0,00 1	Kuo ilgiau nemokamos skolos, tuo didesnis PD.
		Galiojančių areštų kiekis	A (II)**	0,374	0,939	2,56	<0,00 1	Jei yra galiojančių turto areštų, PD didesnis.


Autoriaus skaičiavimai.

- Analizuojant *regresoriams priskirtų koeficientų reikšmes* galima matyti, ar jos atitinka ekonominę logiką. Esant teigiamam koeficientui, didėjant regresoriui, auga įvykio tikimybė ($Y=1$, šiuo atveju, kad įmonė taps nemoki), ir priešingai, jei koeficientas neigiamas, didėjant regresoriui, mažėja tikimybė, jog $Y=0$, t. y., kad įmonė išliks moki. Išanalizavus sudaryto modelio regresorių koeficientus bei įtakos svorius, matyti, kad jie atitinka ekonominę logiką (kiekvieno iš regresorių ir jiems priskirtų koeficientų įtaka nemokumo tikimybei paaiškinta 17 lentelėje).
- Galimybių santykis* (angl. *log odds*) – parodo, kaip pasikeis tikimybių santykis (galimybė), kai atitinkamas regresorius padidės vienetu fiksuojant

visų kitų regresorių reikšmes. Iš 17 lentelės matyti, kad visų regresorių galimybių santykiai rodo, jog regresoriai yra reikšmingi.

4. *Voldo testas regresoriams* parodo, ar į modelį įtraukti kintamieji yra statistiškai reikšmingi. Jei regresoriaus $p \geq 0,5$, toks regresorius laikomas statistiškai nereikšmingu ir šalinamas iš modelio. Iš įtrauktų į modelį 7 kintamųjų, 5-ių $p < 0,05$, vieno regresoriaus p koeficientas neženkliai didesnis, o dar vieno lygus 0,05 (žr. 17 lent.). Tačiau nutarta rodiklių iš modelio nešalinti dėl jų didelės individualios diskriminacinės galios bei siekiant, kad į modelį įtraukti kintamieji pilnai apibūdintų įmonės ekonominę būklę. Statistiniu požiūriu tokios išimtys laikomos priimtynomis (Čekanavičius, 2011).
5. Apskaičiuoti modelio *determinacijos (pseudo) koeficientas* $R^2 = 0,62$ bei *Aikakės kriterijus* $= 582$, leidžia teigti, kad modelis yra tinkamas duomenims.
6. Nubrėžta *gavėjų charakteristikų kreivė* (ROC) pavaizduota 38 paveiksle.
7. Pridedamas prognozuotų tikimybių grafikas (38 pav.) siekiant parodyti, kaip pasiskirstė apskaičiuotos „gerų“ ($Y=0$) ir „blogų“ ($Y=1$) įmonių tikimybės. Kadangi testavimo imtyje buvo 627 įmonės, grafiką nutarta pavaizduoti stačiakampių diagramų forma (23 pav.). Grafiko y ašyje rodomos siūlomo modelio apskaičiuotos įmonių nemokumo tikimybės. X ašis išskirsto analizuotas įmones pagal faktines jų būkles, atitinkamai 0 žymimos „geros“ įmonės ir 1 – „blogos“. Paveiksle esantys objektai parodo analizuotų (atitinkamai, „gerų“ ir „blogų“) įmonių pasiskirstymą pagal apskaičiuotas tikimybes. Vidurinė stačiakampių linija parodo vertintų įmonių PD medianą, stačiakampių kraštai atitinka kvartilius: apatinė stačiakampio kraštinė atitinka pirmojo kvartilio reikšmę, viršutinė – trečiojo. Nuo stačiakampių nueinančios linijos parodo kvartilinį ilgį. Visas likusias reikšmes galima laikyti išskirtimis. Grafikas atskleidžia, kad modelis leidžia teisingai klasifikuoti daugumą „gerų“ ir „blogų“ įmonių, tačiau pasitaiko ir klaidų.

8. Įvertinta sukurto modelio bendra diskriminacijos galia (neišskiriant lūžio taško):
 $AUC = 0,86$; $Gini=AR=2 \cdot AUC - 1 = 0,72$. Kaip matyti, modelis atitinka keltus reikalavimus minimaliai diskriminacinei galiai ($AUC=0,75$). Sukurto modelio diskriminacinę galią palyginus su logistinės regresijos modelių tikslumu naujausiuose moksliniuose tyrimuose (23 pav.), galima teigti, kad sukurto modelio diskriminacinė galia gali būti vertinama kaip puiki.



38 pav. Modelio gavėjų charakteristikos kreivė (ROC) ir modelio prognozuotų tikimybių grafikas

Autoriaus skaičiavimai.

Modelio diskriminacinė galia konkrečiame lūžio taške pavaizduota klasifikavimo lentelėje (18 lent.).

18 lentelė. Siūlomo modelio klasifikavimo tikslumo lentelė prie lūžio taško 0,4

		Modelio apskaičiuotas rezultatas	
		0 („Geras“)	1 („Blogas“)
Faktinė būklė	„Geras“	267 (TP)	83 (FN)
	„Blogas“	71 (FP)	222 (TN)

Autoriaus skaičiavimai.

Pateikti pagrindiniai klasifikavimo tikslumo įvertinimo rodikliai⁵⁶, atskyrimo tašką laikant 0,4⁵⁷ (19 lent.).

19 lentelė. Siūlomo modelio pagrindiniai klasifikavimo tikslumo rodikliai prie lūžio taško 0,4

Ar	0,76	PPV	0,79
CCR	1,6	NPV	0,73
MCR	0,5	α	0,54
Se	0,76	β	0,24
Sp	0,76	F	0,78
BAC	0,76	G-vidurkis	1,23
MCC=AC	0,52	ACP	0,76

Autoriaus skaičiavimai.

Apibendrinant galima teigti, kad išankstinio modelio įvertinimo rezultatai leidžia numanyti, jog sudarytas logistinės regresijos modelis yra kokybiškas ir gali būti tinkamas taikyti kredito unijų veikloje. Toliau siekiama optimaliai nustatyti modelio atskyrimo tašką, sudaryti rangų skalę bei atlikti grįžtamąjį modelio įvertinimą.

3.2.3. Optimalaus lūžio taško nustatymas ir rangų skalės sudarymas

Atsižvelgus į kredito rizikos vertinimo problemos ypatumus ir FP FN klaidų ekonominio poveikio skirtumą, optimalų lūžio tašką nustatyti nutarta pasitelkus Verbraken ir kiti (2014; 2013) pasiūlytą metodą, pristatytą ir pagrįstą šio darbo 2.2.6. poskyryje.

Pirma, analizuojant LCKU verslo paskolų imtį, nustatyta, kad (FP atveju) paskolų dalis, kuri prarandama pilnai skolininkui tapus nemokiu (p_0), kredito unijose vidutiniškai sudaro 33 %, o paskolų dalis, kuri pilnai susigrąžinama nemokumo atveju (p_1), yra 24 %⁵⁸.

Antra, nustatytas c_1 parametras (ROI). Apklausos duomenimis, vidutinė verslo paskolų palūkanų norma kredito unijų sektoriuje apklausos metu sudarė 7,17 %, o vidutinė indėlių palūkanų norma – 1,81 %, tad galima sakyti, jog

⁵⁶ Rodiklių apskaičiavimo metodika bei jų analitinė reikšmė pateikti šio darbo 2.2.5. poskyryje.

⁵⁷ Įprastai moksliniuose darbuose pagal nutylėjimą taikoma lūžio taško reikšmė yra 0,5. Šiuo atveju, atsižvelgus į prognozuotų tikimybių grafiką (**Error! Reference source not found. pav.**), pasirinktas kitas lūžio taškas skaičiuoti (0,4). Pažymėtina, kad šiame etape atliekamas tik pavyzdinis skaičiavimas siekiant pavaizduoti modelio diskriminacinę galią suformuojant klasifikavimo matricą. Maksimali toleruotina tikimybė bus apskaičiuota kitame tyrimo etape.

⁵⁸ Kredito unijos, priklausančios LCKU sistemai. LCKU duomenys.

kredito unijų sektoriaus vidutinė verslo paskolų marža apklausos metu sudarė 5,36 %. Vidutinis paskolų verslui terminas, nustatytas pagal LCKU suteiktą verslo pakolų imtį – 37 mėn. Pasitelkus šiuos dydžius ir atlikus skaičiavimus pagal (2-18) formulę, nustatytas c_1 parametras – 0,083.

Trečia, pasitelkus nustatytus $b_0(\lambda)$ ir $c_1(ROI)$ parametrus ir atlikus skaičiavimus pagal (2-19 – 2-22) formules, nustatytas optimalus lūžio taškas T . Skaičiavimams pritaikytas Bravo ir kiti (2015) sudarytas R programinio paketo plėtinys „EMP“. Nustatyta, kad sudarytas maksimalus vienos paskolos pelnas gaunamas atmetant 52,46 % rizikingiausių paskolų, t. y. optimalus lūžio taškas $T=0,48$.

Rangų skalė sudaryta atsižvelgus į Bazelio bankų priežiūros komiteto rekomendacijas ir nustatytą lūžio tašką T . Bazelio dokumentuose rekomenduojama sudaryti skalę iš ne mažiau kaip 8 rangų, iš kurių ne mažiau kaip 6 rangai, tikėtina, yra vykdančiams įsipareigojimus, ir 2 – jų nevykdančiams skolininkams (BCBS, 2001, p. 198). Todėl siekta, kad lūžio taškas T atitiktų 7-o arba 8-o rango apatinio režio reikšmę (20 lent.). Rangų suskirstymo režiai nustatyti ekspertiškai, atsižvelgus į įmonių pasiskirstymą suformuotuose ranguose. Analizuoti „gerų“, „blogų“ įmonių santykinis ir absoliutus pasiskirstymas (20 lent.; 3, 4, 7, 8, 9 skiltys), vidutinės rangų ODF reikšmės bei visų įmonių pasiskirstymas sudarytuose ranguose. Skaičiavimams pasitelkta modelio testavimo imtis.

Atlikus skaičiavimus (20 lent.) matyti, kad didžiausia dalis analizuotų „gerų“ įmonių suformuotoje skalėje atitiko 3–5 rangus (49 % visų „gerų“ įmonių). Didžiausias „gerų“ įmonių kiekis susitelkęs 5 skalės range. Analizuotos „blogos“ įmonės suformuotoje skalėje koncentruojasi 7–9 ranguose (77 % visų „blogų“ įmonių). Matyti, kad 9 rangui tenka didžiausia dalis analizuotų „blogų“ įmonių (51 %), tačiau šis rangas apima ir didžiausią PD režį $[0,6;1]$.


20 lentelė. Modelio rangų skalė

Rangai	PD skalė	G	B	Viso	ODF	G/V	G/G	B/B	Interpretacija
1	0,03	8	0	8	0,00	0,01	0,02	0	Žemos rizikos segmentas
2	0,05	27	1	28	0,04	0,04	0,08	0	
3	0,08	55	0	55	0,00	0,09	0,16	0	Vidutinės rizikos segmentas
4	0,12	51	4	55	0,07	0,08	0,15	0,01	
5	0,2	67	18	85	0,21	0,10	0,19	0,06	Aukštesnės rizikos segmentas – būtinas ekspertinis įvertinimas
6	0,3	39	23	62	0,37	0,06	0,11	0,08	
7	0,48	46	50	96	0,52	0,07	0,13	0,18	Aukštos nemokumo rizikos segmentas – paraiškos atmetamos
8	0,6	17	40	57	0,70	0,03	0,05	0,14	
9	1	40	141	181	0,78	0,06	0,11	0,51	Labai aukštos nemokumo rizikos segmentas
10	Faktiškai nemokios įmonės								Faktinis nemokumas

Autoriaus skaičiavimai.

Įprastai manoma, kad visų įmonių pasiskirstymas skalėje turi atitikti normalųjį skirstinį (Dzidzevičiūtė, 2013). Šis požiūris galėtų būti paaiškinamas tuo, jog formuojant modelio sudarymo ir testavimo imtis, kuriose vidutinis ODF atitinka vidutinį rinkos ODF lygį (tiksliniame segmente), daugiausia analizuojamų įmonių turėtų atitikti vidutinį kredito rizikos lygį ir atitinkamai koncentruotis ties suformuotos skalės viduriu. Analizuojamu atveju, kai vidutinis modelio testavimo imties ODF sudaro 44,18 % bei dėl didelės „blogų“ įmonių koncentracijos 9 range, visų analizuotų įmonių koncentracija taip pat yra pasislinkusi į suformuotos skalės galą, ir lemian tai, kad 9 range koncentruojasi 51 % visų analizuotų įmonių (testinėje imtyje).

Siekiant vaizdžiai perteikti sukurto modelio struktūrą, analizuotas įmonių veiklos sritis, išskirtus rodiklius, jų koeficientus bei rodiklių reikšmių įtaką analizuojamos įmonės PD, toliau pateiktas sudaryto modelio z parametro ir suformuotos rangų skalės grafinis apibendrinimas (39 pav.).



39 pav. Sudaryto modelio ir rangų skalės grafinis apibendrinimas

Sudaryta autoriaus.

Paveiksle naudotų sutrumpinimų paaiškinimas: RĮ – rodiklio įtaka PD, rodiklio reikšmei didėjant; T – lūžio taškas.

Apibendrinant galima tvirtinti, kad pritaikius maksimalaus tikėtino pelno metodą (EMP, Verbraken ir kiti, 2014; 2013) nustatyta, jog Lietuvos kredito unijos, taikydamos sukurtą modelį, tikėtina, maksimizuosų įmonių kreditavimo veiklos pelną nustatčius lūžio tašką $T=0,48$. Rangų skalę sudaryta atsižvelgus į Bazelio bankų priežiūros komiteto rekomendacijas ir nustatytą lūžio tašką T . Rangų skalę suformuota iš 10 rangų, 6, tikėtina, skirti įsipareigojimus vykdysiančioms įmonėms, 3, tikėtina, nevykdysiančioms ir 1 (10-as) – faktiškai nemokioms įmonėms. Tokia rangų skalės sudarymo metodika atitinka Bazelio bankų priežiūros komiteto rekomendacijas.

Toliau darbe sukurtas modelis taikomas analizuojant LCKU suteiktų verslo paskolų imtį. Pritaikius modelį, atliekamas jo grįžtamasis įvertinimas.

3.3. Sukurto modelio taikymas Lietuvos kredito unijų sektoriuje

3.3.1. Sukurto modelio grįžtamasis įvertinimas ir atitikimas kredito unijų poreikiams

Sukurto modelio grįžtamasis įvertinimas. Sukurto modelio grįžtamajam įvertinimui pasitelkta Lietuvos kredito unijų verslo paskolų imtis, kuri suformuota iš LCKU priklausančių kredito unijų faktiškai suteiktų verslo paskolų duomenų. Analizuojamos įmonės įtrauktos į tyrimą remiantis tais pačiais atrankos kriterijais, kaip ir formuojant modelio kūrimo imtį. Parenkant tyrimui tinkamas įmones siekta, kad nuo paskolos suteikimo laikotarpio būtų praėję ne mažiau kaip 2 metai, t. y. kad vertinimo metu būtų užsibaigęs nustatytas paskolos stebėjimo (arba brandos) laikotarpis. Iš viso į tyrimą buvo įtrauktos 84 įmonės.


Analizuojant „blogas“ įmones, pastebėta, kad iš 37 įmonių, kurioms buvo priskirtas „blogas“ įmonės požymis, tik 9 įmonės tyrimo metu buvo bankrutuojančios, bankrutavusios, likviduotos. Šis faktas, įvertinus kredito unijų bei modelio kūrimo imties analizės rezultatus, **leidžia patvirtinti iškeltą hipotezę H3**, kurioje buvo preziumuojama, jog reikšminga dalis įmonių, kurioms kredito unijų suteiktos paskolos tampa neveiksnios, nebankrutuoja. Šios hipotezės patvirtinimas parodo, kad modelio sudarymo metu taikyti „blogų“ ir „gerų“ įmonių apibrėžimo metodai pasirinkti pagrįstai.

Sudarytas modelis taikytas tokiu eiliškumu:

- 1) iš turimų imties duomenų kiekvienam įrašui apskaičiuotos visos modelyje taikomų regresorių (žr. 17 lent.) reikšmės;
- 2) visoms regresorių reikšmėms apskaičiuoti WOE, originalios regresorių reikšmės pakeistos apskaičiuotomis WOE reikšmėmis;
- 3) laikantis 2.2.3. poskyryje aprašytos metodikos, įrašams priskirti „gerų“ ir „blogų“ įmonių požymiai. Taigi modelio taikymo imtį sudarė 47 „geros“ ir 37 „blogos“ įmonės.

4) įmonių PD apskaičiuotos pagal formulę (3-1 formulė). Kiekvienam imties įrašui priskirtos apskaičiuotos PD bei nustatytas rangas, imtyje suformuojant du papildomus kintamuosius.

Siekiant įvertinti modelio tikslumą, atlikti skaičiavimai. *Pirma*, įvertintas bendras modelio tikslumas (neišskiriant lūžio taško). Nustatyta: modelio $AUC=89,62$, modelio $Gini=AUC \cdot 2 - 1 = 79,24$, suformuotas ROC ir modelio prognozuotų tikimybių grafikai (40 pav.).



40 pav. Sudaryto modelio taikymo, vertinant Lietuvos kredito unijų verslo paskolas, rezultatai: gavėjų charakteristikų kreivė ir modelio prognozuotų tikimybių grafikas

Autoriaus skaičiavimai.

Antra, apskaičiuoti klasifikavimo tikslumo rodikliai nustatytame lūžio taške 0,48. Sudaryta klasifikavimo tikslumo lentelė (21 lent.).

21 lentelė. Sudaryto modelio klasifikavimo tikslumo lentelė lūžio taške T

		Modelio apskaičiuotas rezultatas	
		0 (Geras)	1 (Blogas)
Faktinė būklė	„Geras“	44 (TP)	8 (FN)
	„Blogas“	3 (FP)	29 (TN)

Autoriaus skaičiavimai.

Trečia, apskaičiuoti klasifikavimo tikslumo rodikliai (22 lent.).

22 lentelė. Sudaryto modelio pagrindiniai klasifikavimo tikslumo rodikliai lentelės lūžio taške T

Ar	0,87	PPV	0,94
CCR	1,97	NPV	0,78
MCR	0,30	α	0,73
Se	0,85	β	0,09
Sp	0,91	F	0,89
BAC	0,88	G-vidurkis	1,32
MCC=AC	0,74	ACP	0,87

Autoriaus skaičiavimai.

Sukurto modelio atitikimas Lietuvos kredito unijų poreikiams vertinant mažų ir labai mažų įmonių kredito riziką. Sukūrus modelį, svarbu pakartotinai įsitikinti, ar kuriant modelį taikyti metodai ir naudoti duomenys atitinka reikalavimus, nustatytus atlikus analizę iš trijų perspektyvų: kredito įstaigos, išorės veiksnių ir modeliujamos homogeninės rizikos grupės. Realizuojant šį tikslą, toliau pateikiama suvestinė lentelė (23 lent.), kurioje, atsižvelgus į darbo 1.2.1. poskyryje pateiktą 4 paveikslą, išskirti reikalavimai modelio kūrimo metodams, duomenims bei sukurto modelio charakteristikoms. Iš pateiktos lentelės matyti, kad kuriant modelį atlikta išsami analizė iš minėtų trijų modelio kūrimo perspektyvų. Analizės metu nustatytos modelio charakteristikos, kurias sukurtas modelis atitinka, todėl manytina, kad modelis yra tinkamas naudoti kredito unijų sektoriuje.

Apibendrinus sudaryto modelio taikymo ir grįžtamojo įvertinimo rezultatus, galima teigti, kad modelio diskriminacinė galia vertintina kaip puiki. Atlikus modelio tinkamumo naudoti kredito unijų veikloje analizę, matyti, jog modelis sukurtas atlikus išsamių kompleksinių kredito unijų sektoriaus tyrimą. Modelio kūrimo metodai parinkti įvertinus kreditoriaus veiklos specifiškumą, rizikos toleranciją bei taikomus reguliacinius reikalavimus. Modelio kūrimo imtis suformuota atsižvelgus į kreditoriaus tikslinį kreditavimo segmentą bei atitinka modeliujamą homogeninę grupę. Modelio kintamieji parinkti atlikus išsamią mokslinės ir profesinės literatūros analizę bei įvertinus jų praktinio taikymo galimybes ištyrus kredito unijų išorinę informacinę infrastruktūrą. Sudaryta modelio rangų skalė atitinka Bazelio bankų priežiūros komiteto rekomendacijas. Skalės lūžio taškas

nustatytas statistiniais metodais, įvertinus kredito unijų verslo paskolų portfelio savitumus, kreditavimo maržą bei portfelio LDG. Modelio diskriminacinė galia įvertinta statistiškai bei palyginta su naujausių mokslinių tyrimų rezultatais.

Atsižvelgus į modelio įvertinimo rezultatus, jis gali būti pagrįstai laikomas patikimu ir tinkamu naudoti kredito unijų veikloje. **Tai patvirtina H4 hipotezę ir leidžia motyvuotai teigti, kad sukurtas mažų ir labai mažų įmonių kredito rizikos vertinimo modelis leis tiksliau įvertinti kredito unijų teikiamų verslo paskolų kredito riziką.** Toliau darbe pateikiamos modelio taikymo ir integravimo į bendrą sprendimų priėmimo palaikymo sistemą rekomendacijos.

23 lentelė. Sukurto modelio atitikimo keltiems reikalavimams sąvadas

	Kredito įstaigos perspektyva	Išorinių veiksnių perspektyva	Modeliuojamos homogeninės rizikos grupės perspektyva
Imties ir modelio formav. galimyb.	<i>Nustatytas tikslinis KU kreditavimo segmentas</i> – mažos ir labai mažos Lietuvos įmonės. <i>Įvertinta vidinė informacinė infrastruktūra</i> – ji vertintina kaip nepakankama (KU nekaupia vidinių statistinių duomenų, kurie galėtų būti naudojami sudarant modelį). <i>ŽTF išteklių</i> vertintini kaip labai riboti.	Vertinant modelio kūrimo galimybes atlikta preliminarinė <i>Lietuvos išorinės informacinės infrastruktūros (toliau – Lietuvos IIIF) analizė</i> . Nustatyta, kad Lietuvos IIIF yra išsivysčiusi ir leidžia sukurti bei taikyti statistinius modelius KU veikloje.	<i>Lietuvos mažų ir labai mažų įmonių populiacija tyrimo metu sudarė 28580 įmonių. Modelio kūrimo imtis sudarė 1799 įmonių. Iš modelio kūrimo imties suformuotos modelio sudarymo imtis 625 įmonių ir modelio testavimo imtis 627 įmonių.</i> Apskaičiuota, kad suformuota modelio sudarymo imtis leidžia prognozuoti PD su 95 % tikimybe bei 7 % paklaida. Suformuotose modelio sudarymo ir testavimo imtyse nei viena iš priklausomo (binarinio) kintamojo reikšmių nėra vyraujanti.
Galimi neprikl. kintam.	<i>Nustatytos nepriklausomų kintamųjų grupės, kurias KU apibūdino, kaip svarbiausias</i> kredito rizikos vertinimo veikloje. Visos svarbios kintamųjų grupės įtrauktos į galimų naudoti nepriklausomų kintamųjų sąvadą.	<i>Nustatyti išoriniai šaltiniai</i> , kurie gali būti naudojami paraiškų vertinimo procese taikant sukurtą modelį: RC JAR, VĮ CHI (vėliau prijungta prie RC); KB Creditinfo, LB PRDB, BR, SODRA (14 lent.). Visi šių registrų teikiami kintamieji, pagal galimybę (atsižvelgus į turimus statistinius duomenis), įtraukti sudarant galimų naudoti nepriklausomų kintamųjų sąvadą.	Išanalizavus ir apibendrinus mokslinę ir profesinę literatūrą – 101 įmonės kredito rizikos vertinimo modelį, bei atsižvelgus į KU reikalavimus ir išorinę informacinę infrastruktūrą, kurios kontekste veikia KU, sudarytas galimų naudoti nepriklausomų kintamųjų sąvadas, iš kurio parinkti nepriklausomi kintamieji sudaryti modelį (žr. 4 priedą).
Klasifik. pasirinkimas	<i>KU sektoriaus tyrimo eigoje nustatyta:</i> a) KU ŽTF išteklių yra riboti; ypač stokojama žmoniškųjų išteklių statistikos ir informacinių technologijų srityse; b) KRVM rezultato paaiškinamumas yra prioritetinė modelio charakteristika; c) KU nekaupia vidinių statistinių duomenų, kurie galėtų būti naudojami sudarant modelį. Remiantis šiomis išvadomis, netinkami taikyti tie modeliai, kuriuos taikant praktiškai, interpretuojant rezultatus ir periodiškai tikrinant bei kalibruojant reikėtų ženklų ŽTF resursų. <i>Tad atsisakyta mišrių (hibridinių) arba dirbtinio intelekto modelių.</i>	Išanalizavus Bazelio bankų priežiūros komiteto skelbtus dokumentus (BCBS, 2004), nustatyta, kad modeliai, sukurti naudojant dirbtinio intelekto klasifikatorius, neatitinka reglamentavimo. Ši neatitikimą lemia tai, kad šių modelių skaičiavimo rezultatų negalima paaiškinti ir / ar užfiksuoti modelio veikimo principų bei taisyklių. Bazelio bankų priežiūros komiteto skelbtuose dokumentuose taip pat rekomenduojama taikyti statistinius tikimybinus modelius, kuriais galima nustatyti PD (BCBS, 2004). <i>Remiantis šiomis išvadomis, atsisakyta dirbtinio intelekto ir diskriminantinio tipo klasifikatorių taikymo sudarant modelį.</i>	Išanalizavus ir apibendrinus 96 mokslinės ir profesinės literatūros šaltinius, kuriuose buvo sudaromi įmonių kredito rizikos vertinimo modeliai, <i>nustatyti dažniausiai literatūroje naudojami klasifikatoriai, jų tipai bei klasifikavimo tikslumo tendencijos</i> (žr. 22 ir 23 pav.). Atlikus analizę iš kreditoriaus ir išorinių veiksnių perspektyvos bei pašalinus netinkamus klasifikatorius (dirbtinio intelekto, diskriminantinius ir mišrius), sprendžiama dėl logistinės regresijos ir artimiausio kaimyno metodų pasirinkimų. Modeliui <i>sudaryti pasirinkta logistinė regresija</i> dėl jos didesnio tikslumo (pagal atlikto teorinio tyrimo rezultatus, 22 pav.).
Priklaus	Atlikus apklausą, nustatyta, kad KU sektoriaus	Atlikus mokslinės literatūros analizę, nustatyta, kad	Sudarius Markovo migracijų tikimybių matricą,

	Kredito įstaigos perspektyva	Išorinių veiksnių perspektyva	Modeliuojamos homogeninės rizikos grupės perspektyva
omo kintam. apibrėž.	dalyviai „blogą“ paskolą apibrėžia nevienodai, tačiau dažniausiai taikomi 60 ir 90 DPD apibrėžimai bei bankrotas . Į šiuos tyrimo rezultatus atsižvelgta formuojant modelio priklausomo kintamojo apibrėžimą, siekiant, kad binarinis kintamasis atitiktų sektoriaus rizikos tolerancijos lygį.	priklausomo kintamojo apibrėžimas dažnai siejamas su teisiniu neveiksnių paskolos apibrėžimu (5 lent.). Išanalizavus svarbiausius teisės aktus (BCBS 2005, 2006; ES Nr. 648/2012), nustatyta, kad neveiksni paskola yra laikoma ta, kurios DPD yra 90 ar daugiau dienų. Taip pat nustatyta, kad Lietuvos KU atžvilgiu yra taikomas nuosaikesnis reglamentavimas ir neveiksni paskola yra laikoma ta, kurios DPD yra 180 ir daugiau dienų (LB, 2009).	nustatyta, kad „blogą“ skolininko apibrėžimą tikslinga sieti su 60 ar 90 DPD įvykiu. Atsižvelgus į KU sektoriaus apklausos rezultatus, kaip pagrindinis požymis pasirinktas 90 DPD arba bankrotas. Nustatyta, kad mažos ir labai mažos įmonės pasižymi specifine elgsena – daug įmonių, atitikusių „geros“ įmonės apibrėžimą, po kontrolinio laikotarpio veiklos netesė arba turėjo finansinių sunkumų. Pasiūlytas papildomos patikros metodas, kuriuo iš modelio kūrimo imties pašalintos nesėkmingai veikusios įmonės. Modeliui sudaryti taikyti B2 ir G4 kaip atitinkamai „blogų“ ir „gerų“ skolininkų apibrėžimai (20 pav.).
Rangų skalės sudar.	Nustatyta, kad KU sektoriuje taikoma 5 grupių rangavimo sistema neatitinka Bazelio bankų priežiūros komiteto rekomendacijų (BCBS, 2001, p. 198), todėl suformuota 10-ies rangų skalė: 6 rangai, tikėtina, įsipareigojimus vykdysiantiems skolininkams, 3, tikėtina, nevykdysiantiems ir paskutinis (10-as) – faktiškai įsipareigojimų nevykdantiems skolininkams. Įvertinus modelio testavimo imties paskolų pasiskirstymą ranguose, matyti, jog suformuota rangų skalė tinkama taikyti mažų ir labai mažų įmonių segmente.		
Paskolos steb. laik. apibrėž.	Apklausos metu nustatyta, kad KU sektoriaus dalyviai neturi nuomonės optimalaus paskolos stebėjimo laikotarpio bei kritinių LGD taškų nustatymo klausimais bei pritaria tam, kad šie dydžiai turėtų būti nustatomi statistiniais metodais.	Atlikus reguliacinių reikalavimų analizę, nustatyta, kad minimalus paskolos stebėjimo laikotarpis yra 12 mėn.	Išanalizavus LCKU verslo paskolų portfelį bei sudarius paskolų kohortas, nustatyta, kad KU verslo paskolų optimalus stebėjimo laikotarpis yra 25 mėn. Atsižvelgus į turimus statistinius duomenis, šis laikotarpis suapvalintas iki 24 mėn.
Lūžio taško nustat.		Atlikus reguliacinių reikalavimų analizę, nerasta reguliacinių reikalavimų nustatyti lūžio tašką.	Išanalizavus LCKU verslo paskolų imtį, nustatyti (p_0), ir (p_1) taškai, c_1 parametras (ROI), bei taikant EMP metodą (Verbraken ir kiti, 2014; 2013), kiekybiškai nustatytas optimalus (maksimalaus tikėtino pelno atžvilgiu) lūžio taškas.
Modelio įvertin.	Apibendrinus modelio kūrimui taikytų metodų, naudotų duomenų bei sukurto modelio charakteristikų visumą, manytina, kad modelis atitinka tyrimo metu nustatytus kredito unių poreikius ir yra tinkamas naudoti KU veikloje.	Laikantis Bazelio bankų priežiūros komiteto reikalavimų (BCBS, 2005a), atlikti sukurto modelio išankstinis ir grįžtamasis įvertinimai.	Nustatytos diskriminacinės modelio savybės (vertinant tiek išankstinio įvertinimo, tiek ir grįžtamojo), jos palygintos su atlikto teorinio tyrimo rezultatais, kurio metu įvertinta 60 logistinės regresijos pagrindu sudarytų modelių (23 pav.). Apibendrinus rezultatus, modelio diskriminacinės savybės laikytinos puikiomis.

Sudaryta autoriaus.

3.3.2. Sukurto modelio taikymas ir integravimo į sprendimų paramos sistemą rekomendacijos

Sukūrus statistinį kredito rizikos vertinimo modelį, kyla klausimai dėl jo taikymo kredito rizikos vertinimo procese ribų bei formos. Šio disertacijos poskyrio tikslas – atsižvelgus į tyrimo metu nustatytas kredito unijų veiklos problemas, pateikti atitinkamas modelio taikymo ir integracijos į kredito unijų sprendimų priėmimo paramos sistemą rekomendacijas. Pirma, poskyryje pateikiami sukurto modelio taikymo apribojimai. Antra, atsižvelgus į tyrimo rezultatus ir disertacijos autoriaus išvalgas, pateikiamos modelio taikymo kredito unijų veikloje rekomendacijos.

Sukurtas statistinis kredito rizikos vertinimo *modelis pasižymi šiais taikymo apribojimais*:

1. *Sukurtas modelis turėtų būti suprantamas kaip bendros sprendimų priėmimo paramos sistemos (angl. decision support system) dalis, todėl turėtų būti naudojamas jį įdiegus į bendrą kredito unijos sprendimų priėmimo paramos sistemą, kurios privaloma dalis yra kreditavimo taisyklių rinkinys. Šis apribojimas yra svarbus dėl to, kad sudarant modelį neįtraukti kai kurie stiprią diskriminacinę galią turintys nefinansiniai rodikliai, kuriuos (autoriaus nuomone) kredito unija turėtų įtraukti į kreditavimo taisyklių rinkinius⁵⁹;*
2. *Modelis tinkamas vertinti tik tas įmones, kurios iki vertinimo dienos veikė bent dvejus metus⁶⁰;*
3. *Modelis yra pritaikytas tyrimo metu nustatytam vienam tiksliniam kredito unijų kreditavimo segmentui, todėl tinkamas vertinti tik Lietuvoje veikiančias mažas ir labai mažas⁶¹ įmones.*

Kaip minėta disertacinio tyrimo pradžioje (1.1.2. poskyris), vienas iš kredito unijų išskirtinių bruožų yra tas, jog dažniausiai (Lietuvoje privaloma

⁵⁹ Pavyzdinis kreditavimo sprendimų priėmimo procesas, apimantis ir kreditavimo taisyklių įvertinimą, aptariamas toliau šiame skyriuje.

⁶⁰ Šis apribojimas yra svarbus dėl to, kad kredito unijos teikia paskolas su Valstybės garantija ir naujoms įmonėms. Sukurtas modelis nėra tinkamas vertinti šį kreditavimo segmentą.

⁶¹ Pagal LR Smulkiojo ir vidutinio verslo plėtros įstatymą (1998, Nr. 109-2993).

tvarka) jas vienija Centrinės organizacijos (angl. *appex*; Lietuvos atveju – LCKU, toliau – Centrinė kredito unija) (Fonteyne, 2007; Kupelytė, 2007; MacPherson, 2007). Pagrindinės Centrinės kredito unijos funkcijos – priežiūra, paslaugų teikimas organizacijos nariams bei masto ekonomijos užtikrinimas kredito unijoms perkant prekes ar paslaugas (Fonteyne, 2007). Atsižvelgus į kredito unijų sektoriaus tyrimo metu nustatytus svarbius veiksnius, kurie apsunkina statistinių kredito rizikos vertinimo modelių kūrimą bei tobulinimą kredito unijų veikloje, galima preziumuoti, kad kredito unijoms sukurto modelio praktinės taikymo galimybės nedalyvaujant Centrinei kredito unijai yra ribotos dėl kelių priežasčių.

Pirma, kaip matyti iš atlikto tyrimo, kredito unijos stokoja ŽTF išteklių sėkmingai modelio integracijai į turimą sprendimų priėmimo procesą. *Antra*, Centrinei kredito unijai priklausančių kredito unijų kredito rizikos vertinimo metodikos (vertinimo tvarkos) yra rengiamos centralizuotai (Lietuvos atveju ir LCKU kontekste jas rengia LCKU), todėl Centrinės kredito unijos dalyvavimas diegiant sukurtą ir / ar kitą statistinį modelį yra būtinas. *Trečia*, iš viešai prieinamų kredito unijų finansinių duomenų (LB, 2017) matyti, kad Lietuvoje nei viena kredito unija neturi pakankamai duomenų⁶² periodiškai tikrinti įmonių kredito rizikos vertinimo modelį⁶³.

Tyrimo metu nustatytos šios svarbios KU sektoriaus problemos, turinčios neigiamos įtakos visam sektoriaus stabilumui. *Pirma*, nustatyta, kad ne visos kredito unijos laikosi kreditavimo tvarkų: 37,5 % respondentų teigė visada, dažniausiai arba dažnai pažeidžiantys kreditavimo tvarkas. Išanalizavus LCKU sistemos dalyvių kreditavimo paraiškų vertinimo procesą, nustatyta ir tai, kad Centrinės kredito unijos vaidmuo kontroliuojant kredito unijų-narių prisiimamą kredito riziką apsiriboja kreditavimo tvarkų parengimu bei retrospektyvinio pobūdžio jų taikymo patikrinimais kredito unijose.

⁶² Pakankamai suteiktų paskolų, iš kurių būtų galima suformuoti pakankamą statistinį imtį modeliui testuoti ir kalibruoti. Pažymėtina ir tai, kad, autoriaus duomenimis, nei viena kredito unija tyrimo metu statistinių duomenų nekaupė, todėl tikėtina, jog artimiausiu metu negalėtų sudaryti statistinės imties net iš suteiktų paskolų duomenų.

⁶³ Tikėtina, kad dauguma kredito unijų pritrūks ir ŽTF išteklių norėdamos šiuos veiksmus įgyvendinti kokybiškai.


Antra, 82 % respondentų pritarė teiginiui, kad mažėjant potencialių klientų kiekiui, kredito unijų rizikos tolerancija didėja. Kitaip sakant, tikėtina, kad tarp „einamojo“ kredito įstaigos pardavimų potencialo ir rizikos tolerancijos yra reikšminga neigiama priklausomybė. Kredito unijų sektoriuje šis reiškinys yra svarbus tuo, jog mažose tikslinėse rinkose veikiančios kredito unijos turi žemesnę pardavimų potencialą, todėl tikėtina, kad jos yra linkusios toleruoti aukštesnę riziką. Pažymėtina, kad sektoriaus tyrimo metu nustatyta, jog 20 % kreditavimo tvarkų pažeidimų įvykdoma todėl, kad dėl mažo potencialių klientų kiekio kreditavimo tvarkos tapo formalios (28 pav.). Papildomai nustatyta, kad nors Lietuvos kredito unijos bendrai valdo plačiausią klientų aptarnavimo tinklą šalyje, tarp kredito unijų nėra potencialių klientų pasidalijimo mechanizmo. Dėl to klientai, neatitinkantys narystės reikalavimų, yra prarandami užuot juos perdavus kitoms kredito unijoms, kurių narystės (ar kreditavimo taisyklių) reikalavimus narys atitinka.

Šie faktai suteikia pagrindą teigti, kad Centrinės kredito unijos nariai toleruoja skirtingą kredito riziką, t. y. kredito unijos išliks nehomogeniškos prisiimamos rizikos prasme. Tokia aplinkybė gali ženkliai apsunkinti kredito unijų galimybes bei motyvaciją dalyvauti Centrinės kredito unijos mokumo užtikrinimo sistemoje, kurioje numatyta, kad Centrinę kredito unijų nariai turėtų solidariai atsakyti už vieni kitų finansinį stabilumą (žin. XII-2566, 25 str.).

Šios tyrimo metu nustatytos probleminės aplinkybės leidžia suformuluoti pagrindinius sukurto modelio taikymo siekius, į kuriuos turėtų būti atsižvelgiama implementuojant sukurtą statistinį modelį ir / arba kitus statistinius modelius. *Pirma*, siekiant užtikrinti mokumo užtikrinimo sistemoje(-ose) dalyvaujančių kredito unijų interesų apsaugą, Centrinės organizacijos turėtų užtikrinti galimybę **operatyviai** kontroliuoti sistemos kredito unijų-narių prisiimamos kredito rizikos lygį bei galiojančių kreditavimo tvarkų vykdymą⁶⁴. *Antra*, atsižvelgus į kredito unijų išreikštą poreikį koreguoti

⁶⁴ Operatyvi kredito rizikos prisiėmimo kontrolė taip pat yra svarbi prevencinė priemonė, padėsianti užkirsti sukčiavimo atvejus, dėl kurių KU sektorius jau buvo nukentėjęs 2011–2014 metais.

ir / ar prisitaikyti kreditavimo taisykles savo poreikiams, Centrinės kredito unijos turėtų nustatyti aiškas galimų korekcijų ribas. Tikėtina, kad šios ribos turėtų būti užfiksuotos kreditavimo politikoje, taikomoje Centrinės kredito unijos nariams. Tai suteiktų kredito unijoms galimybę taikyti personalizuotas kreditavimo taisykles, tačiau užkirstų kelią prisiimti nevaldomą riziką. *Trečia*, pertvarkant kredito unijų sprendimų priėmimo sistemą, svarbu atsižvelgti į nustatytą klientų pasidajinimo mechanizmo stoką. Kaip minėta, šis veiksnys svarbus mažinant kredito unijų polinkį toleruoti aukštesnę kredito riziką.




41 pav. Dabartinis paraiškos apdorojimo procesas LKU sistemoje

Atsižvelgus į nustatytus siekius, LCKU pavyzdžiu suformuotas siūlomas sprendimų priėmimo procesas (42 pav.). Suformuoto proceso eiga:

- 1) procesas prasideda pareiškėjui pateikus paskolos paraišką kredito unijai; kredito unija persiunčia užklausą LCKU⁶⁵;
- 2) gavus užklausą, LCKU IT sistemose inicijuojamas vidinis paraiškos vertinimo procesas;
- 3) atliekamas pirminių duomenų surinkimas, susidedantis iš dviejų dalių – vidinių duomenų surinkimas ir išorinių duomenų surinkimas;

⁶⁵ Dėl paprastumo manoma, kad užklausa atitiko pirminį paskolų valdybininko (ar šią pareigybę atitinkančio asmens) vertinimą ir traktuojama, jog paraiškos teikimas yra tikslingas.

- 4) atliekama duomenų sintezė – iš skirtingų duomenų šaltinių gauti duomenys yra sujungiami į vieną analitinių duomenų masyvą⁶⁶;



42 pav. Rekomenduojamas paraiškos paskolai gauti apdorojimo procesas integruojant sukurtą modelį

- 5) vertinamas paraiškos atitikimas kredito unijų kreditavimo taisyklėms (taip pat ir LCKU kreditavimo politikai); vertinamas atitikimas visų LCKU sistemos kredito unijų taisyklėms⁶⁷;

⁶⁶ Kai kurios duomenų bazės viena kitą papildo (Lietuvos atveju pavyzdys galėtų būti LB PRDB ir UAB Creditinfo Lietuva duomenų bazės). Norint surinkti visus vertinimui būtinus duomenis, rekomenduojama gauti informaciją iš visų duomenų šaltinių bei juos metodiškai teisingai sujungti.

⁶⁷ Pastaba: pagal siūlomą vertinimo procesą, laikoma, jog a) LCKU tiksliai žinomos visų sistemos dalyvių vertinimo taisyklės; b) taisyklės implementuotos LCKU IT sistemoje ir analizė

- 6) taikomas statistinis kredito rizikos vertinimo modelis, apskaičiuojamas paskolos PD⁶⁸;
 - 7) įvertinus paraiškos atitikimą kreditavimo taisyklėms, kreditavimo politikai ir nustatytą PD, priimamas (automatinis) sprendimas dėl kreditavimo galimybių bei nustatoma minimali galima palūkanų norma paskolai⁶⁹. Jei paskolos teikimas neatitinka kreditavimo politikos, paskolos suteikimas draudžiamas, priešingu atveju – leidžiamas;
 - 8) atsakoma į kredito unijos užklausą. Atsakant perduodami pirminiai skolininko(-ų) duomenys iš duomenų bazių, (ne)atitikimo kredito unijos vertinimo taisyklėms ataskaita, apskaičiuotas skolininko(-ų) PD, požymis dėl atitikimo LCKU kreditavimo taisyklėms, nustatyta minimali palūkanų norma (ir / ar kiti reikalavimai);
 - 9) kredito unija, vertindama atitikimą kreditavimo politikai bei apsvarsčiusi paraišką ekspertiniais būdais, priima sprendimą dėl kreditavimo galimybių;
 - 10) jei paraiškos finansavimas galimas, tai pareiškėjui pateikiamas pasiūlymas;
 - 11) pareiškėjas priima sprendimą dėl paskolos ėmimo siūlomomis sąlygomis;
 - 12) LCKU informuojama apie sandorio baigtį;
 - 13) vertinama, ar sandorio esmė atitiktų LCKU kreditavimo politiką⁷⁰;
- vertinama, ar paskola yra suteikiama; jei taip, tai pradedama kaupti vidinė kredito istorija;
- 14) jei paskola nesuteikiama, vertinama, ar pagal turimus duomenis paskolą galėtų suteikti kita sistemai priklausanti kredito unija;
 - 15) jei taip, tai inicijuojamas perdavimas kitai KU, kartojamas KU kreditavimo sprendimų procesas bei pareiškėjo premdimų priėmimo

atliekama automatizuotu būdu; c) LCKU užtikrina, jog visų sistemos narių kreditavimo taisyklės atitinka LCKU kreditavimo politiką.

⁶⁸ Turėtų būti sudaryti ir taikomi skirtingi statistiniai modeliai, sudaryti skirtingiems kreditavimo segmentams.

⁶⁹ Pastaba: šiame etape gali būti nustatoma ir daugiau reikalavimų, pvz. privaloma minimali bendra užtikrinimo priemonių vertė ir pan.

⁷⁰ Atsižvelgiant į KU nustatytas paskolos teikimo sąlygas ir kitas aplinkybes.

procesas; jei ne, tada paraiška atmetama, duomenys išsaugomi atmestų paraiškų duomenų bazėje.

*Šiame, paskutiniame disertacijos poskyryje pristatyta sukurto modelio taikymo metodika, kuri sudaryta atsižvelgus į išanalizuotą Lietuvos kredito unijų sektoriaus veiklos problematiką. Šios metodikos naujumas gali būti apibūdintais dviem pagrindiniais aspektais. **Pirma**, į kreditavimo sprendimų priėmimo procesą įtraukiama Centrinė kredito unija. Šis pakeitimas suteikia Centrinei kredito unijai galimybę operatyviai kontroliuoti mokumo užtikrinimo sistemos dalyvių prisiimamą kredito riziką. **Antra**, pasiūlytas procesas leidžia efektyviau išnaudoti plataus kredito unijų tinklo galimybes dalijantis atmestomis paraiškomis. Be to, toks požiūris padidins viso kredito unijų sektoriaus finansuojamų paraiškų dalį (angl. acceptance rate), taip pat patrauklumą galutiniam vartotojui.*

Neskaitant tyrimo rezultatų sklaidos paskelbtose mokslinėse publikacijose, autorius sieks pasidalyti šio disertacinio tyrimo rezultatais su Lietuvos kredito unijomis, jų asociacijomis, Centrine kredito unija bei Lietuvos banku. Autorius tikisi, kad sukurto modelio ir disertacijoje pristatytos modelio sudarymo bei taikymo metodikos taikymas Lietuvos kredito unijų sektoriuje teigiamai paveiks sektoriaus stabilumą ir skatins visuomenės pasitikėjimą kooperatine bankininkyste.

IŠVADOS

1. Šiame disertaciniame tyrime rizika apibrėžiama kaip tikimybė, kad ateityje faktiniai kredito įstaigos veiklos rezultatai skirsis nuo planinių. Rizika gali būti statistiškai išmatuojama ją išreiškiant tikimybės išraiška, kuri gali būti nustatyta analizuojant veiksnius, sukeliamus kredito įstaigos veiklos ir lemiančius rizikos atsiradimą. Kredito unijų veikloje, kaip ir komercinėje bankininkystėje, išskirtinos keturios pagrindinės rizikos rūšys: operacinė, kredito, rinkos ir likvidumo.

Kooperatinėje bankininkystėje, kitaip nei tradicinėje, pasireiškia nepalankaus pasirinkimo, moralinė, nuosavo kapitalo prisitraukimo rizikos, kurios būdingos ir kitoms bankininkystės rūšims, tačiau kooperatinėje bankininkystėje jų raiška susijusi su šios bankininkystės rūšies bruožų ypatumais. Išskirtini ir specifiniai rizikos veiksniai: interesų persidengimas, mažas rinkos gylis, ekspertinių kredito rizikos vertinimo modelių taikymas, ribotos skolinto kapitalo pritraukimo galimybės ir aukšta skolinto kapitalo kaina. Visos rizikos rūšys ir veiksniai yra susiję tarpusavyje priežasties ir pasekmės ryšiais bei daro įtaką bendrai kredito unijų veiklos rizikai.

2. Atlikus mokslinės literatūros analizę, nustatyta, kad veikiant pagal naująjį veiklos modelį, siekiant veiklos efektyvumo ir masto ekonomijos, kredito unijos privalo vystytis ir jų raida iš esmės atitiks Sibbald ir kiti (2002) apibrėžtus raidos etapus. Skirtinguose unijų raidos etapuose, priklausomai nuo kredito unijų gaunamos analitinės informacijos, turimų žmogiškųjų, technologinių ir finansinių resursų, unijos turėtų taikyti skirtingus kredito rizikos vertinimo metodus, siekdamos kuo tiksliau įvertinti potencialių paskolos gavėjų kredito riziką.

Ankstyvajame raidos etape kredito unijos gali gana efektyviai vertinti kredito riziką ekspertiniais kredito rizikos vertinimo metodais, pasitelkdamos socialinės kontrolės elementą. *Tranzitiniame* etape unijų veikla plečiama už bendruomenės ribų, socialinis kontrolės elementas silpsta, todėl kredito unijos

turėtų taikyti kiekybinius metodus, pasitelkdamos objektyvią analitinę informaciją. Įprastai šiame raidos etape kredito unijos dar nebūna sukaupusios pakankamo duomenų kiekio kurti statistinius modelius, todėl pereinamuoju laikotarpiu gali būti taikomi taisyklių pagrindu ekspertiškai suformuoti vertinimo modeliai. Tačiau norėdamos kuo tiksliau įvertinti potencialių paskolos gavėjų kredito riziką, unijos turėtų pradėti taikyti statistinius kredito rizikos vertinimo modelius per kuo trumpesnę laiką.

Brandos etape socialinis kontrolės elementas būna dingęs arba itin nereikšmingas, tad turėtų būti taikomi statistiniai kredito rizikos vertinimo metodai.

3. Statistinio kredito rizikos vertinimo modelio sudarymas yra kompleksinis procesas, kuris gali būti suskirstytas į šešis žingsnius: 1) modelio sudarymo poreikio ir galimybių analizė, 2) statistinės imties formavimas, 3) priklausomo kintamojo apibrėžimas, 4) nepriklausomų kintamųjų apibrėžimas, 5) modelio sudarymas, 6) modelio kiekybinių ir kokybinių savybių įvertinimas.
 - a. Disertacijoje praplėstas pirmas modelio kūrimo žingsnis ir pasiūlyta *teorinė modelio kūrimo koncepcija*, leidžianti įvertinti statistinio modelio sudarymo galimybes, parinkti modelio kūrimo metodus ir modeliui kurti naudojamus duomenis atliekant analizę iš trijų perspektyvų: kreditoriaus, išorinių veiksnių ir prognozuojamo segmento. Atliekant analizę iš *kreditoriaus perspektyvos*, nustatomas kreditoriaus tikslinis kreditavimo segmentas, įvertinama vidinė informacinė infrastruktūra bei turimi ŽTF ištekliai, nagrinėjama kreditavimo politika bei tiriamas paskolų portfelis. Atliekant analizę iš *išorės veiksnių perspektyvos*, tiriama išorinė informacinė infrastruktūra, reguliaciniai reikalavimai bei įvertinama konkurencinė aplinka. Atliekant analizę iš *prognozuojamo segmento perspektyvos*, nagrinėjamo binarinio įvykio kontekste nustatomi galimi diskriminuojantys kintamieji bei įvertinama būdinga elgsena. Disertacijoje parodyta, kad taikomi metodai ir naudojami duomenys lemia pagrindines sudaromo modelio charakteristikas: diskriminacinę galią analizuojamo segmento atžvilgiu, modelio rezultatų paaiškinamumą, rizikos tolerancijos lygį,

atitikimą kreditoriui galiojantiems reguliaciniams reikalavimams bei kitiems kreditoriaus verslo poreikiams.

- b. *Priklausomo kintamojo apibrėžimas* kredito rizikos vertinimo kontekste yra vadinamas „blogos“ paskolos apibrėžimu. Apibrėžiant „blogą“ paskolą, atsakoma į du klausimus: *pirma*, koks požymis ar požymių rinkinys galėtų charakterizuoti analizuojamą paskolą kaip „blogą“; *antra*, koks yra optimalus paskolos stebėjimo laikotarpis. Dažniausiai pagrindiniu „blogos“ paskolos požymiu pasirenkami įvairūs paskolos sutarties nevykdymo požymiai: bankrotas, nemokumas ar užsitęsęs mokėjimo vėlavimas. Darbe atliktos mokslinės literatūros analizė parodė, kad dažniausiai taikomas „blogos“ paskolos apibrėžimas yra mokėjimo vėlavimas 90 dienų. Toks maksimalus mokėjimo vėlavimo toleravimo terminas yra nurodomas ir Bazelio bankų priežiūros dokumentuose. Dažniausiai taikomas statistinis „blogo“ skolininko apibrėžimo metodas – Markovo migracijų matrica. Optimalaus paskolos stebėjimo laikotarpio nustatymo tikslas – nustatyti tokį stebėjimo laikotarpį, per kurį vidutinis pasirinkto paskolų segmento vidutinis vėlavimo dienų skaičius sparčiai auga. Dažniausiai norint pasiekti šį tikslą, taikoma kohortų analizė.
- c. *Nepriklausomų kintamųjų atrinkimas* atliekamas trim etapais. *Pirma*, sudaromas galimų naudoti kintamųjų sąvadas. Šiame etape dažniausiai taikomi bendramoksliniai tyrimo metodai. *Antra*, atliekama rodiklių analizė, kurios metu pašalinami žemos diskriminacinės galios ir tarpusavyje susiję kintamieji. Šiame etape plačiausiai naudojami filtrų metodai, leidžiantys įvertinti kintamųjų individualią diskriminacinę galią bei tarpusavio priklausomybę. *Trečia*, sudaromas optimalus nepriklausomų rodiklių rinkinys, kuris įtraukiamas į galutinį modelį. Šiame etape daugiausiai naudojama šalinamoji arba įtraukiančioji regresija.
- d. *Sudarant modelį* pasirenkamas ir taikomas klasifikavimo metodas. Mokslinėje literatūroje *klasifikavimo metodai* dažniausiai grupuojami į statistinius ir dirbtinio intelekto. Darbe nustatyta, kad dažniausiai taikomi klasifikavimo metodai yra diskriminantinė analizė, logistinė regresija,

neuronų tinklai ir sprendimų medžiai. Darbe aptartos šių metodų teorinės prieigos.

- e. *Modelio diskriminacinės galios įvertinimo metodai* gali būti išskiriami į dvi rūšis: *įvertinimo atsižvelgiant į lūžio tašką* ir *įvertinimo neatsižvelgiant į lūžio tašką*. Pirmai metodų rūšiai priskiriami grafiniai metodai: gavėjų charakteristikų kreivė (ROC), kaupiamojo tikslumo kreivė (CAP). Su šiais grafiniais metodais susiję rodikliai: plotas po gavėjų charakteristikų kreive (AUC), teisingo klasifikavimo rodiklis (AR), Gini indeksas, Pietra indeksas. Darbe atskleista, kad šie įvertinimo metodai yra susiję tiesiniais ryšiais. Prie *įvertinimo metodų pasirinkus lūžio tašką* priskirtini įvairūs klasifikavimo tikslumo įvertinimo rodikliai, kurie apskaičiuojami pagal klasifikavimo matricos duomenis. Šie modelio įvertinimo metodai taikomi atliekant išankstinį ir grįžtamąjį modelio įvertinimą.
 - f. Siekiant *nustatyti optimalų lūžio tašką*, mokslinėje literatūroje išskiriamos dvi metodų rūšys: pagrįstieji klasifikavimo tikslumo analize ir pagrįstieji ekonominės naudos optimizavimo analize. Dėl nuostolių dydžio skirtumo dėl pirmo ir antro tipo klasifikavimo klaidų, kredito rizikos vertinimo atveju ekonominės naudos maksimizavimo metodai yra tinkamesni.
4. Siekiant sukurti kredito rizikos vertinimo modelį, atitinkantį Lietuvos kredito unijų poreikius, atlikta išsami Lietuvos kredito unijų sektoriaus analizė. *Pirmiausia* išanalizuotas Lietuvos kredito unijų sektorius, jo struktūra bei kredito unijų verslo paskolų portfelis, identifikuotos problemos, su kuriomis susiduria kredito unijos vertindamos juridinių asmenų kredito riziką. *Antra*, atlikta kredito unijų apklausa. Apklausos metu nustatyti kredito unijų reikalavimai bendroms kredito rizikos vertinimo modelio savybėms bei išanalizuoti sunkumai tobulinant esamą ir / ar kuriant naują kredito rizikos vertinimo modelį.
- a. Atlikta *sektoriaus struktūros analizė* leido padaryti dvi išvadas. *Pirma*: kredito unijos yra nehomogeniškos, matyti ženklūs skirtumai – jos veikia skirtingų dydžių rinkose, turi skirtingą turto struktūrą, laikosi skirtingų turto valdymo strategijų bei reikšmingai skiriasi jų dydžiai – tiek paskolų

portfelių, tiek ir turto apskritai. *Antra*, dauguma Lietuvos kredito unijų yra mažos pagal savo valdomo turto ir paskolų portfelio dydžius. Nors didžioji dalis kredito unijų veikia mažose rinkose, o kredito unijos Lietuvoje veikia pagal teritorinį principą, matyti, kad tai nėra pagrindinis veiksnys, trukdantis kredito unijų vystymuisi, nes nemaža dalis vidutinio dydžio ir didelėse rinkose veikiančių kredito unijų taip pat yra mažos (tiek turto, tiek valdomų paskolų portfelio požiūriu). Tokia situacija Lietuvos kredito unijų sektoriuje leidžia daryti prielaidą, kad kredito unijos susiduria su sunkumais pereidamos nuo socialiai orientuoto prie verslo veiklos modelio.

- b. Kredito unijų *verslo paskolų portfelio analizė* parodė, kad mažose rinkose veikiančių kredito unijų paskolų portfeliai yra ženkliai kokybiškesni, nei vidutinėse ir didelėse rinkose. Šie rezultatai leidžia teigti, kad mažose rinkose socialinis kontrolės elementas veikia efektyviau, o veiklai plečiantis už bendruomenės ribų, jis silpsta. Tai patvirtina statistinių kredito rizikos vertinimo modelių poreikį kredito unijoms plečiant veiklą už bendruomenės ribų. Šios analizės rezultatas leidžia apibrėžti kredito unijų naudojamo kredito rizikos vertinimo modelio ribotumą – modelis nėra tinkamas naudoti vidutinio ir didelio dydžio rinkose veikiančių kredito unijų veikloje. Pažymėtina ir tai, kad kredito unijų naudojamas modelis neatitinka Bazelio bankų priežiūros komiteto rekomendacijų dėl išskirtino rangų kiekio skalėje.
- c. Atlikta kredito unijų *tikslinių kreditavimo segmentų bei jų problemiško analizė* atskleidė, kad daugiausiai sunkumų vertindamos kredito riziką kredito unijos patiria analizuodamos fizinių asmenų bei verslo subjektų paskolų paraiškas. Šie rezultatai leidžia preziumuoti, kad statistinio kredito rizikos vertinimo modelio naudojimas kredito unijų veikloje supaprastintų paraiškų analizės procesą bei darytų teigiamą įtaką kredito unijų veiklos efektyvumui. Kredito unijų tikslinių kreditavimo segmentų analizės rezultatai leidžia motyvuotai apibrėžti tikslinį modeliavimo segmentą – mažas ir labai mažas įmones, taip, kaip jos apibrėžiamos LT Smulkiojo ir vidutinio verslo plėtros įstatyme (1998, Nr. 109-2993).

- d. Atlikus kredito unijų *verslo poreikių ir reikalavimų kuriamam modeliui tyrimą*, nustatyta, kad tobulindamos naudojamą ir / ar kurdamos naują modelį, kredito unijos patiria daugiausiai sunkumų dėl ribotų ŽTF išteklių ir valdymo organų politinės valios stokos. Buvo nustatyti kredito unijų reikalavimai kuriamam modeliui: aukšta diskriminacinė galia, modelio rezultatų paaiškinamumas ir prieinamos išorinės informacijos įtraukimas (nepriklausomų kintamųjų forma) į modelio sudarymą, įskaitant finansinę ir nefinansinę informaciją.
5. Atsižvelgus į kredito unijų veiklos problematiką ir nustatytus kredito unijų poreikius bei reikalavimus kredito rizikos vertinimo modeliui, parinkti modelio sudarymo metodai ir suformuota modelio kūrimo imtis.
- a. Remiantis LR Kredito unijų įstatymu, atlikta Lietuvos kredito unijų apklausa. Atsižvelgus į maksimalią galimą vienos paskolos sumą, kurią kredito unijos gali suteikti vienam nariui, modeliui kurti pasitelkta mažų ir labai mažų įmonių imtis.
- b. *Priklausomas kintamasis* apibrėžtas pagal nustatytą blogos paskolos apibrėžimą kredito unijų sektoriuje. Lietuvos kredito unijų sektoriaus apklausa atskleidė, kad „blogos“ paskolos apibrėžimui dažniausiai taikomas bruožas yra paskolos įmokos vėlavimas (DPD). Apibendrinant atliktą analizę, galima teigti, kad didžiausia dalis respondentų kaip pagrindinį „blogos“ paskolos požymį traktuoja 90 arba 60 dienų mokėjimo vėlavimą. Atsižvelgus į tai, kad tiriamas kredito unijų segmentas pasirodė esąs nehomogeniškas „blogos“ paskolos apibrėžimo atžvilgiu, nustatant „blogos“ paskolos apibrėžimą pasitelkti statistiniai metodai: Markovo grandinės ir kohortos. Statistinė analizė atlikta LCKU verslo paskolų portfelio imtyje. Nustatyta, kad „blogu“ skolininku tikslinga laikyti įmonę, kuri per 24 mėnesių stebėjimo laikotarpį bankrutavo arba kuriam nors kreditoriui (pagal turimus duomenis) vėlavo sumokėti ilgiau, nei 90 kalendorinių dienų, o bendra vėluojama sumokėti suma sudarė 2000 ar daugiau eurų, atitinkamai bendras vėluojamų sumokėti skolų kiekis sudarė dvi arba daugiau skolų.

- c. Atlikus papildomą „gerų“ įmonių imties patikrą autoriaus pasiūlytu metodu, nustatyta, kad dauguma „gerų“ įmonių imties neturėtų būti laikoma tokia. Šie tyrimo rezultatai leidžia teigti, kad reikšminga dalis įmonių, kurioms kredito unijų suteiktos paskolos tampa neveiksniomis, nebankrutuoja. Šie rezultatai taip pat leidžia teigti, kad mažų ir labai mažų įmonių segmentas sudaro atskirą homogeninę rizikos grupę, kurią įvertinti būtini kiti specifiniai kredito rizikos įvertinimo metodai, nei iki šiol siūlyti mokslinėje ir profesinėje literatūroje.
- d. Papildomos „gerų“ įmonių imties patikros rezultatų pagrindu *formuojant modelio kūrimo imtį* taikytas modifikuotas „geros“ įmonės apibrėžimas. Iš modelio kūrimo imties pašalintos tos įmonės, kurios neatitiko nustatytų „gerų“ ir „blogų“ įmonių apibrėžimų. Apskaičiuota, kad suformuota modelio sudarymo imtis leidžia prognozuoti PD su 95 % tikimybe bei 7 % paklaida.
- e. Galimų naudoti *neriklausomų kintamųjų* sąvadas suformuotas iš dviejų dalių. Pirma, atlikus išsamią mokslinės ir profesinės literatūros analizę, suformuotas galimų naudoti finansinių nepriklausomų kintamųjų rinkinys. Antra, išanalizavus kredito unijų išorinę informacinę infrastruktūrą, parinkti nefinansiniai kintamieji. Sujungus nustatytus finansinius ir nefinansinius rodiklius, suformuotas galimų naudoti nepriklausomų kintamųjų sąvadas.
- f. Atsižvelgus į tikėtiną *klasifikatorių* tikslumą, taikymo dažnumą, modelio rezultato paaiškinamumo galimybes bei galiojančius teisės aktus, sudarant statistinį įmonių kredito rizikos vertinimo modelį pasirinktas logistinės regresijos metodas.
- g. Atsižvelgus į veiklos pelningumo svarbą kredito unijų veikloje, lūžio taško nustatymui pasirinktas Maksimalaus tikėtino pelno metodas (EMP). Rangų skalė pasirinkta formuoti atsižvelgus į nustatytą lūžio tašką ir laikantis Bazelio bankų priežiūros komiteto rekomendacijų.
- h. Atliekant modelio įvertinimą, daugiausiai dėmesio skirta toms modelio savybėms, kurios kredito unijų įvardytos kaip svarbiausios. Išsamiai įvertinta modelio ekonominė veikimo logika, diskriminacinė galia, rezultatų

paaškinamumas bei galimybė modelį taikyti automatiniu ar pusiau automatiniu režimu.

6. Logistinės regresijos pagrindu sukurtas įmonių kredito rizikos vertinimo modelis, skirtas Lietuvos kredito unijoms. Išankstinis modelio įvertinimas parodė, kad į modelio sudarymą įtraukti kintamieji pasižymi stipria diskriminacine galia ir yra statistiškai reikšmingi. Ekonominės logikos prasme pasirinkti kintamieji laikytini reikšmingais, nes analizuoja svarbiausias įmonių veiklos sritis bei apima tiek finansinius, tiek ir nefinansinius rodiklius.
 - a. Nustatyta, kad Lietuvos kredito unijos, taikydamos sukurtą modelį, tikėtina, maksimizuotų įmonių kreditavimo veiklos pelną nustačiusios lūžio tašką $T=0,48$.
 - b. Modelio rangų skalė suformuota iš 10 rangų, 6, tikėtina, įsipareigojimus vykdysiančioms įmonėms, 3, tikėtina, nevykdysiančioms ir 1 (10-as) – faktiškai nemokioms įmonėms. Tokia rangų skalės sudarymo metodika atitinka Bazelio bankų priežiūros komiteto rekomendacijas.
7. Apibendrinus sudaryto modelio taikymo ir grįžtamojo įvertinimo rezultatus, galima tvirtinti, kad modelio diskriminacinė galia vertintina kaip puiki. Atlikus modelio tinkamumo naudoti kredito unijų veikloje analizę, matyti, jog modelis sukurtas atlikus išsamų kompleksinį kredito unijų sektoriaus tyrimą. Modelio kūrimo metodai parinkti įvertinus kreditoriaus veiklos specifiškumą, rizikos toleranciją bei taikomus reguliacinius reikalavimus. Modelio kūrimo imtis suformuota atsižvelgus į kreditoriaus tikslinį kreditavimo segmentą bei atitinka modeliuojamą homogeninę grupę. Modelio kintamieji parinkti atlikus išsamią mokslinės ir profesinės literatūros analizę bei įvertinus jų praktinio taikymo galimybes tiriant kredito unijų išorinę informacinę infrastruktūrą. Modelio diskriminacinė galia įvertinta statistiškai bei palyginta su naujausių mokslinių tyrimų rezultatais. Kaip papildomas tyrimo rezultatas, darbe pateikta sukurto modelio taikymo metodika.

Literatūra

1. ABDOU, H., EL-MASRY, A., POINTON, J. (2007). On the applicability of credit scoring models in Egyptian banks. *Banks and Bank Systems*, vol. 2, no. 1, p. 4-20.
2. ABELLÁN, J., MANTAS, C. J. (2014). Improving experimental studies about ensembles of classifiers for bankruptcy prediction and credit scoring. *Expert Systems with Applications*, vol. 41, no. 8, p. 3825-3830.
3. AKKOÇ, S. (2012). An empirical comparison of conventional techniques, neural networks and the three stage hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) model for credit scoring analysis: The case of Turkish credit card data. *European Journal of Operational Research*, vol. 222, no. 1, p. 168-178.
4. ALTMAN, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, vol. 23, no. 4, p. 589-609.
5. ALTMAN, E. I. (2000). Predicting financial distress of companies: revisiting the Z-score and ZETA models. *Stern School of Business, New York University*. [Interaktyvus, žiūrėta 2014 gruodžio 3 d.] Prieiga per internetą: <http://lemeunier.gilbert.free.fr/Investissement/DOCS/PDF/Zscores.pdf>.
6. ALTMAN, E. I., HOTCHKISS, E. (2006). *Corporate Financial Distress and Bankruptcy*. John Wiley & Sons, Inc. ISBN: 0-471-69189-5.
7. ALTMAN, E. I., SABATO, G. (2007). Modeling Credit Risk for SMEs: Evidence from U.S. Market. *ABACUS*, vol. 43, no. 3, p. 332-357.
8. ALTMAN, E. I., SAUNDERS, A. (1998). Credit risk measurement: Developments over the last 20 years. *Journal of banking and finance*, vol. 21, no. 11, p. 1721-1742.
9. American Banking Association (2010). *Credit Unions: A Changing Industry*. Discussion paper. [Interaktyvus, žiūrėta 2015 m. birželio 19 d.] Prieiga per internetą: <http://www.aba.com/Issues/CUdocs/CreditUnionsAChangingIndustry100202.pdf>
10. AMMANN, M. (2001). *Credit risk valuation*. Methods, models and applications. Springer Finance. ISBN: 978-3-540-67805-2.
11. ANDERSON, R. (2007). *The Credit Scoring Toolkit: Theory and Practice for Retail Credit Risk Management and Decision Automation*. Oxford University Press. New York. ISBN: 978-0-19-922640-5.
12. ANGELINI, E., TOLLO, G., ROLI, A. (2008). A neural network approach for credit risk evaluation. *The Quarterly Review of Economics and Finance*, vol. 48, no. 4, p. 733-755.
13. ASH, D., MEESTER, S. (2002). Best practices in reject inference. Presentation at Credit Risk modeling and Decision Conference. *Wharton Financial Institutions Center, Philadelphia, May*.
14. ATIYA, A. F. (2001). Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Results. *IEEE Transactions on Neural Networks*, vol. 12, no. 4, p. 929-935.
15. Audito ir apskaitos tarnybos direktoriaus įsakymas dėl 2-ojo verslo apskaitos standarto „Balansas“ tvirtinimo (2015). *TAR* nr. 9638.

16. AUSTIN, P. C., TU, J. V. (2004). Automated variable selection methods for logistic regression produced unstable models for predicting acute myocardial infarction mortality. *Journal for clinical epidemiology*, vol. 57, no. 11, p. 1138-1146.
17. BAARDA, J. R. (2006). Current issues in cooperative finance and governance. *USDA, Cooperative Programs Rural Development*, vol. 12.
18. BANASIK J., CROOK J. (2004). Does reject inference really improve the performance of application scoring models? *Journal of Banking & Finance*, vol. 28, no. 4, p. 857-874.
19. BANK FOR INTERNATIONAL SETTLEMENTS (2001). *The internal-rating basel approach*. Basel Committee on Banking Supervision. [Interaktyvus, žiūrėta 2014 m. liepos 2 d.]. Prieiga per internetą: <https://www.bis.org/publ/bcbsca05.pdf>.
20. BANK FOR INTERNATIONAL SETTLEMENTS (2004). *International convergence of capital measurement and capital standards: a revised framework*. Basel Committee on Banking Supervision. [Interaktyvus, žiūrėta 2014 m. gruodžio 21 d.]. Prieiga per internetą: <http://www.bis.org/publ/bcbs128.pdf>.
21. BANK FOR INTERNATIONAL SETTLEMENTS (2005). *Update on work of the Accord Implementation Group related to validation under the Basel II Framework*. Basel Committee on Banking Supervision. [Interaktyvus, žiūrėta 2016 m. gruodžio 20 d.]. Prieiga per internetą: http://www.bis.org/publ/bcbs_nl4.pdf.
22. BANK FOR INTERNATIONAL SETTLEMENTS (2005a). *Studies on the Validation of Internal Rating Systems*. Basel Committee on Banking Supervision. [Interaktyvus, žiūrėta 2016 m. gruodžio 20 d.]. Prieiga per internetą: http://www.bis.org/publ/bcbs_wp14.pdf.
23. BANK FOR INTERNATIONAL SETTLEMENTS (2008). *Principles for sound liquidity risk management and supervision*. Bank for international settlements. Basel Committee on Banking Supervision. [Interaktyvus, žiūrėta 2017 m. kovo 7 d.]. Prieiga per internetą: <http://www.bis.org/publ/bcbs144.pdf>.
24. BANK FOR INTERNATIONAL SETTLEMENTS (2013). *Principles for effective risk data aggregation and risk reporting*. Basel Committee on Banking Supervision. [Interaktyvus, žiūrėta 2017 m. kovo 7 d.]. Prieiga per internetą: <http://www.bis.org/publ/bcbs239.pdf>.
25. BANK FOR INTERNATIONAL SETTLEMENTS (2016). *Minimum capital requirements for market risk*. Basel Committee on Banking Supervision. [Interaktyvus, žiūrėta 2017 m. kovo 7 d.]. Prieiga per internetą: <http://www.bis.org/bcbs/publ/d352.pdf>.
26. BAUER, K. (2008). Detecting abnormal credit union performance. *Journal of Banking & Finance*, vol. 32, no. 4, p. 573-586.
27. BECK R., JAKUBIK P., PILOIU A. (2013). Non-Performing Loans. What Matters in Addition to the Economic Cycle. *Working Paper Series*, no. 1515, p. 1-34. European Central Bank.
28. BEKHET, H., ELETTER, S. (2014). Credit risk assessment model for Jordanian commercial banks: Neural scoring approach. *Review of Development Finance*, vol. 4, no. 1, p. 20-28.
29. BEN-DAVID, A., FRANK, E. (2009). Accuracy of machine learning models versus “hand crafted” expert systems—a credit scoring case study. *Expert Systems with Applications*, vol. 36, no. 3, p. 5264-5271.

30. BENDENDO, M., BRUNO, B. (2012). Credit risk transfer in U. S. commercial banks: What changed during the 2007-2009 crisis? *Journal of Banking & Finance*, vol. 36, no. 12, p. 3260-3273.
31. BIJAK, K., THOMAS, L. C. (2012). Does segmentation always improve model performance in credit scoring? *Expert Systems with Applications*, vol. 39, no. 3, p. 2433-2442.
32. BIRKENMAIER, J., CURLEY, J. (2009). Financial credit: Social work's role in empowering low-income families. *Journal of Community Practice*, vol. 17, no. 3, p. 251-268.
33. BIVAINIS, J., GARŠKAITĖ, K. (2010). Įmonių bankroto grėsmės diagnostikos sistema. *Verslas: teorija ir praktika*, vol. 11, no. 3, p. 204-212.
34. BLACK, J., HASHIMZADE, N., MYLES, G. (2009). *Oxford Dictionary of Economics*. Oxford University Press. ISBN: 9780199237043.
35. BLANCO, A., PINO-MEJÍAS, R., LARA, J., RAYO, S. (2013). Credit scoring models for the microfinance industry using neural networks: Evidence from Peru. *Expert Systems with Applications*, vol. 40, no. 1, p. 356-364.
36. BLOEM, A. M., FREEMAN, R. (2005). The Treatment of Nonperforming Loans. *Issue paper Prepared for the July 2005 Meeting of the Advisory Expert Group on National Accounts, Fondo Monetario International*. [Interaktyvus, žiūrėta 2017 m. gegužės 13 d.]. Prieiga per internetą: <https://www.imf.org/external/pubs/ft/bop/2005/05-29.pdf>.
37. BLUM, A. L., LANGLEY, P. (1997). Selection of Relevant features and examples in machine learning. *Artificial Intelligence*, vol. 97, no. 1, p. 245-271.
38. BOGUSLAUSKAS, V., MILERIS, R. (2009). Estimation of credit risk by artificial neural networks models. *Engineering economics*, 64 (4), p. 7-14.
39. BOLON-CANEDO, V., SANCHEZ-MARONO, N., ALONSO-BETANZOS, A. (2013). A review of feature selection methods on synthetic data. *Knowledge and information systems*, vol. 34, no. 3, p. 483-519.
40. BOLTON, C. (2009). *Logistic regression and it's application in credit scoring*. Doctoral dissertation, university of Pretoria. [Interaktyvus, žiūrėta 2017 m. gegužės 13 d.]. Prieiga per internetą: <http://repository.up.ac.za/bitstream/handle/2263/27333/dissertation.pdf?sequence=1&isAllowed=y>.
41. BORZAGA, C., SPEAR, R. (2004). *Trends and challenges for Co-operative and Social Enterprises in developed and transition countries*. Trento, Italy. ISBN: 88-88224-19-4.
42. BRAVO, C., MALDONADO, S., WEBER, R. (2013). Granting and managing loans for micro-entrepreneurs: New developments and practical experiences. *European Journal of Operational Research*, 227(2), p. 358-366.
43. BREIMAN, L., FRIEDMAN, J., STONE, C. J., OLSHEN, R. A. (1984). *Classification and regression trees*. CRC press. ISBN: 978-0412048418.
44. BROWN, I., MUES, C. (2012). An experimental comparison of classification algorithms for imbalanced credit scoring data sets. *Expert Systems with Applications*, vol. 39(3), p. 3446-3453.
45. BUBNYS, S., KAUPELYTĖ, D. (2004). 15. Development of co-operative enterprises in Lithuania. *Trends and challenges for co-operatives and social enterprises in development and transition countries*, p. 253-280. ISBN: 88-88224-19-4.

46. BÜCKER, M., VAN KAMPEN, M., KRÄMER, W. (2013). Reject inference in consumer credit scoring with nonignorable missing data. *Journal of Banking & Finance*, 37(3), p. 1040-1045.
47. BUDRIKIENĖ, R., PALIULYTĖ, I. (2012). Bankroto prognozavimo modelių pritaikomumas skirtingo mokumo ir pelningumo įmonėms. *Ekonomika ir vadyba: aktualijos ir perspektyvos*, vol. 2, no. 26, p. 90-103.
48. BURGER, A., DACIN, T. (1992). *Field of membership: an evolving concept*. Center for Credit Union Research, The School of Business, University of Wisconsin-Madison. ISBN: 1-880572-02-8.
49. BURSET, M., GUIGO, R. (1996). Evaluation of gene structure prediction programs. *Genomics*, vol. 34(3), p. 353-367.
50. BUTKUS, M., ŽAKARĖ, S., CIBULSKIENĖ, D. (2014). Bankroto diagnostikos modelis ir jo pritaikymas bankroto tikimybei Lietuvos įmonėse prognozuoti. *Taikomoji ekonomika: sisteminiai tyrimai*, vol. 8/1, p. 111-132.
51. BUŽIUS, G., DANĖNAS, P., GARŠVA, P. (2010). Credit risk evaluation using SVM and Bayesian classifiers. *Proceedings of the 15th Master and PhD conference*, p. 88-93.
52. BYANJANKAR, A., HEIKKILÄ, M., MEZEI, J. (2015). Predicting credit risk in peer-to-peer lending: A neural network approach. In *Computational Intelligence, 2015 IEEE Symposium Series on*, p. 719-725. IEEE.
53. CARDOSO, D. O., CARVALHO, D. S., ALVES, D. S., SOUZA, D. F., CARNEIRO, H. C., PEDREIRA, C. E., LIMA, P. M., FRANCA, F. M. (2016). Financial credit analysis via a clustering weightless neural classifier. *Neurocomputing*, vol. 183, p. 70-78.
54. CATANIA, C. A., GARINO, C. (2012). Automatic network intrusion detection: Current techniques and open issues. *Computers & Electrical Engineering*, vol. 38, no. 5, p. 1062-1072.
55. CATENI, S., VANNUCCI, M., VANNOCCI, M., COLLA, V. (2012) Variable Selection and Feature Extraction Through Artificial Intelligence Techniques. *Multivariate Analysis in Management, Engineering and Science*, p. 103-117.
56. CATTURANI, I., STEFANI, M. L. (2016). Italian Credit Cooperative Banks. In *Credit Cooperative Institutions in European Countries*, p. 149-167. Springer International Publishing.
57. ČEKANAVICIUS, V. (2011). *Taikomoji regresinė analizė socialiniuose tyrimuose*. Kaunas: KTU.
58. ČEKANAVIČIUS, V., MURAUSKAS, G. (2000). *Statistika ir jos taikymai*. Vilnius, TEV, 239. ISBN: 9986-546-93-1.
59. CHAMBERS, C., RYDER, N. (2008). The funding of credit unions – where has all the money gone? *Journal of Social Welfare and Family Law*, vol. 30(3), p. 243-252.
60. CHANG, S. Y., YEH, T. Y. (2012). An artificial immune classifier for credit scoring analysis. *Applied Soft Computing*, vol. 12 (2), p. 611-618.
61. CHEN, C. C., LI, S. T. (2014). Credit rating with a monotonicity-constrained support vector machine model. *Expert Systems with Applications*, vol. 41(16), p. 7235-7247.
62. CHEN, D. H., CHOU, H. C., WANG, D., ZAABAR, R. (2011). The predictive performance of a path-dependent exotic-option credit risk model in the emerging market. *Physica A: Statistical Mechanics and its Applications*, vol. 390 (11), p. 1973-1981.

63. CHEN, G., ÅSTEBRO, T. (2003). Bound and collapse Bayesian reject inference when data are missing not at random. *Mathematical Approaches to Credit Risk Management: Conference Proceedings. Banff International Research Station for Mathematical Innovation and Discovery: Banff, Alberta*.
64. CHEN, N., RIBEIRO, B., VIEIRA, A., CHEN, A. (2013). Clustering and visualization of bankruptcy trajectory using self-organizing map. *Expert Systems with Applications*, vol. 40 (1), p. 385-393.
65. CHEN, W., DU, Y. (2009). Using neural networks and data mining techniques for the financial distress prediction model. *Expert Systems with Applications*, vol. 36, no. 2, p. 4075-4086.
66. CHEN, W., XIANG, G., LIU, Y., WANG, K. (2012). Credit risk Evaluation by hybrid data mining technique. *Systems Engineering Procedia*, vol. 3, p. 194-200.
67. CHI, B. W., HSU, C. C. (2012). A hybrid approach to integrate genetic algorithm into dual scoring model in enhancing the performance of credit scoring model. *Expert Systems with Applications*, vol. 39 (3), p. 2650-2661.
68. CHOY, M., LAIK, M. (2010). A Markov Chain approach to determine the optimal performance period and bad definition for credit scorecard. *Research Journal of Social Science & Management*, vol. 01, no. 6, p. 227-234.
69. CHUANG, C. L., LIN, R. H. (2009). Constructing a reassigning credit scoring model. *Expert Systems with Applications*, vol. 36 (2), p. 1685-1694.
70. CHYRA-ROLICZ, Z. (2016). The Polish Credit Co-operative System: Historical and Contemporary Experiences. In *Credit Cooperative Institutions in European Countries*, p. 343-362. Springer International Publishing.
71. CLINE, P. B. (2004). The etymology of risk. *Unpublished manuscript. Retrieved January*, vol. 26, p. 2008.
72. COHEN-FREUE, G., CUBRANIC, D. (2015). *Package "riv"*. R package.
73. COLEMAN, T. S. (2011). *A Practical Guide to Risk Management*. The Research Foundation of CFA Institute. ISBN: 978-1-934667-41-5.
74. COMMITTEE ON FOUNDATIONS OF RISK ANALYSIS (2015). *SRA glossary*. [Interaktyvus, žiūrėta 2016 m. spalio 1 d.], prieiga per internetą: <http://www.sra.org/sites/default/files/pdf/SRA-glossary-approved22june2015-x.pdf>.
75. CRONE, S. F., FINLAY, S. (2012). Instance sampling in credit scoring: An empirical study of sample size and balancing. *International Journal of Forecasting*, vol. 28 (1), p. 224-238.
76. CROOK, J. N., EDELMAN, D. B., THOMAS, L. C. (2007). Recent developments in consumer credit risk assessment. *European Journal of Operational Research*, vol. 183 (3), p. 1447-1465.
77. CROUHY, M., GALAI, D., MARK, R. (2014). *The Essentials of Risk Management*. Mc Graw-Hill Education. ISBN: 978-0-07-182115-5.
78. CUBILES-DE-LA-VEGA, M. D., BLANCO-OLIVER, A., PINO-MEJÍAS, R., LARA-RUBIO, J. (2013). Improving the management of microfinance institutions by using credit scoring models based on Statistical Learning techniques. *Expert Systems with Applications*, vol. 40 (17), p. 6910-6917.
79. CULBERTSON, J. T. (1950). *Consciousness and behavior*. Dubuque, Iowa: Wm. C. Brown.

80. DANĖNAS, P. (2013). *Atraminių vektorių mašinomis grindžiami klasifikavimo metodai intelektualioje sprendimų paramos sistemoje kredito rizikos vertinimui*. Daktaro disertacija, Vilniaus universitetas.
81. DANENAS, P., GARSVA, G. (2009). Support vector machines and their application in credit risk evaluation process. *Transformations in Business & Economics*, vol. 8(3), p. 46-58.
82. DANENAS, P., GARSVA, G. (2010). Credit risk evaluation using SVM-based classifier. In *International Conference on Business Information Systems*, p. 7-12. Springer Berlin Heidelberg.
83. DANENAS, P., GARSVA, G. (2012). Credit risk evaluation modeling using evolutionary linear SVM classifiers and sliding window approach. *Procedia Computer Science*, vol. 9, p. 1324-1333.
84. DANENAS, P., GARSVA, G. (2015). Selection of support vector machines based classifiers for credit risk domain. *Expert Systems with Applications*, vol. 42 (6), p. 3194-3204.
85. DANENAS, P., GARSVA, G., GUDAS, S. (2011). Credit risk evaluation model development using support vector based classifiers. *Procedia Computer Science*, vol. 4, p. 1699-1707.
86. DANĖNAS, P., GARŠVA, G., SIMUTIS, R. (2011a). Development of Discriminant Analysis and Majority-Voting Based Credit Risk Assessment Classifier. *Proceedings of the 2011 international Conference on Artificial Intelligence, ICAI*, vol. 1, p. 204-209.
87. Darzentas, N. (2010). Circoletto: visualizing sequence similarity with Circos. *Bioinformatics*, vol. 26 (20), p. 2620-2621.
88. DAVEY, H., JONES, A., SHAW A., KELL, D. (1999). Variable Selection and Multivariate Methods for the Identification of Microorganisms by Flow Cytometry. *Cytometry*, vol. 35, no. 2, p. 162-168.
89. DAVIS, K. (2001). Credit union governance and survival of the cooperative form. *Journal of financial services research*, vol. 19 (2), p. 197-210.
90. DE ANDRÉS, J., LANDAJO, M., LORCA, P. (2012). Bankruptcy prediction models based on multinorm analysis: An alternative to accounting ratios. *Knowledge-Based Systems*, vol. 30, p. 67-77.
91. DE ANDRES, J., LORCA, P., COS, JUES, F., SANCHEZ-LASHERAS, F. (2011). Bankruptcy forecasting: A hybrid approach using Fuzzy c-means clustering and Multivariate Adaptive Regression Splines (MARS). *Expert Systems with Application*, vol. 38, no. 3, p. 1866-1875.
92. DERELIOĞLU, G., GÜRGEN, F. (2011). Knowledge discovery using neural approach for SME's credit risk analysis problem in Turkey. *Expert Systems with Applications*, vol. 38 (8), p. 9313-9318.
93. DESAI, V. S., CROOK, J. N., OVERSTREET, G. A. (1996). A comparison of neural networks and linear scoring models in the credit union environment. *European Journal of Operational Research*, vol. 95 (1), p. 24-37.
94. DIMITRAS, A. I., SLOWINSKI, R., SUSMAGA, R., ZOPOUDNIS, C. (1999). Business failure prediction using rough sets. *European Journal of Operational Research*, vol. 114, no. 2, p. 263-280.
95. DINH, T. H. T., KLEIMEIER, S. (2007). A credit scoring model for Vietnam's retail banking market. *International Review of Financial Analysis*, vol. 16 (5), p. 471-495.
96. DONG, G., LAI, K. K., YEN, J. (2010). Credit scorecard based on logistic regression with random coefficients. *Procedia Computer Science*, vol. 1(1), p. 2463-2468.
97. DUBAUSKAS, G. (2012). Sustainable growth of the financial sector: the case of credit unions. *Journal of Security and Sustainability Issues*, vol. 1(3), p. 159-166.

98. DZIDZEVIČIŪTĖ, L. (2010). Statistinių vertinimo balais modelių kūrimo ir taikymo ypatumai. *Pinigų studijos* 2010/1, p. 35-54.
99. DZIDZEVIČIŪTĖ, L. (2012). Estimation of Default Probability for Low Default Portfolios. *Ekonomika*, 91-1, p. 132-156.
100. DZIDZEVIČIŪTĖ, L. (2013). *Statistinių vertinimo balais modelių taikymo Lietuvos bankuose galimybės*. Daktaro disertacija, Vilniaus universitetas.
101. ENGELMANN, B., HAYDEN, E., TASCHE, D. (2003). *Measuring the discriminative power of rating systems*, No. 2003, 01. Discussion paper, Series 2: Banking and Financial Supervision.
102. ENKE, D., THAWORNWONG, S. (2009). The use of data mining and neural networks for forecasting stock market returns. *Expert Systems with Application*, vol. 29, no. 4, p. 927-940.
103. FADLALLA, A., LIN, C. H. (2001). An analysis of the applications of neural networks in finance. *Interfaces*, vol. 31 (4), p. 112-122.
104. FEELDERS, A. J. (2000). Credit Scoring and Reject Inference With Mixture Models. *International Journal of Intelligent Systems in Accounting, Finance & Management*, vol. 9, p. 1-8.
105. FEELDERS, A. J. (2003). *An Overview of Model Based Reject Inference for Credit Scoring*. Utrecht University, Institute for Information and Computing Sciences.
106. FEI, W., GU, J., YANG, Y., ZHOU, Z. (2015). Credit Risk Evaluation Based on Social Media. *Procedia Computer Science*, vol. 55, p. 725-731.
107. FERGUSON, C., MCKILLOP, D. (2006). Classifying Credit Union Development in Terms of Mature, Transition and Nascent Industry Types. *The Service Industry Journal*, vol. 20(4), p. 103-120.
108. FERNANDES, G., ARTES, R. (2016). Spatial dependence in credit risk and its improvement in credit scoring. *European Journal of Operational Research*, vol. 249 (2), p. 517-524.
109. FINLAY, S. (2009). Are we modelling the right thing? The impact of incorrect problem specification in credit scoring. *Expert Systems with Applications*, vol. 36 (5), p. 9065-9071.
110. FINLAY, S. (2011). Multiple classifier architectures and their application to credit risk assessment. *European Journal of Operational Research*, vol. 210 (2), p. 368-378.
111. FINLAY, S. (2012). *Credit scoring, response modeling, and insurance rating: a practical guide to forecasting consumer behavior*. Palgrave Macmillan. ISBN: 978-0-230-34776-2.
112. FLOREZ-LOPEZ, R., RAMON-JERONIMO, J. M. (2015). Enhancing accuracy and interpretability of ensemble strategies in credit risk assessment. A correlated-adjusted decision forest proposal. *Expert Systems with Applications*, vol. 42 (13), p. 5737-5753.
113. FONTEYNE, M. W. (2007). *Cooperative banks in Europe: Policy issues*, 7-159. International Monetary Fund.
114. FRYDMAN, H., ALTMAN, E. I., KAO, D. L. (1985). Introducing recursive partitioning for financial classification: the case of financial distress. *The Journal of Finance*, vol. 40 (1), p. 269-291.
115. GANGUIN, B., BILARDELLO, J. (2004). *Fundamentals of corporate credit analysis*. McGraw-Hill. ISBN: 978-0071441636.
116. GARCÍA, V., MARQUÉS, A. I., SÁNCHEZ, J. S. (2015). An insight into the experimental design for credit risk and corporate bankruptcy prediction systems. *Journal of Intelligent Information Systems*, vol. 44 (1), p. 159-189.

117. GARŠKAITĖ, K. (2008). Įmonių bankroto prognozavimo modelių taikymas. *Verslas: teorija ir praktika*, vol. 9, no. 4, p. 281-294.
118. GASTINEAU, G. L., KRITZMAN, M. P. (1999). *Dictionary of Financial Risk Management*. 3-rd ed. Swiss Bank Corporation. ISBN: 978-1-883249-57-1.
119. GLANTZ, M., MUN, J. (2010). *Credit Engineering for bankers. A practical guide for bank lending* (2nd ed.). Elsevier Academic Press. 2-nd ed. ISBN: 9780123785855.
120. GLASS, J., MCKILLOP, D., QUINN, B. (2014). Modelling the Performance of Irish Credit Unions, 2002 to 2010. *Financial Accountability & Management*, vol. 30 (4), p. 430-453.
121. GLENNON, D., KIEFER, N. M., LARSON, C. E., CHOI, H. S. (2008). Development and validation of credit scoring models. *Journal of Credit Risk*, vol. 4 (3), p. 41-102.
122. GORZAŁCZANY, M. B., RUDZIŃSKI, F. (2016). A multi-objective genetic optimization for fast, fuzzy rule-based credit classification with balanced accuracy and interpretability. *Applied Soft Computing*, vol. 40, 206-220.
123. GOYAL, K., AGRAWAL, S. (2010). Risk management in Indian banks: some emerging issues. *Int. Eco. J. Res.* 1-1, p. 102-109.
124. GRIFFITHS, G., HOWELS, G. (1991). Slumbering giant or white elephant: Do credit unions have a role in the United Kingdom credit market. *N. Ir. Legal Q.*, 42, p. 199-215.
125. GRIGARAVIČIUS, S. (2003). Corporate Failure Diagnosis. Reliability and Practice. *Organizacijų Vadyba: sisteminiai tyrimai*, vol. 28, p. 29-42.
126. GRIGARAVIČIUS, S. (2003A). *Įmonių nemokumo diagnostika ir jų pertvarkymo sprendimai*. Daktaro disertacija, Vytauto Didžiojo universitetas.
127. GU, Q., LI, Z., HAN, J. (2012). Generalized Fisher score for feature selection. *asXiv preprint arXiv: 1202.3725*, p. 1-7.
128. GUDELYTĖ, L., VALUŽIS, M. (2012). *Rizikos valdymas banke*. Žinynas. Viešoji įstaiga Socialinių mokslų kolegija.
129. GUINNANE, T. (1994). A Failed Institutional Transplant: Raiffeisen's Credit Cooperatives in Ireland, 1894-1914. *Explorations in Economic History*, vol. 31, p. 38-61.
130. GUJARATI, D. N., PORTER, D. (2009). *Basic Econometrics*. Mc Graw-Hill International Edition. ISBN: 978-0-07-337577-9
131. GUPTA, J., WILSON, N., GREGORIOU, A., HEALY, J. (2014). The effect of internationalisation on modelling credit risk for SMEs: Evidence from UK market. *Journal of International Financial Markets, Institutions and Money*, vol. 31, p. 397-413.
132. GURNY, P., GURNY, P. (2013). Comparysion of credit scoring models on probability of default estimation for us banks. *Prague Economic Papers*, vol. 2, p. 163-181.
133. GUYON, I., ELISSEEFF, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*, vol. 3, p. 1157-1182.
134. HADAD, M. D., SANTOSO, W., SANTOSO, B., BESAR, D., RULINA, D. (2008). Rating migration matrices: empirical evidence in Indonesia. *An overview of challenges related to measuring financial innovations*, vol. 26, p. 260-276. [Interaktyvus, žiūrėta 2017 gegužės 12 d.] Prieiga per internetą: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.225.4866&rep=rep1&type=pdf#page=266>

- 135.HAJEK, P., MICHALAK, K. (2013). Feature selection in corporate credit rating prediction. *Knowledge-Based Systems*, vol. 51, p. 72-84.
- 136.HAN, L., HAN, L., ZHAO, H. (2013). Orthogonal support vector machine for credit scoring. *Engineering Applications of Artificial Intelligence*, vol. 26 (2), p. 848-862.
- 137.HAND, D. J. (2009). Measuring classifier performance: a coherent alternative to the area under the ROC curve. *Machine learning*, vol. 77 (1), p. 103-123.
- 138.HAND, D. J., HENLEY, W. E. (1997). Statistical classification methods in consumer credit scoring: a review. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, vol. 160 (3), p. 523-541.
- 139.HARREL, F., LEE, K. (1985). A comparison of the discrimination of discriminant analysis and logistic regression. *Biostatistics: Statistics in Biomedical, Public Health, and Environmental Sciences*. North Holland, Amsterdam.
- 140.HARRIS, T. (2013). Quantitative credit risk assessment using support vector machines: Broad versus Narrow default definitions. *Expert Systems with Applications*, vol. 40 (11), p. 4404-4413.
- 141.HARRIS, T. (2015). Credit scoring using the clustered support vector machine. *Expert Systems with Applications*, vol. 42 (2), p. 741-750.
- 142.HEENAN, D., MCLAUGHLIN, R. (2002). Re-assessing the role of credit unions in community development: a case study of Derry Credit Union, Northern Ireland. *Community development journal*, vol. 37(3), p. 249-259.
- 143.HEITAN, D. F., BASU, S. (1996). Distinguishing „Missing at Random“ and „Missing Completely at Random“. *The American Statistician*, vol. 50, No. 3, p. 207-213.
- 144.HENS, A. B., TIWARI, M. K. (2012). Computational time reduction for credit scoring: An integrated approach based on support vector machine and stratified sampling method. *Expert Systems with Applications*, vol. 39 (8), p. 6774-6781.
- 145.HÖRKKÖ, M. (2010). *The Determinants of Default in Consumer Credit Risk Market*. Master's thesis. Aalto University School of Economics. Master thesis, Aalto University.
- 146.HUANG, Z., CHEN, H., HSU, C., CHEN, W., WU, S. (2004). Credit rating analysis with support vector machines and neural networks: a market comparative study. *Decision Support Systems*, vol. 37, no. 4, p. 543-588.
- 147.IGARYTĖ, J., RAMANAUSKAS, J. (2011). Lietuvos kredito unijų sistemos vystymosi tendencijų ir perspektyvų vertinimas. *Management theory and studies for rural business and infrastructure development*, vol. 28 (4), p. 51-58.
- 148.INTERNATIONAL ORGANIZATION OF STANDARTIZATION (2016). *Risk managament – Principles and guidelines*.
- 149.IONIȚĂ, I., ȘCHIOPU, D. (2010). Using Principal Component Analysis in Loan Granting. *Buletinul Universității Petrol-Gaze din Ploiești*, vol. 62, no. 1, p. 88-96.
- 150.IRWIN, R. J., IRWIN, T. C. (2013). Appraising Credit Ratings: Does the CAP Fit Better than the ROC? *International Journal of Finance & Economics*, vol. 18 (4), p. 396-408.
- 151.JASEVIČIENĖ, F. (2014). *Kredito unijos: teorija ir praktika*. Vilnius: Vilniaus universiteto leidykla. ISBN: 978-609-459-335-2.

152. JASEVIČIENĖ, F., KĖDAITIS, V., NOVICKYTĖ, L. (2015). Kooperatinė bankininkystė prieškario Lietuvoje. *Ekonomika ir vadyba: aktualijos ir perspektyvos*, vol. 36 (1), p. 6-17.
153. JASEVIČIENĖ, F., KĖDAITIS, V., VIDZBELYTĖ, S. (2014). Credit unions activity and factors determining the choice of them in Lithuania. *Ekonomika* 93-1, p. 117-130.
154. JASEVIČIENĖ, F., TAMOŠIŪNIENĖ, R., VIDZBELYTĖ, S. (2015A). Credit Unions Theoretical Aspects and Performance Analysis. *KSI Transactions on KNOWLEDGE SOCIETY*, vol. 8(1), p. 28-34.
155. JASEVIČIENĖ, F., VALVONIS, V. (2003). Paskolų vertinimas: tarptautinė ir Lietuvos praktika. *Pinigų studijos*, 1, p. 23-49.
156. JIMÉNEZ, G., ONGENA, S., PEYDRÓ, J. L., SAURINA, J. (2014). Hazardous Times for Monetary Policy: What Do Twenty-Three Million Bank Loans Say About the Effects of Monetary Policy on Credit Risk-Taking? *Econometrica*, vol. 82 (2), p. 463-505.
157. JONES, P. (2001). *From Small Acorns to Strong Oaks. A study into the development of credit unions in rural England*. Association of British Credit Unions (ABCUL), Manchester. Prieiga per internetą: https://www.ljmu.ac.uk/~media/files/ljmu/research/centres-and-institutes/rufi/r3_from_small_acorns_to_strong_oaks_rural_credit_union_report.pdf?la=en [žiūrėta 2015.07.29].
158. JONES, P. (2004). Growing Credit Unions in the West Midlands – the case for restructuring. *Journal of cooperative studies*, vol. 37 (1), p. 5-21.
159. JONES, P. (2005). Philanthropy and enterprise in British credit union movement. *Economic affairs*, vol. 25(2), p. 13-19.
160. JONES, P. (2008). From tackling poverty to achieving financial inclusion – The changing role of British credit unions in low income communities. *The Journal of Socio-Economics*, vol. 37, p. 2141-2154.
161. JU, Y. H., SOHN, S. Y. (2014). Updating a credit-scoring model based on new attributes without realization of actual data. *European Journal of Operational Research*, vol. 234 (1), p. 119-126.
162. KAMIENAS, I., VALVONIS, V. (2004). Paskolų registro naudojimas kredito rizikai valdyti. *Pinigų studijos*, 1, p. 5-30.
163. KAO, L. J., CHIU, C. C., CHIU, F. Y. (2012). A Bayesian latent variable model with classification and regression tree approach for behavior and credit scoring. *Knowledge-Based Systems*, vol. 36, p. 245-252.
164. KAPLAN, S. (1997). The words of risk analysis. *Risk analysis*, vol. 17 (4), p. 407-417.
165. KARALEVIČIENĖ, J., BUŽINSKIENĖ, R. (2011). Modernių bankroto diagnozavimo modelių taikymas įmonėje. *Vadyba: Journal of Management*, nr. 2 (19), p. 113-122.
166. KAUPELYTĖ, D. (2007). *Kredito unių sistemų funkcionavimas ir vystymo strateginiai sprendimai Europos Sąjungos šalyse*. Daktaro disertacija, Vytauto Didžiojo universitetas.
167. KAUPELYTĖ, D., MCKARTHY, O. (2006). Risk Management in Lithuanian and Irish Credit Unions: Trends and Impacts on Credit Union Development. *Journal of Rural Cooperation*, vol. 34 (2), p. 179-194.
168. KĖDAITIS, V. (2009). *Koreliacinės ir regresinės analizės pagrindai*. Vilnius: VU leidykla. ISBN: 978-955-33-385-2.

- 169.KĖDAITIS, V., ŽILINSKAS, E. (2013). Lietuvos kredito unijų veikos rizikingumo vertinimas. *Lietuvos statistikos darbai*, vol. 52(1), p. 72-86.
- 170.KELLY, R., O'MALLEY, T. (2016). The good, the bad and the impaired: A credit risk model of the Irish mortgage market. *Journal of Financial Stability*, vol. 22, p. 1-9.
- 171.KEYNES, J. M. (1921). *Treatise on Probability*. Macmillan and Co., Limited, London.
- 172.KHANDANI, A. E., KIM, A. J., LO, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, vol. 34 (11), p. 2767-2787.
- 173.KHASHMAN, A. (2010). Neural networks for credit risk evaluation: Investigation of different neural models and learning schemes. *Expert Systems with Applications*, vol. 37 (9), p. 6233-6239.
- 174.KHASHMAN, A. (2011). Credit risk evaluation using neural networks: Emotional versus conventional models. *Applied Soft Computing*, vol. 11(8), p. 5477-5484.
- 175.KHEMRAJ, T., PASHA, S. (2009). The determinants of non-performing loans: An econometric case study of Guyana. *Caribbean Centre for Banking and Finance Bi-annual Conference on Banking and Finance, St. Augustine, Trinidad*.
- 176.KHUSHABA, R. N., AL-ANI, A., AL-JUMAILY, A. (2008, December). Differential evolution based feature subset selection. *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on* , p. 1-4. IEEE.
- 177.KNIGHT, F. H. (1921). *Risk, Uncertainty and Profit*. New York. [Interaktyvus, žiūrėta 2016 m. lapkričio 3 d.] Prieiga per internetą:
https://mises.org/sites/default/files/Risk,%20Uncertainty,%20and%20Profit_4.pdf
- 178.KOLMOGOROV, A. N. (1950). *Foundations of the Theory of Probability*. Oxford, Chelsea Publishing Co.
- 179.KOUTANAEI, F. N., SAJEDI, H., KHANBABAIEI, M. (2015). A hybrid data mining model of feature selection algorithms and ensemble learning classifiers for credit scoring. *Journal of Retailing and Consumer Services*, vol. 27, p. 11-23.
- 180.KOZENY, V. (2015). Genetic algorithms for credit scoring: Alternative fitness function performance comparison. *Expert Systems with Applications*, vol. 42 (6), p. 2998-3004.
- 181.KRUPPA, J., SCHWARZ, A., ARMINGER, G., ZIEGLER, A. (2013). Consumer credit risk: Individual probability estimates using machine learning. *Expert Systems with Applications*, vol. 40 (13), p. 5125-5131.
- 182.KRZYWINSKI, M., SCHEIN, J., BIROL, I., CONNORS, J., GASCOYNE, R., HORSMAN, D., MARRA, M. A. (2009). Circos: an information aesthetic for comparative genomics. *Genome research*, vol. 19 (9), p. 1639-1645.
- 183.KUNGWANI, P. (2014). *Risk-Management – An Analytical Study*. IOSR Journal of Business and Management (IOSR-JBM), 16-3, p. 83-89.
- 184.KUWAHARA, S., YOSHINO, N., SAGARA, M., TAGHIZADEH-HESARY, F. (2015). *Role of the Credit Risk Database in Developing SMEs in Japan: Lessons for the Rest of Asia*. ADBI Working Paper 547. Tokyo: Asian Development Bank Institute. Prieiga per internetą:
<http://www.adb.org/publications/role-credit-risk-database-developing-smes-japan-lessonsrest-asia/>
[žiūrėta 2016 04 24].

- 185.LANDWEHR, N., HALL, M., FRANK, E. (2005). Logistic model trees. *Machine Learning*, vol. 59 (1-2), p. 161-205.
- 186.LAZAR, C., TAMINAU, J., MEGANCK, S., STEENHOFF, D., COLETTA, A., MOLTER, C., SCHAETZEN, V., DUQUE, R., BERSINI, H., NOWE, A. (2012). A Survey on Filter Techniques for Feature Selection in Gene Expression Microarray Analysis. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, vol. 9, no. 4, p. 1106-1119.
- 187.LEE, M. (2009). Using support vector machine with a hybrid feature selection method to the stock trend prediction. *Expert System with Application*, vol. 38, no. 8, p. 10896-10904.
- 188.LEE, T. S., CHEN, I. F. (2005). A two-stage hybrid credit scoring model using artificial neural networks and multivariate adaptive regression splines. *Expert Systems with Applications*, vol. 28 (4), p. 743-752.
- 189.LEE, T. S., CHIU, C. C., LU, C. J., CHEN, I. F. (2002). Credit scoring using the hybrid neural discriminant technique. *Expert Systems with applications*, vol. 23 (3), p. 245-254.
- 190.LEGGET, K. (2014). *Chartering and Field of Membership Manual*. Letter to NCUA. American Bankers Association.
- 191.LENNOX, C. (1999). Identifying failing companies: a re-evaluation of the logit, probit and DA approaches. *Journal of economics and Business*, vol. 51 (4), p. 347-364.
- 192.LEOW, M., CROOK, J. (2014). Intensity models and transition probabilities for credit card loan delinquencies. *European Journal of Operational Research*, vol. 236, no. 2, p. 685-694.
- 193.LEOW, M., CROOK, J. (2016). A new Mixture model for the estimation of credit card Exposure at Default. *European Journal of Operational Research*, vol. 249, no. 2, p. 487-497.
- 194.LESSMANN, S., BAESENS, B., SEOW, H., THOMAS, L. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, vol. 247 (1), p. 124-136.
- 195.LEVIŠAUSKAITĖ, K., KAUPELYTĖ, D. (2003). Credit Unions in Lithuania, their Regional Development and Perspectives. *Organizacijų vadyba: sisteminiai tyrimai*, vol. 26, p. 113-129.
- 196.LI, J., LI, G., SUN, D., LEE, C. F. (2012). Evolution strategy based adaptive L q penalty support vector machines with Gauss kernel for credit risk analysis. *Applied Soft Computing*, vol. 12 (8), p. 2675-2682.
- 197.LI, J., WEI, L., LI, G., XU, W. (2011). An evolution strategy-based multiple kernels multi-criteria programming approach: The case of credit decision making. *Decision Support Systems*, vol. 51 (2), p. 292-298.
- 198.LIETUVOS BANKAS (2012). *Kredito unijų ir Lietuvos Centrinės kredito unijos veiklos apžvalga. 2011 metai*. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <https://www.lb.lt/lt/leidiniai/kredito-uniju-ir-lietuvos-centrines-kredito-unijos-veiklos-apzvalga-2011>.
- 199.LIETUVOS BANKAS (2013). *Kredito unijų ir Lietuvos Centrinės kredito unijos veiklos apžvalga. 2012 metai*. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <https://www.lb.lt/lt/leidiniai/kredito-uniju-ir-lietuvos-centrines-kredito-unijos-veiklos-apzvalga-2012>.

- 200.LIETUVOS BANKAS (2014). *Kredito unijų ir Lietuvos Centrinės kredito unijos veiklos apžvalga. 2013 metai*. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <https://www.lb.lt/lt/leidiniai/kredito-uniju-ir-lietuvos-centrines-kredito-unijos-veiklos-apzvalga-2013>.
- 201.LIETUVOS BANKAS (2015). *Kapitalo stiprinimas - vienas iš svarbiausių kredito unijų uždavinių*. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <http://lb.lt/lt/naujienos/kredito-uniju-sektoriaus-rodikliai-rodo-tvaraus-kapitalo-formavimo-poreiki>.
- 202.LIETUVOS BANKAS (2015). *Kredito unijų ir Lietuvos centrinės kredito unijos veiklos apžvalga. 2014 metai*. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <https://www.lb.lt/lt/leidiniai/kredito-uniju-ir-lietuvos-centrines-kredito-unijos-veiklos-apzvalga-2014>.
- 203.LIETUVOS BANKAS (2015). *Lietuvos bankas kredito unijų atstovams šalies regionuose pristato sektoriaus stiprinimo priemones*.
- 204.LIETUVOS BANKAS (2016). *Kredito unijų ir Lietuvos Centrinės kredito unijos veiklos apžvalga. 2015 metai*. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <https://www.lb.lt/lt/leidiniai/kredito-uniju-ir-lietuvos-centrines-kredito-unijos-veiklos-apzvalga-2015>.
- 205.Lietuvos banko valdybos nutarimas dėl didžiausios paskolos vienam skolininkui ir didelių paskolų apskaičiavimo taisyklių patvirtinimo. *Valstybės žinios*. 2008, Nr. 147-5937.
- 206.Lietuvos banko valdybos nutarimas dėl kapitalo pakankamumo skaičiavimo bendrųjų nuostatų. *Valstybės žinios*. 2006, Nr. 142-5442.
- 207.Lietuvos banko valdybos nutarimas dėl kredito unijų veiklos riziką ribojančių normatyvų apskaičiavimo (2009). *Valstybės žinios*, nr. 42-1651.
- 208.Lietuvos Respublikos centrinių kredito unijų įstatymas (2017). *Valstybės žinios*, 2000-06-02, Nr. 45-1288.
- 209.Lietuvos Respublikos kredito unijų įstatymas (2016). *Valstybės žinios*. 2016, Nr. XII-2567.
- 210.Lietuvos Respublikos smulkiojo ir vidutinio verslo plėtros įstatyme (1998). *Valstybės žinios*. 1998, Nr. VIII-935.
- 211.Lietuvos statistikos departamentas (2011). Lietuvos gyventojų ir būstų surašymo duomenys. [Interaktyvus, žiūrėta 2016 m. kovo 15 d.]. Prieiga per internetą: <https://osp.stat.gov.lt/2011-m.-surasymas>.
- 212.Lietuvos statistikos departamentas (2011). Lietuvos gyventojų skaičius 2015 m. *Lietuva 1991-dabar*. [Interaktyvus, žiūrėta 2016 m. kovo 15 d.]. Prieiga per internetą: [https:// osp.stat.gov.lt/temines-lenteles19](https://osp.stat.gov.lt/temines-lenteles19).
- 213.LIN, S. (2009). A new two-stage hybrid approach of credit risk in banking industry. *Expert Systems with Application*, vol. 36, no. 4, p. 8333-8341.
- 214.LITTLE, R. J. (1988). Missing-data adjustments in large surveys. *Journal of Business & Economic Statistics*, vol. 6 (3), 287-296.
- 215.LITTLE, R. J., RUBIN, D. B. (1989). The analysis of social science data with missing values. *Sociological Methods & Research*, vol. 18 (2-3), p. 292-326.
- 216.LORCA, P., LANDAJO, M., ANDRES, J. (2013). Nanparametric Quantile Regression-Based Classifiers for Bankruptcy Forecasting. *Journal of Forecasting*, vol. 33, no. 2, p. 124-133.

217. LOUZADA, F., FERREIRA-SILVA, P. H., DINIZ, C. A. (2012). On the impact of disproportional samples in credit scoring models: An application to a Brazilian bank data. *Expert Systems with Applications*, vol. 39 (9), p. 8071-8078.
218. LUKOŠEVIČIUS, V. (2005). Kooperacijos judėjimas Lietuvoje iki Pirmojo Pasaulinio karo. *Pinigų studijos*, 1, p. 43-60.
219. LUO, S. T., CHENG, B. W., HSIEH, C. H. (2009). Prediction model building with clustering-launched classification and support vector machines in credit scoring. *Expert Systems with Applications*, vol. 36 (4), p. 7562-7566.
220. LUO, S., KONG, X., NIE, T. (2016). Spline Based Survival Model for Credit Risk Modeling. *European Journal of Operational Research*.
221. MACDONALD, D., JAZWINSKI, J., MCINTOSH, L. (2012). 21st century co-operative; Rewrite the rules of collaboration. *Deloitte LLP and affiliated entities*. [Interaktyvus, žiūrėta 2015 m. birželio 10 d.] Prieiga per internetą: <https://www2.deloitte.com/content/dam/Deloitte/ca/Documents/financial-services/ca-en-financial-services-21st-century-co-operative.pdf>
222. MACKAY, D. M. (1955). Complementary Measures of Scientific Information Content. *Methodos*, vol. 7 (1955), p. 63-90.
223. MACKEVIČIUS, J. (2007). *Įmonių veiklos analizė. Informacijos rinkimas, sisteminimas ir vertinimas*. Vilnius, TEV, 510 p. ISBN: 978-9955-680-73-4.
224. MACKEVIČIUS, J. (2010). Integruota įmonių bankrotų prognozavimo metodika. *Verslo ir teisės aktualijos*, 5, p. 123-138.
225. MACKEVIČIUS, J., SILVANAČIČIŪTĖ, S. (2006). Įmonių bankroto prognozavimo modelių tinkamumo nustatymas. *Verslas: teorija ir praktika*, vol. 7, no. 4, p. 193-202.
226. MACPHERSON, I. (2007). *One Path to Cooperative Studies. A Selection of Papers and Presentations*. New Rochdale Press, University of Victoria. [Interaktyvus, žiūrėta 2015 m. liepos 9 d.] Prieiga per internetą: https://www.uvic.ca/research/centres/cccbe/assets/docs/publications/RochdalePress/OnePath_to_CooperativeStudies.pdf.
227. MAKUCH, W. M. (2001). Scoring applications. *Handbook of credit scoring*, p. 3-21.
228. MANAB, N., THENG, N., MD-RUS, R. (2015). The Determinants of Credit Risk in Malaysia. *Procedia-Social and Behavioral Sciences*, vol. 172, p. 301-308.
229. MANDALA, I. G. N. N., NAWANGPALUPI, C. B., PRAKTIKTO, F. R. (2012). Assessing credit risk: an application of data mining in a rural bank. *Procedia Economics and Finance*, vol. 4, p. 406-412.
230. MARQUÉS, A. I., GARCÍA, V., SÁNCHEZ, J. S. (2012). Two-level classifier ensembles for credit risk assessment. *Expert Systems with Applications*, vol. 39 (12), p. 10916-10922.
231. MARTIŠIUS, S. (1997). *Statistinių išvadų teorijos pradmenys*. Vilnius: VU leidykla.
232. MATTERN, M., WILSON, K. (2013). *Cooperating for Financial Inclusion: A Case Study on The Federation of Haitian Credit Unions, Le Levier*. The Fletcher School of Law and Diplomacy, Tufts University.

233. MAYS, E., LYNAS, N. (2010). *Credit Scoring for Risk Managers*. Lexington, USA. ISBN: 9781450578967.
234. MCCULLOCH, W. S., PITTS, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, vol. 5 (4), p. 115-133.
235. MCKILLOP, D., WILSON, J. (2015). Credit Union as Cooperative Institutions: Distinctiveness, Performance and Prospects. *Social and Environmental Accountability Journal* (ahead-of-print), p. 1-17. [Interaktyvus, žiūrėta 2015 m. lapkričio 22 d.] Prieiga per internetą: <http://www.tandfonline.com/doi/full/10.1080/0969160X.2015.1022195#.VIHIRHbytaQ>.
236. MCKILLOP, D., WILSON, J. (2011) Credit unions: a theoretical and empirical overview. *Financial Markets, Institutions & Instruments*, vol. 20 (1), p. 79-123.
237. MEDVEDEV, V. (2007). *Tiesioginio sklaidimo neuronų tinklų taikymo daugiamatiams duomenims vizualizuoti tyrimai*. Daktaro disertacija, Vilniaus Gedimino technikos universitetas.
238. MERKEVIČIUS, E. (2008). *Savitvarkių neuroninių tinklų diskriminantinio modelio tyrimai kredito rizikos vertinimo sprendimų paramos sistemoje*. Daktaro disertacija, Vilniaus universitetas.
239. MERKEVIČIUS, E., GARŠVA, G., SIMUTIS, R. (2015). Forecasting of credit classes with the self-organizing maps. *Information technology and control*, vol. 33 (4).
240. MESTER, L. (1997). *What's the Point of Credit Scoring?* Business Review, September/October, p. 3-16.
241. MESTIRI, S., HAMDI, M. (2012). Credit Risk Prediction: a comparative study between logistic regression and logistic regression with random effects. *International Journal of Management Science*, p. 200-204.
242. MILERIS, R. (2009). Statistinių kredito rizikos vertinimo modelių analizė. *Economics & Management*, vol. 14, p. 1156-1162.
243. MILERIS, R. (2011). *Įmonių kredito rizikos vertinimo modelis*. Daktaro disertacija, Kauno technologijos universitetas.
244. MILERIS, R. (2012). Įmonių finansinių įsipareigojimų neįvykdymo tikimybės vertinimas nustatant kredito reitingus. *Taikomoji ekonomika: sisteminiai tyrimai*, vol. 6, no. 2, p. 127-143.
245. MILERIS, R. (2014). Macroeconomic factors of non-performing loans in commercial banks. *Ekonomika*, 93-1, p. 22-39.
246. MILERIS, R., GLINSKIENĖ, R., 2007. Rinkos segmentavimas klasterinės analizės k-vidurkių metodu. *Economics & Management*, p. 432-439.
247. MIN, J., LEE, Y. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Application*, vol. 28, no. 4, p. 603-614.
248. MING, J., JEONG, C. (2009). A binary classification method for bankruptcy prediction. *Expert Systems with Application*, vol. 36, no. 3, p. 5256-5263.
249. MOK, J. M. (2009). *Reject Inference in Credit Scoring*. BMI paper, University of Amsterdam. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: https://www.few.vu.nl/nl/Images/werkstuk-mok_tcm243-91398.pdf.
250. MORI, H., YASUSHI, U. (2007). Credit risk evaluation in power market with random forest. *Systems, Man and Cybernetics. ISIC. IEEE International Conference on*, p. 3737-3742.

251. NGUYEN, H. (2014). *Default Predictors in Credit Scoring-Evidence from France's Retail Banking Institution*. University of Paris West-Nanterre la Défense, EconomiX.
252. NIKLIS, D., DOUMPOS, M., ZOPOUNIDIS, C. (2014). Combining market and accounting-based models for credit scoring using a classification scheme based on support vector machines. *Applied Mathematics and Computation*, 234, p. 69-81.
253. NIKOLIC, N., ZARKIC-JOKSIMOVIC, N., STOJANOVSKI, D., JOKSIMOVIC, I. (2013). The application of brute force logistic regression to corporate credit scoring models: Evidence from Serbian financial statements. *Expert Systems with Applications*, vol. 40 (15), p. 5932-5944.
254. O'CONNEL S. (2012). *Credit and Community: Working-Class Debt in the UK since 1880*. Oxford University Press. New York. ISBN: 978-0-19-926331-8.
255. OLSON, D. L., DELEN, D., MENG, Y. (2012). Comparative analysis of data mining methods for bankruptcy prediction. *Decision Support Systems*, vol. 52 (2), p. 464-473.
256. ORESKI, S., ORESKI, G. (2014). Genetic algorithm-based heuristic for feature selection in credit risk assessment. *Expert systems with applications*, vol. 41 (4), p. 2052-2064.
257. PACELLI, V., AZZOLINI, M. (2011). An Artificial Neural Network Approach for Credit Risk Management. *Journal of Intelligent Learning Systems and Applications*, vol. 3, no. 2, p. 103-112.
258. PACKAITĖ, R. (2004). *Daugiamųjų duomenų vizualizavimas naudojantis daugiasluksniais neuroniniais tinklais*. Magistro diplominis darbas, Vilniaus pedagoginis universitetas.
259. PALEOLOGO, G., ELISSEFF, A., ANTONINI, G. (2010). Subagging for credit scoring models. *European Journal of Operational Research*, vol. 201(2), p. 490-499.
260. PAULASKIENĖ, K. (2013). *Duomenų tyrybos sistemų galimybių tyrimas įvairių apimčių duomenims analizuoti*. Mokslinė ataskaita MII-DS-09P-13-9. [Interaktyvus, žiūrėta 2017 m. gegužės 14 d.] Prieiga per internetą: <http://old.mii.lt/files/paulauskiene.pdf>.
261. PETROPOULOS, A., CHARTZIS, S., XANTHOPULOLOS, S. (2016). A novel corporate credit rating system based on Student's-t hidden Markov models. *Expert Systems with Applications*, vol. 53, p. 87-105.
262. PIGOTT, T. D. (2001). A Review of Methods for Missing Data. *Educational Research and Evaluation*, vol. 7, no. 4, p. 353-383.
263. PING, Y., YONGHENG, L. (2011). Neighborhood rough set and SVM based hybrid credit scoring classifier. *Expert Systems with Applications*, vol. 38 (9), p. 11300-11304.
264. POLECONRESEARCH (2016). *Credit Unions in Massachusetts: Growing, Consolidating, and Increasingly Exempt From Regulation*. May 2016. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <http://www.massbankers.org/mapdfs/PolEcon%20CU%20Study.051616.pdf>.
265. POMPE, P. P. M., FEELDERS, A. J. (1997). Using Machine Learning, Neural Networks, and Statistics to Predict Corporate Bankruptcy. *Computer-Aided Civil and Infrastructure Engineering*, vol. 12, no. 4, p. 267-276.
266. POWER, C., O'CONNOR, R., MCCARTHY, O., WARD, M. (2014). Merging into the mainstream? An empirically based discussion of the potential erosion of competitive advantage in restricted Irish credit union movement. *Journal of Co-operative Organization and Management*, vol. 2 (2), p. 55-64.

267. POWERS, D. M. (2007). Evaluation: From precision, recall and F-factor to ROC, informedness, markedness & correlation (Tech. Rep.). *Adelaide, Australia*. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <https://csem.flinders.edu.au/research/techreps/SIE07001.pdf>.
268. PRADO, J. W., DE CASTRO ALCÂNTARA, V., DE MELO CARVALHO, F., VIEIRA, K. C., MACHADO, L. K. C., TONELLI, D. F. (2016). Multivariate analysis of credit risk and bankruptcy research data: a bibliometric study involving different knowledge fields (1968–2014). *Scientometrics*, vol. 106 (3), p. 1007-1029.
269. PRANCKEVIČIŪTĖ, M. (2007). Apibendrintų Gini indeksų taikymas reitingavimo modeliams. *Lietuvos bankas, Pinigų studijos*, 2007/2, p. 74-58. [Interaktyvus, žiūrėta 2017 m. gegužės 12 d.] Prieiga per internetą: <http://etalpykla.lituanistikadb.lt/fedora/get/LT-LDB-0001:J.04~2007~1367161406490/DS.002.0.01.ARTIC>.
270. PRIDOTKIENĖ, J. (2009). *Eksportuotojo teikiamo prekinio kredito rizikos veiksnių vertinimas*. Daktaro disertacija, Kauno technologijos universitetas.
271. R CORE TEAM (2013). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL: <http://www.R-project.org/>.
272. RAJAN, U., AMIT, S., VIG, V. (2010). The failure of models that predict failure: distance, incentives and defaults. *Chicago GSB Research Paper*, p. 8-19.
273. RASHEVSKY, N. (1938). *Mathematical biophysics*. Chicago: Univer. Chicago Press.
274. Regulation (EU) No. 575/2013 of the European Parliament and of the Council, 2013. *On prudential requirements for the credit institutions and investment firms and amending Regulation*. (EU) No 648/2012.
275. RICHARDSON, D., LENNON, B. (2001). *Teaching Old Dogs New Tricks; the Commercialization of Credit Unions*. Development Alternatives, Bethesda, USA. [Interaktyvus, žiūrėta 2014 m. birželio mėn. 12 d.] Prieiga per internetą: http://www.ruralfinance.org/fileadmin/templates/rflc/documents/1126098999771_Teaching_old_dogs_new_tricks___the_comme2025613414.pdf
276. RINGIENĖ, L. (2014). *Hibridinis neuroninis tinklas daugiamačiams duomenims vizualizuoti*. Daktaro disertacija, Vilniaus universitetas.
277. Roobaert, D., Karakoulas, G., & Chawla, N. V. (2006). Information gain, correlation and support vector machines. *Feature extraction*, p. 463-470. Springer Berlin Heidelberg.
278. ROSENBLATT, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological review*, vol. 65 (6), p. 386.
279. RUBIN, D. B. (1976). Inference and missing data. *Biometrika*, vol. 63, 3, p. 581-592.
280. RUTKAUSKAS, A. V., STASYTYTĖ, V. (2011). Rizikos sampratos formavimosi ypatumai. *Verslas: teorija ir praktika*, vol. 2, p. 141-149.
281. RYSER, M., DENZLER, S. (2009). Selecting credit rating models: a cross-validation-based comparison of discriminatory power. *Financial Markets and Portfolio Management*, vol. 23, no. 2, p. 187-203.

- 282.SABERI, M., MIRTALAIE, M. S., HUSSAIN, F. K., AZADEH, A., HUSSAIN, O. K., ASHJARI, B. (2013). A granular computing-based approach to credit scoring modeling. *Neurocomputing*, vol. 122, p. 100-115.
- 283.SÁNCHEZ-LASHERAS, F., DE ANDRÉS, J., LORCA, P., DE COS JUEZ, F. J. (2012). A hybrid device for the solution of sampling bias problems in the forecasting of firms' bankruptcy. *Expert Systems with Applications*, vol. 39 (8), p. 7512-7523.
- 284.SANCHEZ-MARONO, N., ALONSO-BENTANZOS, A., TOMBILLA-SANROMAN, M. (2007). Filter methods for feature selection – a comparative study. *Intelligent Data Engineering and Automated Learning – IDEAL 2007*, p. 178-187. Springer Berlin Heidelberg.
- 285.SAURINA SALAS, J., JIMÉNEZ, G., LOPEZ, J. A. (2007). How Does Competition Impact Bank Risk Taking? *EFA 2007 Ljubljana Meetings Paper*.
- 286.SAVICKAITĖ, D., VALVONIS, V. (2007). Įmonių reitingavimas: Lietuvos bankų patirtis. *Pinigų studijos*, 1, p. 86-108.
- 287.SCHAFER, J. L. (1997). *Analysis of Incomplete Data*. Chapman & Hall / CRC.
- 288.SCHNABLE, P.WARE, D., FULTON R., STEIN J. WEI F. PASTERNAK S., MINX, P. (2009). The B73 maize genome: complexity, diversity, and dynamics. *Science*, vol. 326 (5956), p. 1112-1115.
- 289.SCHUTT, R., 2011. *Investigating the social world: The process and practice of research*. Pine Forge Press.
- 290.SHI, J., ZHANG, S. Y., QIU, L. M. (2013). Credit scoring by feature-weighted support vector machines. *Journal of Zhejiang University SCIENCE C*, vol. 14 (3), p. 197-204.
- 291.SHIN, K. S., LEE, T. S., KIM, H. J. (2005). An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, vol. 28 (1), p. 127-135.
- 292.SIBBALD, A., FERGUSON, C., MCKILLOP, D. (2002). An examination of key factors of influence in the development process of credit union industries. *Annals of Public and Cooperative Economics*, vol. 73 (3), p. 399-428.
- 293.SIDDIQI, N. (2006). Credit Risk Scorecards. *Developing and Implementing Intelligent Credit Scoring*. John Willey & Sons. ISBN: 978-0-471-75451-0.
- 294.SKJONG, R. (2005). Etymology of risk: Classical Greek origin—nautical expression-metaphor for “difficulty to avoid in the sea.”. *Retrieved September*, vol. 19, p. 2007.
- 295.SOBEHART, J., KEENAN, S. (2001). Measuring default accurately. *Risk*, vol. 14 (3), p. 31-33.
- 296.SOHN, S. Y., KIM, D. H., YOON, J. H. (2016). Technology credit scoring model with fuzzy logistic regression. *Applied Soft Computing*, vol. 43, p. 150-158.
- 297.SOHN, S. Y., KIM, J. W. (2012). Decision tree-based technology credit scoring for start-up firms: Korean case. *Expert Systems with Applications*, vol. 39 (4), p. 4007-4012.
- 298.SOUSA, M., GAMA, J., BRANDÃO, E. (2016). A new dynamic modeling framework for credit risk assessment. *Expert Systems with Application*, vol. 45, p. 341-351.
- 299.SPRINGATE, G. L. (1978). *Predicting the Possibility of Failure in a Canadian Firm: A Discriminant Analysis*. Doctoral dissertation, Simon Fraser University.
- 300.STIGLITZ, J. E., WEISS, A. (1981). Credit rationing in markets with imperfect information. *The American economic review*, vol. 71 (3), p. 393-410.

301. STULPINIENĖ, V. (2013). *Finansinio išsekimo prognozavimo modelis ūkininkų ūkiuose*. Daktaro disertacija, Aleksandro Stulginskio universitetas.
302. SUDARSON, M. (2015). *Package "WOE"*. R package, Version 0.2.
303. TAFFLER, R. J., TISSHAW, H. (1977). Going, going, gone—four factors which predict. *Accountancy*, vil. 88(1003), p. 50-54.
304. TAM, K. Y. (1991). Neural network models and the prediction of bank bankruptcy. *Omega*, vol. 19 (5), p. 429-445.
305. TAN, F. (2007). *Improving Feature Selection Techniques for Machine Learning*. Doctoral thesis. Georgia State University.
306. TAYLOR, R. A. (1971). The credit union as a cooperative institution. *Review of social economy*, vol. 29 (2), p. 207-217.
307. THOMAS, L. C. (2000). A survey of credit and behavioural scoring: forecasting financial risk of lending to consumers. *International Journal of Forecasting*, vol. 16(2), p. 149-172.
308. THOMAS, L. C. (2009). *Consumer Credit Models: Pricing, Profit, and Portfolios*. Oxford University Press. ISBN: 978-0-19-923213-0.
309. THOMPSON, D. (2009). Ranking predictors in logistic regression. Paper D10-2009, *Assurant Health*, West Michigan, p. 1-13.
310. TOMCZAK, J. M., ZIĘBA, M. (2015). Classification restricted Boltzmann machine for comprehensible credit scoring model. *Expert Systems with Applications*, vol. 42 (4), p. 1789-1796.
311. TONG, E. N., MUES, C., THOMAS, L. C. (2012). Mixture cure models in credit scoring: If and when borrowers default. *European Journal of Operational Research*, vol. 218(1), p. 132-139.
312. TSAI, C., HSIAO (2010). Combining multiple feature selection methods for stock prediction: union, intersection, and multi-intersection approaches. *Decision Support Systems*, vol. 50, no. 1, p. 258-269.
313. TSAI, C. F. (2009). Feature selection in bankruptcy prediction. *Knowledge-Based Systems*, vol. 22 (2), p. 120-127.
314. TSENG, F. M., HU, Y. C. (2010). Comparing four bankruptcy prediction models: Logit, quadratic interval logit, neural and fuzzy neural networks. *Expert Systems with Applications*, vol. 37 (3), p. 1846-1853.
315. TWALA, B. (2010). Multiple classifier application to credit risk assessment. *Expert Systems with Applications*, vol. 37 (4), p. 3326-3336.
316. VALUŽIS, M. (2008). *Kai kurie kredito rizikos struktūrinių modelių apibendrinimai*. Daktaro disertacija, Vilniaus universitetas.
317. VALVONIS, V. (2006). Šiuolaikinis kredito rizikos vertinimas banke: Paskolos ir skolininko rizika. *Pinigų studijos*, 2006/1, p. 80-104.
318. VALVONIS, V. (2008). *Kredito rizikos vertinimo ir valdymo modelis: Lietuvos bankų praktika ir perspektyvos*. Daktaro disertacija, Vilniaus universitetas.
319. VALVONIS, V. (2004). Kredito rizikos valdymas banke. *Pinigų studijos*, 4, p. 57-82.
320. VALVONIS, V. (2007). Kreditų koncentracijos rizikos vertinimas ir valdymas. *Ekonomika. Vilniaus universitetas*, vol. 77, p. 94-113.

321. VALVONIS, V. (2008A). Estimating EAD for retail exposures for Basel II purposes. *Journal of Credit Risk*, vol. 4 (1), p. 79-110.
322. VALVONIS, V. (2009). Credit Strategy to the Bank. *Applied Economics: Systematic Research*, vol. 3 (2).
323. VAN VLASSELAER, V., BRAVO, C., CAELEN, O., ELIASSI-RAD, T., AKOGLU, L., SNOECK, M., BAESENS, B. (2015). APATE: A novel approach for automated credit card transaction fraud detection using network-based extensions. *Decision Support Systems*, vol. 75, p. 38-48.
324. VARETTO, F. (1998). Genetic algorithms application in the analysis of insolvency risk. *Journal of Banking & Finance*, vol. 22, no. 10, p. 1421-1439.
325. VASILIAUSKAITĖ, A., CVILIKAS, A. (2008). Fuzzy sets theory adoption for credit risk assessment in leasing sector. *Taikomoji ekonomika: sisteminiai tyrimai*, vol. 2, no. 1, p. 85-98.
326. VERBRAKEN, T., BRAVO, C., WEBER, R., BAESENS, B. (2014). Development and application of consumer credit scoring models using profit-based classification measures. *European Journal of Operational Research*, vol. 238 (2), p. 505-513.
327. VERBRAKEN, T., VERBEKE, W., BAESENS, B. (2013). A novel profit maximizing metric for measuring classification performance of customer churn prediction models. *Knowledge and Data Engineering, IEEE Transactions on*, vol. 25 (5), p. 961-973.
328. VUKOVIC, S., DELIBASIC, B., UZELAC, A., SUKNOVIC, M. (2012). A case-based reasoning model that uses preference theory functions for credit scoring. *Expert Systems with Applications*, vol. 39 (9), p. 8389-8395.
329. WANG, G., HAO, J., MA, J., JIANG, H. (2011). A comparative assessment of ensemble learning for credit scoring. *Expert systems with applications*, vol. 38(1), p. 223-230.
330. WANG, G., MA, J. (2012). A hybrid ensemble approach for enterprise credit risk assessment based on Support Vector Machine. *Expert Systems with Applications*, vol. 39 (5), p. 5325-5331.
331. WANG, G., MA, J., HUANG, L., XU, K. (2012a). Two credit scoring models based on dual strategy ensemble trees. *Knowledge-Based Systems*, vol. 26, p. 61-68.
332. WANG, H., XU, Q., ZHOU, L. (2015). Large Unbalanced Credit Scoring Using Lasso-Logistic Regression Ensemble. *PloS one*, vol. 10 (2), e0117844.
333. WANG, J., GUO, K., WANG, S. (2010). Rough set and Tabu search based feature selection for credit scoring. *Procedia Computer Science*, vol. 1 (1), p. 2425-2432.
334. WANG, Y., WANG, S., LAI, K. (2005). A New Fuzzy Support Vector Machine to Evaluate Credit Risk. *IEEE Transactions on Fuzzy Systems*, vol. 12, no. 6, p. 821-831.
335. WARD, M. (1995). *Is the spirit of credit union still alive and healthy in Ireland?* Centre for Cooperative Studies, University College Cork. [Interaktyvus, žiūrėta 2017 m. gegužės 14 d.] Prieiga per internetą:
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.202.4652&rep=rep1&type=pdf>.
336. WEBSTER'S, I. I. (1993). *New Encyclopedic Dictionary*. Konemann, Cologne.
337. WELDON, G. (1999). Inferring Behavior on Reject Credit Applicants. *Sigma Analytics and Consulting: Atlanta, GA. Statistics, Data, and Modelling, SUGI 24, SAS Conference*.

338. WEST, D. (2000). Neural network credit scoring models. *Computers & Operations Research*, vol. 27 (11), p. 1131-1152.
339. WESTRICH, T., BUSH, M. (2005). Blindfolded into debt: A comparison of credit card costs and conditions at banks and credit unions. *Chicago, IL: Woodstock Institute*.
340. WILLIAMS, S. (2010). *Best Practices in Credit Union Efficiency*. A White Paper Commissioned by CUNA's Community Credit Union Committee. Arizona.
341. WOLFF, W. (1893). *Peoples Banks: A Record of Social and Economic Success*. University of California. Longmans. [Inetraktyvus, žiūrėta 2015.11.22] Prieiga per internetą: [www..worldcat.org%2Ftitle%2Fpeoples-banks-a-record-of-social-and-economic-success%2Foclc%2F9460932&usg=AFQjCNEBzzbeDHE7SXvf1-tgrXTQorK14A&sig2=eXvBNiSe-BYc1GuruEJviA&bvm=bv.108194040](http://www.worldcat.org/title/peoples-banks-a-record-of-social-and-economic-success/foclc%2F9460932&usg=AFQjCNEBzzbeDHE7SXvf1-tgrXTQorK14A&sig2=eXvBNiSe-BYc1GuruEJviA&bvm=bv.108194040)
342. WORTHINGTON, A. C. (2004). Determinants of merger and acquisition activity in Australian cooperative deposit-taking institutions. *Journal of business research*, vol. 57 (1), p. 47-57.
343. WU, T. C., HSU, M. F. (2012). Credit risk assessment and decision making by a fusion approach. *Knowledge-Based Systems*, vol. 35, p. 102-110.
344. WWW.PYMNTS.COM (2014). [Interaktyvus, žiūrėta 2015.01.25] prieiga per internetą: <http://www.pymnts.com/in-depth/2014/max-levchin-opens-up-about-affirm/#.VMSNwEeUfTB>.
345. XIAO, H., XIAO, Z., WANG, Y. (2016). Ensemble classification based on supervised clustering for credit scoring. *Applied Soft Computing*, vol. 43, p. 73-86.
346. YANG, C., DUAN, X. (2008). Credit Risk Assessment in Commercial Banks Based on SVM Using PCA. *Machine Learning and Cybernetics, 2008 International Conference on*, vol. 2, p. 1207 – 1211.
347. YANPING, Y., ZHENGMIN, Q., MIN, Y., RUI, G., LITING, F., PENGHUI, G. (2012). Research on the Application of Decision Tree to the Analysis of Individual Credit Risk. *Lecture Notes in Information Technology*, vol. 25.
348. YAP, B. W., ONG, S. H., HUSAIN, N. H. M. (2011). Using data mining to improve assessment of credit worthiness via credit scoring models. *Expert Systems with Applications*, vol. 38 (10), p. 13274-13283.
349. YU, L., WANG, S., LAI, K. K. (2008). Credit risk assessment with a multistage neural network ensemble learning approach. *Expert systems with applications*, vol. 34 (2), p. 1434-1444.
350. YU, L., YAO, X., WANG, S., LAI, K. K. (2011). Credit risk evaluation using a weighted least squares SVM classifier with design of experiment for parameter selection. *Expert Systems with Applications*, vol. 38 (12), p. 15392-15399.
351. YU, L., YUE, W., WANG, S., LAI, K. K. (2010). Support vector machine based multiagent ensemble learning for credit risk evaluation. *Expert Systems with Applications*, vol. 37 (2), p. 1351-1360.
352. ZHANG, D., ZHOU, X., LEUNG, S. C., ZHENG, J. (2010). Vertical bagging decision trees model for credit scoring. *Expert Systems with Applications*, vol. 37 (12), p. 7838-7843.
353. ZHANG, J. L., HARDLE, W. K. (2008). The Bayesian Additive Classification Tree. *Computational Statistics & Data Analysis*, vol. 54, no. 5, p. 1197-1205.
354. ZHANG, J. L., HARDLE, W. K. (2010). The Bayesian additive classification tree applied to credit risk modelling. *Computational Statistics & Data Analysis*, vol. 54 (5), p. 1197-1205.

- 355.ZHANG, Z., GAO, G., SHI, Y. (2014). Credit risk evaluation using multi-criteria optimization classifier with kernel, fuzzification and penalty factors. *European Journal of Operational Research*, vol. 237 (1), p. 335-348.
- 356.ZHOU, J., TIAN, J. (2007). Credit Risk Assessment Based on Rough Set Theory and Fuzzy Support Vector Machine. *Advances in Intelligent Systems Research, ISKE-2007*, p. 1-6.
- 357.ZHOU, X., JIANG, W., SHI, Y. (2010). Credit risk evaluation by using nearest subspace method. *Procedia Computer Science*, vol. 1 (1), p. 2449-2455.
- 358.ZOPOUDINIS, C., DOUMPOS, M. (1999). Business failure prediction using the UTADIS multicriteria analysis method. *Journal of the Operational Research Society*, vol. 50 (11), p. 1138-1148.
- 359.ZUO, X. (2001). The development of credit unions in China: past experiences and lessons for the future. In *Financial Sector Reform in China. Paper presented at the Conference on Financial Sector Reform in China, Harvard University, Cambridge, MA, September*, p. 11-13.
- 360.ZURADA, J., KUNENE, K. N. (2011). Comparisons of the Performance of Computational Intelligence Methods for Loan Granting Decisions. In *System Sciences (HICSS), 2011 44th Hawaii International Conference on*, p. 1-10. *IEEE*.
- 361.БАРБАУМОВ, В. Е., ЕРМАКОВ, В. И., КРИВЕНЦОВА, Н. Н., ЛЕБЕДЕВ, А. С., МАТВЕЕВ, В. И., РУДЫК, Б. М., СИЛАЕВА, Е. А., СМАГИНА О. К. (2009). *Справочник по математике для экономистов*. 3-е изд., перераб. и доп. Москва. ISBN:978-5-16-003542-0.
- 362.ЛОПАТНИКОВ, Л. И. (2003). *Экономико-математический словарь: Словарь совр. экон. науки*. 5-е изд., перераб. и доп. Москва. ISBN:5-7749-0275-7.
- 363.СОРОКИН, А. С. (2014) Построение скоринговых карт с использованием модели логистической регрессии. *Интернет-журнал Науковедение*, vol. 2 (21), p. 1-29.

Priedai

1 priedas. Kredito unių apklausos anketa

	Verslo tikslų ir taisyklių nustatymas kuriant statistinį kredito rizikos vertinimo modelį Lietuvos kredito unių sektoriui	
Respondentas		
Apklauso data		2015 m.
Apklauso vieta		

Segmentavimas / homogeninių rizikos grupių apibrėžimas

1. Kokias tikslinių vartotojų grupes (vartotojų segmentus), kuriems taikomi skirtingi kredito rizikos vertinimo modeliai (formos / tvarkos), išskirate?

a)	Fiziniai asmenys	g)	
b)	Juridiniai asmenys	h)	
c)	Žemės ūkio subjektai	i)	
d)	Fiziniai komerciniai asmenys	j)	
e)		k)	
f)		l)	

2. Ar išskirate papildomus fizinių asmenų segmentus, kuriems būtų taikomos kitokie arba atskiri vertinimo modeliai (formos / tvarkos) pagal žemiau esančius kriterijus? Jei taikote kitokius segmentavimo kriterijus – pažymėkite juos po lentele, jei gilesnio segmentavimo netaikote – visur pažymėkite „Ne“.

Segmentavimo požymis	Taip	Ne
Lytis	☐	☒
Amžius	☐	☒
Pajamos (jų dydis)	☐	☒
Pajamos (jų rūšis)	☐	☒
Gyvenamoji vieta	☐	☒
Profesija (veiklos sritis)	☐	☒
Prašomos paskolos tikslas (tipas)	☐	☒
Paskolos suma ar terminas	☐	☒
Rizikingumas	☐	☒

3. Ar išskirate papildomus fizinių asmenų segmentus, kuriems būtų taikomi kitokie arba atskiri vertinimo modeliai (formos / tvarkos) pagal žemiau esančius kriterijus? Jei taikote kitokius segmentavimo kriterijus – pažymėkite juos po lentele, jei gilesnio segmentavimo netaikote – visur pažymėkite „Ne“.

Segmentavimo požymis	Taip	Ne
Apyvartos dydis	☐	☒
Darbuotojų skaičius	☐	☒
Turto dydis	☐	☒
Veiklos sritis	☐	☒
Profesija (veiklos sritis)	☐	☒
Registracijos ir / ar veiklos vieta	☐	☒
Paskolos suma ar terminas	☐	☒
Rizikingumas	☐	☒

Rizikos vertinimas

4. Kokie indikatoriai galėtų būti pasitelkti identifikuoti blogas paskolas? Paaiškinimas: blogo skolininko apibrėžimas yra būtinas sudarant statistinį kredito rizikos vertinimo modelį. Remiantis juo yra apibrėžiama, kokių paskolų kreditorius nenorėtų. Dažniausiai apibrėžimas išreiškiamas toleruotinu vėlavimo dienomis skaičiumi. Labai žema toleruotina vėlavimo dienomis riba parodo labai žemą toleruojamą riziką, ir priešingai. Įprastai šis rodiklis yra nuo 30 iki 180 dienų. Gali būti ir kiti blogų paskolų identifikatoriai. Galima paklausti ir kitaip: jei galėtumėte iš paskolų portfelio išmesti visas nenorimas paskolas, pagal kokius kriterijus tai padarytumėte?

a)		g)	
b)		h)	
c)		i)	
d)		j)	
e)		k)	
f)		l)	

5. Kaip dažnai sprendimai dėl paskolos išdavimo sutampa su unijoje naudojamo kredito rizikos vertinimo modelio atsakymais? Paaiškinimas: čia kalbama nebūtinai apie faktinius, bet ir apie „norimus priimti“, bet nepriimamus sprendimus. Pvz., pagal modelį (tvarkas / formas) paskolą suteikti galima, tačiau ekspertiškai priimamas sprendimas nesuteikti, arba suteikti būtų galima, jei ne taikomas modelis (tvarkos / formas)

1. Dažniausiai. Turima vertinimo sistema yra pagrindinis vertinimo instrumentas. Priimant sprendimus yra remiamasi tik ja.	
2. Dažnai. Vertinimo sistema yra pagrindinis vertinimo instrumentas, tačiau neretai tenka koreguoti sprendimus, atsižvelgiant į unijos ekspertų rekomendacijas ir įžvalgas.	
3. Retai. Turima vertinimo sistema yra netobula ir jos indikacijomis yra remiamasi retai, dažniau pasikliaujama unijos ekspertų rekomendacijomis ir įžvalgomis.	
4. Kita. (Paaiškinti)	

6. Jei į 7 klausimą atsakyta B, C ar D, nurodykite, kokios dabartinio modelio savybės neleidžia visada juo remtis priimant kreditavimo sprendimus? Paaiškinimas: gali būti koks nors unijos veiklos specifinis veiksnys, prie kurio nėra pritaikytas modelis (tvarkos / formas); dažnos netipinės narių pajamos; iš valdymo organų gauta reikšminga subjektyvi informacija ir pan.

7. Kokio tipo kredito rizikos vertinimo modeliai(-is) yra naudojami unijoje?

Naudojami modelių tipai	Taikoma	Netaikoma
Ekspertinis ir / ar paremtas taisyklėmis (angl. <i>rule based model</i>) (LCKU modelis)	☒	☐
Statistinis (logistinė ar probit regresija, diskriminantinis ar pan.)	☐	☒
Dirbtinio intelekto (neuronų tinklai, atraminių vektorių, atsitiktinio miško modelis ir pan.)	☐	☒
Kita (nurodyti)	☐	☒

8. Kiek klasių (rangų, kategorijų, reitingų) išskiria šiuo metu naudojamas kredito rizikos modelis? (jei taikomi keli modeliai su skirtingomis rangavimo sistemomis – nurodykite kelis skaičius)

	(Irašyti)
--	-----------

9. Paskolos paraiškos svarstymo procesą galima išskirstyti į tris tipinius etapus, kaip nurodyta žemiau esančioje lentelėje. Nurodykite, kokia dalis klientų (%) yra atmetama kiekviename iš tų etapų ir kokia dalis klientų persigalvoja (dėl skirtingų priežasčių) imti paskolą šio proceso metu (praėjus pirmą etapą).

Paskolos gavimo etapai	Patvirtinimo normos proc.
Pirmas kontaktas su potencialiu klientu	
Formalių reikalavimų atitikimas (turimo modelio taikymo etapas)	
Ekspertinis vertinimas (neparemtas taisyklėmis)	
Persigalvojusių klientų dalis (visi etapai)	

10. Ar turite galutinės palūkanų normos nustatymo taisykles / modelį?

☒ Turi	☐ Neturi
---------------------------------------	------------------------------

11. Ar galutinė paskolos palūkanų norma priklauso nuo:

Veiksny	Taip	Ne
Paskolos suma	☐	☒
Paskolos terminas	☐	☒
Paskolos gavėjo rizika (nuo faktinio vėlavimo ir nuo rizikos balo)	☐	☒
Paskolos tipas / tikslas (užtikrinimo priemonės skiriasi nuo produkto)	☐	☒
Bendros užstatų vertės ir paskolos sumos santykis	☐	☒
Užtikrinimo priemonių tipas	☐	☒

12. Ar vertinant paskolos užtikrinimui pateikiamų materialių užstatų vertės pakankumą, turto rinkos vertė indeksuojama (mažinama) atsižvelgiant į:

Veiksny	Taip	Ne
Imama likvidacinė vertė		
Turto tipą (kilnojamą / nekilnojamą) (privaloma pagal LB)	☒	☐
Nekilnojamojo turto tipą (gyvenamosios paskirties NT, žemė, komercinės paskirties NT ir pan.) (privaloma pagal LB)	☒	☐
Nekilnojamojo turto vietą (pvz., savivaldybė) (tik žemės)	☐	☒
Įkeičiamo turto savininko ryšį su paskolos gavėju (nebuvo poreikio)	☐	☒
Transporto priemonės tipą (lengvasis automobilis, žemės ūkio technika, motociklas ir pan.)	☐	☒
Transporto priemonės gamybos metai	☐	☒
Transporto priemonės markė	☐	☒

13. Kokios yra pagrindinės kliūtys, su kuriomis susiduriama kuriant / tobulinant kredito rizikos vertinimo sistemą? Jei savo kredito rizikos vertinimo ir / ar valdymo sistemos nekūrėte – pažymėkite tam įtakos turėjusius veiksnys. Jei nekūrėte dėl poreikio nebuvimo – toks veiksnys taip pat yra lentelėje.

	Labai svarbu	Vidutiniškai svarbu	Nei svarbu, nei nesvarbu	Labiau nesvarbu, nei svarbu	Nesvarbu
Dideli sistemos tobulinimo sukūrimo / palaikymo kaštai	☐	☐	☐	☐	☒
Kvalifikuoto personalo trūkumas	☐	☐	☐	☐	☒
Kokybiškos informacijos (modeliavimui) trūkumas	☐	☐	☐	☐	☒
Sistemos kūrimo / tobulinimo poreikio nebuvimas	☐	☐	☐	☐	☒
Politinės valios trūkumas (kai kurių unijos valdymo organų nenoras diegti / tobulinti sistemą ir pan.)	☐	☐	☐	☐	☒
Specialių žinių trūkumas	☐	☐	☐	☐	☒
Kita	☐	☐	☐	☐	☒

14. Kaip įvertintumėte savo atstovaujamos kredito unijos darbuotojų specialiąsias žinias ir profesinius gebėjimus žemiau išvardytose srityse?

Specialios žinios ir įgūdžiai	Labai geri	Geri	Vidutiniai	Žemiau nei vidutiniai	Blogi / Nėra
Paskolų kredito rizikos vertinimas	☐	☐	☐	☐	☒
Įmonių finansai / apskaita (ūkininkų)	☐	☐	☐	☐	☒
Statistika	☐	☐	☐	☐	☒
IT / programavimas	☐	☐	☐	☐	☒
Rinkodara / pardavimai	☐	☐	☐	☐	☒

15. Ar turimas tvarkas koreguojate, pritaikydami jas prie unijos poreikių?

Ekspertiniu būdu	☐
Statistinė / dirbtinio intelekto analize	☐
Kitų modelių analize	☐
Be korekcijų taikomos LCKU tvarkos	☐
Kita (nurodyti)	☒

16. Kuriuos paskolų segmentus galėtumėte išskirti kaip probleminius kredito rizikos prasme?

Segmentas	
Vartojimo kreditai	☐
Būsto	☐
Fiziniai nekomerciniai	☐
Ūkininkai	☐
Verslo	☐
FA komerc.	☐
Kita (paaiškinti) neturite blogų	☐

17. Kokios palūkanų normos taikomos pasirinktiems segmentams (nuo-iki). Jei komercinė paslaptis – nenurodykite. Jei nurodyti ne visi kredituojami segmentai ar jų per daug – koreguokite arba palikite nepildytą.

Segmentai	Patvirtinimo normos proc.
Vartojimo	
Ūkininkams	
Verslui	
Komerciniams	
Būstas	

18. Nurodykite savo tikslinę(-es) kreditavimo grupę(-es):

19. Ar iš esmės sutiktumėte su žemiau esančiu teiginiu?

Kreditoriaus rizikos tolerancija iš dalies priklauso nuo turimo potencialių klientų srauto.


Paaškinimas: teiginys skirtas ne konkrečiai unijai, bet bendrai visiems kreditoriams. Galima paklausti ir kitaip: jei už durų išsirikiuotų 100 potencialių paskolos gavėjų, ar įprastai toleruotina rizika būtų žemesnė, nei kad potencialių klientų būtų 2–3?


Su teiginiu iš esmės sutinku	Su teiginiu iš esmės nesutinku
☐	☒

20. Ar formuojant kredito komitetą, valdybą ir/ar kitus valdymo organus atsižvelgiama į jų gebėjimą suteikti vertingą subjektyvią informaciją apie potencialius paskolų gavėjus dėl asmeninio jų pažinimo? Pvz., įtraukiamas ūkininkas iš tam tikros seniūnijos tam, kad, esant reikalui, jis suteiktų reikšmingos informacijos apie kitus toje seniūnijoje veikiančius ūkininkus.

Taip, atsižvelgiama	Ne, neatsižvelgiama
☐	☒

2 priedas. Paskolų gavėjų segmentų pasiskirstymas kredito unių sektoriuje pagal vertinimo metodus, priskyrimą tiksliniam segmentui ir problemiškumą kredito rizikos atžvilgiu, iškiriant skirtingus KU dydžius





3 priedas. Kintamųjų įtraukimas į logistinės regresijos modelį

Grupė	Rodiklio pavadinimas (LT)	Priskirtas pavadinimas	1 etapas	2 etapas			3 etapas			4 etapas	5 etapas	6 etapas	Galutiniai kintamieji
			Su blogos paskolos apibrėžimu tiesiogiai susijusių rodiklių šalinimas	Trūkstančių reikšmių analizė			Diskriminantinės galios analizė			Tarpusavio priklausomybės analizė	WOE svorių tolydumas ir atitikimas ekonominei logikai	Šalinamoji regresija	
				Įrašų su trūkstančiomis reikšmėmis kiekis	Pasirinktas / nepasirinktas tolimesnei analizei	Atliktos kintamojo reikšmių transformacijos	IV	Diskriminacinė galia	Pasirinktas / nepasirinktas tolimesnei analizei				
Nefinansiniai rodikliai	Nesumokėtų skolų skaičius	NSSK	P	0	P	Ekspertinis kategorizavimas	0,0920	Silpna	P	P	N		
	Nesumokėtų skolų suma	NSSUM	P	0	P	Ekspertinis kategorizavimas	0,0430	Silpna	P	N			
	Nesumokėtų skolų vidutinis vėlavimo terminas	NSVVT	P	0	P	Ekspertinis kategorizavimas	0,0540	Silpna	P	P	P	P	NSVVT
	Pradelstų skolų skaičius	PSSK	P	0	P	Ekspertinis kategorizavimas	0,0940	Silpna	P	N			
	Pradelstų skolų suma	PSSUM	P	0	P	Ekspertinis kategorizavimas	0,0860	Silpna	P	N			
	Pradelstų skolų vidutinis vėlavimo terminas	PSVVT	P	0	P	Ekspertinis kategorizavimas	0,0870	Silpna	P	P	N		
	Užklausų kiekis kreditų biure	UK	P	0	P	Ekspertinis kategorizavimas	0,0340	Silpna	N				
	Galiojančių areštų kiekis	A	P	0	P		0,3740	Stipri	P	P	P	P	A
	Padengtų skolų skaičius	PSSK	N	0									
	Padengtų skolų vidutinis vėlavimo terminas	PSVVT	N	0									

Grupė	Rodiklio pavadinimas (LT)	Priskirtas pavadinimas	1 etapas	2 etapas			3 etapas			4 etapas	5 etapas	6 etapas	Galutiniai kintamieji
			Su blogos paskolos apibrėžimu tiesiogiai susijusių rodiklių šalinimas	Trūkstumų reikšmių analizė			Diskriminantinės galios analizė			Tarpusavio priklausomybės analizė	WOE svorių tolydumas ir atitikimas ekonominei logikai	Šalinamoji regresija	
				Įrašų su trūkstumomis reikšmėmis kiekis	Pasirinktas / nepasirinktas tolimesnei analizei	Atliktos kintamojo reikšmių transformacijos	IV	Diskriminacinė galia	Pasirinktas / nepasirinktas tolimesnei analizei				
	Padengtų skolų suma	PSSUM	N	0									
	Vidutinis darbuotojų skaičius	DSV	N	0									
Finansiniai rodikliai	Grynasis pelnas / Turtas	NP_TA	P	0	P		0,9780	Labai stipri	P	P	P	P	NP_TA
	Grynasis pelnas / Nuosavas kapitalas	NP_EQ	P	0	P		0,3850	Stipri	P	P	N		
	Grynasis pelnas / Pardavimo pajamos	NP_S	P	25	P		0,7660	Labai stipri	P	P	N		
	Pelnas prieš palūkanas ir mokesčius / Pardavimo pajamos	EBIT_S	P	25	P	NA pakeistos į 0	0,6950	Labai stipri	P	N			
	Bendras pelnas / Pardavimo pajamos	GP_S	P	25	P	NA pakeistos į 0	0,0730	Silpna	N				
	Trumpalaikis turtas / Trumpalaikiai įsipareigojimai	CUA_CL	P	12	P		0,7940	Labai stipri	P	P	P	N	
	Pelnas prieš palūkanas ir mokesčius / Palūkanų sąnaudos	EBIT_IE	P	315	N								
	Pinigai ir pinigų ekvivalentai / Trumpalaikiai įsipareigojimai	CA_CL	P	12	P		0,9460	Labai stipri	P	P	P	N	
	Apyvartinis kapitalas / Turtas	WC_TA	P	0	P		0,8060	Labai stipri	P	P	P	N	
	Mokėtinos sumos ir įsipareigojimai /	TL_TA	P	0	P		1,1870	Įtartinai stipri	P	N			

Grupė	Rodiklio pavadinimas (LT)	Priskirtas pavadinimas	1 etapas	2 etapas			3 etapas			4 etapas	5 etapas	6 etapas	Galutiniai kintamieji
			Su blogos paskolos apibrėžimu tiesiogiai susijusių rodiklių šalinimas	Trūkstumų reikšmių analizė			Diskriminantinės galios analizė			Tarpusavio priklausomybės analizė	WOE svorių tolydumas ir atitikimas ekonominei logikai	Šalinamoji regresija	
				Įrašų su trūkstamomis reikšmėmis kiekis	Pasirinktas / nepasirinktas tolimesnei analizei	Atliktos kintamojo reikšmių transformacijos	IV	Diskriminacinė galia	Pasirinktas / nepasirinktas tolimesnei analizei				
	Turtas												
	Nuosavas kapitalas / Turtas	EQ_TA	P	0	P		1,1450	Įtartinai stipri	P	P	P	P	EQ_TA
	Nuosavas kapitalas / Mokėtinos sumos ir įsipareigojimai	EQ_TL	P	0	P		1,1830	Įtartinai stipri	P	N			
	Nepaskirstytas pelnas / Turtas	RE_TA	P	0	P		0,8580	Labai stipri	P	P	P	N	
	Pinigai ir pinigų ekvivalentai / Turtas	CA_TA	P	0	P		0,3700	Stipri	P	P	P	N	
	Ilgalaikis turtas / Nuosavas kapitalas	LTA_EQ	P	0	P		0,8480	Labai stipri	P	P	P	N	
	Atsargos / Turtas	INV_TA	P	0	P		0,0930	Silpna	N				
	Pardavimo pajamos / Turtas	S_TA	P	0	P		0,2290	Stipri	P	N			
	Pardavimo pajamos / Atsargos	S_INV	P	128	N								
	Pardavimo pajamos / Gautinos lėšos	S_AR	P	109	N								
	Apyvartinis kapitalas / Pardavimo pajamos	WC_S	P	25	P	NA pakeistos į 0	0,6470	Labai stipri	P	P	P	P	WC_S
	Trumpalaikis turtas / Pardavimo pajamos	CUA_S	P	25	P	NA pakeistos į 0	0,0820	Silpna	N				
	Nuosavas kapitalas / Pardavimo pajamos	EQ_S	P	25	P	NA pakeistos į 0	0,9640	Labai stipri	P	N			
	Trumpalaikiai įsipareigojimai / Pardavimo pajamos	CL_S	P	25	P	NA pakeistos į 0	0,5370	Labai stipri	P	N			

Grupė	Rodiklio pavadinimas (LT)	Priskirtas pavadinimas	1 etapas	2 etapas			3 etapas			4 etapas	5 etapas	6 etapas	Galutiniai kintamieji
			Su blogos paskolos apibrėžimu tiesiogiai susijusių rodiklių šalinimas	Trūkstumų reikšmių analizė			Diskriminantinės galios analizė			Tarpusavio priklausomybės analizė	WOE svorių tolydumas ir atitikimas ekonominei logikai	Šalinamoji regresija	
				Įrašų su trūkstamomis reikšmėmis kiekis	Pasirinktas / nepasirinktas tolimesnei analizei	Atliktos kintamojo reikšmių transformacijos	IV	Diskriminacinė galia	Pasirinktas / nepasirinktas tolimesnei analizei				
	Pardavimo pajamos / Pinigai ir pinigų ekvivalentai	S_CA	P	59	P		0,067	Silpna	N				
	Pardavimų savikaina / Pardavimo pajamos	COS_S	P	25	P		0,078	Silpna	N				
	Pelnas prieš apmokestinimą / Trumpalaikis turtas	EBT_TA	P	0	P		0,976	Labai stipri	P	N			
	Bendrasis pelnas / Turtas	GP_TA	P	0	P		0,215	Stipri	P	N			
	Pelnas prieš apmokestinimą / Nuosavas kapitalas	EBT_EQ	P	0	P		0,358	Stipri	P	N			
	Pelnas prieš palūkanas ir mokesčius / Mokėtinos sumos ir įsipareigojimai	EBIT_CL	P	11	P		0,623	Labai stipri	P	P	P	N	
	Pelnas prieš apmokestinimą / (Nuosavas kapitalas – Trumpalaikiai įsipareigojimai)	EBT_EQ_CL	P	0	P		0,215	Stipri	P	P	N		
	(Trumpalaikiai įsipareigojimai – Pinigai ir pinigų ekvivalentai) / Turtas	CL_CA_TA	P	0	P		0,966	Labai stipri	P	N			
	(Pinigai ir pinigų ekvivalentas – Atsargos) / Trumpalaikiai	CA_INV_CL	P	0	P		0,703	Labai stipri	P	N			

Grupė	Rodiklio pavadinimas (LT)	Priskirtas pavadinimas	1 etapas	2 etapas			3 etapas			4 etapas	5 etapas	6 etapas	Galutiniai kintamieji
			Su blogos paskolos apibrėžimu tiesiogiai susijusių rodiklių šalinimas	Trūkstumų reikšmių analizė			Diskriminantinės galios analizė			Tarpusavio priklausomybės analizė	WOE svorių tolydumas ir atitikimas ekonominei logikai	Šalinamoji regresija	
				Įrašų su trūkstamomis reikšmėmis kiekis	Pasirinktas / nepasirinktas tolimesnei analizei	Atliktos kintamojo reikšmių transformacijos	IV	Diskriminacinė galia	Pasirinktas / nepasirinktas tolimesnei analizei				
	įsipareigojimai												
	(Trumpalaikis turtas – Atsargos) / Trumpalaikiai įsipareigojimai	CUA_INV_CL	P	11	P		0,670	Labai stipri	P	N			
	Apyvartinis kapitalas / Nuosavas kapitalas	WC_EQ	P	0	P		0,410	Stipri	P	N			
	Atsargos / Trumpalaikiai įsipareigojimai	INV_CL	P	11	P			Silpna	N				
	Pinigai ir pinigų ekvivalentai / Mokėtinos sumos ir įsipareigojimai	CA_TL	P	0	P		0,838	Labai stipri	P	N			
	Pinigai ir pinigų ekvivalentai / Nuosavas kapitalas	CA_EQ	P	0	P		1,044	Įtartina stipri	P	P	P	P	CA_EQ
	Trumpalaikiai įsipareigojimai / (Mokėtinos sumos ir įsipareigojimai – Pinigai ir pinigų ekvivalentai)	CL_TL_CA	P	0	P		0,584	Labai stipri	P	N			
	Per vienerius metus gautinos sumos / (Mokėtinos sumos ir įsipareigojimai – Pinigai ir pinigų ekvivalentai)	AR_TL_CA	P	0	P		0,263	Stipri	P	N			

Grupė	Rodiklio pavadinimas (LT)	Priskirtas pavadinimas	1 etapas	2 etapas			3 etapas			4 etapas	5 etapas	6 etapas	Galutiniai kintamieji
			Su blogos paskolos apibrėžimu tiesiogiai susijusių rodiklių šalinimas	Trūkstamų reikšmių analizė			Diskriminantinės galios analizė			Tarpusavio priklausomybės analizė	WOE svorių tolydumas ir atitikimas ekonominei logikai	Šalinamoji regresija	
				Įrašų su trūkstamomis reikšmėmis kiekis	Pasirinktas / nepasirinktas tolimesnei analizei	Atliktos kintamojo reikšmių transformacijos	IV	Diskriminacinė galia	Pasirinktas / nepasirinktas tolimesnei analizei				
	Per vienerius metus gautinos sumos / Mokėtinos sumos ir įsipareigojimai	AR_TL	P	0	P		0,326	Stipri	P	P	P	N	
	Nuosavas kapitalas / (Nuosavas kapitalas + Ilgalaikiai įsipareigojimai)	EQ_EQ_LT_L	P	0	P		0,407	Stipri	P	P	N		
	Trumpalaikis turtas / Mokėtinos sumos ir įsipareigojimai	CUA_TL	P	0	P		0,606	Labai stipri	P	N			
	Trumpalaikis turtas / (Mokėtinos sumos ir įsipareigojimai – Pinigai ir pinigų ekvivalentai)	CUA_TL_CA	P	0	P		0,594	Labai stipri	P	P	P	P	CUA_TL_CA
	Trumpalaikis turtas / Turtas	CUA_TA	P	0	P		0,168	Vidutinė	N				
	Per vienerius metus gautinos sumos / Atsargos	AR_INV	P	128	N								
	Pardavimo pajamos / Kapitalas	S_CS	P	3	P		0,074	Silpna	N				
	Apyvartinis kapitalas / Veiklos sąnaudos	WC_OE	P	76	N								
	Turto logaritminė transformacija	Lg_TA	P	0	P		0,141	Vidutinė	N				
	Nuosavas kapitalas / Materialusis turtas	EQ_FA	P	147	N								

Grupė	Rodiklio pavadinimas (LT)	Priskirtas pavadinimas	1 etapas	2 etapas			3 etapas			4 etapas	5 etapas	6 etapas	Galutiniai kintamieji
			Su blogos paskolos apibrėžimu tiesiogiai susijusių rodiklių šalinimas	Trūkstumų reikšmių analizė			Diskriminantinės galios analizė			Tarpusavio priklausomybės analizė	WOE svorių tolydumas ir atitikimas ekonominei logikai	Šalinamoji regresija	
				Įrašų su trūkstumomis reikšmėmis kiekis	Pasirinktas / nepasirinktas tolimesnei analizei	Atliktos kintamojo reikšmių transformacijos	IV	Diskriminacinė galia	Pasirinktas / nepasirinktas tolimesnei analizei				
	Pardavimo pajamų logaritminė transformacija	Lg_S	P	25	P	NA pakeistos į 0	0	Silpna	N				
	Pelnas prieš mokesčius / Pardavimo pajamos	EBT_S	P	25	P	NA pakeistos į 0	0,788	Labai stipri	P	N			
	Pardavimo pajamos / Materialusis turtas	S_FA	P	68	N								
	Pelnas prieš palūkanas ir mokesčius / Turtas	EBIT_TA	P	0	P		0,841	Labai stipri	P	N			

4 priedas. Programavimo kodas (R): kintamųjų atranka, modelio sudarymas, išankstinis įvertinimas, optimalaus lūžio taško nustatymas, rangų skalės sudarymas ir įmonių rangų apskaičiavimas

```
setwd("/Users/renatas/WD") # set working directory
data<-read.csv2('Imtis_V.2.6.2.csv') # open dataset

# Stage 3 (by Annex 4). Checking variable significance by applying
Information value test. (Note: stages 1-2 (by Annex 4) are made
manually)

# describe some variables in data

data$B1<-as.factor(data$B1)
data$B2<-as.factor(data$B2)
data$B3<-as.factor(data$B3)
data$B4<-as.factor(data$B4)
data$B5<-as.factor(data$B5)
data$NSSK_KAT<-as.factor(data$NSSK_KAT)
data$NSSUM_KAT<-as.factor(data$NSSUM_KAT)
data$NSVVT_KAT<-as.factor(data$NSVVT_KAT)
data$PSSK_KAT<-as.factor(data$PSSK_KAT)
data$PSSUM_KAT<-as.factor(data$PSSUM_KAT)
data$PSVVT_KAT<-as.factor(data$PSVVT_KAT)
data$UK_KAT<-as.factor(data$UK_KAT)
data$A<-as.factor(data$A)

data <- data[, c(-1, -2, -3, -5, -6, -7, -8)] # exclude
1,2,3,5,6,7,8 variables from dataset

library(devtools)
install_github("riv","tomasgreif")
library(woe)
iv.mult(data,"B2",TRUE)
iv.plot.summary(iv.mult(data,"B2",TRUE)) # Get IV data

# Stage 4 (by Annex 4). Checking interdependence of chosen variables
by building correlation matrix
setwd("/Users/renatas/Tyrimo duomenys V.1")
data<-read.csv2('Imtis_V.2.6.2.csv')

# make subset 'd' of var's with high descriptive power (selected in
Stage 3 (by Annex 4))

myvars <-
c('NP_TA','EBIT_TA','NP_EQ','NP_S','EBIT_S','CUA_CL','CA_CL',

'WC_TA','TL_TA','EQ_TA','EQ_TL','RE_TA','CA_TA','LTA_EQ',

'S_TA','WC_S','EQ_S','CL_S','EBT_TA','GP_TA','EBT_EQ','EBT_EQ_CL',
```

```

      'EBT_S', 'CL_CA_TA', 'CA_INV_CUA', 'CUA_INV_CL', 'WC_EQ',
      'CA_TL', 'CA_EQ', 'CL_TL_CA', 'AR_TL_CA', 'AR_TL', 'EQ_EQ_LTL',
      'CUA_TL', 'CUA_TL_CA', 'AP_S', 'EBIT_CL')

d <- data[myvars]

# generate coorelation matrix of descriptive variables
cor(d, use="pairwise.complete.obs")

# Visualising correlation matrix
library(corrplot)

M <- cor(d, use="pairwise.complete.obs")
(order.AOE <- corrMatOrder(M, order="AOE"))
(order.FPC <- corrMatOrder(M, order="FPC"))
(order.hc <- corrMatOrder(M, order="hclust"))
(order.hc2 <- corrMatOrder(M, order="hclust", hclust.method="ward"))

M.AOE <- M[order.AOE,order.AOE ]
M.FPC <- M[order.FPC,order.FPC ]
M.hc <- M[order.hc, order.hc ]
M.hc2 <- M[order.hc2,order.hc2]
par(ask=FALSE)
png(height=1200, width=1500, pointsize=10, file="overlap.png")
corrplot(M.FPC, tl.cex=2, tl.col='black', method='circle',
addCoef.col = "grey") # Original order
dev.off()

corrplot(M.FPC, tl.cex=1, tl.col='black') # The first principal
component order

# Stage 5 (by Annex 4). Recoding variables by WOE
data <- read.csv2('Imtis_V.2.6.1.csv')

library(devtools)
library(woe)
library(riv)

options(digits=2)
iv.mult(data, "B2", vars=c('NSVVT_KAT', 'NSSK_KAT', 'PSVVT_KAT', 'A', 'NP_
TA',
      'NP_EQ', 'NP_S', 'EBIT_S', 'CUA_CL', 'CA_CL', 'WC_TA', 'EQ_TA',

      'RE_TA', 'CA_TA', 'LTA_EQ', 'WC_S', 'EBT_EQ_CL', 'CA_EQ',
      'AR_TL',
      'EQ_EQ_LTL', 'CUA_TL_CA', 'EBIT_CL', 'UK_KAT'))

```

```

data_woe <- data
str(data_woe)
data_woe <-
iv.replace.woe(data, iv=iv.mult(data, "B2", vars=c('NSVVT_KAT',
'PSVVT_KAT', 'A', 'NP_TA', 'NP_EQ', 'NP_S', 'EBIT_S', 'CUA_CL', 'CA_CL',
'WC_TA', 'EQ_TA', 'RE_TA', 'CA_TA', 'LTA_EQ', 'WC_S', 'EBT_EQ_CL', 'CA_EQ',
'AR_TL', 'EQ_EQ_LTL', 'CUA_TL_CA', 'EBIT_CL', 'UK_KAT'))))

library(xlsx)
write.table(data_woe, "/Users/renatas/WD/Imtis_V.2.6.3_woe.txt")

# Stage 6 (by Annex 4). Applying backward regression for selection
of final set of variables

data <- read.table('Imtis_V.2.6.3_woe.txt')
data <- data[complete.cases(data), ]
data <- data[, c(-1, -2, -3, -5, -6, -7, -8, -9, -10, -11, -12, -13,
-14,
-15, -16, -17, -18, -19, -20, -21, -22, -23, -24, -25,
-26,
-27, -28, -29, -30, -31, -32, -33, -34, -35, -36, -
37, -38,
-39, -40, -41, -42, -43, -44, -45, -46, -47, -48, -
49, -50,
-53, -54, -64, -65, -67, -68 )]

library(leaps)

null=lm(B2~1, data=data)
null

full=lm(B2~., data=data)
full

step(full, data=data, direction="backward")

# Fitting logistic regression model

library(caret)
library(ROCR)
library(aod)
library(ggplot2)
library(Rcpp)
library(survey)

```

```

setwd("/Users/renatas/wd")
data<-read.table("Imtis_V.2.6.3_woe.txt")

data$B2<-as.factor(data$B2)
data$NSVVT_KAT_woe<-as.factor(data$NSVVT_KAT_woe)
data$PSVVT_KAT_woe<-as.factor(data$PSVVT_KAT)
data$A_woe<-as.factor(data$A_woe)

good <- data[which(data$B2 == 0), ]
bad <- data[which(data$B2 == 1), ]

set.seed(379) #any random number
bad_test <- bad[sort(sample(nrow(bad), 293)), ]
bad_train <- bad[-sort(sample(nrow(bad), 293)), ]

for (i in 1:1) {
  bad_train <- rbind(bad_train, bad_train)
  good_test <- good[sort(sample(nrow(good), 350)), ]
  good_train <- good[-sort(sample(nrow(good), 350)), ]
  test <- rbind(good_test, bad_test)
  train <- rbind(good_train, bad_train)

  auc <- c()

  m <- glm(B2 ~ EQ_TA_woe + NP_TA_woe + I(A_woe==
0.898999234764094) + I(NSVVT_KAT_woe== -0.103169934278008) +
CA_EQ_woe + CUA_TL_CA_woe +
          CA_CL_woe + WC_S_woe, data=train, family=binomial)
  exp(coef(m))
  exp(cbind(OR = coef(m), confint(m)))

  test$score <- predict(m, type = "response", test)
  pred <- prediction(test$score, test$B2)
  perf <- performance(pred, "tpr", "fpr")
  plot(perf, ylim=c(0, 1))
  auc.tmp <- performance(pred, "auc")
  auc <- rbind(auc, as.numeric(auc.tmp@y.values))

  auc
  mean(auc)
  max(auc)
  min(auc)
  median(auc)
}

```

```

# Preliminary model validation
# Overview:
auc
mean(auc)
max(auc)
min(auc)
median(auc)
summary(m)

# Calculating Gini score
Gini<-auc*2-1
Gini
# KS statistics
max(attr(perf,'y.values')[[1]]-attr(perf,'x.values')[[1]])

# Log odds validation
exp(coef(m))
exp(cbind(OR = coef(m), confint(m)))

# Building confusion matrix
test.probs <- predict(m, test, type='response')
pred.logit <- rep('Geras',length(test.probs))
pred.logit[test.probs>=0.4] <- 'Blogas' # cut off point set on
0.4
temp <- t(table(pred.logit, test$B2))
gerai <- data.frame(Geras = temp[, 2], Blogas = temp[, 1])
gerai

# building predicted probability plots
tikimybes <- predict(m, data, type = "response")
tikimybes
tikimybes <- as.data.frame(tikimybes)
plot(data$B2, tikimybes$tikimybes)
test_good = test[which(test$B2 == 0), ]
test_bad = test[which(test$B2 == 1), ]
plot(density(test_good$score))
plot(density(test_bad$score))
plot(density(test_good$score), xlim = c(0, 1), ylim = c(0, 4))
par(new=TRUE)
plot(density(test_bad$score), xlim = c(0, 1), ylim = c(0, 4))

```

```

# Calculate optimal cutoff point
library(EMP)
# Construct artificial probability scores and true class labels
score.ex <- test.probs
class.ex <- data$B2

# Calculate EMP measures for credit risk scoring
empCreditScoring(score.ex, class.ex)

# Calculate EMP measures for credit risk scoring with point masses
in 0.1 and 0.9, and 0.1 ROI
empCreditScoring(score.ex, class.ex, 0.3, 0.3, 0.083)

# Rank companies in model testing dataset
test$rangas <- NA
for (i in 1:nrow(test)) {
  if (test[i, 70] < 0.03) {
    test[i, 71] <- 1
  } else if(test[i, 70] < 0.05) {
    test[i, 71] <- 2
  } else if(test[i, 70] < 0.08) {
    test[i, 71] <- 3
  } else if(test[i, 70] < 0.12) {
    test[i, 71] <- 4
  } else if(test[i, 70] < 0.2) {
    test[i, 71] <- 5
  } else if(test[i, 70] < 0.3) {
    test[i, 71] <- 6
  } else if(test[i, 70] < 0.48) {
    test[i, 71] <- 7
  } else if(test[i, 70] < 0.60) {
    test[i, 71] <- 8
  } else {
    test[i, 71] <- 9
  }
}
tapply(test$B2, test$rangas, summary)

```

5 priedas. Apskaičiuoti WOE dydžiai ir interpretavimas

		1		2		3		4		5		6		Sprendimas dėl rodiklio
NP_TA	Skalė	min	-0,5158	-0,5158	-0,2737	-0,2737	-0,08115	-0,08115	-0,004	-0,004	0,0245	0,0245	maks	Galima taikyti
	WOE	-1,87		-0,76		-0,31		0,16		0,82		1,24		
	G/B	33	161	52	83	128	131	100	64	130	43	281	61	
	Viso įm.	194		135		259		164		173		342		
	ODF	0,83		0,61		0,51		0,39		0,25		0,18		

		1		2		3		4		5		Sprendimas dėl rodiklio
NP_EQ	Skalė	min	-0,2721	-0,2721	0,048	0,048	0,1621	0,1621	0,4101	0,4101	maks	Negalima taikyti
	WOE	-0,31		0,87		0,58		0,12		-0,76		
	G/B	113	115	236	74	100	42	138	92	137	220	
	Viso įm.	228		310		142		230		357		
	ODF	0,5		0,24		0,3		0,4		0,62		

		1		2		3		4		Sprendimas dėl rodiklio
NP_S	Skalė	min	-0,3331	-0,3331	-0,121	-0,121	-0,0002	-0,0002	maks	Galima taikyti, tačiau įtakos svorių pasiskirstymas kelia abejonių
	WOE	-1,157		-0,0673		0,095		1,089		
	G/B	83	198	85	125	154	105	400	101	
	Viso įm.	281		210		259		501		
	ODF	0,7		0,6		0,41		0,2		

		1		2		3		4		5		Sprendimas dėl rodiklio
EBIT_S	Skalė	min	-0,2448	-0,2448	-0,04353	-0,04353	0,001493	0,001493	0,03791	0,03791	maks	Galima taikyti
	WOE	-1,09		-0,29		0,24		1,31		0,87		
	G/B	101	226	150	150	80	47	153	31	238	75	
	Viso įm.	327		300		127		184		313		
	ODF	0,69		0,5		0,37		0,17		0,24		

		1		2		3		4		5		Sprendimas dėl rodiklio
CUA_CL	Skalė	min	0,4949	0,4949	1,021	1,021	1,34	1,34	2,883	2,883	maks	Galima taikyti
	WOE	-1,09		-0,31		0,32		0,75		1,74		
	G/B	105	234	156	160	103	56	184	65	174	23	
	Viso įm.	339		316		159		249		197		
	ODF	0,69		0,51		0,35		0,26		0,12		

		1		2		3		4		5		6		Sprendimas dėl rodiklio
CA_CL	Skalė	min	0,0007186	0,0007186	0,004591	0,004591	0,025	0,025	0,215	0,215	0,6149	0,6149	maks	Galima taikyti
	WOE	-1,5		-0,86		-0,47		0,24		0,85		2,23		
	G/B	36	121	47	83	120	144	245	144	100	32	174	14	
	Viso įm.	157		130		264		389		132		188		
	ODF	0,77		0,64		0,55		0,37		0,24		0,07		

		1		2		3		4		5		Sprendimas dėl rodiklio
WC_TA	Skalė	min	-1,292	-1,292	-0,1815	-0,1815	0,01926	0,01926	0,2252	0,2252	maks	Galima taikyti
	WOE	-1,759		-0,619		0,081		0,471		1,036		
	G/B	34	148	117	163	120	83	141	66	312	83	
	Viso įm.	182		280		203		207		395		
	ODF	0,81		0,58		0,41		0,32		0,21		

		1		2		3		4		5		6		Sprendimas dėl rodiklio
EQ_TA	Skalė	min	-1,292	-1,292	-0,3472	-0,3472	0,1304	0,1304	0,3756	0,3756	0,5717	0,5717	maks	Galima taikyti
	WOE	-1,63		-0,98		-0,54		0,49		0,98		1,77		
	G/B	38	145	50	100	127	163	154	71	121	34	234	30	
	Viso įm.	183		150		290		225		155		264		
	ODF	0,79		0,67		0,56		0,32		0,22		0,11		

		1		2		3		4		5		Sprendimas dėl rodiklio
RE_TA	Skalė	min	-1,118	-1,118	-0,1627	-0,1627	- 0,007936	- 0,007936	0,2014	0,2014	maks	Galima taikyti
	WOE	-1,34		-0,24		-0,6		0,55		1,4		
	G/B	67	191	164	157	55	75	157	68	281	52	
	Viso įm.	258		321		130		225		333		
	ODF	0,74		0,49		0,58		0,3		0,16		

		1		2		3		4		5		6	
CA_TA	Skalė	min	0,001526	0,001526	0,01672	0,01672	0,06537	0,06537	0,1522	0,1522	0,3074	0,3074	maks
	WOE	-1,1		-0,19		0,23		0,76		0,11		0,88	
	G/B	68	153	168	152	177	106	122	43	83	56	106	33
	Viso įm.	221		320		283		165		139		139	
	ODF	0,69		0,48		0,37		0,26		0,4		0,24	
Sprendimas dėl rodiklio		1		2		3		4		5		Sprendimas dėl rodiklio	
Įtakos svoriai pasiskirstę netolygiai, jungiami 5 ir 6 intervalai ->		min	0,001526	0,001526	0,01672	0,01672	0,06537	0,06537	0,1522	0,1522	maks	Galima taikyti	
		-1,1		-0,19		0,23		0,76		0,88			
		68	153	168	152	177	106	122	43	83	56		
		221		320		283		165		139			
		0,69		0,48		0,37		0,26		0,4			

		1		2		3		4		5		Sprendimas dėl rodiklio
LTA_EQ	Skalė	min	-0,1658	-0,1658	0,0002294	0,0002294	0,8086	0,8086	2,658	2,658	maks	Galima taikyti, rodiklio svoriai pasiskirstę logiškai, atitinka U formą
	WOE	-0,72		-1,41		1,08		0,71		0,15		
	G/B	115	177	57	175	302	77	171	63	79	51	
	Viso įm.	292		232		379		234		130		
	ODF	0,61		0,75		0,2		0,27		0,39		

		1		2		3		4		5		6		Sprendimas dėl rodiklio	
WC_S	Skalė	min	-0,2496	-0,2496	-0,09341	-0,09341	0,02635	0,02635	0,1176	0,1176	0,7281	0,7281	maks		Galima taikyti, rodiklio svoriai pasiskirstę logiškai, atitinka U forma
	WOE	-0,98		-0,58		0,12		0,74		1,13		0,48			
	G/B	120	241	59	79	108	72	106	38	243	59	86	40		
	Viso įm.	361		138		180		144		302		126			
	ODF	0,67		0,57		0,4		0,26		0,2		0,32			

		1		2		3		4		5		6		Sprendimas dėl rodiklio
EBT_EQ_CL	Skalė	min	-0,03878	-0,03878	0,01609	0,01609	0,08221	0,08221	0,2727	0,2727	0,5743	0,5743	maks	Negalima taikyti
	WOE	0,465		0,773		0,039		-0,568		-0,336		0,205		
	G/B	189	89	104	36	79	57	142	188	102	107	108	66	
	Viso įm.	278		140		136		330		209		174		
	ODF	0,32		0,26		0,42		0,57		0,51		0,38		

		1		2		3		4		5		6		Sprendimas dėl rodiklio
CA_EQ	Skalė	min	-0,02082	-0,02082	0,001522	0,001522	0,02172	0,02172	0,1345	0,1345	0,6481	0,6481	maks	Galima taikyti
	WOE	-0,6		-1,37		0,38		0,82		1,73		0,48		
	G/B	112	153	77	227	84	43	161	53	204	27	86	40	
	Viso įm.	265		304		127		214		231		126		
	ODF	0,58		0,75		0,34		0,25		0,12		0,32		

		1		2		3		4		Sprendimas dėl rodiklio
AR_TL	Skalė	min	0,05024	0,05024	0,3859	0,3859	1,096	1,096	maks	Galima taikyti
	WOE	-0,709		-0,046		0,285		1,329		
	G/B	128	195	270	212	195	110	131	26	
	Viso įm.	323		482		305		157		
	ODF	0,6		0,44		0,36		0,17		

		1		2		3		4		Sprendimas dėl rodiklio
EQ_EQ_LTL	Skalė	min	0,141	0,141	0,9985	0,9985	1	1	maks	Negalima taikyti
	WOE	-0,584		0,74		0,088		-1,406		
	G/B	84	113	274	98	332	228	34	104	
	Viso įm.	197		372		560		138		
	ODF	0,57		0,26		0,41		0,75		

		1		2		3		4		5		Sprendimas dėl rodiklio
CUA_TL_CA	Skalė	min	0,002917	0,002917	0,3911	0,3911	0,6743	0,6743	1,193	1,193	maks	Galima taikyti, tačiau įtakos svorių pasiskirstymas kelia abejonių
	WOE	1,792		-0,823		-0,288		-0,048		0,838		
	G/B	112	14	140	239	100	100	150	118	222	72	
	Viso įm.	126		379		200		268		294		
	ODF	0,11		0,63		0,5		0,44		0,24		

		1		2		3		4		5		Sprendimas dėl rodiklio
EBIT_CL	Skalė	min	-0,3864	-0,3864	-0,1052	-0,1052	- 0,002208	- 0,002208	0,6201	0,6201	maks	Galima taikyti
	WOE	-0,67		-0,4		-0,71		0,8		1,87		
	G/B	117	171	151	169	59	90	282	95	113	13	
	Viso įm.	288		320		149		377		126		
	ODF	0,59		0,53		0,6		0,25		0,1		

		1		2		Sprendimas dėl rodiklio
NSVVT_KAT	Skalė	min	4,5	4,5	maks	Galima taikyti
	WOE	-0,1		0,21		
	G/B	457	380	267	163	
	Viso įm.	837		430		
	ODF	0,45		0,38		

PSVVT_KAT	Skalė	min	1,5	1,5	2,5	2,5	4,5	4,5	maks	Sprendimas dėl rodiklio
	WOE	0,309		-1,86		-0,381		0,073		Negalima taikyti
	G/B	347	191	114	103	164	180	99	69	
	Viso įm.	538		217		344		168		
	ODF	0,36		0,47		0,52		0,41		

		1		2		Sprendimas dėl rodiklio
A	Skalė	inf	0,5	0,5	maks	Galima taikyti
	WOE	0,12		-0,9		
	G/B	584	285	140	258	
	Viso įm.	869		398		
	ODF	0,33		0,65		

6 priedas. Papildomas analizuotos literatūros sąrašas

Paveikslas / Lentelė	Šaltiniai
15 pav. Dažniausiai naudojami santykiniai finansiniai rodikliai	Altman (1968); Altman, Sabato (2007); Angelini et al. (2008); Bužius et al. (2010); Chen, Du (2009); Cubiles-De-La-Vega et al. (2013); Danėnas et al. (2011); De Andres et al. (2011); Dimitras et al. (1999); Dzidzevičiūtė (2010); Frydman et al. (1985); Fulmer (1984); Grigaravičius (2003); Gurny, Gurny (2013); Huang et al. (2004); Lin (2009); Lorca et al. (2013); Mileris (2012); Min, Jeong (2009); Min, Lee (2005); Mori, Yasushi (2007); Nikolic (2013); Ohlson (1980); Olson et al. (2012); Pacelli, Azzollini (2011); Pompe, Feelders (1997); Ryser, Denzler (2009); Springate (1978); Tafler, Tisshaw (1977); Tseng, Hu (2001); Tseng, Hu (2010); Varetto (1998); Vasiliauskaitė, Cvilikas (2008); Wang et al. (2005); Wang, Ma (2012); Wu, Hsu (2012); Zhang, Hardle (2008); Zhou, Tian (2006); Zmijevski (1984); Zopoudinis, Doumpos (1999).
22 pav. Klasifikavimo metodai, jų tipai ir taikymo dažnis ir 23 pav. Klasifikatorių tikslumas naujausiuose moksliniuose tyrimuose	Cardoso ir kiti (2016); Fernandes, Artes (2016); Sousa ir kiti (2016); Luo ir kiti (2016); Petropoulos ir kiti (2016); Sohn ir kiti (2016); Xiao ir kiti (2016); Lessmann ir kiti (2015); Danėnas, Garšva (2015); Manab ir kiti (2015); Merkevičius ir kiti (2015); Fei ir kiti (2015); Florez-Lopez, Ramon-Jeronimo (2015); Tomczak, Zięba (2015); Kozeny (2015); Harris (2015); Van Vlasselaer ir kiti (2015); Wang ir kiti (2015); Bekhet, Eletter (2014); Gupta ir kiti (2014); Zhang ir kiti (2014); Niklis ir kiti (2014); Ju, Sohn (2014); Verbraken ir kiti (2014); Chen, Li (2014); Abellán, Mantas (2014); Dzidzevičiūtė (2013); Chen ir kiti (2013); Harris (2013); Kruppa ir kiti (2013); Cubiles-De-La-Vega ir kiti (2013); Saberi ir kiti (2013); Nikolic ir kiti (2013); Hajek, Michalak (2013); Bucker ir kiti (2013); Han ir kiti (2013); Gurný, Gurný (2013); Shi ir kiti (2013); Blanco ir kiti (2013); Mileris (2012); Danėnas, Garšva (2012); Li ir kiti (2012); Wang, Ma (2012); Chen ir kiti (2012); Mandala ir kiti (2012); Tong ir kiti (2012); Kao ir kiti (2012); Marqués ir kiti (2012); Chi, Hsu (2012); Louzada ir kiti (2012); Wu, Hsu (2012); Akkoç (2012); Bijak, Thomas (2012); Vukovic ir kiti (2012); Wang ir kiti (2012); Sohn, Kim (2012); Hens, Tiwari (2012); Brown, Mues (2012); Olson ir kiti (2012); Oreski ir kiti (2012); Sánchez-Lasheras ir kiti (2012); de Andrés ir kiti (2012); Wang ir kiti (2012a); Chang, Yeh (2012); Crone, Finlay (2012); Danėnas ir kiti (2011); Khashman (2011); Yu ir kiti (2011); Derelioğlu, Gürgeen (2011); Yap ir kiti (2011); Finlay (2011); Li ir kiti (2011); Ping, Yongheng (2011); Wang ir kiti (2011); Bužius ir kiti (2010); Khandani ir kiti (2010); Khashman (2010); Zhou ir kiti (2010); Twala (2010); Yu ir kiti (2010); Paleologo ir kiti (2010); Zhang, Härdle (2010); Tseng, Hu (2010); Dong ir kiti (2010); Zhang ir kiti (2010); Boguslauskas, Mileris (2009); Chuang, Lin (2009); Luo ir kiti (2009); Finlay (2009); Ben-David, Frank (2009); Yu ir kiti (2008); Abdou ir kiti (2007); Dinh, Kleimeier (2007); Lee ir kiti (2006); Lee, Chen (2005); I-Fei, Chen (2005).
25 pav. Dažniausiai naudojami modelio patikimumo vertinimo metodai	Cardoso ir kiti (2016); Gorzalczy, Rudziński (2016); Kelly, O'Malley (2016); Luo ir kiti (2016); Petropoulos ir kiti (2016); Sohn ir kiti (2016); Sousa ir kiti (2016); Xiao ir kiti (2016); Danėnas, Garšva (2015); Fei ir kiti (2015); Florez-Lopez, Ramon-Jeronimo (2015); Harris (2015); Koutanaei ir kiti (2015); Kozeny (2015); Lessmann ir kiti (2015); Manab ir kiti (2015); Merkevičius ir kiti (2015); Tomczak, Zięba (2015); Van Vlasselaer ir kiti (2015); Wang ir kiti (2015); Abellán, Mantas (2014); Bekhet, Eletter (2014); Chen, Li (2014); Gupta ir kiti (2014); Ju, Sohn (2014); Niklis ir kiti (2014); Oreski, Oreski (2014); Verbraken ir kiti (2014); Zhang ir kiti (2014); Blanco ir kiti (2013); Bucker ir kiti (2013); Chen ir kiti (2013); Cubiles-De-La-Vega ir kiti (2013); Dzidzevičiūtė (2013); Fernandes, Artes (2016); Gurný, Gurný (2013); Hajek, Michalak (2013); Han ir kiti (2013); Harris (2013); Kruppa ir kiti (2013); Nikolic ir kiti (2013); Saberi ir kiti (2013); Shi ir kiti (2013); Akkoç (2012); Bijak, Thomas (2012); Brown, Mues (2012); Chang, Yeh (2012); Chen ir kiti (2012); Chi, Hsu (2012); Crone, Finlay (2012); Danėnas, Garšva (2012); De Andrés ir kiti (2012); Hens, Tiwari (2012); Kao ir kiti (2012); Li ir kiti (2012); Louzada ir kiti (2012); Mandala ir kiti (2012); Marqués ir kiti (2012); Mileris (2012); Olson ir kiti (2012); Sánchez-Lasheras ir kiti (2012); Sohn, Kim (2012); Tong ir kiti (2012); Vukovic ir kiti (2012); Wang ir kiti (2012); Wang, Ma (2012); Wu, Hsu (2012); Chen ir kiti (2011); Danėnas ir kiti (2011); Derelioğlu, Gürgeen (2011); Finlay (2011); Khashman (2011); Li ir kiti (2011); Ping, Yongheng (2011); Wang ir kiti (2011); Yap ir kiti (2011); Yu ir kiti (2011); Chen ir kiti (2010); Dong ir kiti (2010); Khandani ir kiti (2010); Khashman (2010); Paleologo ir kiti (2010); Tseng, Hu (2010); Twala (2010); Wang, Wang (2010); Yu ir kiti (2010); Zhang ir kiti (2010); Zhang, Härdle (2010); Zhou ir kiti (2010); Ben-David, Frank (2009); Boguslauskas, Mileris (2009); Chuang, Lin (2009); Finlay (2009); Luo ir kiti (2009); Yu ir kiti (2008); Abdou ir kiti (2007); Dinh, Kleimeier (2007).