

VILNIAUS UNIVERSITETAS

LAIMA DZIDZEVIČIŪTĖ

STATISTINIŲ VERTINIMO BALAIS MODELIŲ TAIKYMO
LIETUVOS BANKUOSE GALIMYBĖS

Daktaro disertacija

Socialiniai mokslai, ekonomika (04 S)

Vilnius, 2013 metai

Disertacija rengta 2008–2013 metais Vilniaus universitete

Mokslinis vadovas:

doc. dr. Rūta Kropienė (Vilniaus universitetas, socialiniai mokslai, ekonomika – 04 S)

TURINYS

ĮVADAS	9
I. STATISTINIAIS VERTINIMO BALAIS MODELIAIS PAGRĮSTŲ REITINGŲ SISTEMŲ KŪRIMO IR TAIKYMO YPATUMAI	16
1.1. STATISTINIO VERTINIMO BALAIS MODELIO IR REITINGŲ SKALĖS KŪRIMAS IR TAIKYMAS BANKUOSE.....	16
1.1.1. Statistinio vertinimo balais modelio kūrimo etapai	17
1.1.1.1. Projekto įgyvendinamumo analizė	18
1.1.1.2. „Blogo“ skolininko ir stebėjimo laikotarpio apibrėžimas	24
1.1.1.3. Skolininkų grupės pasirinkimas	28
1.1.1.4. Paraiškų ir elgsenos vertinimo balais modeliai	31
1.1.1.5. Statistinio metodo pasirinkimas	39
1.1.1.6. Imties sudarymas	50
1.1.1.7. Atmestų paraiškų įtraukimas	52
1.1.1.8. Įvesties kintamųjų analizė ir koeficientų apskaičiavimas	61
1.1.2. Reitingų skalės sukūrimas	67
1.2. REITINGŲ ĮSIPAREIGOJIMŲ NEĮVYKDYMO TIKIMYBĖS APSKAIČIAVIMO METODAI	69
1.2.1. Įprastų reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimo metodai ...	69
1.2.2. Reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimo metodai, kai yra žemo „blogo“ skolininkų lygio portfeliai	72
1.3. REITINGŲ SISTEMŲ PATIKIMUMO VERTINIMAS	83
1.3.1. Išankstinis patikimumo vertinimas.....	83
1.3.2. Vertinimo balais modelio ir reitingų skalės patikimumo vertinimas	85
1.3.3. Reitingų įsipareigojimų neįvykdymo tikimybės patikimumo vertinimas	91
II. STATISTINIŲ VERTINIMO BALAIS MODELIŲ TAIKYMAS LIETUVOS BANKUOSE	95
2.1. PASKOLŲ PRISKYRIMO MAŽMENINIŲ PASKOLŲ GRUPEI KRITERIJAI	96
2.2. VERTINIMO BALAIS MODELIŲ RŪŠYS	98
2.3. VERTINIMO BALAIS MODELIŲ ĮVESTIES KINTAMIEJI	102
2.4. VERTINIMO BALAIS MODELIŲ PATIKIMUMAS IR JŲ TAIKYMO SRITYS	104

III. LOGISTINĖS REGRESIJOS MODELIU PAGRĮSTA LIETUVOS ĮMONIŲ REITINGŲ SISTEMA	108
3.1. STATISTINIO LIETUVOS ĮMONIŲ VERTINIMO BALAIS MODELIO IR REITINGŲ SKALĖS SUKŪRIMAS	108
3.1.1. Statistinis Lietuvos įmonių vertinimo balais modelis	108
3.1.1.1. Duomenys	108
3.1.1.2. Modelio kūrimo metodika	110
3.1.1.3. Išankstinis patikimumo vertinimas	117
3.1.2. Lietuvos įmonių reitingų skalė	123
3.2. ĮMONIŲ REITINGŲ ĮSIPAREIGOJIMŲ NEĮVYKDYMO TIKIMYBĖS APSKAIČIAVIMAS	131
3.2.1. Reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimas iš įmonių individualių įsipareigojimų neįvykdymo tikimybių	131
3.2.2. Reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimas iš metinių faktinių „blogų“ įmonių dažnių	133
3.2.3. Stabilumo ir lyginamoji analizė	141
3.3. SUKURTOS REITINGŲ SISTEMOS TAIKYMAS BANKE	143
3.3.1. Reitingų sistemos taikymo sritys	143
3.3.2. Pakartotinis patikimumo vertinimas	157
3.3.3. Atmestų paraiškų įtraukimas kuriant naujus statistinius vertinimo balais modelius	160
3.3.3.1. Žemas paraiškų atmetimo lygis	161
3.3.3.2. Aukštas paraiškų atmetimo lygis	168
IŠVADOS IR PASIŪLYMAI	173
AUTORĖS PUBLIKACIJŲ DISERTACIJOS TEMA SĄRAŠAS	181
LITERATŪRA	182
PRIEDAI	191

SANTRUMPOS

AR – tikslumo santykis

AUC – plotas po gavėjų veiklos charakteristikų kreive

CAP kreivė – kaupiamojo tikslumo kreivė

EAD – pozicijos vertė, esant įsipareigojimų neįvykdymui

HHI – Herfindahlio ir Hirschmano indeksas

H ir L kriterijus – Hosmerio ir Lemešou kriterijus

IRB metodas – vidaus reitingais pagrįstas metodas

IV – informacijos vertė

LDP – žemo įsipareigojimų neįvykdymo lygio portfeliai

LGD – nuostolis dėl įsipareigojimų neįvykdymo

NPV – grynoji dabartinė vertė

ODF – faktinio įsipareigojimų neįvykdymo dažnis

PD – įsipareigojimų neįvykdymo tikimybė

ROC kreivė – gavėjų veiklos charakteristikų kreivė

WOE – įtakos svoris

LENTELĖS, PAVEIKSLAI, INTARPAI, PRIEDAI

LENTELĖS

1 lentelė. „Blogos“ įmonės apibrėžimai pagal Lietuvos teisės aktus	25
2 lentelė. Išorės ir vidaus modelių palyginimas	30
3 lentelė. Paraiškų ir elgsenos modelių kūrimo būdai	32
4 lentelė. Patikimumo vertinimo imties sudarymo būdai	52
5 lentelė. Modelių patikimumo tyrimai	60
6 lentelė. Dažniausiai į modelius įtraukiami rodikliai	62
7 lentelė. Reitingų PD apskaičiavimo metodai	70
8 lentelė. Klasifikacinė lentelė	84
9 lentelė. AUC ir AR interpretacija	89
10 lentelė. Praktikoje pasiekiami AR	89
11 lentelė. Bankų taikomi visos paskolos sumos limitai	96
12 lentelė. Įmonėms taikomi papildomi kriterijai	97
13 lentelė. Vertinimo balais modelių taikymo patirtis	99
14 lentelė. Statistinių modelių taikymas	99
15 lentelė. Mišrių modelių taikymas	101
16 lentelė. Ekspertinių modelių taikymas	101
17 lentelė. Patikimumo vertinimo metodai	105
18 lentelė. Modelių taikymo sritys	106
19 lentelė. Numatomi modelių taikymo pokyčiai	106
20 lentelė. Įvesties kintamojo <i>Apskritis</i> analizė	114
21 lentelė. Įvesties kintamojo <i>Grynasis pelnas (nuostoliai)/Turtas iš viso</i> analizė	114
22 lentelė. Įvesties kintamieji logistinės regresijos modelyje	116
23 lentelė. Koeficientų nelygybės 0 reikšmingumo analizė	118
24 lentelė. Suderinamumo su empiriniais duomenimis analizė	119
25 lentelė. Lietuvos įmonių klasifikacinė lentelė	120
26 lentelė. Pasiūlyto modelio diskriminacinės galios analizė	122
27 lentelė. Lietuvos įmonių reitingų skalė	124
28 lentelė. Reitingų skalės stabilumo analizė	125
29 lentelė. Įmonių stabilumo indekso apskaičiavimas naudojant patikimumo vertinimo imtį	128
30 lentelė. Įvesties kintamųjų diskriminacinės galios ir stabilumo analizė	129
31 lentelė. Įvesties kintamojo <i>Pinigai ir pinigų ekvivalentai / Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai</i> reikšmių skirstinio pokyčiai	130
32 lentelė. Lietuvos įmonių reitingų PD	132
33 lentelė. Reitingų PD(4) palyginimas	135
34 lentelė. Minimalios ir maksimalios PD ₂₀₀₆ ir PD ₂₀₀₇	138
35 lentelė. PD(1) stabilumo analizė	142
36 lentelė. PD(1) lyginamoji analizė	143
37 lentelė. Lūžio reitingas naudojant kūrimo imtį	146
38 lentelė. Lūžio reitingas naudojant patikimumo vertinimo imtį	146
39 lentelė. Reitingų sistema teikiant paskolas	148
40 lentelė. Kūrimo ir patikimumo vertinimo imčių įmonių paskolos	151
41 lentelė. Reitingų ir PD pokyčiai blogėjant ekonominėms sąlygoms	156
42 lentelė. Didinimas (atmesta 10,92% paraiškų)	161
43 lentelė. Perklasifikavimas (1) (atmesta 10,92% paraiškų)	162

44 lentelė. Perklasifikavimas (2) (atmesta 10,92% paraiškų)	163
45 lentelė. Lūžio taško metodas (1) (atmesta 10,92% paraiškų)	164
46 lentelė. Lūžio taško metodas (2) (atmesta 10,92% paraiškų)	164
47 lentelė. Proporcingas poliarizuotas dalijimas reitinguose (atmesta 10,92% paraiškų) ...	165
48 lentelė. Konservatyvus poliarizuotas dalijimas reitinguose (atmesta 10,92% paraiškų)	165
49 lentelė. Dvigubas dalijimas bendrai (1) (atmesta 10,92% paraiškų)	166
50 lentelė. Dvigubas dalijimas bendrai (2) (atmesta 10,92% paraiškų)	167
51 lentelė. Modelių diskriminacinė galia (atmesta 10,92% paraiškų)	167
52 lentelė. Didinimas (atmesta 50% paraiškų)	169
53 lentelė. Konservatyvus poliarizuotas dalijimas reitinguose (atmesta 50% paraiškų)	169
54 lentelė. Modelių diskriminacinė galia (atmesta 50% paraiškų)	170

PAVEIKSLAI

1 pav. Skolininkų reitingų sistemos taikymas banke	16
2 pav. Modelio kūrimo etapai	17
3 pav. Paskolų teikimo procesas	19
4 pav. Visiškai automatizuotas paskolų teikimo procesas	20
5 pav. „Blogos“ įmonės apibrėžimo pasirinkimo dažnumas	26
6 pav. Paraiškų modelio kūrimas	34
7 pav. Elgsenos modelio kūrimas	34
8 pav. Perėjimas nuo paraiškos prie elgsenos vertinimo balo (1-as metodas)	38
9 pav. Perėjimas nuo paraiškos prie elgsenos vertinimo balo (2-as metodas)	38
10 pav. Statistinių vertinimo balais modelių klasifikavimas	39
11 pav. PD priklausomybė nuo Z.....	42
12 pav. Kaupiamosios PD priklausomybė nuo laikotarpio ir tapsmo „blogu“ skolininku greičio	43
13 pav. Grafinio modeliavimo pavyzdys	44
14 pav. Daugiasluoksnių perceptrono modelis	46
15 pav. Statistinio metodo taikymo dažnumas, %	49
16 pav. Atmestų paraiškų įtraukimo metodų grupės	54
17 pav. LDP problemos aktualumas	73
18 pav. Dviejų iš eilės LDP reitingų, kai nėra faktinių „blogų“ skolininkų, PD	79
19 pav. Dviejų iš eilės LDP reitingų, kai yra keli faktiniai „blogi“ skolininkai, PD	80
20 pav. Reitingų sistemos patikimumo vertinimas	85
21 pav. Patikimumo vertinimo metodų taikymo dažnumas, %	86
22 pav. CAP kreivė	87
23 pav. ROC kreivė	88
24 pav. Įmonių duomenų rinkimo schema	109
25 pav. Kūrimo ir patikimumo vertinimo imtys	111
26 pav. Pasiūlyto modelio CAP kreivė	121
27 pav. Pasiūlyto modelio ROC kreivė	122
28 pav. „Gerų“ ir „blogų“ kūrimo imties įmonių skirstiniai	125
29 pav. „Gerų“ ir „blogų“ patikimumo vertinimo imties įmonių skirstiniai	126
30 pav. ODF kūrimo ir patikimumo vertinimo imtyse palyginimas	127
31 pav. Pirmų trijų LDP reitingų ODF ₂₀₀₆ ir PD ₂₀₀₆	134
32 pav. Pirmų trijų LDP reitingų ODF ₂₀₀₇ ir PD ₂₀₀₇	136
33 pav. Septinto reitingo PD ₂₀₀₇ apskaičiavimas	138
34 pav. Posterioriniai pirmo, antro ir trečio reitingų PD ₂₀₀₆ ir PD ₂₀₀₇ skirstiniai $p(\theta D,e)$..	140

35 pav.	Posteriorinis septinto reitingo PD_{2007} skirstinys $p(\theta D,e)$	140
36 pav.	Portfelio ODF priklausomybė nuo atmetimo lygio.....	144
37 pav.	Lūžio reitingo pasirinkimas.....	145
38 pav.	NPV analizė (kūrimo imtis)	147
39 pav.	NPV analizė (patikimumo vertinimo imtis).....	147
40 pav.	Kredito rizikos marža (kūrimo imtis).....	149
41 pav.	Kredito rizikos marža (patikimumo vertinimo imtis)	150
42 pav.	Kapitalo poreikis (kūrimo imtis).....	152
43 pav.	Kapitalo poreikis (patikimumo vertinimo imtis)	152
44 pav.	Įmonių skirstinio ir reitingų $PD(1)$ pokyčiai (kūrimo imtis)	153
45 pav.	Kapitalo poreikis esant ekonominiam nuosmukiui (kūrimo imtis)	154
46 pav.	Įmonių skirstinio ir reitingų $PD(1)$ pokyčiai (patikimumo vertinimo imtis)	155
47 pav.	Kapitalo poreikis esant ekonominiam nuosmukiui (patikimumo vertinimo imtis)	155
48 pav.	Reitingų sistemos pakartotinio patikimumo vertinimo schema	159
49 pav.	Atmestų paraiškų įtraukimo metodo pasirinkimas	171

INTARPAI

1 intarpas.	Duomenų masyvo sudarymo problemos pavyzdys	36
2 intarpas.	Trukmės metodų taikymo pavyzdžiai	75

PRIEDAI

1 priedas.	Pavyzdinis ekspertinis fizinių asmenų vertinimo balais modelis	191
2 priedas.	Vertinimo balais modelių kūrimas (atsižvelgiant į paskolos ir skolininko lygį)	193
3 priedas.	Patikimumo vertinimo imčių pavyzdžiai	194
4 priedas.	Mokėjimų istorijos rodikliai	195
5 priedas.	Forrest (2005) metodai be koreliacijos	196
6 priedas.	Vertinimo balais modelių taikymo Lietuvos bankuose tyrimo anketa	197
7 priedas.	Lietuvos bankų vertinimo balais modelių įvesties kintamieji	204
8 priedas.	Individuali įvesties kintamųjų diskriminacinė galia	208
9 priedas.	Įvesties kintamieji logistinės regresijos modelyje	210
10 priedas.	Multikolinearumo analizė	215
11 priedas.	Nagrinėtos reitingų skalės	216
12 priedas.	Lyginamajai analizei taikyti modeliai	219
13 priedas.	Lyginamosios analizės rezultatai	220
14 priedas.	Reitingų $PD(1)$, $PD(2)$ ir $PD(3)$ kalibravimo tikslumo vertinimas	221
15 priedas.	LDP reitingų PD_{2006} ir PD_{2007} apskaičiavimas	226
16 priedas.	Reitingų PD (Pluto, Tasche (2005) metodas be koreliacijų)	227
17 priedas.	Reitingų $PD(4)$ kalibravimo tikslumo vertinimas	228
18 priedas.	Eksponentinio PD glodinimo rezultatai	235
19 priedas.	Portfelio NPV analizė	236
20 priedas.	Reitingų sistemos taikymo Lietuvos bankuose galimybės	237

IVADAS

Temos aktualumas. Suteikdamas paskolą, bankas prisiima kredito riziką. Kad galima būtų priimti sprendimą suteikti paskolą (nesuteikti paskolos), banke turi būti kredito rizikos vertinimo modelis. Bankas negali tokiu pačiu būdu vertinti visų savo skolininkų kredito rizikos. Pirma, įvairių skolininkų rūšių kredito rizikos vertinimo kriterijai skiriasi. Pavyzdžiui, centrinės valdžios ir centrinių bankų kreditingumas priklauso nuo makroekonominių sąlygų, o įmonės kreditingumas vertinamas atsižvelgiant į jos valdymą, padėtį rinkoje, finansinę būklę. Antra, skiriasi skirtingų skolininkų rūšių duomenų šaltiniai, pavyzdžiui, įmonių kredito rizikai vertinti bankas gali naudoti jų finansinių ataskaitų duomenis, tačiau tai neįmanoma vertinant fizinius asmenis. Trečia, skiriasi įvairių skolininkų rūšių faktinio įsipareigojimų neįvykdymo dažniai. Praeityje tiek smulkių ir vidutinių, tiek stambių įmonių, taip pat fizinių asmenų kredito rizika bankuose buvo vertinama individualiai, skolininkų priskyrimas reitingams buvo pagrįstas laisvai interpretuojamais kriterijais, kuriuos pasirinkti ir pasverti ekspertas turėjo didelę laisvę, tačiau ekspertui ilgai truko priskirti skolininkus reitingams. Pastaraisiais dešimtmečiais bankų konkurencija ir siekis didinti pajamas gerokai padidėjo, o tai skatina ieškoti veiksmingesnių ir tikslesnių skolininkų kredito rizikos vertinimo metodų. Praėjusio amžiaus septintame–aštuntame dešimtmetyje paplitus kredito kortelėms, atsirado poreikis automatizuoti paskolų teikimo procesą, todėl buvo pradėti taikyti vertinimo balais modeliai (angl. *scoring models*). Vertinimo balais modeliai gali būti ekspertiniai, kai kriterijai ir jų svoriai nustatomi ekspertiniu būdu, statistiniai, kai kriterijai ir jų svoriai nustatomi statistiniu būdu, ir mišrūs. Smulkių, vidutinių įmonių ir fizinių asmenų kredito rizikai vertinti bankuose buvo vis plačiau pradėti taikyti statistiniai vertinimo balais modeliai, jie tampa vis reikšmingesni bendrame visų kredito rizikos vertinimo metodų kontekste.

Jei taikant statistinius vertinimo balais modelius yra automatizuojamas paskolų teikimo procesas, galima, susidarant mažesnėms laiko ir piniginių sąnaudoms bei tiksliau vertinant kredito riziką, daugiau skolinti „ribiniams skolininkams“, t. y. tokiems, kurie kitu atveju negautų paskolos. Dėl to padidėja banko pelnas. Yra atmetama daugiau rizikingesnių paraiškų, sumažėja pirmos rūšies klaida (kai bankas suteikia paskolą, kuri vėliau tampa „bloga“) ir banko kredito nuostoliai. Tačiau tuo pat metu yra priimama daugiau nerizikingų paraiškų, sumažėja antros rūšies klaida (kai bankas nesuteikia paskolos, nors ji būtų tapusi „gera“) ir padidėja banko pajamos. Kai paraiškų vertinimo procesas yra automatizuotas, esant tokiam pačiam paraiškų atmetimo lygiui, faktinio įsipareigojimų neįvykdymo dažniai būna 15 %–25 % mažesni nei tada, kai paraiškos yra vertinamos individualiai. Be to, paskolų

teikimo procesas tampa aiškesnis, kredito rizikos vertinimas – objektyvesnis, gerėja paskolų portfelio valdymas.

Lietuvoje poreikis taikyti statistinius vertinimo balais modelius ypač padidėjo perkėlus pagal Naująjį kapitalo susitarimą parengtos Naujosios kapitalo pakankamumo direktyvos nuostatas į nacionalinę teisę. Remiantis jomis, vidaus reitingais pagrįstą metodą taikantiems bankams leidžiama patiems skaičiuoti savo skolininkų įsipareigojimų neįvykdymo tikimybę (angl. *probability of default*), tačiau jie turi laikytis tam tikrų teisinių reikalavimų (Lietuvos bankas 2006a). Be to, iki 2009 metų pradžios šalies bankų suteiktų paskolų portfelis sparčiai didėjo, o 2012 metais vėl pradėjo didėti. Teigiamo paskolų portfelio augimo tikimasi ir 2013 metais. Padidėjus paskolų imčiam, daugeliui bankų, niekada anksčiau netaikiusių statistinių vertinimo balais modelių, atsirado galimybė juos taikyti. Dėl to tampa ypač aktualu išnagrinėti Lietuvos bankų statistinių vertinimo balais modelių taikymo praktiką, surasti jos tobulintinas sritis ir sukurti tinkamus modelius.

Mokslinės problemos esmė. Lietuvos bankuose statistiniai vertinimo balais modeliai vis dar nėra plačiai taikomi (Dzidzevičiūtė 2010d). Trūkstant mokslinių darbų ir straipsnių apie šių modelių kūrimą, bankams neaišku, kaip skolininkus suskirstyti į „gerus“ ir „blogus“, kaip apibrėžti laikotarpį, per kurį skolininkas tampa „blogas“, ar kurti vieną bendrą modelį, ar atskirus modelius skirtingoms skolininkų rūšims, kokį statistinį metodą pasirinkti, kaip sudaryti imtį, ar įtraukti atmetas paraiškas, ir jei taip, tai kokiu būdu, kokius įvesties kintamuosius naudoti, kaip priskirti skolininkus reitingams ir apskaičiuoti reitingų įsipareigojimų neįvykdymo tikimybę, ypač tada, kai yra žemo įsipareigojimų neįvykdymo lygio portfeliai ir t. t.

Statistiniai vertinimo balais modeliai yra taikomi tada, kai bankas turi daug konkrečios rūšies paskolų. Be to, jeigu bankas turi mažai duomenų apie tam tikros paskolų rūšies faktinius „blogus“ skolininkus, neįmanoma sukurti patikimo modelio. Dėl to įmonių kredito rizikai vertinti statistiniai vertinimo balais modeliai yra taikomi rečiau negu fizinių asmenų kredito rizikai. Dėl skirtingų skolininkų savybių yra sunku sukurti patikimą bendrą modelį. Lietuvoje bankams ne visada pakanka duomenų, kad jie galėtų sukurti savus įmonių statistinius vertinimo balais modelius, todėl jie ieško kitų išeičių: kuria ekspertinius modelius, taiko moksliniuose straipsniuose pasiūlytus statistinius vertinimo balais modelius arba perka išorinių paskolų registru parduodamus modelius, skolininkų duomenis, išorinių paskolų registru sukurtais modeliais nustatytus skolininkų reitingus. Tačiau iš išorinių paskolų registru pirkti modelius ar skolininkų reitingus yra brangu. Užsienio autorių pasiūlyti statistiniai vertinimo balais modeliai buvo sukurti naudojant Lietuvos įmonių

nereprezentuojančius duomenis. Iki šiol kiti Lietuvos autoriai nepasiūlė bankams statistinio vertinimo balais modelio, sukurto naudojant didelę Lietuvos įmonių imtį ir taikant įsipareigojimų neįvykdymo apibrėžimą, tinkančio įvairių ekonominės veiklos rūšių įmonėms vertinti.

Disertacijos tikslas – sukurti statistiniu vertinimo balais modeliu pagrįstą Lietuvos įmonių reitingų sistemą ir įvertinti šios sistemos taikymo Lietuvos bankuose galimybes.

Disertacijos objektas – statistiniais vertinimo balais modeliais pagrįstos reitingų sistemos.

Disertacijos uždaviniai:

- Išanalizuoti statistinių vertinimo balais modelių kūrimo etapus ir reitingų skalės sudarymą.
- Ištirti reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimo metodus.
- Išnagrinėti statistiniais vertinimo balais modeliais pagrįstų reitingų sistemų patikimumo vertinimo metodus.
- Atlikti Lietuvos komercinių bankų ir Lietuvoje veikiančių užsienio bankų skyrių apklausą, siekiant išanalizuoti šalies bankų vertinimo balais modelių kūrimo ir taikymo praktiką, nustatyti jos tobulintinas sritis.
- Naudojant iš išorinio paskolų registro gautus Lietuvos įmonių duomenis, sukurti statistiniu vertinimo balais modeliu pagrįstą Lietuvos įmonių reitingų sistemą.
- Įvertinti šios reitingų sistemos taikymo Lietuvos bankuose galimybes.

Mokslinis naujumas. Kiti Lietuvos autoriai kruopščiai nenagrinėjo statistinių vertinimo balais modelių, jų kūrimo ir taikymo šalies bankuose. Daugiausia dėmesio iki šiol yra skirta Altmano modelių tinkamumui šalies įmonių bankrotui prognozuoti ir restruktūrizavimo naudai vertinti (Mackevičius, Poškaitė 1999; Tvaronavičienė 2001; Bivainis, Tamošiūnas 2003; Mackevičius, Rakštelienė 2005; Mackevičius, Silvanavičiūtė 2006; Stundžienė, Boguslauskas 2006; Garškaitė 2008; Mackevičius, Sneiderė 2010). Kiti užsienio autorių sukurti statistiniai vertinimo balais modeliai nebuvo taip plačiai ištyrinėti Lietuvos mokslininkų (žr. Mackevičius, Silvanavičiūtė 2006; Garškaitė 2008; Mackevičius, Sneiderė 2010). Leipus ir Valužis (2006) nagrinėjo tik struktūrinius (įmonių vertės) ir redukuotuosius (intensyvumo) kredito rizikos modelius, bet ne vertinimo balais modelius. Kamienas ir Valvonis (2004), Valvonis (2006) teorinius vertinimo balais modelių aspektus nagrinėjo kartu su kitais kredito rizikos vertinimo metodais, tačiau jų straipsniuose vertinimo balais modeliai yra apibūdinti tik bendrais bruožais, kaip viena iš skolininkų kredito rizikos vertinimo metodų grupių, o statistinių vertinimo balais modelių kūrimo etapai nėra smulkiai

išanalizuoti. Dauguma jų nagrinėtų metodų gali būti taikomi vertinant tik tų įmonių, kurių akcijos kotiruojamos vertybinių popierių biržoje ar kurios yra išleidusios skolos vertybinių popierių, kredito riziką. Visų kitų įmonių ir fizinių asmenų kredito rizikai vertinti yra taikomi vertinimo balais modeliai, taigi jie šalies bankams yra patys svarbiausi. Todėl šioje disertacijoje yra detalai išanalizuoti statistinių vertinimo balais modelių kūrimo etapai, jų taikymas banke. Be to, kiti Lietuvos autoriai iki šiol atskirai neanalizavo paraiškų ir elgsenos vertinimo balais modelių kūrimo aspektų, atmestų paraiškų įtraukimo metodų ir reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimo metodų, ypač kai yra žemo įsipareigojimų neįvykdymo lygio portfeliai. Visa tai yra nuodugnai išanalizuota šioje disertacijoje.

Iki šiol kiti autoriai neatliko ir šalies bankų apklausos apie statistinius vertinimo balais modelius. Informacija, ar šalies bankai taiko statistinius vertinimo balais modelius, kokia jų aprėptis ir pobūdis, yra konfidenciali; nei patys bankai, nei juos prižiūrintis Lietuvos bankas tokio pobūdžio informacijos viešai prieinamuose informaciniuose leidiniuose, interneto tinklalapiuose neskelbia. Nors buvo atlikti du tyrimai, iš kurių vienas skirtas šalies bankuose organizuojamam kredito rizikos valdymui (Valvonis 2004), o kitas – bankų taikomai stambių įmonių reitingavimo praktikai (Savickaitė, Valvonis 2007), nė viename iš šių straipsnių nebuvo išnagrinėta mažmeninių paskolų kredito rizikos vertinimo praktika, nebuvo apimti mažmeninių paskolų vertinimo balais modeliai. Dėl to šios disertacijos autorė atliko šalies bankų apklausą, siekdama iširti mažmeninių paraiškų vertinimo balais modelių taikymo šalies bankuose praktiką (žr. Dzidzevičiūtė 2010d). Šioje disertacijoje yra detalai išanalizuoti šios apklausos rezultatai.

Keletas Lietuvos autorių (Grigaravičius 2003; Merkevičius ir kt. 2006; Stoškus ir kt. 2007; Mileris 2009, 2010; Buzius ir kt. 2010; Mileris, Boguslauskas 2011) sukūrė įmonių statistinių vertinimo balais modelių, tačiau naudodami nedidelę įmonių imtį, todėl šie modeliai tinka ne visoms įmonėms vertinti. Grigaravičius (2003) sukūrė logistinės regresijos modelį naudodamas tik 88 Lietuvos įmonių, kurių akcijos kotiruojamos vertybinių popierių biržoje, duomenis, todėl modelis labiau tinka šiai įmonių grupei. Stoškus ir kt. (2007), kurdami diskriminantinės analizės modelį, ištyrė tik 13 įmonių – penkias bankrutavusias ir aštuonias sėkmingai dirbančias. Merkevičius ir kt. (2006), kurdami dirbtinių neuroninių tinklų modelius, naudojo tik 742 Lietuvos įmonių duomenis, Mileris (2009, 2010), Mileris, Boguslauskas (2011), kurdami diskriminantinės analizės, logistinės regresijos ir dirbtinių neuroninių tinklų modelius – tik 100 Lietuvos įmonių duomenis. Be to, visi minėti autoriai, kurdami modelius, naudojo tik finansinius santykinius rodiklius, apibrėždami „blogą“

įmonę, taikė tik bankroto požymį, o dauguma jų straipsniuose nepateikė į modelius įtrauktų įvesties kintamųjų ir (arba) jų koeficientų, todėl bankai negalėtų taikyti jų modelių praktikoje. Šioje disertacijoje pateiktas statistinis modelis tinka visų ekonominės veiklos rūšių įmonėms vertinti, yra sukurtas naudojant net 22 799 „įmonės-metų“ įrašus, jį sudaro tiek kiekybiniai, tiek kokybiniai įvesties kintamieji. „Blogai“ įmonei apibrėžti buvo taikytas įsipareigojimų neįvykdymo apibrėžimas, todėl modelis gali būti taikomas skaičiuojant kapitalo poreikį vadovaujantis Lietuvos banko teisės aktų reikalavimais.

Praktinis reikšmingumas. Sukurta statistiniu vertinimo balais modeliu pagrįsta Lietuvos įmonių reitingų sistema gali būti taikoma ne tik bankuose įvairiais tikslais, bet ir kitose įstaigose, kuriose tenka vertinti įmonių kredito riziką: vartojimo kreditų, smulkiųjų vartojimo kreditų ir išperkamosios nuomos įmonės gali jį taikyti skolininkų darbdavių kredito rizikai vertinti, taip pat draudimo įmonėse ir pan. Ją taip pat gali taikyti įmonės, norinčios įvertinti savo pačių kreditingumą. Nors pasiūlyta reitingų sistema yra elgsenos (angl. *behavioural*), o ne paraiškų (angl. *application*) reitingų sistema, ją galima taikyti ir kaip paraiškų reitingų sistemą.

Jeigu bankas turi pakankamai duomenų ir gali sukurti savo statistinį įmonių vertinimo balais modelį, jis galėtų pasinaudoti šioje disertacijoje pateiktais atliktos analizės rezultatais ir pasiūlymais: pasirinkti tuos įvesties kintamuosius, kurie buvo įtraukti į pasiūlytą modelį, tokiu pačiu būdu sugrupuoti jų reikšmes, taikyti tokius pačius metodus ir t. t. Be to, šioje disertacijoje pateikta analizė gali būti naudinga ir kuriant bei taikant ekspertinius įmonių vertinimo balais modelius ar fizinių asmenų vertinimo balais modelius.

Tyrimo metodai. Nagrinėjant statistinių vertinimo balais modelių kūrimo etapus ir reitingų skalės sudarymą, reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimo ir patikimumo vertinimo metodus buvo išanalizuota teorinė literatūra ir dokumentai, logiškai analizuota, apibendrinta, sisteminta, abstrahuota ir konkretinta, taip pat atlikta metaanalizė ir sintezė. Šalies bankų mažmeninių paraiškų vertinimo balais modelių kūrimo ir taikymo praktika buvo ištirta anketinės apklausos būdu. Surinktai informacijai apibendrinti ir sisteminti buvo taikyti grupavimo, palyginimo ir grafinio vaizdavimo metodai, padarytos loginės išvados. Lietuvos įmonių reitingų sistemai kurti gauti empiriniai duomenys buvo susisteminti, atlikta jų statistinė analizė ir sintezė. Taip pat kuriant reitingų sistemą buvo abstrahuota, modeliuota, sisteminta ir logiškai analizuota, padarytos apibendrinamosios išvados. Informacijos šaltiniai buvo užsienio ir Lietuvos autorių knygos ir moksliniai straipsniai, tarptautinių bankus prižiūrinčių institucijų rekomendaciniai dokumentai,

tarptautinių seminarų medžiaga, Europos Sąjungos ir Lietuvos teisės aktai, Lietuvos bankų atsakymai į anketos klausimus, išorinis paskolų registras UAB „Creditinfo Lietuva“.

Tyrimo apribojimai. Atliekant tyrimą buvo susidurta su keletu apribojimų:

- Apklausos atlikimo metu Lietuvoje veikė devyni komerciniai bankai ir septyni užsienio bankų skyriai. Su jais visais buvo deramasi dėl dalyvavimo apklausoje. Dalyvauti sutiko tik aštuoni komerciniai bankai ir vienas užsienio banko skyrius. Todėl šalies bankų mažmeninių paraiškų vertinimo balais modelių kūrimo ir taikymo praktikos analizė nėra išsami.
- Bankai išoriniam paskolų registrui UAB „Creditinfo Lietuva“ informacijos apie konkrečių paskolų suteikimo datas neteikia, todėl nebuvo galima sukurti paraiškų modelio, kai įsipareigojimų neįvykdymo tikimybė yra prognozuojama metams į priekį nuo paskolos suteikimo datos. Todėl buvo sukurtas tik Lietuvos įmonių elgsenos vertinimo balais modelis.
- Statistiniam Lietuvos įmonių vertinimo balais modeliui kurti buvo naudotas siauresnis nei reikalauja Lietuvos bankas įsipareigojimų neįvykdymo apibrėžimas (buvo įtrauktas tik mokėjimo termino pradelsimas daugiau kaip 90 kalendorinių dienų ir bankrotas). Siauresnis apibrėžimas buvo naudotas atsižvelgiant į tai, kad UAB „Creditinfo Lietuva“ nekaupia informacijos apie paskolų persvarstymą, jų vertės tikslinimą, nemokumą ir kitus papildomus apibrėžiant įsipareigojimų neįvykdymą naudojamus požymius.
- Ne visus užsienio autorių pasiūlytuose modeliuose naudotus įvesties kintamuosius galima naudoti Lietuvoje dėl apskaitos, ekonominių, teisinių ir kt. skirtumų. Išoriniame paskolų registre UAB „Creditinfo Lietuva“ yra kaupiami ne visi įmonių finansinių ataskaitų straipsniai, pavyzdžiui, nekaupiami įrašai apie *Finansinę ir investicinę veiklą* ir pan. Dėl to kuriant įmonių modelį nebuvo galima įtraukti kai kurių populiarių rodiklių, pavyzdžiui, *Pelno (nuostolių) prieš palūkanas ir mokesčius ir Turto iš viso* santykio. Be to, dėl šios priežasties atliekant lyginamąją analizę buvo galima taikyti tik tuos kitų autorių sukurtus statistinius vertinimo balais modelius, kurių rodiklius galima apskaičiuoti naudojant šiame registre sukauptais duomenimis.
- Nebuvo gauta informacijos apie įmonių rodiklių pokyčius per metus ir tikslias datas, kada įmonės tapo „blogos“, todėl nebuvo galima taikyti kai kurių autorių pasiūlytų reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimo metodų, kai yra žemo įsipareigojimų neįvykdymo lygio portfeliai. Taip pat dėl tos pačios priežasties nebuvo galima sukurti išlikimo analizės modelio.

Disertacijos rezultatų aprobavimas. Beveik visos disertacijos dalys ir tyrimų rezultatai yra pateikti paskelbtuose straipsniuose (1.1–1.2 dalys, 2.1–2.4 dalys, 3.1.1 dalis ir 3.2.2 dalis). Mokslo žurnaluose buvo publikuoti penki straipsniai disertacijos tema. Vienas jų buvo pristatytas 2010 m. balandžio 22–23 d. Rygoje vykusioje konferencijoje „*International Conference of Economics and management ICEM 2010*“. Dirbdama Lietuvos banke, kredito rizikos srityje, disertacijos autorė buvo kelių tarptautinių bankų priežiūros institucijų darbo grupių narė, dalyvavo keliuose su kredito rizika susijusiuose tarptautiniuose seminaruose. Vėliau autorė dirbo viename iš Lietuvos komercinių bankų, kuriame buvo pritaikytos kai kurios disertacijos dalys.

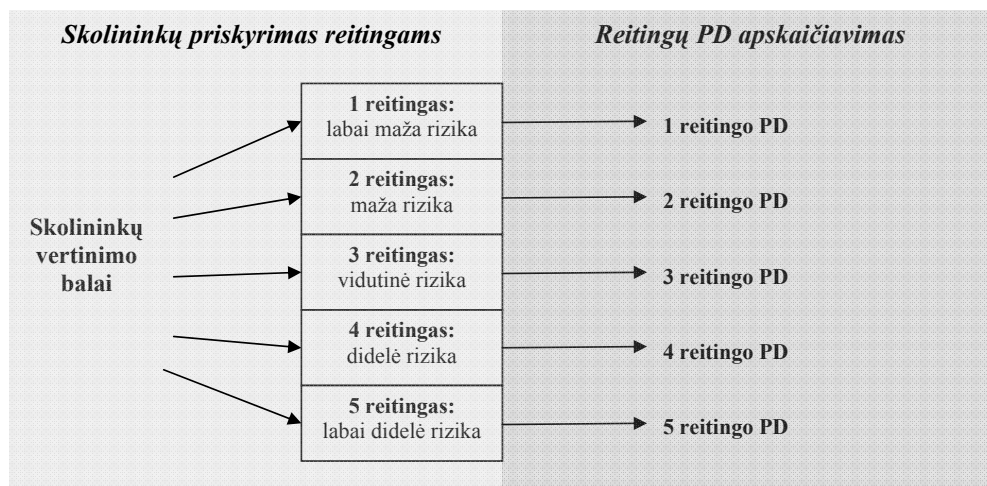
Disertacijos struktūra. Darbas susideda iš trijų skyrių. Pirmajame skyriuje yra aprašyti statistiniais vertinimo balais modeliais pagrįstų reitingų sistemų kūrimo ir taikymo bankuose ypatumai, antrajame – išanalizuoti šios disertacijos autorės atliktos šalies bankų apklausos rezultatai, trečiajame – pateikta statistiniu vertinimo balais modeliu pagrįsta Lietuvos įmonių reitingų sistema, įvertintos jos taikymo Lietuvos bankuose galimybės.

I. STATISTINIAIS VERTINIMO BALAIS MODELIAIS PAGRĪSTŲ REITINGŲ SISTEMŲ KŪRIMO IR TAIKYMO YPATUMAI

Reitingų sistema banke – tai sistema, apimanti visus metodus, procesus, kontrolės, duomenų rinkimo ir informacinių technologijų sistemas, padedančias įvertinti skolininkų kredito riziką, priskirti skolininkus reitingams ir apskaičiuoti kredito rizikos parametrus (Lietuvos bankas 2006a). Taikant reitingų sistemą banke yra susiduriama su dviem procesais – skolininkai yra priskiriami reitingams ir yra apskaičiuojami reitingų kredito rizikos parametrai. Naujasis kapitalo susitarimas (BCBS 2006) numato tris kredito rizikos parametrus: išpareigojimų neįvykdymo tikimybę (toliau – PD), nuostolį dėl išpareigojimų neįvykdymo (toliau – LGD) ir pozicijos vertę, esant išpareigojimų neįvykdymui (toliau – EAD). Šioje disertacijoje yra analizuojamas tik vienas kredito rizikos parametras – PD.

1.1. STATISTINIO VERTINIMO BALAIS MODELIO IR REITINGŲ SKALĖS KŪRIMAS IR TAIKYMAS BANKUOSE

Kai reitingų sistema yra pagrįsta statistiniu vertinimo balais modeliu, skolininkai yra priskiriami reitingams pagal tokio modelio rezultata.



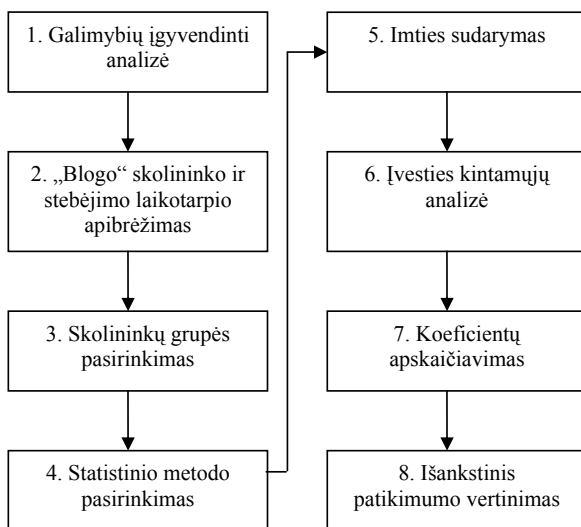
1 pav. Skolininkų reitingų sistemos taikymas banke

Šaltinis: sudaryta autorės.

Kiekvienam skolininkui statistiniu vertinimo balais modeliu yra apskaičiuojamas *vertinimo balas* (angl. *score*), pagal kurį jis yra priskiriamas vienam iš reitingų. Tada yra apskaičiuojama kiekvieno reitingo PD (žr. 1 pav.). Tai, kas yra įvardijama kaip *vertinimo balas*, priklauso nuo statistinio vertinimo balais modelio rezultato. Jeigu modelio rezultatas yra skolininko individuali PD (pvz., taikant logistinės ar *cloglog* regresijos modelį), tai *vertinimo balas* ir yra ši skolininko individuali PD. Tačiau jeigu modelio rezultatas yra ne PD, bet kreditingumo rodiklis (pvz., taikant diskriminantinės analizės modelį), tada *vertinimo balu* yra laikomas šis rodiklis.

1.1.1. Statistinio vertinimo balais modelio kūrimo etapai

Statistinio vertinimo balais modelio kūrimas – sudėtingas procesas, reikalaujantis nuodugniai išanalizuoti banko turimus duomenis ir iš anksto numatyti tikslus, kurių bus siekiama taikant tą modelį. Apibendrinus šios srities literatūrą (Thomas ir kt. 2002; Mays 2004; Siddiqi 2006; Anderson 2007), galima skirti aštuonis tokio modelio kūrimo etapus (žr. 2 pav.).



2 pav. Modelio kūrimo etapai

Šaltinis: sudaryta autorės pagal Thomas ir kt. 2002; Mays 2004; Siddiqi 2006; Anderson 2007.

Pirmasis jų – išanalizuoti tokį banko projekto modelį kurti ir jį taikyti įgyvendinamumą. Tai atlikus, yra apibrėžiamas „blogas“ skolininkas ir laikotarpis, per kurį nustatoma, ar skolininkas tampa „blogas“, ar ne. Tą laikotarpį galima vadinti stebėjimo laikotarpiu. Apsibrėžus, kokiais požymiais pasižymintis skolininkas bus laikomas „blogu“ ir

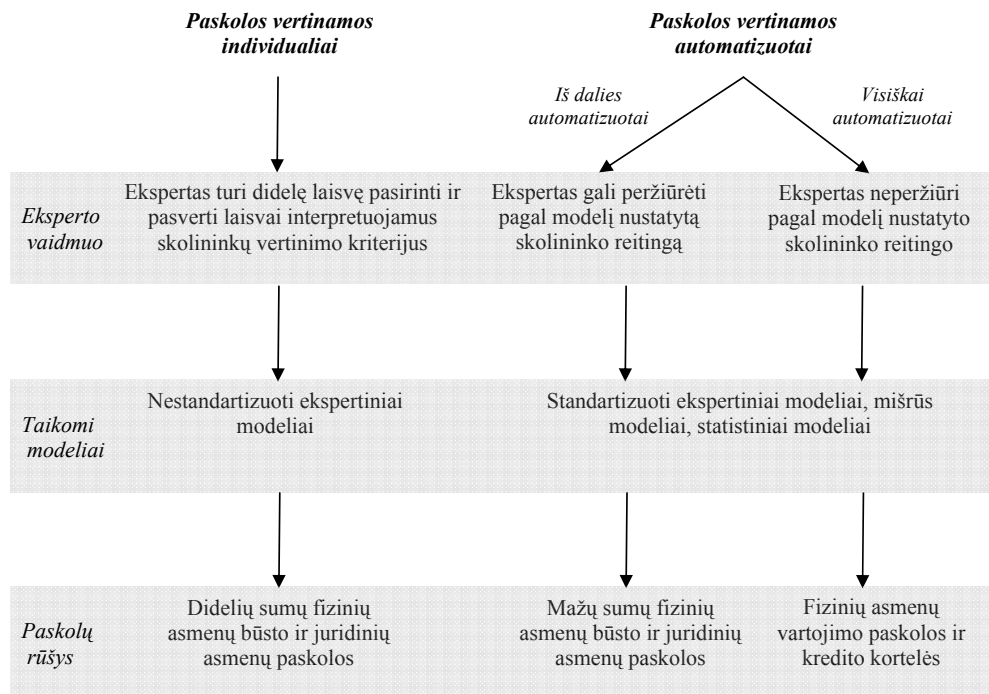
pasirinkus stebėjimo laikotarpį, yra sprendžiama, kokių skolininkų duomenis įtraukti kuriant vertinimo balais modelį, t. y. yra pasirenkamos skolininkų grupės. Paskui yra pasirenkamas statistinės duomenų analizės metodas, sudaroma imtis, analizuojami įvesties kintamieji, apskaičiuojami į modelį įtrauktų įvesties kintamųjų koeficientai, atliekamas išankstinis modelio patikimumo vertinimas. Prireikus grįžtama į bet kurį iš ankstesnių etapų ir procesas kartojamas, pavyzdžiui, bankas gali nuspręsti kurti vieną modelį visų fizinių asmenų paskoloms vertinti, tačiau analizuojant įvesties kintamuosius gali paaiškėti, kad yra labai daug neprediktyvių įvesties kintamųjų, todėl bankas gali grįžti į ankstesnį etapą – skolininkų grupės pasirinkimą – ir susiaurinti skolininkų grupę (pvz., pasirinkti tik fizinių asmenų būsto paskolų duomenis).

1.1.1.1. Projekto įgyvendinamumo analizė

Analizuojant projekto įgyvendinamumą, yra nustatomos projekto sąnaudos ir pajamos, įvertinamas statistinio vertinimo balais modelio kūrimo banke poreikis, apsisprendžiama, ar toks modelis bus kuriamas banko darbuotojų, ar ši paslauga bus perkama iš išorės, numatomi kiekvieno iš modelio kūrimo etapų išteklių, visų į jo kūrimą įtraukiamų banko darbuotojų ir trečiųjų asmenų atsakomybė, apsvarstomi organizaciniai klausimai (McNab, Wynn 2003).

Pradiniame statistinio vertinimo balais modelio kūrimo etape svarbu įvertinti banko turimų duomenų kokybę ir priimti su tuo susijusius sprendimus. Nepakankama duomenų kokybė paprastai būna viena pagrindinių priežasčių, neleidžiančių sukurti patikimą ar apskritai kokį nors modelį. Duomenų kokybės problemas lemia nepakankama darbuotojų kompetencija, informacinių technologijų trūkumai, apgaulė ir klaidos, tinkamo vadovavimo stoka ir pan. Tačiau pradiniame etape duomenų kokybę nėra paprasta įvertinti, tam tikri jos problemas lemiantys veiksniai gali būti nustatomi tik vėlesniuose etapuose. Antai atliekant įvesties kintamųjų analizę gali paaiškėti, kad trūksta pernelyg daug tam tikro įvesties kintamojo reikšmių. Būtent dėl duomenų kokybės bankas gali atsisakyti tokį įvesties kintamąjį naudoti tolesnei analizei, tačiau iš anksto to numatyti neįmanoma.

Iš anksto, pirmajame etape, būtina numatyti ir statistinio vertinimo balais modelio taikymo banke sritis. Tokie modeliai dažniausiai yra taikomi teikiant paskolas. Paskolos banke gali būti vertinamos individualiai arba paskolų teikimo procesas gali būti automatizuotas (žr. 3 pav.).



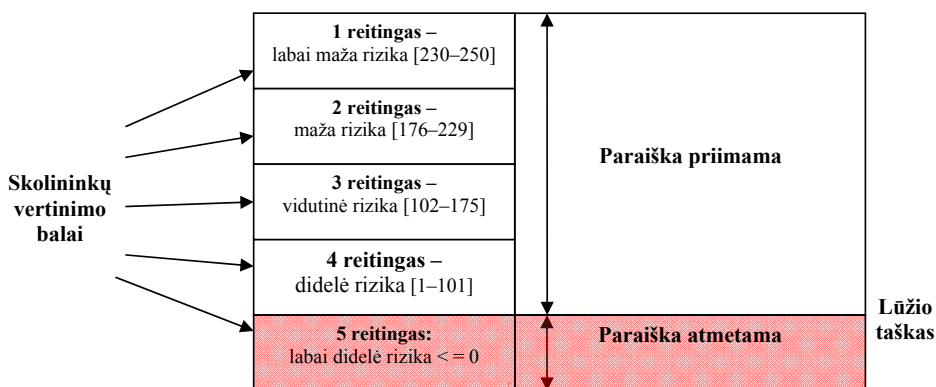
3 pav. Paskolų teikimo procesas

Šaltinis: sudaryta autorės.

Kai paskolų teikimo procesas yra visiškai automatizuotas, klientų aptarnavimo specialistas (vadybininkas) gali net nenusimanyi apie metodiką, pagal kurią yra apskaičiuojamas vertinimo balas ir nustatomas reitingas, paprastai jis tik suveda skolininko duomenis į informacinių technologijų sistemą. Jei konkretaus skolininko vertinimo balas yra blogesnis už banko nustatytą lūžio tašką, jo paraiška yra iš karto atmetama ir paskola nesuteikiama. Pavyzdžiui, tarkime, kad bankas visus skolininkus, kurių vertinimo balas yra nuo 230 iki 250, laiko labai mažos rizikos skolininkais ir juos priskiria 1 reitingui. Skolininkus, kurių vertinimo balas yra nuo 176 iki 229, laiko mažos rizikos skolininkais ir priskiria antram reitingui, ir t. t. Tų skolininkų, kurių vertinimo balas yra mažesnis arba lygus 0, paraiškas bankas atmeta (žr. 4 pav.). Nors dažniausiai visiškai automatizuotas paskolų teikimo procesas būna taikant statistinius modelius, toks jis gali būti ir taikant standartizuotus ekspertinius (žr. 1 priedą) ar mišrius modelius. Pavyzdžiui, banko ekspertai gali sukurti standartizuotą ekspertinį modelį nustatydami paskolų vertinimo kriterijus ir jų svorius, tačiau vėliau teikiant paskolas nedalyvauti. Visiškai automatizavus paskolų teikimo procesą, gali kilti kai kurių sunkumų, palyginti su individualiu paskolų vertinimu, juos

būtina apsvarstyti analizuojant galimybes įgyvendinti projektą (Liu 2001; Berger ir kt. 2002):

- mažiau dėmesio pavieniams skolininkams (paskola gali būti nesuteikiama tokiam skolininkui, kurio blogi būtent tie rodikliai, kurie yra modelio įvesties kintamieji, tačiau neatsižvelgiama į papildomą teigiamą informaciją apie tą skolininką);
- sunkiau įvertinti kai kuriuos kokybinius rodiklius, pavyzdžiui, vadovavimo kokybę, techninį „know-how“, padėtį rinkoje;
- neįmanoma deramai įvertinti skolininko perspektyvų ateityje;
- duomenų slaptumo pažeidimas, kai skolininkų duomenys yra siunčiami automatinio būdu.



4 pav. Visiškai automatizuotas paskolų teikimo procesas

Šaltinis: sudaryta autorės.

Kai paskolų teikimo procesas yra tik iš dalies automatizuotas, banko ekspertai ir (arba) aukštesnis banko organas gali peržiūrėti pagal modelį nustatytą skolininko reitingą ir, jei reikia, jį arba sprendimą suteikti paskolą (nesuteikti paskolos) pakoreguoti. Be to, modelyje gali būti tokių įvesties kintamųjų, kurių reikšmių iš karto nustatyti neįmanoma, būtina atlikti nuodugnią analizę, pavyzdžiui, įvertinti vadovavimo kokybę, techninį „know-how“, įmonės padėtį rinkoje ir pan. (OCC 1997; Puri ir kt. 2011).

Gali būti naudojami „minkšto“ ir „kieto“ lūžio taškai. Kai skolininko vertinimo balas yra blogesnis už „kieto“ lūžio tašką, paraiška yra iš karto atmetama ir paskola nesuteikiama, tačiau kai skolininko vertinimo balas yra „pilkojoje zonoje“ (tarp „kieto“ ir „minkšto“ lūžio taškų), toks skolininkas turi būti vertinamas papildomai, atsižvelgiant į papildomą informaciją apie jį, jo paskolą (sumą, tikslą, terminą ir kt.), užtikrinimo priemones, sakysime, paskola gali būti suteikiama tik taikant atitinkamas kredito rizikos mažinimo

priemonės ir pan. Ši papildomą vertinimą gali atlikti banko ekspertai individualiai (kai paskolų teikimo procesas yra iš dalies automatizuotas) arba jis gali būti atliekamas banko informacinių technologijų sistemose naudojant iš anksto numatytus kriterijus (kai paskolų teikimo procesas yra visiškai automatizuotas). Pastaruoju atveju atsakymas skolininkui, ar jam bus suteikta paskola ar ne, yra pateikiamas iš karto.

Lūžio taškui nustatyti yra keletas metodų (Thomas ir kt. 2002; Stein 2005; Blöchlinger, Leippold 2006; SAS 2009; Lieli, White 2010):

- atskiras lūžio taškas kiekvienai paskolai;
- istorinis metodas – yra analizuojama faktinių „blogų“ viso portfelio skolininkų dažnio priklausomybė nuo paraiškų atmetimo lygio (žr. 36–37 pav.);
- kaupiamojo faktinių „gerų“ skolininkų skaičiaus pokyčio ir kaupiamojo faktinių „blogų“ skolininkų skaičiaus pokyčio santykis: paprastai lūžio reitingu, nuo kurio yra atmetamos skolininkų paraiškos, yra pasirenkamas toks reitingas, kai šis santykis yra nuo 5:1 iki 3:1 (žr. 37–38 lenteles);
- portfelio grynosios dabartinės vertės maksimizavimas: lūžio reitingu galima pasirinkti tokį reitingą, nuo kurio, atmetus paraiškas, portfelio grynoji dabartinė vertė yra didžiausia (žr. 38–39 pav.). Skaičiuojant portfelio grynąją dabartinę vertę yra įtraukiamos ir alternatyviosios pajamos bei alternatyviosios sąnaudos:

$$NPV_i = ONDF_i \cdot b(TN) \cdot TN_i - ONDF_a \cdot c(FP) \cdot FP_i + ODF_a \cdot b(TP) \cdot TP_i - ODF_i \cdot c(FN) \cdot FN_i,$$

čia: NPV_i – portfelio grynoji dabartinė vertė, kai portfelį sudaro $i-1$ reitingų skolininkai, i reitingas – lūžio reitingas, nuo kurio yra atmetamos skolininkų paraiškos; $ONDF_i$ – faktinių „gerų“ portfelio skolininkų dažnis, kai portfelį sudaro $i-1$ reitingų skolininkai; $b(TN)$ – pajamos, gautos dėl to, kad buvo suteikta paskola skolininkui, kuris pagal modelį buvo pripažintas „geru“ ir iš tikrųjų toks tapo; TN_i – faktinių „gerų“ skolininkų skaičius nuo i reitingo (neįskaitytinai) iki geriausio reitingo; $ONDF_a$ – faktinių „gerų“ portfelio skolininkų dažnis, kai portfelį sudaro atmesti skolininkai; $c(FP)$ – alternatyviosios sąnaudos dėl to, kad nebuvo suteikta paskola skolininkui, kuris pagal modelį buvo pripažintas „blogu“, bet iš tikrųjų tapo „geras“ (II rūšies klaida); FP_i – faktinių „gerų“ skolininkų skaičius nuo blogiausio reitingo iki i reitingo (įskaitytinai); ODF_a – faktinių „blogų“ portfelio skolininkų dažnis, kai portfelį sudaro atmesti skolininkai; $b(TP)$ – alternatyviosios pajamos dėl to, kad nebuvo suteikta paskola skolininkui, kuris pagal modelį buvo pripažintas „blogu“ ir iš tikrųjų toks tapo; TP_i – faktinių „blogų“ skolininkų skaičius nuo blogiausio reitingo iki i reitingo (įskaitytinai); ODF_i – faktinių „blogų“ portfelio skolininkų dažnis, kai portfelį sudaro $i-1$ reitingų skolininkai; $c(FN)$ – sąnaudos dėl to, kad buvo suteikta paskola skolininkui, kuris

pagal modelį buvo pripažintas „geru“, bet iš tikrųjų tapo „blogas“ (I rūšies klaida); FN_i – faktinių „blogų“ skolininkų skaičius nuo i reitingo (neįskaitytinai), iki geriausio reitingo; i kinta nuo 1 iki $n + 1$, n – reitingų skaičius.

Taikant šį metodą yra atsižvelgiama į daugiau veiksnių nei taikant antrą ir trečią metodus, t. y. atsižvelgiama ne tik į faktinį „gerų“ ir „blogų“ reitingo skolininkų skaičių, bet ir į EAD, LGD, paskolų palūkanų normas, nerizikingą palūkanų normą, naudojamą pinigų srautams diskontuoti, paskolų trukmę, mokėjimo grafiką ir kitus veiksnius. Dėl to galima būtų daryti išvadą, kad šis metodas labiau nei antras ar trečias tinka renkantis lūžio reitingą.

Kai paskolos yra vertinamos individualiai, skolininkų priskyrimas reitingams yra pagrįstas laisvai interpretuojamais kriterijais, kuriuos pasirinkti ir pasverti ekspertas turi didelę laisvę. Individualiai paprastai yra vertinamos didelių sumų juridinių asmenų paskolos. Įmonės (ir jų paskolos) labiau skiriasi tarpusavyje nei fiziniai asmenys (ir jų paskolos), todėl šiuo atveju yra svarbus kokybinis rizikos įvertinimas, nes standartizuotais ekspertiniais ar statistiniais modeliais yra sunku įvertinti visus subjektyvius veiksnius. Be to, didelių sumų įmonių paskolos yra susijusios su didesne rizika bankui, todėl įmonių, paėmusių tokias paskolas, rizikai įvertinti turi būti skiriama daugiau dėmesio. Kartu didelių sumų įmonių paskolos duoda dideles pajamas bankui, todėl eksperto dalyvavimas vertinant tokių skolininkų riziką bankui santykinai nėra brangus. Tačiau paskolas vertinant individualiai visuomet išlieka žmogiškojo veiksnio rizika (t. y. ekspertas gali sąmoningai arba nesąmoningai nustatyti geresnį, nei turėtų būti, reitingą, ypač jei banko ekspertai yra materialiai skatinami už didesnius pardavimus arba blogesnį, nei turėtų būti, reitingą). Kartais individualiai yra vertinamos ir didelių sumų fizinių asmenų paskolos.

Banke paskolų palūkanų normos paprastai yra nustatomos iš nerizikingos palūkanų normos ir kredito rizikos maržos, o pastaroji priklauso nuo skolininko reitingo ir paskolos LGD. Kredito rizikos maržą galima apskaičiuoti pagal šią formulę (Stein 2005; Blöchlinger, Leippold 2006):

$$r_i = \frac{c(FN)_{proc.} \cdot ODF_i}{ONDF_i},$$

čia: r_i – i reitingo skolininkų kredito rizikos marža; $c(FN)_{proc.}$ – sąnaudų dėl to, kad buvo suteikta paskola skolininkui, kuris pagal modelį buvo pripažintas „geru“, bet iš tikrųjų tapo „blogas“, ir EAD santykis (t. y. LGD); ODF_i – faktinių „blogų“ portfelio skolininkų dažnis, kai portfelį sudaro i reitingų skolininkai; $ONDF_i$ – faktinių „gerų“ portfelio skolininkų dažnis, kai portfelį sudaro i reitingų skolininkai; i reitingas – toks, kuriam priskirto skolininko kredito rizikos maržą reikia apskaičiuoti; i kinta nuo 1 iki n ; n – reitingų skaičius.

Vertinimo balais modeliai gali būti taikomi ne tik teikiant paskolas ir skaičiuojant kredito rizikos maržas, bet ir rengiant ataskaitas vadovybei, skaičiuojant vertės sumažėjimą ar paskirstant kapitalą, valdant mokėjimo terminų pradelsimą, vertinant banko veiklos pelningumą ir efektyvumą, numatant jo veiklos strategiją, atliekant testavimą nepalankiausiomis sąlygomis, sudarant pakeitimo vertybiniais popieriais sandorius. Be to, vertinimo balais modeliai gali būti taikomi ir nustatant atnaujinamųjų paskolų limitus, numatant tikslinius naujų banko produktų klientus ar iš esamų atrenkant tuos, kurie galėtų būti kitų banko paslaugų vartotojai, pavyzdžiui, dideliais vertinimo balais vertinamus būsto paskolų skolininkus, kuriems galėtų būti pasiūlyta įsigyti dar ir kredito kortelę (Longenecker ir kt. 1997; Thomas ir kt. 2002; Schreiner 2003; Mays 2004; FIS, CEBS 2006b; Anderson 2007; Chorafas 2007; DB, ONB 2007; Banque de France 2008; Khandani ir kt. 2010).

Tarptautinės audito bendrovės *Deloitte Touche Tohmatsu* (2002) atlikto tyrimo rezultatai parodė, kad Australijos, Naujosios Zelandijos ir Pietų Afrikos bankuose vertinimo balais modeliai dažniausiai buvo taikomi teikiant paskolas, atliekant išieškojimą, prognozuojant kredito nuostolius, skaičiuojant vertės sumažėjimą ir nustatant atnaujinamųjų paskolų limitus.

Kita vertinimo balais modelių taikymo sritis – kapitalo poreikio skaičiavimas bankuose, taikančiuose vidaus reitingais pagrįstą (toliau – IRB) metodą¹. Tokie bankai turi patys skaičiuoti savo skolininkų PD, kuri vėliau yra naudojama skaičiuojant kapitalo poreikį (BCBS 2006; EP 2006; Lietuvos bankas 2006a). Kapitalo, reikalingo mažmeninės paskolos kredito rizikai padengti, poreikis yra apskaičiuojamas taip (EP 2006; Lietuvos bankas 2006a):

$$CR = RW \cdot EAD \cdot 8\%;$$

$$RW = (LGD \cdot \Phi\left(\frac{\Phi^{-1}(PD)}{\sqrt{1-R}} + \sqrt{\frac{R}{1-R}} \cdot \Phi^{-1}(0,999)\right) - PD \cdot LGD) \cdot 12,5 \cdot 1,06;$$

$$R = 0,03 \cdot \frac{1 - e^{-35 \cdot PD}}{1 - e^{-35}} + 0,16 \cdot \left[1 - \frac{1 - e^{-35 \cdot PD}}{1 - e^{-35}}\right],$$

čia: CR – kapitalo poreikis; RW – rizikos koeficientas; R – koreliacijos koeficientas.

Kai įmonių paskolos nėra priskiriamos mažmeninių paskolų grupei, turi būti taikomos kitos rizikos koeficiento ir koreliacijos formulės:

¹ Rašant disertaciją šį metodą taikė du Lietuvos bankai.

$$RW = (LGD \cdot \Phi \left(\frac{\Phi^{-1}(PD)}{\sqrt{1-R}} + \sqrt{\frac{R}{1-R}} \cdot \Phi^{-1}(0,999) \right) - PD \cdot LGD) \cdot \frac{1}{1-1,5 \cdot b} \cdot (1 + (M - 2,5) \cdot b) \cdot 12,5 \cdot 1,06;$$

$$R = 0,12 \cdot \frac{1 - e^{-50 \cdot PD}}{1 - e^{-50}} + 0,24 \cdot \left[1 - \frac{1 - e^{-50 \cdot PD}}{1 - e^{-50}} \right];$$

$$b = (0,11852 - 0,05478 \cdot \ln(PD))^2,$$

čia: M – terminas; b – termino veiksnys.

Kai įmonės paskola nėra priskiriama mažmeninių paskolų grupei, bet konsoliduotos įmonių grupės, kurios narė yra ta įmonė, bendra metinių pardavimo pajamų suma yra mažesnė kaip 50 mln. eurų (172 640 tūkst. Lt), bankas gali taikyti šią koreliacijos formulę²:

$$R = 0,12 \cdot \frac{1 - e^{-50 \cdot PD}}{1 - e^{-50}} + 0,24 \cdot \left[1 - \frac{1 - e^{-50 \cdot PD}}{1 - e^{-50}} \right] - 0,04 \cdot \left(1 - \frac{S - 5}{45} \right),$$

čia: S – metinių pardavimo pajamų suma.

Bankai, prieš pateikdami Lietuvos bankui prašymą leisti taikyti IRB metodą kapitalo poreikiui skaičiuoti, vidaus reitingų sistemas vidiniuose procesuose turi būti taikę ne mažiau kaip trejus metus (Lietuvos bankas 2006a). Taigi, vertinimo balais modelius daugelyje banko vidinių procesų rekomenduojama taikyti ir tiems bankams, kurie šiuo metu dar tik planuoja pradėti taikyti IRB metodą.

1.1.1.2. „Blogo“ skolininko ir stebėjimo laikotarpio apibrėžimas

Kuriant statistinį vertinimo balais modelį, būtina aiškiai apibrėžti, kokiais požymiais pasižymintis skolininkas bus priskiriamas prie „blogo“ skolininkų³. Ankstesni statistiniai įmonių vertinimo balais modeliai (*Altman, Lis, Tafler, Springate, Zavgren, Chesser, Ohlson, Zmijewski, Shumway*) daugiausia buvo kuriami taikant bankroto ar finansinių sunkumų (nemokumo) požymį (Shumway 1999; Doumpou, Zopounidis 1999; Altman 2000; Mackevičius, Silvanavičiūtė 2006; Garškaitė 2008).

² Kai metinių pardavimo pajamų suma ne didesnė kaip 5 mln. eurų (17 264 tūkst. litų), skaičiuojant koreliaciją turi būti laikoma, kad ji yra lygi 5 mln. eurų (17 264 tūkst. litų).

³ Statistiniai vertinimo balais modeliai gali būti kuriami skolininko arba paskolos lygiu. Toliau, kad būtų paprasčiau, yra rašoma apie skolininko lygiu kuriamus modelius, jeigu nenurodyta kitaip.

1 lentelė. „Blogos“ įmonės apibrėžimai pagal Lietuvos teisės aktus

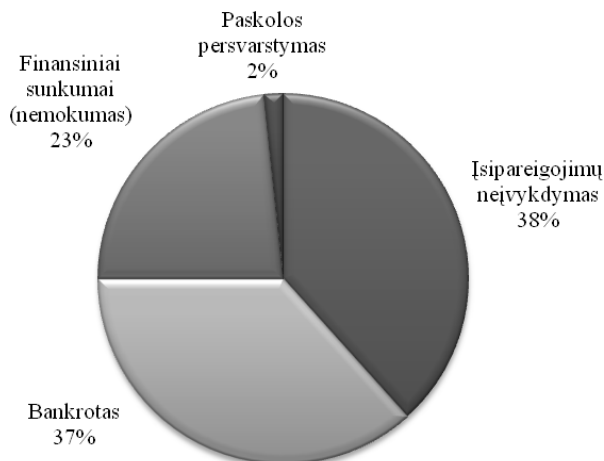
Nemokumas	Bankrotas	Įsipareigojimų neįvykdymas
Įmonės būseną, kai įmonė nevykdo įsipareigojimų (nemoka skolų, neatlieka iš anksto apmokėtų darbų ir kt.), ir pradelsti įmonės įsipareigojimai (skolos, neatlikti darbai ir kt.) viršija pusę į jos balansą įrašyto turto vertės	Nemokios įmonės būseną, kai įmonei teisme yra iškelta bankroto byla arba kreditoriai įmoneje vykdo bankroto procedūras ne teismo tvarka	Skolininko būklė, kai esama bent vieno iš šių požymių: <ul style="list-style-type: none"> skolininkas vėluoja įvykdyti savo įsipareigojimus bankui, patronuojančiajam bankui ar banko kontroliuojamai finansų įmonei daugiau kaip 90 kalendorinių dienų, išskyrus tuos atvejus, kai paskolos vertės likutis neviršija 100 litų ar kitos sumos, banko laikomos nereikšminga; bankas numato, kad skolininkas iki galo neįvykdys įsipareigojimų bankui, patronuojančiajam bankui ar bet kuriai iš jo kontroliuojamų finansų įmonių tol, kol bankas nesiims tokių veiksmų, kaip paskolos gražinimo užtikrinimo priemonės (jei ji yra) objekto realizavimas (t. y. <i>bankrotas, nemokumas, paskolos persvarstymas, paskolos vertės tikslinimas ir kt.</i>)

Šaltinis: sudaryta autorės pagal LRS (2001); Lietuvos bankas (2006a).

Tačiau statistiniai įmonių vertinimo balais modeliai gali būti grindžiami skirtingais „blogos“ įmonės apibrėžimais – bankrotas, finansiniai sunkumai (nemokumas), paskolos persvarstymas, paskolos vertės tikslinimas, mokėjimo termino pradelsimas, įsipareigojimų neįvykdymas. Pastaruoju metu IRB metodą taikantys bankai, priskirdami savo skolininkus „blogų“ skolininkų grupei, turi taikyti įsipareigojimų neįvykdymo apibrėžimą (žr. 1 lent.). Tačiau net ir IRB metodo netaikantys bankai, apibrėždami „blogą“ įmonę, dažnai naudoja įsipareigojimų neįvykdymo požymį.

Išanalizavus per 12 metų (nuo 1999 iki 2011 metų) autorių iš įvairių pasaulio šalių parašytus 60 straipsnių, matyti, kad apibrėžiant „blogą“ įmonę bankroto požymis buvo pasirinktas beveik taip pat dažnai, kaip ir įsipareigojimų neįvykdymo požymis, rečiau buvo pasirinktas finansinių sunkumų (nemokumo) požymis (žr. 5 pav.). Kartais įsipareigojimų neįvykdymo apibrėžimas buvo susiaurintas iki mokėjimo termino pradelsimo daugiau kaip 90 kalendorinių dienų, o bankroto ar kitoks požymis neįtrauktas (Aragon 2004; Mircea 2007; Luppi ir kt. 2008). Yra atlikta nemažai tyrimų, kuriais buvo siekta nustatyti, ar modeliai, sukurti taikant vienokią „blogos“ įmonės apibrėžimą, gali būti taikomi kitokiems įvykiams prognozuoti, pavyzdžiui, ar bankroto požymiu pagrįsti modeliai leidžia prognozuoti įsipareigojimų neįvykdymą. Pavyzdžiui, Hayden (2003) atlikto tyrimo rezultatai parodė, kad paskolos persvarstymo ar mokėjimo termino pradelsimo tikimybei prognozuoti taikant modelį, sukurtą naudojant bankroto apibrėžimą, modelio diskriminacinė galia, t. y. modelio gebėjimas atskirti „geras“ įmones nuo „blogų“, būna nedaug mažesnė nei modelių, pagrįstų

paskolos persvarstymo ar mokėjimo termino pradelimo apibrėžimais. Taigi, modelių, kuriuos kuriant „blogai“ įmonei apibrėžti yra taikomi bankroto ar nemokumo požymiai, neturėtų būti atsakyta, jie bankuose gali būti sėkmingai taikomi kartu su kitais vertinimo balais modeliais. Tačiau bankroto ir nemokumo atveju, palyginti su mokėjimo termino pradelimo daugiau kaip 90 kalendorinių dienų atvejais, būna gerokai mažiau, todėl bankui gali pritrūkti duomenų. IRB metodą taikantys bankai, skaičiuodami kapitalo poreikį, turi remtis išpareigojimų neįvykdymo požymiu, kuris yra griežtesnis, tačiau kitais atvejais, jeigu netrūksta duomenų, gali būti remiamasi ir bankroto ar nemokumo požymiu. Juolab kad taikant griežtesnį apibrėžimą, t. y. išpareigojimų neįvykdymo požymį, gali susidaryti daug formalių išpareigojimų neįvykdymo atveju, kai skolininkas, vėluojantis sumokėti įmoką daugiau kaip 90 kalendorinių dienų, ją sumoka.



5 pav. „Blogs“ įmonės apibrėžimo pasirinkimo dažnumas

Šaltinis: sudaryta autorės pagal 3; 4; 10; 11; 13; 15; 22; 29; 32; 41; 45; 48; 49; 51; 53; 54; 64; 68; 69; 71; 78; 80; 87; 88; 94; 102; 104; 105; 106; 111; 112; 113; 115; 119; 120; 125; 126; 141; 157; 159; 163; 176; 179; 180; 181; 182; 190; 191; 193; 196; 197; 198; 201; 204; 207; 215; 216; 217; 223; 234.

Kuriant fizinių asmenų vertinimo balais modelius, dažniausiai „blogas“ skolininkas yra apibrėžiamas kaip pradėjęs mokėjimo terminą daugiau kaip 90 kalendorinių dienų. Tačiau yra ir įvairių kitų apibrėžimų – dvi įmokos iš eilės pradėjęs skolininkas, mokėjimo terminą šešis mėnesius pradėjęs skolininkas ir kt. (Greene 1992; Thomas ir kt. 2000; Andreeva 2006; Thomas 2007; Kocenda, Vojtek 2009).

Gali būti taikomi ir keli „blogo“ skolininko apibrėžimai, pavyzdžiui, taikant eilės logistinę regresiją (angl. *ordered logistic regression*) galima prognozuoti tikimybę, kad skolininkas pradels mokėjimo terminą 30, 60 ar 90 dienų. Taip pat galima sudaryti tris skolininkų grupes – „geri“, „blogi“ ir „tarpiniai“. Pavyzdžiui, „geras“ skolininkas – nė karto mokėjimo termino nepradelsęs skolininkas, „tarpinis“ skolininkas – mokėjimo terminą ne daugiau kaip 90 kalendorinių dienų pradelsęs skolininkas, o „blogas“ skolininkas – mokėjimo terminą daugiau kaip 90 kalendorinių dienų pradelsęs skolininkas. Kuriant modelį būtų naudojami tik „gerų“ ir „blogų“ skolininkų duomenys (Liu 2001; SAS 2008, 2009).

Prieš pradėdamas kurti modelį bankas turėtų atlikti analizę, kuri leistų nustatyti, ar pasirinkus tam tikrą apibrėžimą formalių skolininkų priskyrimo prie „blogų“ skolininkų atvejų dalis būtų reikšminga ir, jeigu taip, taikyti ne tokį griežtą apibrėžimą (nustatyti ilgesnį mokėjimo termino pradelsimo laikotarpį, taikyti tik nemokumo ar tik bankroto požymį ir pan.). Kuo „blogo“ skolininko apibrėžimas laisvesnis, tuo didesnė tikimybė, kad modelis „blogą“ skolininką priskirs prie „gerų“ (pirmos rūšies klaidos tikimybė), o kuo apibrėžimas griežtesnis, tuo didesnė tikimybė, kad modelis „gerą“ skolininką priskirs prie „blogų“ (antros rūšies klaidos tikimybė). Pirmos rūšies klaida bankams yra svarbesnė.

Kitas svarbus veiksmas, kurį būtina atlikti antrajame modelio kūrimo etape, yra apibrėžti skolininko stebėjimo laikotarpį, t. y. laikotarpį, per kurį skolininkas tampa „geras“ arba „blogas“. Pavyzdžiui, jeigu skolininkas gauna paskolą 2008 m. spalio 2 d., o bankas, apibrėždamas „blogus“ skolininkus, taiko išsipareigojimų neįvykdymo požymį, siejamą su vienerių metų laikotarpiu, tai jis, kurdamas naują modelį, šį skolininką priskirs „blogų“ skolininkų grupei, jeigu šis bent kartą neįvykdys išsipareigojimų bankui iki 2009 m. spalio 2 d. Būtent šis vienerių metų laikotarpis nuo paskolos suteikimo datos yra vadinamas stebėjimo laikotarpiu, šiam laikotarpiui yra skaičiuojama skolininko PD (žr. 6 pav.). Dažniausiai jis yra vieneri metai (Greene 1992; Hayden 2003). Toks stebėjimo laikotarpis yra numatytas ir pagal Naująjį kapitalo susitarimą parengtuose Europos Sąjungos ir Lietuvos teisės aktuose (BCBS 2006; EP 2006; Lietuvos bankas 2006a).

Taikyti vienerių metų stebėjimo laikotarpį yra paranku dėl daugelio priežasčių. Pasirenkant trumpesnį laikotarpį, yra nuvertinama skolininko rizika (Thomas 2000). Trumpesnis laikotarpis gali būti neparankus ir dėl įmonių veiklos sezoniskumo. Be to, vienerių metų trukmės laikotarpis labiau dera prie kitokios kasmetinės banko veiklos: paskolų peržiūros, informacijos apie skolininkus atnaujinimo, naujų emisijų siekiant padidinti kapitalą, biudžeto sudarymo ir kt. (Hayden 2003; DB, ONB 2007).

Ilgesnis nei vienerių metų laikotarpis yra neparankus trumpalaikių paskolų rizikai vertinti, be to, per ilgesnį laikotarpį gali pasikeisti skolininkų savybių skirstinys, ir skolininkai, kurių duomenys buvo naudojami kuriant modelį, gali nereprezentuoti tų skolininkų, kuriems sukurtas modelis bus taikomas. Be to, gali pritrūkti duomenų tokiam modeliui sukurti. Ilgesnis laikotarpis gali būti taikomas ilgalaikėms paskoloms vertinti. Tačiau Lietuvos bankas (2008) reikalauja, kad šalies bankai reguliariai peržiūrėtų skolininkų kreditingumo kokybę, bent kartą per metus tikrintų ir, jei reikia, patikslintų skolininkų ir paskolų reitingus. Todėl net ir ilgalaikėms paskoloms vertinti yra rekomenduojama kurti modelį, pagrįstą vienerių metų stebėjimo laikotarpiu. O tikimybė, kad skolininkas taps „blogas“ per ilgesnį laiką, jei reikia, gali būti apskaičiuojama ir iš vienerių metų tikimybės⁴.

Kai yra labai mažai arba visai nėra faktinių „blogų“ skolininkų, tiek kuriant statistinį fizinių asmenų, tiek įmonių modelį „blogais“ skolininkais galima laikyti blogiausio „gerų“ skolininkų reitingo skolininkus (BCBS 2005b), taip pat galima taikyti kitą griežtesnį „blogo“ skolininko apibrėžimą arba pasirinkti ilgesnį stebėjimo laikotarpį.

Toliau šioje disertacijoje yra vartojama tik viena sąvoka – „blogas“ skolininkas, kuri gali reikšti tiek įsipareigojimų neįvykdantį skolininką, tiek kitokiais požymiais pasižymintį skolininką, atsižvelgiant į naudojamą „blogo“ skolininko apibrėžimą.

1.1.1.3. Skolininkų grupės pasirinkimas

Kuriant modelį naudojami duomenys turi reprezentuoti tuos skolininkus, kurių rizikai vertinti sukurtas modelis bus taikomas. Kitaip tariant, sukurtas modelis turėtų būti taikomas toje pačioje šalyje ir tos pačios rūšies skolininkams kaip ir faktiniai duomenys. Pagal naudojamus duomenis yra skiriamos dvi vertinimo balais modelių rūšys (Longenecker ir kt. 1997; Mays 2004):

- *bendrieji (išorės) modeliai*. Jie yra kuriami naudojant daugelio bankų praeities duomenis (pvz., gautus iš išorinių paskolų registru). Naudojant bankų duomenis apie tos pačios ekonominės veiklos rūšies įmones joms gali būti kuriami specialūs tos ekonominės veiklos rūšies modeliai;
- *individualaus vartotojo (vidaus) modeliai*. Jie kuriami naudojant vieno banko skolininkų duomenis.

⁴ Tarkime, vienerių metų PD yra lygi 3 %. Tada ilgesnio laikotarpio (pvz. penkerių metų) PD gali būti apskaičiuojama taikant „MS Excel“ funkciją $=Betadist(3\%; 1;5)$. Penkerių metų PD bus lygi 14,13 %. Tačiau gali būti atliekamas ir atvirkštinis veiksmas, t. y. iš penkerių metų PD apskaičiuojama vienerių metų PD. Tada taikoma „MS Excel“ funkcija $=Betainv(14,13\%; 1;5)$. Tai gali būti naudinga skaičiuojant nerizikingų skolininkų, pavyzdžiui, institucijų, PD, nes tokie skolininkai labai retai tampa „blogi“, tačiau per ilgesnį laiką tokių atvejų vis dėlto pasitaiko.

Vidaus ar išorės modelio pasirinkimas priklauso nuo daugelio veiksnių (žr. 2 lent.). Lietuvoje kuriant išorės modelius būtų galima pasinaudoti Lietuvos banko turima paskolų rizikos duomenų baze, privačių įmonių (pvz., UAB „Creditinfo Lietuva“) sudaromais registrais arba, kaip kitose šalyse, bankams išorės modelius galėtų padėti kurti bankų asociacija⁵. Nuo 2003 metų Lietuvos banko paskolų rizikos duomenų bazėje buvo pradėti kaupti juridinių asmenų finansinių ataskaitų duomenys. Dauguma duomenų, kurių reikia fizinių asmenų vertinimo balais modeliui sukurti, irgi jau seniai yra sukaupti paskolų rizikos duomenų bazėje.

Tiek išorės, tiek vidaus modeliai gali būti skirstomi ne tik pagal ekonominės veiklos rūšį, bet ir pagal skolininkų pajamas, geografinį regioną, paskolos sumą ir pan. Dažniausiai naudojant skirtingų šalių duomenis sukurtų tos pačios paskolų rūšies modelių labai skiriasi tiek įvesties kintamieji ir jų skaičius, tiek jų reikšmių grupės ir koeficientai (jei yra įtraukiami tokie patys įvesties kintamieji) (Andreeva ir kt. 2004; Gusev 2005; Andreeva 2006). Tai rodo, jog kai bankas turi patronuojantį banką užsienio šalyje, jam geriau kurti atskirus vietinius modelius. Analizuojant statistinius įmonių vertinimo balais modelius matyti, kad dažniausiai tikslesni yra ne bendri, o pagal įmonių dydį ar ekonominės veiklos rūšį kuriami modeliai. Gali būti kuriami tam tikri modeliai, skirti pačių bankų rizikai vertinti, juos galėtų taikyti ne tik bankų darbuotojai, investuotojai ir pan., bet ir bankų priežiūros institucijos, pavyzdžiui, bankams ir visam bankų sektoriui testuoti nepalankiausiomis sąlygomis ir pan. (autoriai yra pasiūlę Rusijos, Vokietijos, Lenkijos, Norvegijos, Turkijos bankų statistinius vertinimo balais modelius, žr. Golovan ir kt. 2003; Porath 2004, 2006; Wozniewska 2008; Andersen 2008; Erdogan 2008). Skirtinga rizika pasižymi skolininkai, kurių paskolos ir užstato vertės santykis yra didelis, ir tie skolininkai, kurių toks santykis mažas, ar nevienodas pajamas gaunantys skolininkai (Gerschick 2002; Ciampi, Gordini 2008). Atsižvelgiant į tai, galėtų būti kuriami atskiri modeliai arba į šiuos kriterijus galėtų būti atsižvelgiama sudarant įvesties kintamuosius.

⁵ Toks pasiūlymas jau buvo iškeltas viename kredito rizikos problemas nagrinėjančiame straipsnyje (žr. Valvonis 2006).

2 lentelė. Išorės ir vidaus modelių palyginimas

Modelio požymiai	Išorės modelis	Vidaus modelis
Imties dydis	Išorinės įmonės ar bankų priežiūros institucijos turi labai daug duomenų, todėl nekyla duomenų imties nepakankamumo problema. Galima kurti atskirus modelius skirtingoms skolininkų ar paskolų grupėms	Vienas bankas gali neturėti pakankamos duomenų imties, kad galėtų sukurti patikimą modelį. Vidaus modelius dažniausiai kuria stambesni, ilgai rinkoje veikiantys bankai arba bankų grupės
Kreditavimo patirtis, reprezentatyvumas	Neatsižvelgiama į banko kreditavimo ypatumus: skolininkų grupes, paskolų rūšis, geografinius regionus ir kitus kriterijus	Labiau atsižvelgiama į skolininkus, kuriems vertinti modelis bus taikomas, nes kaupiami duomenys atitinka banko kreditavimo ypatumus
Modelio paskirtis	Išorinė įmonė gali taikyti konkretaus banko tikslų neatitinkantį „blogo“ skolininko apibrėžimą ar stebėjimo laikotarpį	Bankas pasirenka jo tikslus atitinkantį „blogo“ skolininko apibrėžimą ir stebėjimo laikotarpį
Skolininkų grupės	Galima kurti atskirus modelius skirtingoms skolininkų ar paskolų grupėms, tačiau išorinės įmonės nustatyta grupė gali neatitikti konkretaus banko poreikių	Kuriant modelį įtraukiami tik tie skolininkai ar paskolos, kurie atitinka konkretaus banko poreikius
Mokėjimų istorija	Galima įtraukti informaciją apie skolininko mokėjimų istoriją, kurios bankas neturi. Tačiau to paties skolininko mokėjimų istorija skirtinguose bankuose gali skirtis, todėl skolininkų elgseną keblu klasifikuoti	Bankas gali įtraukti tą informaciją apie mokėjimų istoriją, kuri nepateikta paskolų registrams. Be to, net pirkdamas išorinę informaciją apie mokėjimų istoriją kituose bankuose, jis didesnė reikšmė vis tiek teiktų vidinei mokėjimų istorijai
Atmestų paraiškų įtraukimo problema	Gali būti įtraukiami visų bankų duomenys, todėl nereikia spręsti su atmestų paraiškų įtraukimu susijusios problemos	Bankas turi spręsti atmestų paraiškų įtraukimo problemą, t. y. tinkamai įtraukti duomenis ir apie tuos skolininkus, kuriems paskola nebuvo suteikta
Greitis	Įsigytą išorės modelių bankas gali įdiegti iš karto. Be to, dažniausiai bankai perka ne išorės modelių, bet išorės modeliu nustatomą skolininkų išorės reitingą.	Modelio kūrimas užima daug laiko, be to, turi būti pakankamas vidaus duomenų kaupimo laikotarpis
Šnaudos	Bankas nepatiria tiesioginių sąnaudų, susijusių su išorės modelio kūrimu, tačiau patiria sąnaudas, įsigydamas išorės modelių arba skolininko išorės reitingą. Įsigyjant išorės reitingą banko patiriamos sąnaudos priklauso nuo skolininkų, kurių reitingas įsigyjamas, apimtys. Jeigu ji nedidelė, tai išorės reitingų įsigijimas gali būti finansiniu požiūriu priimtinesnis sprendimas nei vidaus modelio kūrimas	Bankui tenka informacinių technologijų, kvalifikacijos kėlimo kursų, papildomų darbuotojų darbo užmokesčio ir kitos sąnaudos. Kai skolininkų ar paskolų, kuriems taikomi vidaus modeliai, banke yra daug, vidaus modelio kūrimas gali būti finansiniu požiūriu priimtinesnis sprendimas nei išorės reitingų ar išorės modelio įsigijimas
Igūdžiai	Išorinės įmonės sukaupia vertinimo balais modelių kūrimo patirtį. Bankui, įsigyjančiam išorės modelių, nebūtina išleisti papildomų lėšų darbuotojų kvalifikacijai kelti ar ekspertams iš išorės samdytis	Banko darbuotojai turi turėti tinkamą kvalifikaciją ir igūdžius, reikalingus vidaus modeliui sukurti. Jeigu bankas turi pakankamai duomenų, tačiau neturi šios srities ekspertų, gali būti samdomi ekspertai iš išorės
Taikymas	Išorės modelius gali įsigyti visi bankai, todėl nėra konkurencinio pranašumo	Vidaus modelis naudojamas tik jį sukūrusiame banke, informacija apie modelį yra konfidenciali
Patikimumo vertinimas	Bankas, reguliariai vertindamas įsigyto išorės modelio patikimumą, gali gauti nepalankius rezultatus. Tačiau išorės modelio jis negali tikslinti, ypač tada, kai įsigyja tik išorės reitingą	Jeigu bankas, atlikęs vidaus modelio patikimumo vertinimą, gauna nepalankius rezultatus, jis gali modelį tikslinti, t. y. įtraukti papildomus įvesties kintamuosius ir pan.

Šaltiniai: sudaryta autorės pagal Longenecker ir kt. (1997); Mays (2004).

Vertinimo balais modeliai gali būti skirstomi ir pagal tai, ar jie kuriami skolininkams, ar paskoloms vertinti, taip pat pagal tai, ar kuriamas bendras modelis, ar atskiri modeliai skirtingų rūšių paskoloms (žr. 2 priedą). Paprastai skirtingoms fizinių asmenų paskolų rūšims būna būdinga skirtinga rizika (Gerschick 2002; FRS 2007). Pavyzdžiui, „blogų“ būsto paskolų gavėjų dažniausiai būna gerokai mažiau negu „blogų“ kredito kortelių gavėjų. Be to, skirtingų rūšių paskolų gali skirtis tiek tikslas, tiek trukmė, tiek skolininkų savybės. Būsto paskolas dažniau gauna jaunesni, aukštąjį išsilavinimą turintys, didesnes nei vidutinės pajamas gaunantys skolininkai, o kredito kortelių gavėjų pajamų vidurkis gali būti gerokai mažesnis už būsto paskolų gavėjų. Todėl bankas skirtingoms fizinių asmenų paskolų grupėms turėtų kurti atskirus vertinimo balais modelius. Tačiau juos kuriant turėtų būti atsižvelgiama į banko poreikius bei skolininkų ypatybes. Jeigu skirtingų rūšių paskolų rizika labai panaši, galima kurti bendrą modelį.

Bendri skirtingų paskolų rūšių ar skirtingų bankų tos pačios paskolų rūšies modeliai dažnai yra kuriami tada, kai yra mažai skolininkų, arba kai yra labai mažai ar visai nėra faktinių „blogų“ skolininkų.

Bankas, įvertinęs tiek bendro, tiek atskirų modelių diskriminacinę galią, turi pasirinkti tą modelį ar kelis modelius, kurių diskriminacinė galia yra didžiausia. Jeigu būtų kuriama daugiau vertinimo balais modelių, tektų reguliariai vertinti jau ne vieno, o kelių modelių patikimumą, todėl padidėtų laiko, informacinių technologijų, darbo užmokesčio sąnaudos.

1.1.1.4. Paraiškų ir elgsenos vertinimo balais modeliai

Vertinimo balais modeliai gali būti skirstomi ir pagal tai, ar jie taikomi naujoms paraiškoms (paraiškų modeliai), ar jau suteiktų paskolų elgsenai vertinti (elgsenos modeliai). Šios dalies tikslas – detalai išanalizuoti keturis paraiškų ir elgsenos modelių kūrimo būdus, šių būdų pranašumus bei trūkumus ir pasiūlyti, kaip sujungti to paties skolininko paraiškų ir elgsenos vertinimo balus laikui bėgant. Šie keturi būdai yra pagrįsti šios disertacijos autorės patirtimi, sukaupta dirbant Lietuvos banke ir viename iš Lietuvos komercinių bankų (žr. Dzidzevičiūtė 2010a).

Pagrindinis paraiškų ir elgsenos modelių skirtumas yra tas, kad elgsenos modeliams kurti bankai turi daugiau informacijos. Elgsenos modeliams kurti yra naudojama informacija apie tai, kaip skolininkas moka įmokas, kaip aktyviai naudojasi atnaujinamosiomis paskolomis ir kita panaši informacija, kuri ne visada gali būti įtraukiama kuriant paraiškų modelius. Todėl dažniausiai elgsenos modelių diskriminacinė galia būna didesnė už paraiškų modelių diskriminacinę galią (Gayler 2009). Paraiškų modeliai dažniausiai yra taikomi

priimant sprendimą suteikti paskolą ar jos nesuteikti, o elgsenos modeliai – siekiant nuspręsti, kurie iš jau esamų skolininkų pasižymi didesne kredito rizika, koreguojant kredito limitų dydį, valdant vėluojančias įmokas (pvz., su skolininkais, kurių elgsenos vertinimo balai yra blogi, gali būti susisiekiama iš anksto prieš mokėjimo datą arba nuo elgsenos vertinimo balo gali priklausyti susisiekimo su skolininku būdas), vykdant išieškojimą, pasirenkant esamus skolininkus, kurie galėtų būti potencialūs kitų paslaugų vartotojai, prognozuojant kredito nuostolius ir t. t. Paraiškos vertinimo balas yra nustatomas tik vieną kartą – besikreipiant dėl naujos paskolos, o elgsenos vertinimo balas yra reguliariai perskaičiuojamas.

Tarptautinės audito bendrovės *Deloitte Touche Tohmatsu* (2002) atlikto tyrimo rezultatai parodė, kad Australijos, Naujosios Zelandijos ir Pietų Afrikos bankuose buvo labiau linkstama taikyti paraiškų modelius, o elgsenos modeliai vis dar buvo kuriami arba juos dar tik buvo pradėta taikyti. Tai rodo, kad bankams daug svarbiau nesuteikti paskolos rizikingiems skolininkams negu reguliariai vertinti jau suteiktų paskolų riziką. Tačiau jeigu bankas taiko IRB metodą ir savus vertinimo balais modelius kapitalo poreikiui skaičiuoti, jis turi kurti ir elgsenos modelius, kad galėtų reguliariai apskaičiuoti savo esamų skolininkų PD.

Paraiškų ir elgsenos modeliai yra kuriami nevienodai: reikšmingai skiriasi ne tik įvesties kintamieji, bet ir atskaitos datos, duomenų masyvų sudarymas. Tačiau nors šių modelių kūrimas ir taikymo sritys labai skiriasi, kai kuriuose bankuose kuriami bendri modeliai jų neskirstant į paraiškų ir elgsenos. Paraiškų modeliai gali būti kuriami naujiems skolininkams, pirmą kartą besikreipiantiems dėl paskolos, ir jau esamiems banko skolininkams, teikiantiems paraišką dėl naujos paskolos. Tačiau gali būti kuriamas ir bendras paraiškų modelis, skirtas abiejų rūšių paraiškoms vertinti (žr. 3 lent.).

3 lentelė. Paraiškų ir elgsenos modelių kūrimo būdai

Būdas	Naujų skolininkų paraiškų modeliai	Esamų skolininkų naujų paraiškų modeliai	Elgsenos modeliai
1-as	X		X
2-as	X	X	X
3-ias	X		X
4-as	X (bendras modelis)		

Šaltinis: sudaryta autorės.

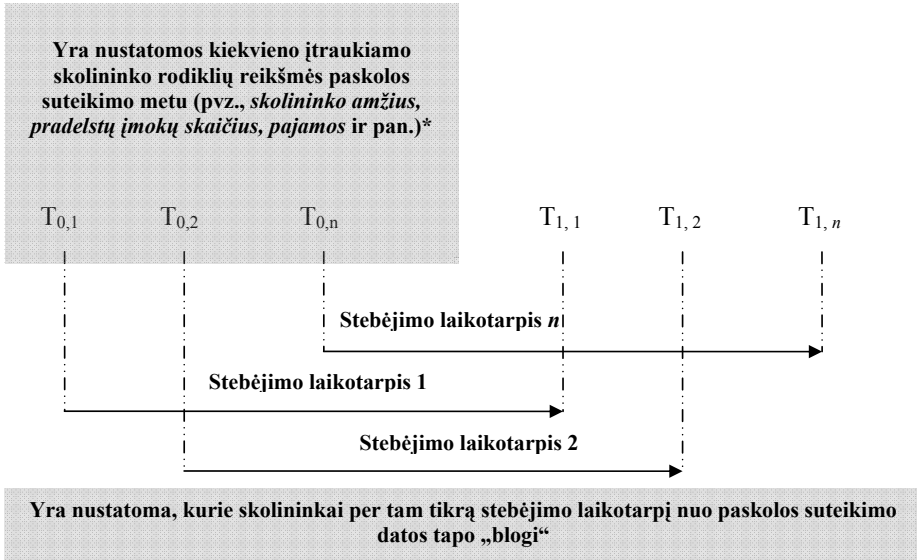
- *1-as būdas*: naujų skolininkų paraiškos ir esamų skolininkų naujos paraiškos yra vertinamos tuo pačiu paraiškų modeliu; jau suteiktos paskolos yra pakartotinai vertinamos atskiru elgsenos modeliu.

- *2-as būdas*: yra taikomi atskiri naujų skolininkų paraiškų ir esamų skolininkų naujų paraiškų modeliai; jau suteiktos paskolos yra pakartotinai vertinamos atskiru elgsenos modeliu.
- *3-ias būdas*: yra taikomi atskiri naujų skolininkų paraiškų modeliai, bet tiek esamų skolininkų naujų paraiškų vertinimas, tiek jau suteiktų paskolų pakartotinis vertinimas yra atliekamas naudojant tą patį modelį.
- *4-as būdas*: yra taikomi bendri modeliai jų neskirstant į paraiškų ir elgsenos.

1-as būdas. Kurdamas paraiškų modelį, bankas turėtų įtraukti skolininkus⁶, kuriems paskolos buvo suteiktos per paskutinius kelerius metus (pvz., nuo 2005 m. iki 2011 m.), ir nustatyti, ar per tam tikrą laikotarpį nuo paskolos suteikimo datos T_0 (stebėjimo laikotarpį) skolininkas tapo „blogas“ ar ne (žr. 6 pav.). Labai seniai suteiktų paskolų nederėtų įtraukti, nes seniau paskolas gavę skolininkai gali nereprezentuoti šiandieninių banko skolininkų, sakysime, gali keistis skolininkų savybių skirstinys ir pan. Paskolų suteikimo datos skiriasi, todėl kiekvienos paskolos atskaitos data T_0 yra skirtinga, tačiau visų paskolų stebėjimo laikotarpis turi būti vienodas (dažniausiai 1 metai), t. y. trukmė nuo $T_{0,1}$ iki $T_{1,1}$ turi būti lygi trukmei nuo $T_{0,2}$ iki $T_{1,2}$ ir t. t. Kadangi skirtingų skolininkų atskaitos datos skiriasi, tai ir skolininkų rodiklių reikšmės nustatomos skirtingoms datoms. Be to, rodikliai gali būti momentiniai (pvz., skolininko amžius) arba periodiniai (pvz., visų per paskutinius metus iki vertinimo datos T_0 pradelstų įmokų skaičius). Rodiklio rūšis priklauso nuo konkretaus rodiklio savybių. Nėra prasmės vertinti skolininko amžių per paskutinius 12 mėnesių, tačiau labai informatyvu įtraukti informaciją apie skolininko pradelsimus per paskutinius 12 mėnesių.

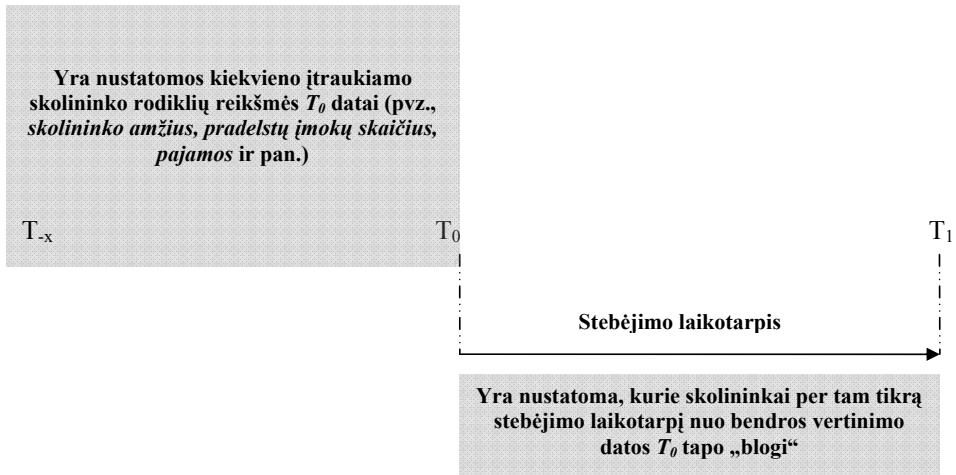
Kuriant elgsenos modelį, kitaip nei kuriant paraiškų modelį, turėtų būti įtraukiami visi „geri“ skolininkai, tam tikru laiko momentu turėję paskolų banke. Visų įtraukiamų skolininkų rodiklių reikšmės nustatomos atskaitos datai T_0 , o tada tikrinama, kurie skolininkai per tam tikrą stebėjimo laikotarpį nuo atskaitos datos T_0 tapo „blogi“. Skirtumas nuo paraiškų modelių yra tas, kad atskaitos data T_0 yra ne paskolos suteikimo data, bet bendra data, dažniausiai kalendorinių metų arba ketvirčio pabaiga. Kai kuriant elgsenos modelį yra sudaromas duomenų masyvas, gali būti naudojama keletas bendrų atskaitos datų T_0 (jos gali būti paslenkamos per vienerius metus, per vieną ketvirtį, per vieną mėnesį ir pan.), taip yra gaunamas didesnis įrašų skaičius. Kaip ir kuriant paraiškų modelius, rodikliai gali būti momentiniai arba periodiniai (nuo T_x iki T_0) (žr. 7 pav.).

⁶ Tai priklauso nuo to, koku lygiu yra kuriamas modelis. Kad būtų paprasčiau, šioje dalyje yra naudojamas skolininko lygis ir logistinė regresija.



6 pav. Paraiškų modelio kūrimas

Šaltinis: sudaryta autorės. *Buvo padaryta prielaida, kad paraiškos vertinimo data ir paskolos suteikimo data sutampa. Tačiau praktikoje šios datos dažnai skiriasi. Tada, jei rodiklių reikšmės per laikotarpį nuo paraiškos vertinimo iki paskolos suteikimo pasikeitė, galima naudoti šias naujas reikšmes.



7 pav. Elgsenos modelio kūrimas

Šaltinis: sudaryta autorės.

Kai IRB metodą taikantis bankas skaičiuoja PD, kurios bus naudojamos kapitalo poreikiui skaičiuoti, turi būti remiamasi bent 5 metų praeities duomenų kaupimo laikotarpiu (Lietuvos bankas 2006a)⁷, t. y. kuriant modelį negali būti apsiribojama tik kurių nors vienu metų informacija, turėtų būti bent penki nesutampantys stebėjimo laikotarpiai nuo T_0 iki T_1 . Jeigu bankas turi to paties skolininko informaciją visoms penkioms atskaitos datoms T_0 ir visiems penkiems stebėjimo laikotarpiams, tai į bendrą duomenų masyvą šie duomenys gali būti įtraukiami darant prielaidą, kad tai yra penkių skirtingų skolininkų duomenys.

2-as būdas. Šis būdas labai panašus į ankstesnį, vienintelis skirtumas yra tas, kad paraiškų modeliai yra diferencijuojami, t. y. naujų skolininkų paraiškoms ir esamų skolininkų naujoms paraiškoms vertinti yra kuriami atskiri modeliai. Kuriant atskirus paraiškų modelius nereikia įtraukti papildomų įvesties kintamųjų. Pavyzdžiui, taikant 1-ą būdą ir kuriant bendrą paraiškų modelį, galėtų būti įtraukiamas įvesties kintamasis „*Naujo skolininko paraiška / Esamo skolininko nauja paraiška*“ ir pan., o taikant 2-ą būdą tokių įvesties kintamųjų įtraukti nereikia. Tačiau galima įtraukti specifinius kiekvienos paraiškų rūšies įvesties kintamuosius, pavyzdžiui, kuriant esamų skolininkų naujų paraiškų modelį, galima įtraukti informaciją apie vidinę mokėjimų istoriją. Paraiškų modeliai yra kuriami taip, kaip pavaizduota 6 pav., o elgsenos modelis – kaip pavaizduota 7 pav. Jeigu tiek nauji, tiek esami skolininkai per paskutinius kelerius metus pateikė bankui pakankamai daug paraiškų dėl naujų paskolų ir yra gera banko sukauptų duomenų kokybė, verčiau kurti atskirus paraiškų modelius, nes tada galima įtraukti specifinius įvesties kintamuosius ir tiksliau įvertinti skolininkų kredito riziką.

3-ias būdas. Kuriamas bendras modelis tiek esamų skolininkų naujoms paraiškoms vertinti, tiek jau suteiktoms paskoloms pakartotinai vertinti, nes bankas turi informacijos apie esamų skolininkų vidinę mokėjimų istoriją, naudojimąsi atnaujinamosiomis paskolomis ir pan. Naujų skolininkų paraiškų modelis yra kuriamas kaip pavaizduota 6 pav., o esamų skolininkų naujoms paraiškoms ir jau suteiktoms paskoloms pakartotinai vertinti skirtas modelis dažniausiai yra kuriamas kaip pavaizduota 7 pav. Tačiau pastaruoju atveju problema yra ta, kad konkrečiu laiko momentu banke visada bus daugiau seniau suteiktų paskolų nei per tam tikrą laikotarpį esamiems skolininkams suteiktų naujų paskolų. Todėl tiek į bendrą modelį įtrauktus įvesties kintamuosius, tiek jų koeficientus labiau nulemtų skolininkų, kuriems seniau buvo suteiktos paskolos, savybės, o ne esamų skolininkų, besikreipiančių dėl naujos paskolos, savybės. Į bendrą modelį greičiausiai nepatektų specifiniai paraiškų

⁷ Tačiau bankai, dar tik įgyvendinantys IRB metodą, tam tikrais atvejais gali šį laikotarpį sutrumpinti iki dvejų metų.

vertinimo įvesties kintamieji. Be to, galėtų atsirasti sunkumų sudarant bendram modeliui kurti reikalingų duomenų masyvą. Jeigu visiems skolininkams būtų naudojama ta pati atskaitos data, tada tai, ar esamas skolininkas, gavęs naują paskolą, tapo „blogas“ ar ne, būtų nustatoma ne per vienerių metų laikotarpį nuo paskolos suteikimo datos, bet per vienerių metų laikotarpį nuo bendros atskaitos datos. Tada būtų prarandama tam tikra dalis su esamų skolininkų naujomis paraiškomis susijusios informacijos.

1 intarpas. Duomenų masyvo sudarymo problemos pavyzdys

Tarkime, kad jau esamas banko skolininkas gavo dar vieną, naują, paskolą 2009 m. kovo 10 d., bet bendra atskaitos data T_0 yra 2009 m. gruodžio 31 d. Jeigu šis skolininkas taptų „blogas“ per laikotarpį nuo 2009 m. kovo 10 d. iki 2009 m. gruodžio 31 d. ir bendrą atskaitos datą (t. y. 2009 m. gruodžio 31 d.) tebebūtų „blogas“, jo duomenys tiesiog nebūtų įtraukiami kuriant bendrą modelį. Tačiau jeigu šis skolininkas per laikotarpį nuo naujos paskolos suteikimo datos iki bendros atskaitos datos taptų „blogas“, o paskui – vėl „geras“, ir bendrą atskaitos datą (t. y. 2009 m. gruodžio 31 d.) tebebūtų „geras“, jo duomenys būtų įtraukiami kuriant bendrą modelį, tačiau nebūtų atsižvelgiama į tapsmą „blogu“. Skolininkas nuo 2009 m. kovo 10 d. iki 2009 m. gruodžio 31 d. teoriškai galėtų net tris kartus tapti „blogas“ ir vėl „geras“. Net jeigu tokia informacija būtų įtraukiama pridėdamus įvesties kintamuosius (pvz., „skolininkas tapo / netapo „blogas“ nuo naujos paskolos suteikimo datos iki bendros atskaitos datos“ arba „kiek kartų skolininkas tapo „blogas“ nuo naujos paskolos suteikimo datos iki bendros atskaitos datos“), tai turėtų įtakos tik įvesties kintamiesiems, bet ne faktiniam išvesties kintamajam („0“ ar „1“). Jeigu skolininkas nuo 2009 m. kovo 10 d. iki 2009 m. gruodžio 31 d. taptų „blogas“, paskui – vėl „geras“, bet netaptų „blogas“ per vienerių metų stebėjimo laikotarpį nuo bendros atskaitos datos 2009 m. gruodžio 31 d. iki 2010 m. gruodžio 31 d., tai kuriant bendrą modelį jis būtų priskiriamas prie „gerų“. O jeigu būtų kuriamas atskiras esamų skolininkų naujų paraiškų modelis, toks skolininkas būtų priskiriamas prie „blogų“. Be to, jeigu bankas įtrauktų informaciją apie tuos tris tapsmo „blogu“ atvejus per atitinkamus įvesties kintamuosius, o skolininkas netaptų „blogas“ nuo 2009 m. gruodžio 31 d. iki 2010 m. gruodžio 31 d., bankas gautų iškreiptus rezultatus, nes tapsmas „blogu“ nuo paskolos suteikimo datos iki bendros atskaitos datos būtų laikomas prognozuojamą PD mažinančiu veiksmu.

Šaltinis: autorės pavyzdys.

Duomenų masyvo sudarymo problemai spręsti gali būti:

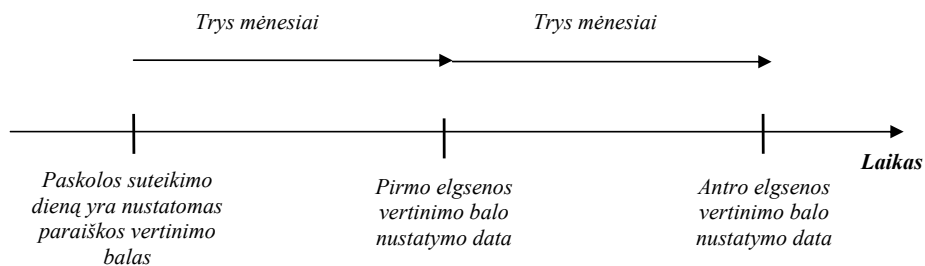
- atskaitos datos T_0 paslenkamos per trumpesnę intervalą (pvz., per vieną savaitę, per kelias dienas arba gali būti naudojamos kasdieninės atskaitos datos). Tai ypač tinka, kai imties dydis modeliui kurti yra nepakankamas, nes padidėja įrašų skaičius. Tačiau tada yra sunku surinkti duomenis, pernelyg apsunkinamas banko informacinių technologijų sistemų darbas, todėl pasunkėja modelio kūrimo procesas.
- naudojamos skirtingos atskaitos datos T_0 : esamų skolininkų naujoms paraiškoms – paskolos suteikimo data, o skolininkams, kuriems seniau suteiktos paskolos, – bendra atskaitos data, pavyzdžiui, kalendorinių metų pabaiga. Įrašai, kuriuose atskaitos datos skirtingos, įtraukiami į bendrą duomenų masyvą.

4-as būdas. Šis būdas labai panašus į 3-ią, vienintelis skirtumas yra tas, kad naujų skolininkų paraiškos yra vertinamos ne atskiru modeliu, be tuo pačiu bendru modeliu. Bendrame modelyje turėtų būti papildomi įvesties kintamieji, tarkime, „*paraiškos vertinimas / elgsenos vertinimas*“ arba „*bankas turi / neturi informacijos apie skolininko mokėjimų istoriją*“ ir pan. Tačiau šiuo atveju nagrinėjant 3-ią būdą minėtos problemos tampa dar aktualesnės. Dėl atskaitos datų nesuderinamumo yra prarandama ne tik su esamų skolininkų naujomis paraiškomis, bet ir su naujų skolininkų paraiškomis susijusios informacijos dalis.

Taigi, tinkamiausi bankui yra pirmieji du būdai (žr. 3 lent.). Juos taikant sukurti statistiniai vertinimo balais modeliai yra reprezentatyviausi ir pasižymi didžiausia diskriminacine galia. Jeigu per paskutinius kelerius metus esami skolininkai pateikė bankui pakankamai daug paraiškų dėl naujų paskolų ir yra gera banko sukauptų duomenų kokybė, rekomenduojamas 2-as būdas. Tačiau jeigu banke per paskutinius kelerius metus nebuvo pakankamai daug tokių atvejų, kai esamas skolininkas vėl kreipėsi dėl naujos paskolos, arba banko sukauptų duomenų kokybė nėra gera, tada tinkamiausias yra 1-as būdas.

Perėjimo nuo paraiškos prie elgsenos vertinimo balo metodai. Taikydamas 1-ą, 2-ą ar 3-ią būdus, bankas turi pasirinkti metodą, kaip tinkamai po tam tikro laiko pereiti nuo to paties skolininko paraiškos vertinimo balo prie elgsenos vertinimo balo ar atvirkščiai. Toliau yra pateikti du šios disertacijos autorės pasiūlyti metodai, kaip susieti skirtingus to paties skolininko vertinimo balus.

1-as metodas: Tam tikrą nustatytą laikotarpį nuo paskolos suteikimo datos (tarkime, tris mėnesius) galioja paraiškos vertinimo balas, o paskui pradeda galioti atskiru modeliu nustatytas elgsenos vertinimo balas. Šis pirmasis elgsenos vertinimo balas galioja tris mėnesius, paskui jis yra perskaičiuojamas, tada kitus tris mėnesius galioja naujasis elgsenos vertinimo balas ir t. t. (žr. 8 pav.).



8 pav. Perėjimas nuo paraiškos prie elgsenos vertinimo balo (1-as metodas)


Šaltinis: sudaryta autorės.

Bankas gali pasirinkti kitokios trukmės laikotarpį, bet derėtų rinktis ne trumpesnę nei vienas mėnuo ir ne ilgesnę nei vieneri metai laikotarpį. Suteikus paskolą dažniausiai yra taikomas vieno mėnesio trukmės mokėjimo atidėjimo laikotarpis, todėl bankas pirmą kartą informaciją apie tai, kaip skolininkas moka su nauja paskola susijusias įmokas, gauna tik praėjus vienam mėnesiui. Be to, kadangi bankai turi bent kartą per metus tikrinti ir, jei reikia, patikslinti skolininkų ir paskolų reitingus, nevertėtų rinktis ilgesnę nei vienerių metų laikotarpį.

2-as metodas: Galima ne iš karto pereiti nuo paraiškos prie elgsenos vertinimo balo, bet taikyti atitinkamus vertinimo balų⁸ svorius (žr. 9 pav.). Praėjus tam tikram nustatytam laikotarpiui, pavyzdžiui, vienam mėnesiui, elgsenos PD yra suteikiamas x svoris, o paraiškos PD – $(1-x)$ svoris. Galutinė individuali PD yra lygi:

$$\text{Galutinė_PD} = x \cdot \text{elgsenos_PD} + (1-x) \cdot \text{paraiškos_PD}; \quad x = \frac{t}{365},$$

čia: t – nuo paskolos suteikimo dienos praėjęs laikas, dienomis.



9 pav. Perėjimas nuo paraiškos prie elgsenos vertinimo balo (2-as metodas)

Šaltinis: sudaryta autorės.

⁸ Šioje dalyje, pateikiant pavyzdžius, vertinimo balu yra laikoma individuali PD.

Skolininkas yra priskiriamas atitinkamam reitingui pagal galutinę PD. Jeigu modeliai yra taikomi skolininko lygiu ir skolininkas turi daugiau nei vieną paskolą, nuo paskolos suteikimo dienos praėjęs laikas formulėje gali būti keičiamas kitu rodikliu, tarkime, svertiniu nuo paskolos suteikimo dienos praėjusio laiko vidurkiu ir t. t.

Taikant pirmąjį metodą paraiškos PD po tam tikro laiko yra paprasčiausiai iš karto pakeičiama elgsenos PD, o taikant antrąjį metodą paraiškos PD svoris yra mažinamas po truputį atsižvelgiant į nuo paskolos suteikimo dienos praėjusį laiką, todėl nėra staigaus galutinės PD padidėjimo ar sumažėjimo. Gali būti taikomi ir kiti perėjimo metodai, tačiau reikia turėti omenyje, kad kai bankas vienu metu (pvz., kiekvieno ketvirčio gale) iš karto pakeičia paraiškų PD į elgsenos PD, gali būti didelių specialiųjų atidėjinių, kapitalo poreikio ir kitų su kredito rizika susijusių banko rodiklių svyravimų. O kai PD yra keičiamapo truputį, perėjimas nėra toks staigus, todėl išvengiama didelių banko rodiklių svyravimų.

1.1.1.5. Statistinio metodo pasirinkimas

Yra kelios statistinių vertinimo balais modelių grupės: gryniesi statistiniai, mašininio mokymosi ir programavimo metodai⁹ (žr. 10 pav.).

Grynieji statistiniai	Mašininio mokymosi	Programavimo
<ul style="list-style-type: none"> - Tiesinė regresija - Diskriminantinė analizė - Probito regresija - Logistinė regresija - Cloglog regresija - Tobit regresija - Išlikimo analizė 	<ul style="list-style-type: none"> - Grafiniai (Bajeso) - Sprendimų medžiai - <i>k</i> artimiausių kaimynų - Dirbtiniai neuroniniai tinklai - Genetiniai algoritmai 	<ul style="list-style-type: none"> - Genetinio programavimo - Tiesinio programavimo - Sveikųjų skaičių programavimo - Atramos vektorių mašinos - Duomenų apgaubimo analizė

10 pav. Statistinių vertinimo balais modelių klasifikavimas

Šaltinis: sudaryta autorės pagal Hand, Henley 1997; Thomas ir kt. 2002; Mays 2004; Pociecha 2005; Lahsasna ir kt. 2008; Kennedy 2009; Danėnas, Garšva 2009; Lopez 2010.

Tiesinė regresija. Skolininko PD yra apskaičiuojama pagal formulę (Pindyck, Rubinfeld 1997; Anderson 2007; SAS 2008, 2009; Kennedy 2009):

$$PD_i = b_0 + b_1 \cdot X_{1i} + \dots + b_n \cdot X_{ni},$$

čia: PD_i – tikimybė, kad i skolininkas taps „blogas“; X_{1i}, \dots, X_{ni} – i skolininko įvesties kintamųjų reikšmės; b_0, b_1, \dots, b_n – koeficientai, n – įvesties kintamųjų skaičius.

⁹ Kai kurie autoriai, sakysime, Thomas ir kt. (2002), dirbtinius neuroninius tinklus, genetinius algoritmus ir programavimo metodus įvardija kaip nestatistinius vertinimo balais modelius. Išlikimo analizę kai kurie autoriai, pavyzdžiui, Valvonis (2006), apskritai priskiria ne prie vertinimo balais modelių, bet prie atskiros kredito rizikos vertinimo metodų grupės – mirtingumo (aktuarinių) metodų.

Tiesinė regresija pasižymi reikšmingais trūkumais, todėl dabar yra retai taikoma bankuose statistiniams vertinimo balais modeliams kurti. Nors galima tiesiogiai apskaičiuoti skolininko PD, ji gali būti didesnė už 1 arba mažesnė už 0. Be to, taikant tiesinę regresiją reikia laikytis griežtų prielaidų (paklaidų normalumas, vidurkių lygybė nuliui, dispersijų lygybė, paklaidų nepriklausomumas, tarpusavyje nekoreliuojantys įvesties kintamieji, tiesinė įvesties kintamųjų ir išvesties kintamojo priklausomybė). Be to, modeliui yra būdingas didelis jautrumas išskirtims.

Diskriminantinė analizė. Ji yra taikoma skolininko kreditingumo balui apskaičiuoti ir grupei, kuriai turėtų priklausyti skolininkas, nustatyti. Skolininko kreditingumo balas Z yra apskaičiuojamas taip (Čekanavičius, Murauskas 2004; Pocięcha 2005; Anderson 2007; SAS 2008, 2009; Kennedy 2009):

$$Z_i = b_0 + b_1 \cdot X_{1i} + \dots + b_n \cdot X_{ni} ,$$

čia Z_i – i skolininko kreditingumo balas.

Praktiškai klasifikuoti skolininkus yra patogiau naudojantis klasifikavimo funkcijomis. Kiekvienai grupei yra sudaroma atskira klasifikavimo funkcija. Skolininkas yra priskiriamas prie „gerų“ skolininkų grupės, jeigu „gerų“ skolininkų grupės klasifikavimo funkcijos reikšmė tam skolininkui yra didesnė už „blogų“ skolininkų grupės klasifikavimo funkcijos reikšmę ir atvirkščiai. Diskriminantinę analizę ne visada yra patogu taikyti bankuose, nes įvesties kintamieji turi būti arba kiekybiniai, arba kokybiniai, bet vertinami pagal rangų skalę, tačiau tada grupių skaičius turi būti ne mažesnis kaip penki. Kai įvesties kintamųjų normalumo sąlyga yra netenkinama, geriausia alternatyva diskriminantinei analizei – logistinė regresija. Diskriminantinės analizės modelio patikimumo vertinimo rezultatai yra labai jautrūs „gerų“ ir „blogų“ skolininkų grupių neproporcingumui. Modeliui yra būdingas jautrumas išskirtims, be to, įvesties kintamųjų kovariacijų matricos grupėse turi būti lygios.

Probito regresija. Skolininko PD yra apskaičiuojama taip (Pindyck, Rubinfeld 1997; SAS 2008, 2009):

$$PD_i = \Phi(Z_i) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{Z_i} e^{-\frac{s^2}{2}} ds ;$$

$$Z_i = b_0 + b_1 \cdot X_{1i} + \dots + b_n \cdot X_{ni} ,$$

čia: $\Phi()$ – standartinio normaliojo dydžio pasiskirstymo funkcija; Z_i – i skolininko teorinis tolydusis indeksas.

Taikant probito regresiją negali būti pažeidžiama normalumo prielaida. Be to, PD gali būti per maža arba per didelė (žr. 11 pav.).

Logistinė regresija. Skolininko PD yra apskaičiuojama taip (Pindyck, Rubinfeld 1997; SAS 2008, 2009; Kennedy 2009):

$$PD_i = \frac{1}{1 + e^{-Z}}; Z_i = \ln\left(\frac{PD_i}{1 - PD_i}\right) = b_0 + b_1 \cdot X_{1i} + \dots + b_n \cdot X_{ni},$$


čia: $\frac{PD_i}{1 - PD_i}$ – i skolininko galimybė tapti „blogu“ (reikšmė gali kisti intervale nuo 0 iki ∞); Z_i – i skolininko galimybės tapti „blogu“ natūrinis logaritmas, dar vadinamas logitu.

Daugelis autorių rekomenduoja kuriant vertinimo balais modelį taikyti logistinę regresiją (Hayden 2003; Fernandes 2005; Kocenda, Vojtek 2006; Hörkkö 2010 ir kt.). Palyginti su kitais statistiniais metodais, logistinė regresija pasižymi tam tikrais pranašumais (Crone, Finlay 2002; Thomas ir kt. 2002; Čekanavičius, Murauskas 2004; Mays 2004; ONB 2004; Iscanoglu Aysegul 2005; Kocenda, Vojtek 2006; Anderson 2007). Ją galima taikyti galiojant gana bendro pobūdžio prielaidoms: įvesties kintamieji X_1, X_2, \dots, X_n nebūtinai turi būti normalieji, nereikia normaliai pasiskirsčiusių paklaidų, išvesties kintamojo homoskedastiškumo. Yra apskaičiuojama skolininko individuali PD, kuri gali būti taikoma ne tik teikiant paskolas, bet ir skaičiuojant vertės sumažėjimą, kainodaroje, atliekant testavimą nepalankiausiomis sąlygomis ir kituose procesuose. Logistinė regresija labiau negu tiesinė tinka dvireikšmiam išvesties kintamajam prognozuoti, nes naudojamas natūrinis galimybės logaritmas, t. y. $\ln(PD/(1-PD))$, todėl PD negali būti didesnė už 1 ar mažesnė už 0. Be to, priešingai nei taikant diskriminantinę analizę, gali būti naudojami net ir kokybiniai įvesties kintamieji, vertinami pagal pavadinimų skalę, nes atitinkamai kokybinio įvesties kintamojo reikšmei ar reikšmių grupėms galima nustatyti tam tikrą pseudokintamąjį. Modeliui būdingas mažesnis jautrumas išskirtims nei taikant diskriminantinę analizę. Be to, mažesnis nei taikant diskriminantinę analizę, dirbtinius neuroninius tinklus ar sprendimų medžius modelio patikimumo vertinimo rezultatų jautrumas „gerų“ ir „blogų“ skolininkų grupių neproporcingumui. Atliktų tyrimų (žr. ONB 2004; Mileris 2009) rezultatai parodė, kad logistinės regresijos modelių patikimumas nusileidžia tik dirbtinių neuroninių tinklų modelių patikimumui.

Cloglog regresija. Skolininko PD yra apskaičiuojama taip (SAS 2008, 2009):

$$PD_i = 1 - \exp(-\exp(Z_i)); Z_i = b_0 + b_1 \cdot X_{1i} + \dots + b_n \cdot X_{ni}.$$

Paanalizavus skolininkų PD priklausomybę nuo teorinio tolydaus indekso Z , kai yra kuriami probito, logistinės ir *cloglog* regresijų modeliai, matyti, kad pastarosios regresijos funkcijos reikšmės neišsidėsto simetriškai ties 50 %, nuo 0 % PD didėja lėtai, tačiau staigiau artėja prie 100 % (žr. 11 pav.).



11 pav. PD priklausomybė nuo Z

Šaltinis: Pindyck, Rubinfeld 1997; SAS 2008, 2009.

Taikant logistinę regresiją, yra sunkesnės „uodegos“ nei taikant probito regresiją, tačiau tiek probito, tiek logistinės regresijų funkcijų reikšmės išsidėsto simetriškai ties 50 %.

Tobit regresija. Skolininko PD yra apskaičiuojama taip (Thomas ir kt. 2002):

$$PD_i = \max\{b_0 + b_1 \cdot X_{1i} + \dots + b_n \cdot X_{ni}, 0\}.$$

Yra apribojama apatinė regresijos funkcijos reikšmė, kuri negali būti neigiami. Tačiau nors PD negali būti mažesnė už 0, ji gali būti didesnė už 1.

Išlikimo analizė. Pagrindinis išlikimo analizės pranašumas yra tas, kad atsižvelgiama ne tik į patį faktą, kad skolininkas tapo „blogas“, bet ir į tai, kada jis toks tapo. Todėl galima prognozuoti ne tik įvairių laikotarpių PD, bet ir tikėtiną tapsmo „blogu“ laiką. Metodas gali būti taikomas ne tik kredito rizikai vertinti, bet ir daugelyje kitų banko veiklos sričių, kur yra aktualus atitinkamo modeliuojamo įvykio laikas, pavyzdžiui, skoloms išieškoti, pelningumui prognozuoti ir kitur. Tarkime, kad t metų PD prognozuoti yra taikoma Coxo regresija, tada skolininko PD yra apskaičiuojama taip (Kleinbaum, Klein 2005; SAS 2009):

$$PD_i(t) = 1 - S(t)_i = 1 - S_0(t)^{\exp(b_0 + b_1 \cdot X_{1i} + \dots + b_n \cdot X_{ni})},$$

čia: $S(t)_i$ – i skolininko išlikimo t metų tikimybė; $S_0(t)$ – bazinė išlikimo funkcija, kurią taikant galima apskaičiuoti išlikimo tikimybę, kai visi įvesties kintamieji X_1, \dots, X_n yra lygūs 0.

Coxo regresija yra priskiriama prie semiparametrinių išlikimo analizės modelių, todėl išlikimo metų t skirstinys nėra apibrėžiamas iš anksto. Tačiau parametriniuose išlikimo analizės modeliuose turi būti daroma išankstinė prielaida dėl šio skirstinio. Yra pasiūlyta


keletas skirstinių rūšių¹⁰, tačiau dažniausiai yra manoma, kad ilgalaikių paskolų momentinė rizika iš pradžių didėja, praėjus 3–5 metams nuo paskolos suteikimo pasiekia maksimalią reikšmę ir tada pradeda mažėti, t. y. skirstinys yra log-logistinis (Bonfim 2009). Tada yra taikomos šios formulės (Kleinbaum, Klein 2005):

$$PD_i(t) = 1 - S(t)_i = 1 - \frac{1}{1 + \lambda_i t^p}; \quad h(t)_i = \frac{\lambda_i p t^{p-1}}{1 + \lambda_i t^p};$$

$$f(t)_i = h(t)_i \cdot S(t)_i,$$

čia: $h(t)_i$ – i skolininko pavojaus funkcija, žyminti riziką, kad i skolininkas taps „blogas“ laiko momentu t (t. y. tapimo „blogu“ greitį); λ_i – i skolininko įvesties kintamųjų reikšmių ir koeficientų įverčių veikiamas parametras; p – fiksuotas parametras; $f(t)_i$ – tikimybinio tankio funkcija; tikėtinausia, kad skolininkas taps „blogas“ tada, kai šios funkcijos reikšmė bus didžiausia.

Kai skirstinys yra log-logistinis, dažniausiai kaupiamoji PD sparčiausiai didėja pirmuosius trejus metus, vėliau jos didėjimo tempas pradeda lėtėti. Iš pateikto pavyzdžio matyti, kad, jei skolininkas taps „blogas“, tai tikėtinausia, jog tai įvyks trečiaisiais metais po paskolos suteikimo (žr. 12 pav.).




12 pav. Kaupiamosios PD priklausomybė nuo laikotarpio ir tapimo „blogu“ skolininku greičio*

Šaltinis: autorės skaičiavimai. *Skaičiuojant parametrai λ ir p buvo prilyginti atitinkamai 0,02 ir 3.

¹⁰ Weibull, eksponentinis, log-logistinis, lognormalusis ir apibendrintasis gama (Kleinbaum, Klein 2005).

Grafiniai (Bajeso) metodai. Grafinis modeliavimas – tai statistinių metodų, taikomų kintamųjų tarpusavio ryšiams analizuoti, grupė. Grafiką sudaro kintamuosius vaizduojančios viršūnės, kurios gali būti sujungtos kraštinėmis. Jeigu dvi viršūnės nesusjungtos kraštinėmis, neįmanoma tiesiogiai patekti nuo vienos viršūnės prie kitos, reikia eiti pro kitą ar kelis kitus kintamuosius. Laikoma, kad tokie du kintamieji yra sąlyginai nepriklausomi, esant kitiems kintamiesiems. Tai yra vadinama globaliąja Markovo savybe. Pavyzdžiui, kintamasis X_1 sąlyginai nepriklauso nuo X_3 , kai (X_2, Y) , taip pat ir X_2 sąlyginai nepriklauso nuo X_3 , kai (X_1, Y) (žr. 13 pav.). Modeliuojant galima pradėti nuo tokio varianto, kai visos viršūnės yra sujungtos kraštinėmis, ir palaipsniui tikrinti, kurių kraštinių neįtraukti, arba nuo tokio varianto, kai nėra nė vienos kraštinės, ir palaipsniui tikrinti, kurias kraštines pridėti. Gali būti taikomi skirtingi statistiniai metodai atsižvelgiant į tai, ar kintamieji yra diskretieji, ar tolydieji, ar yra ir tokių, ir tokių. Kai kintamieji yra diskretieji, yra taikomi logtiesiniai metodai, o kai tolydieji, kurių reikšmės yra pasiskirsčiusios pagal normalųjį skirstinį – daugiafaktoriniai Gauso modeliai (žr. Stanghellini 1999; Thomas ir kt. 2002; Biçer ir kt. 2010).



13 pav. Grafinio modeliavimo pavyzdys

Šaltinis: Thomas ir kt. 2002.

Grafinio modeliavimo pranašumas yra tas, kad vienu metu atskleidžiami kintamųjų tarpusavio ryšiai, nenaudojant vieno kurio nors atskiro kintamojo kaip išvesties kintamojo, todėl galima lengviau nustatyti tam tikromis mokymo savybėmis pasižyminčias skolininkų grupes. Naudojant ryšius tarp kintamųjų galima prognozuoti nežinomas kitų kintamųjų reikšmes, pavyzdžiui, skolininko individualią PD (Y). Tačiau tyrimų rezultatai parodė, kad, pradėjus modeliuoti nuo tokio varianto, kai visos viršūnės yra sujungtos kraštinėmis, nebuvo galima atsikratyti daugelio kraštinių, o pradėjus modeliuoti nuo tokio varianto, kai nėra nė

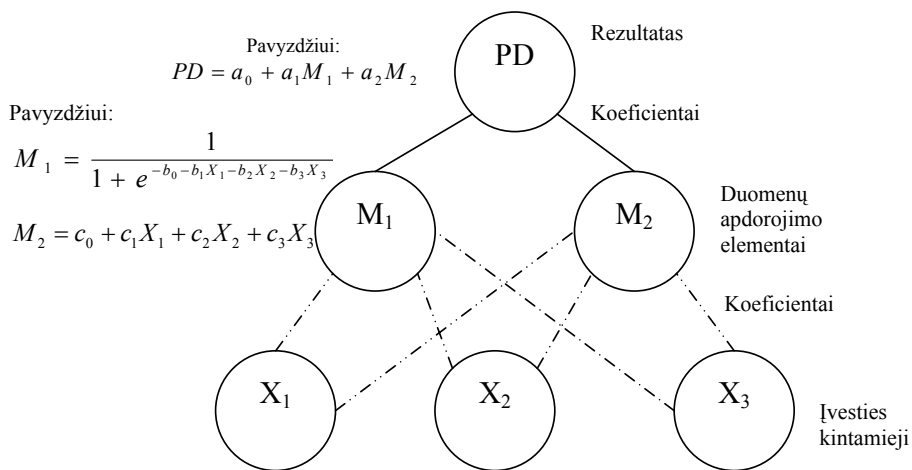
vienos kraštinės, nebuvo įmanoma pridėti daug kraštinių. Taigi reikia daugiau grafinių metodų taikymo, vertinant skolininkų kredito riziką, srities tyrimų.

Sprendimų medžiai. Skolininkai yra suskirstomi į grupes pagal tam tikro įvesties kintamojo reikšmes, o šios grupės savo ruožtu suskirstomos į dar smulkesnius pogrupius jau pagal kito įvesties kintamojo reikšmes, ir t. t. Suskirsčius skolininkus į grupes, naujose grupėse turi būti kur kas homogeniškesni skolininkai nei pradiniame rinkinyje prieš skirstant į konkrečias grupes. Galutiniai pogrupiai yra įvardijami kaip „gerų“ arba „blogų“ skolininkų pogrupiai, atsižvelgiant į tai, kokių skolininkų tame konkrečiame pogrupyje yra daugiau. Svarbu apibrėžti tris aspektus: pagal kokio įvesties kintamojo reikšmes skirstyti skolininkus, kada sustabdyti skirstymo procesą, kada galutinius skolininkų rinkinius priskirti prie „gerų“ skolininkų, o kada – prie „blogų“ (Thomas ir kt. 2002; Anderson 2007). Metodas yra lankstus, nedaromos jokios prielaidos dėl įvesties kintamųjų skirstinio, nereikia laikytis kitų griežtų prielaidų, naudojamų kuriant parametrinius metodus. Metodas ypač tinka, kai yra daug kokybinių įvesties kintamųjų ar kai trūksta reikšmių, be to, galima pastebėti ir analizuoti įvesties kintamųjų ryšius. Tačiau yra didelė persimokymo (angl. *overfitting*) rizika, ypač kai yra daug įvesties kintamųjų, turinčių daug reikšmių grupių. Nėra nustatomi įvesties kintamųjų svoriai, be to, atlikus monotoninę įvesties kintamųjų transformaciją, rezultatai nesikeičia. Gali kilti sunkumų kuriant reitingų skalę ar priskiriant skolininkus reitingams, nes visi galutinio pogrupio skolininkai turi tą pačią PD. Todėl bankuose šis metodas yra taikomas tik kaip papildoma priemonė, sakysime, ieškant prediktyviausių įvesties kintamųjų.

k artimiausių kaimynų metodas. Yra pasirenkamas vienas ar keli rodikliai (dažniausiai – Euklido atstumas), siekiant įvertinti, kiek toli vienas nuo kito yra du konkretūs skolininkai pagal įvairių įvesties kintamųjų reikšmes. Kiekvienas naujas potencialus skolininkas yra priskiriamas prie „gerų“ arba prie „blogų“ skolininkų, atsižvelgiant į „gerų“ ir „blogų“ skolininkų proporcijas (nustatytas pagal reprezentatyvius praeities duomenis) tarp k artimiausių kaimynų (Thomas ir kt. 2002; Anderson 2007; Lopez 2010). Pavyzdžiui, jeigu iš 10 konkretaus skolininko artimiausių kaimynų pagal įvairių įvesties kintamųjų reikšmes 7 yra „geri“ ir 3 – „blogi“, tas konkretus skolininkas yra priskiriamas prie „gerų“ arba yra apskaičiuojama jo PD (30 %), naudojama priskiriant skolininką prie vieno iš reitingų. Metodas paprastas, be to, duomenys yra periodiškai atnaujinami (naujų skolininkų duomenys įtraukiami, senų – atmetami), todėl artimiausi kaimynai reprezentuoja naujus skolininkus. Tačiau modelio rezultatai yra labai jautrūs artimiausių kaimynų skaičiaus ir

atstumo funkcijos pasirinkimo atžvilgiu, be to, nesukuriama galutinė funkcija su įvesties kintamųjų svoriais, ilgai apdorojami duomenys.

Dirbtiniai neuroniniai tinklai. Šiais modeliais yra imituojami žmogaus smegenyse vykstantys procesai. Pagrindinis skirtumas, palyginti su kitais metodais, yra tas, kad dirbtiniai neuroniniai tinklai nereikalauja tikslaus duomenų analizės modelio, o sudaro jį patys pagal į tinklą įvestą skolininkų informaciją. Populiariausias dirbtinių neuroninių tinklų metodas – daugiasluoksnis perceptronas – yra tęstinė biologinės nervų sistemos įkvėpta tradicinės daugialypės regresijos versija (Mays 1998; SAS 2008, 2009; Kennedy 2009; Lopez 2010) (žr. 14 pav.). Skirtumas nuo daugialypės regresijos yra tas, kad atsiranda ir papildomas etapas, kuriame yra apskaičiuojamos duomenų apdorojimo elementų M_1 ir M_2 reikšmės. Tarkime, yra trys įvesties kintamieji X_1 , X_2 ir X_3 . Pradiniame etape yra tik tiek neuronų, kiek yra įvesties kintamųjų. Tačiau tarpiniame etape atsiranda papildomi neuronai M_1 ir M_2 , kurie yra tarpinių regresijos lygčių išvesties kintamieji, bet kartu ir galutinės PD lygties įvesties kintamieji.



14 pav. Daugiasluoksnio perceptrono modelis

Šaltinis: Mays 1998; SAS 2008, 2009; Kennedy 2009; Lopez 2010.

Jeigu yra naudojama keletas tarpinių etapų, gali būti aproksimuojama bet kokios rūšies funkcija tarp įvesties kintamųjų ir išvesties kintamojo, todėl taikant dirbtinius neuroninius tinklus sukurtų modelių patikimumas dažniausiai yra didesnis už modelių, sukurtų taikant kitus metodus (ONB 2004; Anderson 2007; Mileris 2009). Galima apdoroti didelį duomenų kiekį, automatiškai vertinti kintamųjų sąveikas. Tačiau šiam metodui yra būdinga didelė persimokymo rizika, ji didėja didėjant neuronų skaičiui. Todėl modelis gali puikiai

diskriminuoti skolininkus, kurių duomenys buvo naudoti modeliui kurti, bet gerokai prasčiau tuos tos pačios paskolų rūšies skolininkus, kurių duomenys nebuvo naudoti modeliui kurti. Be to, skaičiavimai yra sudėtingi, neaišku, kaip pasirinkti tarpinių etapų ir duomenų apdorojimo elementų kiekviename tarpiniame etape skaičių, reikia atlikti daug iteracijų, modelio kūrėjui sunku interpretuoti mašininio mokymosi metu atrastus ryšius, metodą brangu įdiegti ir palaikyti. Dirbtiniai neuroniniai tinklai labiau tinka tada, kai portfelyje yra mažai skolininkų (pvz., vertinant stambių įmonių ar kredito unijų klientų kredito riziką).

Genetiniai algoritmai. Tai yra neparаметrinis metodas, pagrįstas biologija ir Darvino natūraliosios atrankos koncepcija. Genetiniai algoritmai yra naudojami kaip euristiniai globaliosios paieškos algoritmai, pagrįsti atrankos, paveldimumo, mutacijų ir kryžminimo principais. Genetiniai algoritmai pasitelkia kompiuterinio imitavimo priemones, leidžiančias sukurti individų populiacijas. Kiekvieną populiacijos individą charakterizuoja chromosomų aibė (Plikynas, Budrionis 2010). Tarkime, norime apskaičiuoti vertinimo balais modelio lygties koeficientus $b_1, \dots, b_n, c_1, \dots, c_n, d$ (Thomas ir kt. 2002):

$$f(x_i) = b_1 \cdot X_{1i}^{c_1} + \dots + b_n \cdot X_{ni}^{c_n} + d,$$

čia: X_{1i}, \dots, X_{ni} – i skolininko įvesties kintamųjų reikšmės.

Apskaičiavus lygties koeficientus skolininkas yra priskiriamas prie „gerų“, jei $f(x_i) > 0$, arba prie „blogų“, jei $f(x_i) < 0$. Iš pradžių yra sudaroma koeficientų $b_1, \dots, b_n, c_1, \dots, c_n, d$ kandidatinių įverčių populiacija. Pavyzdžiui, b_1 įverčiai gali būti intervale nuo $-1\ 000$ iki $1\ 000$ ir t. t. Lygties sprendinys yra baigtinė $\{0,1\}$ reikšmių aibė koeficientams $b_1, \dots, b_n, c_1, \dots, c_n, d$. Kandidatinių sprendinių skaičių pasirenka modelio kūrėjas. Antrame etape yra vertinamas sprendinių atitikimas (pvz., yra apskaičiuojamas bendras teisingo klasifikavimo rodiklis ar kitas bankui aktualus rodiklis) ir atrenkami tam tikri sprendiniai. Trečiame etape šie sprendiniai yra koreguojami, kryžminimo arba mutacijos būdu sukuriant naujus sprendinius. Kryžminimo ir mutacijos tikimybes turi pasirinkti modelio kūrėjas. Antrasis ir trečiasis etapai yra kartojami daug kartų (kartojimų skaičių taip pat pasirenka modelio kūrėjas). Yra pasirenkamas atitikimo funkciją maksimizuojantis sprendinys. Metodas tinka, kai vienu metu yra siekiama optimizuoti kelis banko rodiklius, tarkim, pagal riziką įvertintą pelną, vertės sumažėjimą ir kt., be to, jį taikant galima gauti alternatyvius sprendinius, kurie nėra iš karto aiškiai matomi. Tačiau metodui yra būdinga aiškumo stoka ir persimokymo rizika, jis yra imlus laikui, be to, kai kada gali būti gaunama lokali, o ne globalioji didžiausia atitikimo funkcijos reikšmė (Anderson 2007; Lahsasna ir kt. 2008).

Programavimo metodai. Sprendžiant tokius uždavinius, kuriuos sunkiai pavyksta spręsti taikant genetinius algoritmus, galima pasitelkti genetinį programavimą. Tokiu atveju

dažniausiai prireikia dar daugiau laiko nei taikant genetinius algoritmus, tačiau skaičiavimo pajėgumas didesnis.

Tiesinį programavimą paranku taikyti tada, kai reikia nustatyti papildomas sąlygas ir apribojimus. Tačiau metodas yra kritikuojamas dėl to, kad neįmanoma įvertinti apskaičiuotų koeficientų statistinio reikšmingumo. Kitas trūkumas, palyginti su regresijos metodais, yra tas, kad neįmanoma iš anksto nustatyti norimų matyti galutiniame modelyje įvesties kintamųjų skaičiaus. Tokiam skaičiui nustatyti buvo pasiūlyta taikyti visrakčio metodą, tačiau tada būna labai daug iteracijų, skaičiavimai ilgai trunka. Tyrimų rezultatai parodė, kad taikant tiesinį programavimą sukurtų modelių teisingo klasifikavimo rodikliai yra mažesni už modelių, sukurtų taikant grynuosius statistinius metodus, teisingo klasifikavimo rodiklius (Thomas ir kt. 2002; Anderson 2007; SAS 2008, 2009; Kennedy 2009).


Taip pat tyrimų rezultatai parodė, kad taikant sveikųjų skaičių programavimą sukurti modeliai skolininkus klasifikuoja geriau nei taikant tiesinį programavimą sukurti modeliai. Tačiau skaičiavimai ilgiau trunka, metodas tinka tik nedidelėms duomenų imtims (< 500 stebėjimų). Be to, patikimumo vertinimo rezultatai naudojant patikimumo vertinimo imtį gali būti blogesni nei naudojant kūrimo imtį (Thomas ir kt. 2002; SAS 2008, 2009).

Atramos vektorių mašinos yra lankstus metodas, galima įtraukti tokius įvesties kintamuosius, kurių reikšmės, didėjant skolininko PD, nedidėja (ar nemažėja) monotoniškai, ir nereikia apdoroti kiekvieno atskiro įvesties kintamojo reikšmių. Kitaip nei taikant dirbtinius neuroninius tinklus ar genetinius algoritmus, taikant atramos vektorių mašinas yra gaunamas unikalus sprendinys. Tačiau šis metodas yra kritikuojamas dėl to, kad modelio kūrėjui sunku interpretuoti gautus rezultatus, įvesties kintamųjų koeficientai nėra pastovūs, kiekvieno atskiro įvesties kintamojo įtaka galutiniam rezultatui yra kintanti (žr. Hårdle ir kt. 2005, 2007; Auria, Moro 2008; SAS 2009; Lopez 2010; Feng, Jin 2010).

Duomenų apgaubimo analizės metodas yra labai jautrus atskiriems kūrimo imties įrašams, nes yra apskaičiuojamas efektyvumo rodiklis, rodantis santykinį skolininko kreditingumą, atsižvelgiant į kitus kūrimo imties skolininkus. Tyrimų rezultatai parodė, kad taikant duomenų apgaubimo analizę sukurtų modelių teisingo klasifikavimo rodikliai yra panašūs kaip ir (arba net geresni už) modelių, sukurtų taikant diskriminantinę analizę ir tiesinę regresiją (žr. Emel ir kt. 2003; Feruš 2008; Wozniowska 2008; Psillaki ir kt. 2009).

Kurį metodą pasirinkti, priklauso nuo keleto veiksnių: duomenų struktūros, naudojamų įvesties kintamųjų rūšies (tik kiekybiniai, tik kokybiniai ar abiejų rūšių), statistinio vertinimo balais modelio kūrimo tikslo (mažinti bendrą klaidingo klasifikavimo rodiklį, mažinti klaidingo klasifikavimo sąnaudas ar kt.) ir nuo individualios įvesties kintamųjų diskriminacinės galios. Jeigu „gerų“ ir „blogų“ skolininkų grupėse įvesties kintamojo reikšmės nedaug skiriasi, taikant labai lanksčius metodus – k artimiausių kaimynų metodą ar dirbtinius neuroninius tinklus – išskyla persimokymo rizika, todėl tenka imti didesnę

artimiausių kaimynų skaičių ir pan. Jei bankas nori apskaičiuoti skolininkų individualias PD, jam tikslinga rinktis logistinę ar *cloglog* regresiją ar kitus individualias PD leidžiančius apskaičiuoti metodus (probito, tiesinę ar *tobit* regresijas, išlikimo analizę). Jei bankas nori apskaičiuoti tikimybes, kad skolininkas taps „blogas“ per įvairios trukmės laikotarpius, ir tikėtinausią tapsmo „blogu“ laiką, tada tikslinga rinktis išlikimo analizę. Tyrimų rezultatai parodė, kad modelių, sukurtų taikant įvairius skirtingus statistinius metodus, patikimumas skiriasi nereikšmingai, daug didesni modelių patikimumo skirtumai yra naudojant skirtingas skolininkų duomenų imtis (žr. Thomas ir kt. 2002; Andreeva 2006; Anderson 2007). Ankstesni įmonių statistiniai vertinimo balais modeliai (*Altman, Lis, Tafler, Springate, Fulmer*) dažniausiai buvo kuriami taikant diskriminantinę analizę, tačiau 1974 metais Chesser, o 1980 metais ir Ohlson pasiūlė logistinę regresiją (žr. Altman 2000; Mackevičius, Silvanavičiūtė 2006; Garškaitė 2008). Aziz, Dar (2004) atliko tyrimą, siekdami nustatyti, kokį statistinį metodą dažniausiai taikė straipsnių autoriai. Jų tyrimų rezultatai parodė, kad nuo 1968 iki 1996 metų dažniausiai buvo taikyta diskriminantinė analizė – net 45 % visų nagrinėtų atvejų (žr. 15 pav.). Tačiau šios disertacijos autorė, išanalizavusi naujesnius, per 15 metų (nuo 1996 iki 2011 m.) autorių iš įvairių pasaulio šalių parašytus 89 straipsnius, nustatė, kad dažniausiai buvo taikyta logistinė regresija (net 37 % visų nagrinėtų atvejų), o diskriminantinės analizės populiarumas jau buvo gerokai mažesnis.



15 pav. Statistinio metodo taikymo dažnumas, %

Šaltinis: sudaryta autorės pagal 3; 4; 8; 10; 11; 13; 14; 15; 16; 22; 29; 32; 33; 40; 41; 45; 47; 48; 49; 51; 53; 54; 64; 68; 69; 71; 75; 78; 80; 86; 87; 88; 94; 101; 102; 103; 104; 105; 106; 109; 111; 112; 113; 114; 115; 118; 119; 120; 124; 125; 126; 138; 140; 141; 142; 144; 148; 157; 159; 163; 169; 176; 179; 180; 181; 182; 190; 191; 193; 196; 197; 198; 201; 204; 207; 212; 213; 215; 216; 217; 221; 223; 224; 227; 233; 234; 239; 241; 244.

Pastaruoju metu ir bankuose plačiausiai yra taikoma būtent logistinė regresija, yra sukurta standartizuotų kompiuterinių paketų, nors sparčiai populiarėja ir sprendimų medžiai bei išlikimo analizė, ypač Coxo regresija (Stepanova, Thomas 2002; Tong ir kt. 2005; Bellotti, Crook 2007; Anderson 2007; SAS 2008, 2009). Nors pastaraisiais metais ir daugėjo straipsnių, susijusių su naujos kartos mašininio mokymosi ir programavimo metodais – dirbtiniais neuroniniais tinklais ir atramos vektorių mašinomis (žr. Danėnas, Garšva 2009; Buzius ir kt. 2010; Lahsasna ir kt. 2010; Mileris, Boguslauskas 2010, 2011), šie metodai vis dar yra tyrimų stadijos, jų tinkamumas skolininkų kredito rizikai vertinti dar nėra iki galo iširtas, nėra standartizuotų kompiuterinių paketų. Be to, tyrimų rezultatai parodė, kad nors taikant šiuos metodus modelių jautrumas¹¹ dažniausiai būna didesnis nei taikant grynuosius statistinius metodus, bendras teisingo klasifikavimo rodiklis – panašus kaip ir taikant grynuosius statistinius metodus.

1.1.1.6. Imties sudarymas

Sudarydamas imtį modeliui, bankas turėtų atsižvelgti į kelis aspektus: imties dydį, proporcijų skirtumus, skolininkų skaičiaus optimalumą, duomenų rinkinio išskaidymą, atmestų paraiškų įtraukimą (Hand, Vinciotti 2002; Crone, Finlay 2002, 2012; ONB 2004; Verstraeten, Van den Poel 2005; BCBS 2005b; Lucas 2007; SAS 2008, 2009; Burez, Van den Poel 2008; Marquez 2008; Menardi 2009).

Imties dydis. Imties dydis n , reikalingas patikimam PD įverčiui nustatyti, gali būti apskaičiuojamas pagal tokią formulę:

$$n = \left(\frac{\Phi^{-1}\left(\frac{\alpha}{2}\right) \cdot \sqrt{PD_{MAX}(1 - PD_{MAX})}}{\Delta PD} \right)^2,$$

čia: PD_{MAX} – viršutinė PD riba¹², kuri gali būti nustatoma banko ekspertų, išanalizavus tos paskolų rūšies (ar viso paskolų portfelio, kai kuriamas bendras modelis) skolininkų patirtį ir pan.; α – reikšmingumo lygmuo (gamas iš 100 procentų atėmus banko pasirinktą pasiklovimo lygmenį); $\Phi^{-1}()$ – atvirkštinė standartinio normaliojo dydžio pasiskirstymo funkcija; ΔPD – procentinis PD paklaidos rėžis. Pavyzdžiui, jeigu bankas pasirenka 95 % pasiklovimo lygmenį ir 0,20 procentinių punktų PD paklaidos rėžį, jis siekia būti 95 % tikras, kad tos paskolų rūšies (ar viso paskolų portfelio, kai kuriamas bendras modelis)

¹¹ Žr. 1.3.1 dalį.

¹² Gali būti taikoma ne tik įsipareigojimų neįvykdymo, bet ir kitokio įvykio maksimali tikimybė, atsižvelgiant į tai, koks yra naudojamas apibrėžimas priskiriant skolininkus prie „blogų“.

vidutinė pagal sukurtą modelį apskaičiuota PD pateks į intervalą [$PD_{MAX} - 0,20\%$; $PD_{MAX} + 0,20\%$].

Kai banko skolininkų yra mažiau negu nustatoma pagal formulę, jų skaičių galima padidinti pradinius skolininkų įrašus įtraukiant po kelis kartus, naudojant kelių paskolų rūšių ar net kelių bankų duomenis ir t. t. Taip pat galima naudoti skirtingas stebėjimo laikotarpio atskaitos datas, t. y. vis perkelti atskaitos datą taip sudarant daugiau to paties skolininko įrašų. Naudojant nepakankamą skolininkų skaičių, vertinimo balais modelis gali būti nepatikimas (pernelyg maža diskriminacinė galia ir t. t.). Vis dėlto yra ir tokių nuomonių, kad kuriant vertinimo balais modelį pakanka po 1 500–5 000 „gerų“ ir „blogų“ skolininkų.

„Gerų“ ir „blogų“ skolininkų proporcijos problema. Bet kurios paskolų rūšies „gerų“ skolininkų bankuose paprastai būna kur kas daugiau nei „blogų“, tačiau dažniausiai yra siūloma taikyti lygias jų proporcijas, t. y. po 50 %. Lygioms skolininkų proporcijoms nustatyti galima taikyti skirtingus metodus: a) mažinti imtį, įtraukiant visus „blogus“ skolininkus, tačiau sumažinant „gerų“ skolininkų skaičių, kad jis prilygtų „blogų“ skolininkų skaičiui; b) didinti imtį, įtraukiant visus „gerus“ skolininkus, tačiau padidinant „blogų“ skaičių, kad jis prilygtų „gerų“ skaičiui; c) taikyti mišrų metodą, padidinant „blogų“ skolininkų skaičių ir sumažinant „gerų“. Taip pat galima „blogais“ skolininkais laikyti blogiausio „gerų“ skolininkų reitingo skolininkus, naudoti kitą griežtesnę „blogo“ skolininko apibrėžimą ir (arba) ilgesnį stebėjimo laikotarpį. Ne visada būtina siekti lygių proporcijų. Logistinė regresija gali būti taikoma tik tuo atveju, kai „gerų“ skolininkų dalis sudaro ne mažiau kaip 20 % ir ne daugiau kaip 80 % visų stebinių (Čekanavičius, Murauskas 2004). Tyrimų rezultatai parodė, kad modeliui kurti naudojant skirtingas „gerų“ ir „blogų“ skolininkų proporcijas jo patikimumo vertinimo rezultatai nedaug skyrėsi.

Optimalus skolininkų skaičius. Šis modelio tikslumą leidžiantis padidinti skaičius gali būti nustatomas naudojant *Neymano ir Pearsono* optimalaus paskirstymo algoritmą:

$$n_j = \frac{n \cdot N_j \cdot \sqrt{ODF_j(1-ODF_j)}}{\sum_{j=1}^m [N_j \cdot \sqrt{ODF_j(1-ODF_j)}]}$$

čia: n_j – optimalus j grupės skolininkų skaičius; j kinta nuo 1 iki m ; m – skolininkų grupių skaičius; n – faktinis visų grupių skolininkų skaičius; N_j – faktinis j grupės skolininkų skaičius; ODF_j – faktinių „blogų“ j grupės skolininkų dažnis.

Optimalus skolininkų skaičius gali būti nustatomas būsto ir vartojimo paskolų, kredito kortelių ir išperkamosios nuomos grupėms (žr. 2 priedą). Apskaičiavus optimalų grupės

skolininkų skaičių, faktinis tos grupės skolininkų skaičius yra atitinkamai padidinamas arba sumažinamas.

Duomenų rinkinio išskaidymas. Iš turimų duomenų bankas turėtų sudaryti modelio kūrimo imtį ir patikimumo vertinimo imtį. Kurdamas modelį jis turėtų naudoti ne visus turimus tos paskolų rūšies skolininkų duomenis, o tik jų dalį. Kita skolininkų duomenų dalis turėtų būti paliekama kuriamo modelio patikimumui vertinti (žr. 4 lent. ir 3 priedą).

4 lentelė. Patikimumo vertinimo imties sudarymo būdai

Būdas	Paiškinimas
Kūrimo imčiai nepriskiriamų skolininkų duomenys	Iš pradinės imties atsitiktiniu būdu yra išrenkami tie skolininkai, kurių duomenys bus naudojami ne modeliui kurti, bet jo patikimumui vertinti
Kūrimo imčiai nepriskiriamo laiko duomenys	Pradinė skolininkų imtis yra padalijama į dvi dalis laiko atžvilgiu: vieno laikotarpio duomenys yra naudojami modeliui kurti, kito – jo patikimumui vertinti
Kitos rūšies paskolų duomenys	Modelis yra kuriamas naudojant vienos rūšies paskolų duomenis, o jo patikimumas yra vertinamas naudojant kitos rūšies paskolų duomenis
Kitos rūšies paskolų ir kūrimo imčiai nepriskiriamo laiko duomenys	Modelis yra kuriamas naudojant vienos rūšies ir vieno laikotarpio duomenis, o jo patikimumas yra vertinamas naudojant ne tik tos pačios rūšies, bet kito laikotarpio paskolų, bet ir kitos rūšies paskolų bei kito laikotarpio duomenis

Šaltinis: sudaryta autorės pagal Stein (2002); Lietuvos bankas (2006b); SAS (2008, 2009).

Dažniausiai kūrimo imtį sudaro 60–80 % visų turimų įrašų, o patikimumo vertinimo imtį – likę 20–40 % įrašų, įrašai tarp imčių yra paskirstomi atsitiktiniu būdu (žr. Camoes, Hill 2001; Andreeva 2006; Wu 2008). Kai yra labai mažai įrašų, patikimumo vertinimo imčiai sudaryti galima taikyti savirankos ar visrakčio metodus (žr. Krapavickaitė, Plikusas 2005).

1.1.1.7. Atmestų paraiškų įtraukimas

Banko paraiškų atmetimo lygis priklauso nuo keleto veiksnių: paskolų rūšies, tikslinės skolininkų populiacijos, banko tolerancijos rizikai, makroekonominių sąlygų, skolininkų lūkesčių. Tiek skirtingų bankų, tiek skirtingų paskolų rūšių tame pačiame banke paraiškų atmetimo lygis labai skiriasi (literatūros šaltiniuose yra minimas tiek labai žemas atmetimo lygis (2,2 %, 3 %), tiek labai aukštas (83 %), dažniausiai yra minimas 30 % atmetimo lygis) (žr. Hand, Henley 1997; Siddiqi 2006; Puri ir kt. 2011).

Bankai siekia užsitikrinti, kad teikiant paskolas taikomas statistinis vertinimo balais modelis tikėtų didžiausią riziką keliančioms paraiškoms atmesti. Tik priimtų paraiškų duomenimis pagrįstas modelis būtų nereprezentatyvus. Jei kuriant modelį nėra įtraukiamos

atmestos paraiškos, į jį gali būti įtraukiami netinkami įvesties kintamieji ar gaunami netikslūs įvesties kintamųjų koeficientai. Todėl kuriant modelius yra įprasta taikyti įvairius atmestų paraiškų įtraukimo metodus, didinančius kuriamo modelio patikimumą. Tačiau įtraukti atmestas paraiškas yra keblu, nes nėra žinoma, ar asmuo arba įmonė, kuriems paskola nebuvo suteikta, iš tikrųjų būtų tapę „blogais“ skolininkais¹³, t. y. kuriant modelį trūksta išvesties kintamojo reikšmių. Todėl kuriant modelius iškyla problema, kaip į duomenų imtį įtraukti atmestų paraiškų informaciją. Atmestų paraiškų problemą tenka spręsti tik kuriant paraiškų modelius.

Įtraukus atmestas paraiškas, faktinis „gerų“ ir „blogų“ paskolų skaičius yra padidinamas, nes kiekviena atmesta paraiška yra priskiriama prie „gerų“ arba prie „blogų“ paskolų, arba tam tikrais atvejais dalis atmestos paraiškos informacijos yra priskiriama prie „gerų“, o likusi dalis – prie „blogų“ paskolų¹⁴. Kuriant modelius gali būti įtraukiama ne tik faktiškai atmestų paraiškų informacija, bet ir informacija apie tariamas potencialių skolininkų, kurie į banką net nesikreipė, bet, banko manymu, galėtų kreiptis ateityje, paraiškas. Pavyzdžiui, bankas gali iš išorinių paskolų registru pirkti informaciją apie skolininkus, kurie į jį dėl paskolų nesikreipė, bet yra tam tikros rūšies paskolų gavę kituose bankuose (Liu 2001).

Yra įvairių atmestų paraiškų įtraukimo metodų: metodai, pagrįsti skolininkų, kurių prašymai suteikti paskolą buvo atmesti, realia elgsena, didinimas, visų atmestų paraiškų priskyrimas prie „blogų“ paskolų, ekstrapoliacija, klasterizacija ir kt. Atsižvelgiant į tai, kokios prielaidos yra daromos dėl trūkstamų išvesties kintamojo reikšmių, mokslinėje literatūroje yra išskirtos trys atmestų paraiškų įtraukimo metodų grupės (Feelders ir kt. 1998; Feelders 2000, 2001; Fogarty 2000; Chen, Astebro 2003; Smith, Elkan 2004; Anderson 2007; Kim, Sohn 2007; Banasik, Crook 2007; Bücken, Krämer 2011). Tai metodai, kai: 1) reikšmių trūksta visiškai atsitiktinai; 2) reikšmių trūksta atsitiktinai; 3) reikšmių trūksta neatsitiktinai (žr. 16 pav.).

Pirmosios grupės metodai remiasi prielaida, kad tikimybė, jog truks išvesties kintamojo reikšmių, nepriklauso nei nuo modelio įvesties kintamųjų, nei nuo išvesties kintamojo reikšmių, t. y. duomenų trūkumas yra visiškai atsitiktinis (angl. *missing completely at random* – MCAR). Šie metodai tinka, kai banko vertinimo balais modelis, kuriuo paraiškos buvo priimtose arba atmestos, taip blogai skiria paraiškas, jog galima manyti, kad jos yra atmetamos atsitiktinai. Antrosios grupės metodai remiasi prielaida, kad

¹³ Toliau šioje dalyje yra vartojama sąvoka „*bloga*“ paskola, o ne „*blogas*“ skolininkas, be to, buvo padaryta prielaida, kad vienas skolininkas pateikia paraišką tik dėl vienos paskolos.

¹⁴ Taikant tokius metodus – dvigubo atmestų paraiškų dalijimo bendrai arba pagal reitingus.

tikimybė, jog truks išvesties kintamojo reikšmių, priklauso nuo įvesties kintamųjų, bet nepriklauso nuo išvesties kintamojo reikšmių, t. y. duomenų trūkumas yra atsitiktinis (angl. *missing at random* – MAR). Tada suteiktų paskolų išvesties kintamieji negali reprezentuoti visos imties portfelio lygiu, įskaitant ir atmetas paraiškas. Tačiau atskiruose įvesties kintamųjų reikšmių intervaluose ar reitinguose suteiktų paskolų išvesties kintamieji gali reprezentuoti tiek priimtas, tiek atmetas paraiškas. Trečiosios grupės metodai remiasi prielaida, kad tikimybė, jog truks išvesties kintamojo reikšmių, priklauso tiek nuo įvesties kintamųjų, tiek nuo išvesties kintamojo reikšmių, t. y. duomenų trūkumas yra neatsitiktinis (angl. *missing not at random* – MNAR). Jeigu banko taikomas vertinimo balais modelis, kuriuo paraiškos buvo priimtos arba atmetos, pakankamai gerai skiria paraiškas, labiausiai tinka neatsitiktinių trūkstamų reikšmių metodai.

Metodai, kai reikšmių trūksta visiškai atsitiktinai	Metodai, kai reikšmių trūksta atsitiktinai	Metodai, kai reikšmių trūksta neatsitiktinai
<ul style="list-style-type: none"> - <i>Atsitiktinis papildymas</i> 	<ul style="list-style-type: none"> - <i>Didinimas (pakartotinis svorių nustatymas)</i> - <i>Mišrūs skirstiniai</i> - <i>Daugiareikšmis įrašymas</i> 	<ul style="list-style-type: none"> - <i>Išorinių duomenų įsigijimas</i> - <i>Vidinių duomenų naudojimas</i> - <i>Priskyrimas prie „blogų“ paskolų</i> - <i>Ekstrapoliacija</i> - <i>Klasterizacija</i> - <i>Dvifaktorinės išvados</i>

16 pav. Atmestų paraiškų įtraukimo metodų grupės

Šaltinis: sudaryta autorės pagal Feelders ir kt. (1998); Feelders (2000, 2001); Fogarty (2000); Chen, Astebro (2003); Smith, Elkan (2004); Anderson (2007); Kim, Sohn (2007); Banasik, Crook (2007); Bücker, Krämer (2011).

Atsitiktinis papildymas. Šis atmestų paraiškų įtraukimo metodas vienintelis leidžia sužinoti, kokia būtų tikra (o ne numanoma) skolininko, kuriam paskola nebūtų suteikiama, elgsena (Hand 1998; Siddiqi 2006; Anderson 2007). Kad tai sužinotų, bankas tam tikrą laikotarpį (pvz., tris mėn.) teikia paskolas ir tokiems skolininkams, kuriems kitu atveju jos nebūtų suteikiamos. Paskolos gali būti teikiamos:

- visiems skolininkams, neatsižvelgiant į jų vertinimo balą;
- tik pasirinktiems iš vertinamų blogesniu negu nustatytas lūžio taškas balu,

- visiems skolininkams, kurių vertinimo balas yra tik šiek tiek (iki nustatytos ribos) blogesnis už nustatytą lūžio tašką.

Taikyti atsitiktinio papildymo metodą bankui rizikinga, nes taip galima patirti didelių kredito nuostolių, susijusių su rizikingomis paskolomis. Vis dėlto XX a. paskutiniame dešimtmetyje šis metodas buvo paplitęs tarp naujai įeinančių į rinką kredito kortelės išduodančių įmonių. Siekiant sumažinti galimus patirti kredito nuostolius, skolininkams, kurių vertinimo balas yra blogesnis nei nustatytas lūžio taškas, galima teikti mažesnės apimties paskolas. Bankui būtų pravartu tokiems skolininkams teikti paskolas ilgesnį laikotarpį, tai leistų išvengti sezoninių svyravimų įtakos. Atsitiktinio papildymo metodo keliamą riziką atsveria tai, kad jis leidžia padidinti banko kuriamo modelio diskriminacinę galią, dėl to per ilgą laikotarpį gali gerokai padidėti banko pelnas.

Didinimas (pakartotinis svorių nustatymas). Kad į modelio kūrimo imtį įtraukiamos priimtoms paraiškos reprezentuotų tiek priimtas, tiek atmestas paraiškas, priimtoms paraiškoms yra suteikiami didesni svoriai. Pirmiausia yra pasirenkamas pagalbinis modelis, kuriuo kiekviena, tiek priimta, tiek atmesta, paraiška pakartotinai yra įvertinama tam tikru balu (Weldon 1999; Smith, Elkan 2004; Banasik, Crook 2004, 2005, 2007; Siddiqi 2006; Anderson 2007; Montrichard 2007). Bankas kaip pagalbinį gali rinktis išorinį vertinimo balais modelį (ar iš išorinio paskolų registro įsigytus vertinimo balus), moksliniuose straipsniuose aprašomą vertinimo balais modelį, paties susikurtą ekspertinį ar kitą statistinį vertinimo balais modelį, elgsenos ar tik priimtų paraiškų duomenimis pagrįstą statistinį vertinimo balais modelį, paraiškų priėmimo tikimybės modelį, prognozuojantį tikimybę, kad paraiška nebus atmesta. Kai šiuo pagalbiniu modeliu yra nustatomas kiekvienos paraiškos vertinimo balas, kiekvienam reitingui yra apskaičiuojamas didinimo veiksnys:

$$\text{Didinimo veiksnys} = \frac{P + A}{P},$$

čia: P – priimtų reitingo paraiškų skaičius, A – atmestų reitingo paraiškų skaičius.

Galiausiai kiekvieno reitingo priimtų „gerų“ ir „blogų“ paraiškų skaičius yra proporcingai didinamas, t. y. dauginamas iš didinimo veiksnio. Taikant šį metodą, kyla modelio rizika, nes nepatikimas pagalbinis modelis gali netiksliai paskirstyti paraiškas pagal reitingus. Todėl kuriant ar renkantis jį yra siūloma neapsiriboti tik tais rodikliais, kurie būtų galutinio modelio investicijos kintamieji, bet naudoti kuo daugiau įvairiapusiškesnės informacijos (Montrichard 2007). Taikant didinimo metodą, galutiniam modeliui kurti yra naudojami tik „pasverti“ priimtų paraiškų duomenys, todėl didinimo metodą yra rekomenduojama taikyti esant blogai atmestų paraiškų duomenų kokybei (pvz., banko

darbuotojams į banko sistemas neįvedus dalies informacijos apie atmetas paraiškas) ar tada, kai pagal pagalbinį modelį daug priimtų paraiškų yra priskiriama prie labai didelės rizikos paskolų, kurių derėjo nesuteikti (t. y. kai pagalbinio modelio įvesties kintamieji ir svoriai reikšmingai skiriasi nuo įvesties kintamųjų, naudojamų modelyje, kuriuo nusprendžiama, ar priimti paraišką) ir didelė jų dalis tapo „blogos“. Kai paraiškų atmetimo lygis yra aukštas, šis metodas netinka. Nors jis yra vienas dažniausiai taikomų atmetų paraiškų įtraukimo metodų (Banasik, Crook 2005, 2007), vis dėlto atliktų tyrimų rezultatai parodė, kad jį taikant sukurtų modelių patikimumas dažniausiai yra mažesnis už tik priimtų paraiškų duomenimis pagrįstų modelių patikimumą (žr. 5 lent.).

Mišrūs skirstiniai. Tai metodas, kurį taikant galima apskaičiuoti „gerų“ ir „blogų“ paskolų grupių dydį nežinant, kokia yra paskolų priskyrimo prie „gerų“ ar „blogų“ tikimybė konkrečiuose įvesties kintamųjų reikšmių intervaluose ar reitinguose. Šio metodo trūkumas yra tai, jog jį taikant turi būti laikomasi prielaidų dėl įvesties kintamųjų reikšmių ar reitingų skirstinių atskirai „gerų“ ir „blogų“ paskolų grupėse, t. y. iš turimos informacijos turi būti nustatomi šių skirstinių parametrai (Feelders 1996, 2000, 2001; Feelders ir kt. 1998; Hand 1998; Smith, Elkan 2004; Kiefer, Larson 2005; Mok 2009). Stebimų duomenų skirstinys yra susiejamas su mišriu skirstiniu, kuris yra apskaičiuojamas kaip „gerų“ ir „blogų“ paskolų numanomų skirstinių „svertinis vidurkis“:

$$f(x) = f(b)f(x|b) + f(g)f(x|g),$$

čia: $f(x|g)$ ir $f(x|b)$ yra atitinkamai „gerų“ ir „blogų“ paskolų skirstiniai, $f(g)$ ir $f(b)$ – atitinkamai „blogų“ ir „gerų“ paskolų imties dalys.

Šie parametrai yra apskaičiuojami optimaliai suderinant kairę ir dešinę lygties puses. Populiariausias yra didžiausio tikėtinumo metodas (Hand 1998). Kai yra skaičiuojami dešinės lygties pusės parametrai, tikimybė, kad kurio nors įvesties kintamojo reikšmių intervalo ar reitingo paraiška bus priskirta prie „gerų“, gali būti apskaičiuojama taikant Bajeso teoremą:

$$f(g|x) = \frac{f(x|g)f(g)}{f(x)}.$$

Kai nurodytos lygybės yra taikomos tik atmetoms paraiškoms, tada:

$$f(x|r) = f(b|r)f(x|b,r) + f(g|r)f(x|g,r); f(g|x,r) = \frac{f(x|g,r)f(g|r)}{f(x|r)};$$

$$f(g|x) = f(g|x,a)f(a|x) + f(g|x,r)f(r|x) = f(g|x,a)[1 - f(r|x)] + f(g|x,r)f(r|x),$$

čia a žymi įvykį, kai išvesties kintamasis yra žinomas, nes paraiška buvo priimta, r žymi įvykį, kai išvesties kintamasis yra nežinomas, nes paraiška buvo atmesta.

Daugiareikšmis įrašymas. Taikant šį metodą, modeliui kurti naudojami įrašai apie atmetas paraiškas yra dubliuojami, kiekvienai trūkstamai reikšmei modeliuojant keletą reikšmių. Taikant pagalbinį modelį, kiekviena (tiek priimta, tiek atmesta) paraiška yra įvertinama balu, tada yra sudaromi reitingai. Kiekvienam reitingui iš priimtų paraiškų yra sudaroma atsitiktinė gražintinė imtis, jos dydis turi atitikti priimtų viso portfelio paraiškų skaičių. Tuomet kiekvienam reitingui iš priimtų paraiškų sudaroma antra atsitiktinė gražintinė imtis, kurios dydis turi atitikti atmestų viso portfelio paraiškų skaičių. Taip duomenų imtis padidėja tiek kartų, tiek yra reitingų (Fogarty 2000).

Išorinių duomenų įsigijimas. Dažnai būna taip, kad asmuo ar įmonė, negavę paskolos viename banke, dėl jos kreipiasi į kitą ir ją gauna. Informaciją apie kituose bankuose gautas paskolas bankas gali pirkti iš išorinių paskolų registru. Jeigu kitų bankų suteiktos paskolos per nustatytą laikotarpį tapo „blogos“, jos yra priskiriamos prie „blogų“ ir modelį kuriančiame banke. Bankai gali taikyti skirtingą „blogos“ paskolos apibrėžimą, bet informaciją perkantis bankas išoriniam paskolų registru gali pateikti savo naudojamą apibrėžimą. Taip jis gautų informaciją apie tai, ar tam tikriems skolininkams suteiktos paskolos tapo „blogos“ pagal šį apibrėžimą. Taikyti tokį metodą yra brangu, nes bankui tenka pirkti išorinę informaciją. Be to, skolininkų elgsena ir paskolų teikimo sąlygos bankuose skiriasi, o tarp paraiškos atmetimo ir paskolos gavimo kitame banke gali susidaryti ilgas laiko tarpas. Esama tikimybės, kad jei paskolos nesuteikė vienas bankas, jos nesuteiks ir kiti, todėl duomenų imtis gali būti nepakankama (Weldon 1999; Hand 1998; Siddiqi 2006; SAS 2008, 2009; Anderson 2007; Kiefer, Larson 2005). Įsigyti informaciją iš išorinių paskolų registru gali trukdyti ir bankų priežiūros institucijų sudaromos kliūtys. Lietuvoje įsigyti tokią informaciją bankams nedraudžiama, bet Lietuvos bankas (2006a) reikalauja, kad duomenys, banko naudojami kuriant statistinį vertinimo balais modelį, reprezentuotų jo faktinius skolininkus ar paskolas. O jei bankas įsigytų išorės modelį skolininkų rizikai vertinti, tai jo neatleistų nuo minimalių reikalavimų, keliamų vidaus reitingais pagrįstam metodui, taikymo. Siekdamas atitikti šiuos reikalavimus, išorės modeliais nustatomus rezultatus bankas turi tikslinti¹⁵.

Vidinių duomenų naudojimas. Atmetas paraiškas tų skolininkų, kurie jau yra gavę paskolą tame pačiame banke, galima priskirti prie „blogų“ paskolų, jei tos kitos paskolos yra „blogos“ (Weldon 1999; Siddiqi 2006; Anderson 2007). Pavyzdžiui, jei bankas atmetė

¹⁵ Ši nuostata tinka ne tik IRB metodą taikantiems, bet ir kitiems bankams. Lietuvos banko *Vidaus kontrolės ir rizikos vertinimo (valdymo) organizavimo nuostatose* numatyta, kad, jei bankas, priskirdamas skolininkus reitingams, naudoja statistinius modelius, jie turi atitikti *Kapitalo pakankamumo skaičiavimo bendrosiose nuostatose* pateiktus tokiems modeliams keliamus reikalavimus (Lietuvos bankas 2006a, 2008).

paraišką dėl vartojimo paskolos, bet tam pačiam skolininkui anksčiau buvo suteikta kredito kortelė ir jos sąskaita per nustatytą stebėjimo laikotarpį tapo „bloga“, tai kurdamas vartojimo paskolų modelį bankas atmestą paraišką gali priskirti prie „blogų“ paskolų. Vis dėlto duomenys apie vienos rūšies paskolas ne visuomet perteikia kitos rūšies paskolų ypatumus, ypač kai paskolos yra labai skirtingų rūšių. Skirtingos fizinių asmenų paskolų grupės paprastai pasižymi skirtinga rizika. Be to, gali gerokai skirtis paskolų suteikimo datos (tada bankas turėtų nustatyti maksimalų laiko intervalą), nemažai skolininkų kitų paskolų tame pačiame banke gali neturėti.

Visų atmestų paraiškų priskyrimas prie „blogų“ paskolų. Toks metodas, kai visos atmestos paraiškos yra priskiriamos prie „blogų“, yra kritikuojamas. Kai paraiškų atmetimo lygis yra labai žemas, galima daryti prielaidą, kad visos atmestos paraiškos būtų tapusios „blogos“. Tačiau kai atmetimo lygis nėra labai žemas (t. y. viršija 3 %), remiantis išorinių paskolų registrų informacija ir per daugelį metų bankų atliktais atsitiktinių reitingų peržiūrėjimų tyrimais galima teigti, kad tam tikra dalis atmestų paraiškų būtų tapusios „geros“ (Hand 1998; Siddiqi 2006). Taigi, šį metodą tiktų taikyti tik tuo atveju, kai paraiškų atmetimo lygis banke yra labai žemas, pavyzdžiui, yra atmetami 3 % visų paraiškų.

Ekstrapoliacija. Tai, kaip ir didinimas, yra vienas dažniausiai taikomų atmestų paraiškų įtraukimo metodų. Jo yra keli variantai: perklasifikavimas, atsitiktinis, poliarizuotas arba dvigubas visų atmestų paraiškų dalijimas bendrai arba reitinguose, žingsninis perklasifikavimas (Weldon 1999; Ash, Meester 2002; Banasik, Crook 2004; SAS 2008, 2009; Siddiqi 2006; Anderson 2007; Montrichard 2007; Anderson ir kt. 2009). Dažniausiai, kaip ir taikant didinimą, pirmiausia pagalbinio modeliu yra pakartotinai nustatomas kiekvienos paraiškos vertinimo balas. Tačiau skirtumas nuo didinimo yra tas, kad į naujo modelio kūrimo imtį yra įtraukiama ir atmestų paraiškų informacija, prieš tai joms hipotetiškai priskyrus trūkstamų išvesties kintamųjų reikšmes. Įvairių autorių atliktų tyrimų rezultatai parodė, kad modeliai, sukurti pasitelkiant ekstrapoliacijos metodą, dažniausiai yra patikimesni už tik priimtų paraiškų duomenimis pagrįstus modelius (žr. 5 lent.). Esminis aspektas taikant šį metodą yra atmestų paraiškų, kurias derėtų priskirti prie „blogų“ paskolų, skaičius, kuriam nustatyti gali būti taikomi keli metodai. Vienas jų – ekspertinis metodas, kai tokį skaičių nustato banko ekspertai. Kitas – naudoti suteiktų „blogų“ paskolų dalies ir atmestų paraiškų skaičiaus sandaugą. Vis dėlto šis būdas yra kritikuojamas, nes paskolas gavusių skolininkų ir tų, kurių paraiškos buvo atmestos, elgsena gali ir skirtis. Todėl atmestoms paraiškoms geriau taikyti didesnę „blogų“ paskolų dalį nei suteiktoms paskoloms.

Atmestų paraiškų, kurias derėtų priskirti prie „blogų“ paskolų, skaičių galima nustatyti ir pagal šią formulę (Anderson 2007):

$$B_A = A \cdot \frac{1}{1 + \frac{G_S / B_S}{MK}},$$

čia: A – atmestų paraiškų skaičius; G_S – suteiktų „gerų“ paskolų skaičius; B_S – suteiktų „blogų“ paskolų skaičius; MK – mažinimo koeficientas, t. y. banko ekspertų pasirenkamas santykis tarp kitų dviejų santykių (tarp suteiktų „gerų“ ir „blogų“ paskolų skaičiaus santykio ir tarp atmestų paraiškų, priskiriamų prie „gerų“ paskolų, ir atmestų paraiškų, priskiriamų prie „blogų“, skaičiaus santykio). Dažniausiai šis santykis yra nustatomas tarp 1,5 ir 4, konservatyvumo tikslu paprastai yra pasirenkama didesnė reikšmė.

Atmestų paraiškų, priskiriamų prie „blogų“ paskolų, skaičius gali būti nustatomas visoms atmestoms paraiškoms kartu arba kiekvienam reitingui atskirai.

Klasterizacija (k artimiausių kaimynų metodas). Iš priimtų paraiškų yra sudaromi du klasteriai – vienas iš paskolų, priskirtų prie „gerų“, kitas – iš paskolų, priskirtų prie „blogų“. Tada yra analizuojami atmestų paraiškų rodikliai ir apskaičiuojami Euklido atstumai (Siddiqi 2006; SAS 2008, 2009; Anderson ir kt. 2010). Pavyzdžiui, jeigu iš dešimties į atmetą paraišką panašių priimtų paraiškų, vadinamųjų artimiausių kaimynų, septynios yra „geros“ ir trys – „blogos“, tokiai paraiškai yra priskiriama 30 % PD. Ši PD toliau gali būti naudojama kaip vertinimo balas taikant vieną iš ekstrapoliacijos metodų.

Dvifaktorinės išvados. Ekstrapoliacijos ir didinimo metodai gali būti taikomi kartu, t. y. kartu gali būti apskaičiuojama ir paraiškų priėmimo tikimybė, ir vertinimo balas ar PD (Feelders 2001; Ash, Meester 2002; Jacobson, Roszbach 2003; Chen, Astebro 2003, 2006; Banasik, Crook 2003, 2007; Smith, Elkan 2004; Kim, Sohn 2007; Anderson 2007; Mok 2009; Bücker, Krämer 2011). Prie šios metodų grupės yra priskiriamas Ash ir Meester (2002) taikytas ekstrapoliacijos metodas, Bajeso ir tikėtinumo metodai, Heckmano dvifaktorinis dviejų etapų metodas. Pastarasis įvairių autorių tyrimuose yra nagrinėjamas dažniausiai (žr. 5 lent.). Jį taikant yra daroma prielaida, kad atmestų ir priimtų paraiškų savybių skirstiniai skiriasi, todėl yra kuriamas dviejų lygčių modelis: viena lygtis yra sudaroma paraiškų priėmimo tikimybei, antra – PD apskaičiuoti.

Neretai yra siūloma taikyti ir mišrius metodus: kartu didinimą ir perklasifikavimą, didinimą ir atsitiktinį papildymą ir kt. (Weldon 1999; Parnitzke 2005; Montrichard 2007). Kai atmestų paraiškų skaičius yra nedidelis, gali būti taikomas ekspertinis metodas (Montrichard 2007). Ekspertas, naudodamasis praeities duomenimis, savo nuožiūra pasirenka vertinimo kriterijus ir atsitiktinai priskiria atmetas paraiškas „gerų“ ir „blogų“ paskolų grupėms.

Pavyzdžiui, praėjusiais metais iš paskolų, suteiktų tokioms įmonėms, kurių turto pelningumo rodiklis buvo mažesnis nei 3 %, net 50 % tapo „blogos“, likusios – „geros“. Ekspertas iš atmetų paraiškų atranka pateiktas tokių įmonių, kurių turto pelningumo rodiklis yra mažesnis nei 3 %, iš jų atsitiktinai išrenka 50 % paraiškų ir jas priskiria prie „blogų“ paskolų, likusius 50 % paraiškų – prie „gerų“. Likusioms atmetoms paraiškoms galima taikyti mažesnę „blogų“ paskolų dalį, sakysime, 30 %, ir jas taip pat atsitiktinai paskirstyti.

5 lentelė. Modelių patikimumo* tyrimai

Metodas	Autorius	Tyrimo rezultatai
Didinimas	Banasik, Crook (2004, 2005, 2007, 2010)	Modeliai buvo mažiau patikimi už tik priimtų paraiškų duomenimis pagrįstus modelius. Kai didinimo metodas buvo taikytas kuriant išlikimo analizės modelius, rezultatai irgi buvo blogesni
	Parnitzke (2005)	Modeliai buvo mažiau patikimi arba tik šiek tiek patikimesni už tik priimtų paraiškų duomenimis pagrįstus modelius
	Chen, Astebro (2006)	Modeliai buvo mažiau patikimi už tik priimtų paraiškų duomenimis pagrįstus modelius
	Montrichard (2007)	Nepatikimi modeliai
Mišrūs skirstiniai	Feelders ir kt. (1998)	Modeliai buvo šiek tiek patikimesni už tik priimtų paraiškų duomenimis pagrįstus modelius
Daugiareikšmis įrašymas	Fogarty (2000)	Modeliai buvo patikimesni už modelius, sukurtus taikant įprastus trūkstantų verčių nustatymo metodus
Išorinių duomenų įsigijimas	Ash, Meester (2002)	Modeliai buvo patikimesni už tik priimtų paraiškų duomenimis pagrįstus modelius
Ekstrapoliacija:		
<i>poliarizuotas dalijimas bendrai</i>	Banasik, Crook (2004)	Modeliai tik kai kuriais atvejais buvo šiek tiek patikimesni už tik priimtų paraiškų duomenimis pagrįstus modelius
	Anderson ir kt. (2009)	Tinkamiausias ekstrapoliacijos metodas – atsitiktinis dalijimas reitinguose
<i>atsitiktinis dalijimas reitinguose</i>	Parnitzke (2005)	Modeliai buvo patikimesni už tik priimtų paraiškų duomenimis pagrįstus modelius
Klasterizacija	Anderson ir kt. (2010)	Modeliai buvo patikimesni už modelius, sukurtus taikant atsitiktinį ir dvigubą dalijimą reitinguose, bet tik tada, kai artimiausių kaimynų skaičius k buvo didelis (atitinkamai ne mažiau kaip 15 ir 10)
Bajeso metodas	Chen, Astebro (2003)	Modeliai buvo patikimesni už modelius, sukurtus taikant Heckmano dvifaktorių dviejų etapų metodą ar naudojant tik priimtų paraiškų duomenis
Didžiausio tikėtimumo metodas	Chen, Astebro (2006)	Modelis buvo patikimesnis už modelius, sukurtus taikant didinimą, Heckmano dvifaktorių dviejų etapų metodą ar naudojant tik priimtų paraiškų duomenis
Empirinio tikėtimumo metodas	Bücker, Krämer (2011)	Modelis buvo patikimesnis už tik priimtų paraiškų duomenimis pagrįstus modelius
Heckmano dvifaktorių dviejų etapų metodas	Banasik, Crook (2003, 2007)	Modeliai tik kai kuriais atvejais buvo šiek tiek patikimesni už tik priimtų paraiškų duomenimis pagrįstus modelius, be to, patikimumą lėmė naudoti įvesties kintamieji
	Chen, Astebro (2003, 2006)	Modeliai buvo mažiau patikimi už tik priimtų paraiškų duomenimis pagrįstus modelius
	Kim, Sohn (2007)	Modelis buvo patikimesnis už tik priimtų paraiškų duomenimis pagrįstą modelį

*Šaltinis: sudaryta autorės. *Modelių patikimumui vertinti autoriai naudojo kaupiamojo tikslumo (toliau – CAP) ir gavėjų veiklos charakteristikų (toliau – ROC) kreives arba teisingo klasifikavimo analizę.

3.3.3 dalyje yra praktiškai pritaikyti šie metodai: didinimas, visų atmestų paraiškų priskyrimas prie „blogų“ paskolų, septynios ekstrapoliacijos metodo modifikacijos.

1.1.1.8. Įvesties kintamųjų analizė ir koeficientų apskaičiavimas

Kuriant modelį fizinių asmenų rizikai vertinti, dažniausiai yra įtraukiama informacija apie skolininko pajėgumą įvykdyti įsipareigojimus bankui (jo pajamas, išlaidas, finansinius įsipareigojimus), skolininko turtą (taupymo produktus, sąskaitas banke ir t. t.), skolininko stabilumą ir patikimumą (amžių, išsilavinimą, pareigas, šeiminę padėtį, darbo trukmę dabartinėje darbovietėje), išorinę ir vidinę skolininko mokėjimų istoriją, ar skolininkas turi nuosavą būstą, ar jį nuomoja, makroekonominės sąlygas ir (arba) kitas aplinkybes, galinčias turėti įtakos paskolos grąžinimui (žr. 1 priedą).

Ankstesni statistiniai įmonių vertinimo balais modeliai dažniausiai buvo kuriami naudojant tik finansinius rodiklius (pvz, *Altman, Lis, Tafler, Springate*), kita informacija apie įmonę bankuose buvo vertinama individualiai. Tačiau vėlesniuose modeliuose statistiškai buvo įtraukiami ir kiti rodikliai (pvz, gyvavimo laikas), o pastaruoju metu kuriant statistinius įmonių vertinimo balais modelius yra naudojami visapusišką informaciją apie įmonę atskleidžiantys rodikliai: finansiniai rodikliai, gyvavimo laikas, informacija apie išorinę ir vidinę mokėjimų istoriją, jos padėtį rinkoje (užimamą rinkos dalį, konkurentus, tiekėjus, klientus ir pan.), nuosavo kapitalo struktūrą ir valdymą (akcininkus, vadovus, organizacinę struktūrą), apskaitos kokybę, ekonominės veiklos rūšies perspektyvas, taip pat makroekonominiai ir kiti rodikliai. 6 lentelėje yra pateikti dažniausiai į vertinimo balais modelius įtraukiami rodikliai, išrikiuoti pagal dažnumą.

Pagal tai, kaip atsižvelgiama į makroekonominės sąlygas, vertinimo balais modeliai yra skirstomi į laiko momento ir ekonominio ciklo modelius (Löffler 2004; BCBS 2005a; Bank of Japan 2005). Kuriant laiko momento modelius, yra įtraukiami makroekonominiai ir (arba) kiti ekonominiam ciklui jautrūs rodikliai, taigi pablogėjus makroekonominėms sąlygoms skolininkų rizika *ceteris paribus* padidėja. O štai ekonominio ciklo modeliu nustatomas skolininko vertinimo balas keičiantis ekonominiam ciklui nesikeičia. Bankams yra rekomenduojama kurti tiek vienus, tiek kitus modelius: ekonominio ciklo modelius – ilgalaikėms paskoloms vertinti, banko veiklos strategijai kurti ar kitais tikslais, laiko momento modelius – trumpalaikėms paskoloms vertinti ir pan. Dažniausiai modeliams naudojami makroekonominiai rodikliai yra realiojo bendrojo vidaus produkto pokytis, nedarbo lygis, palūkanų normos, nekilnojamojo turto kainų indeksas (Bunn, Redwood 2003; Dionne ir kt. 2006; Malik, Thomas 2006; Castro 2008; Bonfim 2009). Lietuvos bankai,

6 lentelė. Dažniausiai i modelius įtraukiami rodikliai

Fizinių asmenų modelių rodikliai	Komentarai	Įmonių modelių rodikliai	Komentarai
Skolininko amžius	Vyresni skolininkai yra patikimesni ir stabilesni: turi daugiau patirties, gali uždirbti daugiau pinigų, yra įgiję išsilavinimą, tikėtina, jau turi nuosavą būstą, yra mažesnė emigravimo rizika, vaikai jau būna užaugę ir t. t. Tačiau pensinio amžiaus skolininkų įsipareigojimų nevykdymo rizika yra didelė, ypač kai didelė paskolos suma, ilgas gražinimo terminas	Grynasis pelnas (nuostoliai) / turtas	Kuo didesnė rodiklio reikšmė, tuo mažesnė įsipareigojimų nevykdymo rizika
Duomenys apie gyvenamąją vietą (ar skolininkas turi nuosavą būstą, ar ji nuomoja ir pan.)	Kai skolininkas turi nuosavą būstą, jis yra patikimesnis: nereikia mokėti nuomos, prirėkus gali pats išnuomoti būstą arba jį parduoti ir gauti papildomų pajamų, be to, nuosavas būstas gali būti užtikrinimo priemonė	Pardavimo pajamos / turtas	Kuo didesnė rodiklio reikšmė, tuo didesnė įsipareigojimų nevykdymo rizika
Stažas dabartinėje darbovietėje	Kuo ilgesnis stažas, tuo skolininkas patikimesnis ir stabilesnis: mažesnė atleidimo iš darbo tikimybė, didesnė atlyginimo padidinimo ar paaugstinimo tikimybė, tikėtina, jog skolininkas yra geras ir kvalifikuotas darbuotojas	Įsipareigojimai / turtas	Kuo didesnė rodiklio reikšmė, tuo didesnė įsipareigojimų nevykdymo rizika
Gyvenimo dabartiniu adresu laikas	Kuo ilgiau skolininkas gyvena vienoje vietoje, tuo jis patikimesnis ir stabilesnis	Trumpalaikis turtas / trumpalaikiai įsipareigojimai	Normalu, kai šis rodiklis yra 1,2-2. Jeigu šis rodiklis yra mažesnis nei vienas, gali kilti mokumo problemų, o jei didesnis nei du – gali paaiškėti, kad turtas yra naudojamas neracionaliai, t. y. jo yra laikoma per daug, tai mažina veiklos efektyvumą
Kita su skolininko darbu susijusi informacija (vadovas, savarankiškai dirbantis asmuo, specialistas, pensininkas, studentas ir t. t.)	Vadovai gauna didesnes pajamas ir retai būna atleidžiami iš darbo. Savarankiškai dirbantys asmenys negali būti atleisti iš darbo. Specialistai gali netekti darbo arba jų atlyginimas gali būti sumažintas, bet yra didelė tikimybė vėl greitai susirasti naują darbą arba gauti didesnį atlyginimą. Pensininkų pajamos, nors ir mažos, bet yra garantuotos, todėl įsipareigojimų nevykdymo rizika priklauso nuo paskolos sumos ir termino. Nedirbantys studentai dažniausiai gauna labai nedideles pajamas, bet yra didelė tikimybė, kad ateityje uždirbs gerokai daugiau.	Apyvartinis kapitalas / trumpalaikis turtas	Kuo didesnė rodiklio reikšmė, tuo didesnė trumpalaikio turto dalis yra finansuojama ilgalaikių finansavimo šaltinių. Nuosakiai valdant finansus, ilgalaikių finansavimo šaltinių turėtų būti finansuojamas visas nuolat reikalingas trumpalaikis turtas, o trumpalaikių finansavimo šaltinių – tik tie trumpalaikio turto poreikiai, kurie būtini sezoninio ar vienkartinio pobūdžio pardavimo pajamoms uždirbti
Šeiminei padėtis	Vėdęs skolininkas yra laikomas subrendusiu, stabiliu, atsakingu žmogumi, todėl jis yra patikimesnis skolininkas	Nepaskirstytasis pelnas (nuostoliai) / turtas	
Vaikų turėjimo faktas	Jei skolininkas turi vaikų, tai rodo, kad jis yra subrendęs, stabilus, atsakingas žmogus	Pelnas (nuostoliai) prieš patikamas ir mokesčius / turtas	
Skolininko šeimos pajamos	Kuo didesnės vidutinės grynosios šeimos pajamos vienam šeimos nariui per mėnesį, tuo mažesnė įsipareigojimų nevykdymo rizika	Pelnas (nuostoliai) prieš apmokėstimą / palūkanų išlaidas	Kuo didesnė rodiklio reikšmė, tuo mažesnė įsipareigojimų nevykdymo rizika
Išlaidyčių skaičius	Kuo daugiau finansškai priklausomų išlaidyčių, tuo didesnė įsipareigojimų nevykdymo rizika	Grynasis pelnas (nuostoliai) / nuosavas kapitalas	

Buvimo banko klientu laikas	Rodiklis rodo skolinniko lojalumą skolinničiam bankui, kuo šis laikas ilgesnis, tuo skolinnikas patikimesnis	Pardavimo pajamų didėjimo tempas	Pemelyg didelis pardavimo pajamų didėjimo tempas gali būti rizikingas. Geriausia yra stabilus vidutinis didėjimo tempas
Kiek laiko informacija apie skolinniko paskolas yra išorinio paskolų registro duomenų bazėje	Kuo ilgesnė skolinniko kreditavimo istorija, tuo daugiau informacijos apie jį galima gauti	Gyvavimo laikas	Ilgiau gyvuojančios imonės turi daugiau patirties (pvz., yra išobitunusios savo taikomas technologijas, jai turi savo nuolatinį klientų, išmokusios kovoti su konkurentais ir pan.), todėl jų išpareigojimų nevykdymo rizika yra ne tokia didelė kaip trumpiau gyvuojančių imonių. Tačiau labai trumpai gyvuojančios imonės gali būti dar tik pradėjusios vykdyti atitinkamus projektus, naudojasi pradinėmis lėšomis veiklai finansuoti ir pan.
Skolinniko kredito sąskaitų skaičius	Jeigu skolinnikas turi daug kredito sąskaitų, yra didesnė tikimybė, kad kils sunkumų vykdant išpareigojimus bankui. Tačiau jei kredito sąskaitų visai nėra, neįmanoma gauti informacijos apie tai, kaip skolinnikas mokėjo įmokas	Darbuotojų skaičius	Darbuotojų skaičius rodo imonės dydį ir veiklos pobūdį. Stambesnės imonės yra strategiškai svarbesnės, gali pasiekti masto ekonomiją ir pan., todėl jų išpareigojimų nevykdymo rizika yra ne tokia didelė kaip smulkių imonių. Tačiau labai smulkios imonės yra lankstesnės, kils sunkumų gali lengviau pakeisti veiklos sritį ir pan.
Vidutinis atnaujinamųjų paskolų panaudojimas per 12 ar 6 mėnesius	Jeigu skolinnikas turi atnaujinamąją paskolą, bet ja visai nesinaudoja, tai reiškia, kad jis nemoka tvarkyti savo finansinių reikalų. Tačiau jeigu panaudojimas yra labai didelis ir vis didėja, tai greičiausiai skolinnikas turi finansinių sunkumų	Ekonominės veiklos rūšis	Skirtingų ekonominės veiklos rūšių imonės pasižymi skirtinga išpareigojimų nevykdymo rizika, nes skiriasi veiklos pobūdis (gamyba, prekyba ir pan.), rinka, konkurencija, veiklos cikliškumas ir (ar) sezoniškumas, darbo sąlygos, vyriausybės dėmesys, teisinė aplinka ir įstatymų reikalavimai, plėtos tolydumas ir stabilumas ir t. t.
Užklausu apie skolinniką skaičius per paskutinius 12 mėnesių	Kuo daugiau išoriniam paskolų registrui pateikta neįgijamo pobūdžio užklausu apie skolinniką, tuo didesnė jo išpareigojimų nevykdymo rizika	Geografinis regionas	Skiriasi įvairių regionų ekonominis ir socialinis išsivystymo lygis, yra plėtojamos skirtingos ekonominės veiklos rūšys. Be to, Lietuvoje darbo paklausos struktūra teritoriniu atžvilgiu dažnai neatitinka darbo pasiūlos struktūros, kai kuriuose regionuose tai pasireiškia stipriau, todėl imonėms gali būti sunku susirasti pageidaujamos kvalifikacijos ir kompetencijos darbuotojų
Iš išorinių paskolų registru gauta informacija apie bent vieną mokėjimo termino pradelimą per paskutinius 12 mėnesių	Jei skolinnikas nė karto nė vienai finansų įstaiagai nepavėlavo sumokėti įmokos, tai rodo, kad jis yra patikimas ir moka gerai planuoti savo pinigų srautus	Turtas (logaritminė transformacija)	Kuo didesnė rodiklio reikšmė, tuo mažesnė išpareigojimų nevykdymo rizika
Skolinniko paskolų, pradelstų 30 dienų ar ilgiau, skaičius (informacija iš išorinių paskolų registru)	Kuo daugiau buvo taip ilgai pradelstų įmokų, tuo didesnė skolinniko išpareigojimų nevykdymo rizika.	Pardavimo pajamos (logaritminė transformacija)	

Šaltinis: sudaryta autorės pagal Shumway (1999); Altman (2000); Stepanova, Thomas (2001, 2002); Bunn, Redwood (2003); Grigaravičius (2003); McNab, Wynn (2003); Aragon (2004); Lykke (2004); Fernandes (2005); Siddiqi (2006); Dionne ir kt. (2006); Malik, Thomas (2006); Mircea (2007); Castro (2008); Ciampi, Gordini (2008); Luppi ir kt. (2008); Marquez (2008); Bonfim (2009); Psillaki ir kt. (2009); Kocenda, Vojtek (2009); Chung-Hua Shen ir kt. (2010); Horckko (2010).

kurdami laiko momento modelius, galėtų įtraukti Lietuvos ekonominį ciklą ir (arba) Lietuvos valstybės kredito reitingą lemiančius rodiklius: valstybės biudžeto balanso ir bendrojo vidaus produkto santykį, einamosios sąskaitos balanso ir bendrojo vidaus produkto santykį, grynojo užsienio turto pokytį per ketvirtį, trumpalaikę išorinę skolą ir kt. (žr. Pačebutaitė 2011; Proškutė 2012). Tačiau ekonominiam ciklui jautrūs gali būti ne tik makroekonominiai, bet ir kiti rodikliai: skolininko pajamos, mokėjimų istorija, atnaujinamųjų paskolų panaudojimas vertinimo dieną arba per trumpą laikotarpį iki vertinimo dienos.

Kad modelis įgytų ekonominio ciklo modelio bruožų, reikia arba visai neištraukti ekonominiam ciklui jautrių įvesties kintamųjų, arba tokius kintamuosius pakoreguoti (tačiau tada turėtų būti įtraukiami ilgesnio laikotarpio duomenys¹⁶).

Dažnai kredito rizikai įvertinti svarbiausi yra vidinės mokėjimų istorijos rodikliai (žr. 4 priedą). Skolininkas, kuris kreipiasi į banką paskolos pirmą kartą, *ceteris paribus* turėtų būti vertinamas ne taip palankiai, kaip tas skolininkas, kuris jau yra gavęs paskolų šiame banke ir visada laiku mokėjo įmokas. Vidinės mokėjimų istorijos rodiklius bankai galėtų modeliuoti atskirai, o tokio modeliavimo rezultatas galėtų būti naudojamas kaip atskiras pagrindinio modelio įvesties kintamasis. Atskirai modeliuoti vidinės mokėjimų istorijos rodiklius galėtų ir ekspertinius modelius taikantys bankai. Tada tokio modeliavimo rezultatas galėtų būti naudojamas kaip atskiras ekspertinio modelio įvesties kintamasis, kuriam yra ekspertiškai nustatomas konkretus svoris. Tačiau tada bankui tektų vertinti papildomo modelio patikimumą: šis modelis turėtų būti vertinamas tiek analizuojant ekspertinio modelio įvesties kintamuosius, tiek kaip atskiras modelis.

Pasirenkant įvesties kintamuosius reikia vengti tam tikrų skolininkų grupių diskriminacijos, kai kuriose šalyse tai draudžia teisės aktai (OCC 1997; Fortowsky, LaCour-Little 2001; Avery 2010). Yra trys diskriminacijos rūšys:

- *atvira diskriminacija*: kai bankas suteikia *ceteris paribus* blogesnę vertinimo balą tam tikros rasės, tautybės, lyties ir t. t. skolininkams;
- *skirtingas vertinimas*: kai informacija apie skolininką yra subjektyviai iškraipoma prieš įvedant to konkretaus skolininko įvesties kintamuosius į modelį arba pagal modelį nustatytas tam tikra savybe pasižyminčio skolininko reitingas yra peržiūrimas, nors to pagal banko kreditavimo politiką neturėtų būti;

¹⁶ Piniginių kreditinių veiksnių ciklai trunka mažiausiai septynerius metus (Paliulytė 2004). Kuriant ekonominio ciklo modelį reikėtų turėti bent dviejų ciklų duomenis. Taigi, reikėtų sukaupti bent 14 metų ekonominiam ciklui jautrių įvesties kintamųjų reikšmių dinamikos eilutes ir atimti periodiškai kintančias cikliškumo (ir sezoniškumo, jei duomenys ketvirtiniai) dedamąsias, paliekant tik tendą ir atsitiktinius nuokrypius.

- *skirtinga įtaka*: banko kreditavimo praktika yra visiems vienoda, bet tam tikra savybe pasižyminčių skolininkų paraiškų atmetimo lygiui, palūkanų normoms ir pan. banko kreditavimo praktikos įtaka yra pernelyg neigiama.

Pasirinkus tinkamus pradinius įvesties kintamuosius, jie yra toliau analizuojami. Iš pradžių turėtų būti atliekama trūkstumų reikšmių analizė. Jei banko ekspertai nustato, kad vieno įvesties kintamojo trūkstumų reikšmių dalis yra reikšminga, tas įvesties kintamasis iš tolesnės analizės turėtų būti pašalinamas. Jei trūksta reikšmingos vieno skolininko įvesties kintamųjų reikšmių dalies, iš tolesnės analizės turėtų būti pašalinamas toks skolininkas; kitais atvejais trūkstama reikšmė gali būti pakeičiama aritmetiniu visų to įvesties kintamojo reikšmių vidurkiu, mediana (tinka tik kiekybiniais įvesties kintamiesiems) arba moda (tinka ir kokybiniais įvesties kintamiesiems). Taip pat gali būti sudaroma atskira konkretaus įvesties kintamojo trūkstumų reikšmių grupė. Atlikus trūkstumų reikšmių analizę, iš likusių pradinių įvesties kintamųjų yra sudaroma daug galutinių įvesties kintamųjų, apimančių įvairias su skolininko kreditingumu susijusias sritis. Tada turėtų būti atliekama kiekybinių įvesties kintamųjų išskirčių analizė (Thomas ir kt. 2002; McNab, Wynn 2003; Mays 2004; ONB 2004; Leung ir kt. 2008; SAS 2008, 2009).

Tiesiogiai į modelį yra įtraukiami ne visi skolininką apibūdinantys galutiniai įvesties kintamieji, be to, galutiniai įvesties kintamieji gali būti tarpusavyje susiję. Ypač svarbu yra įvertinti individualią įvesties kintamųjų diskriminacinę galią, skaičiuojant atskiro įvesties kintamojo tikslumo santykį, plotą po ROC kreive¹⁷, informacijos vertę ar kitus rodiklius (žr. Fernandez 2005; Pranckevičiūtė 2007; Dzidzevičiūtė 2010b; Kocenda, Vojtek 2011). Taip pat gali būti lyginami atskirai „gerų“ ir „blogų“ skolininkų konkretaus įvesties kintamojo vidurkiai, pavyzdžiui, atliekant vienfaktorę dispersinę analizę (ANOVA) (žr. Mileris, Boguslauskas 2010). Įvesties kintamieji, kurių reikšmių vidurkiai „gerų“ ir „blogų“ skolininkų grupėse statistiškai reikšmingai nesiskiria, tolesnei analizei neturėtų būti naudojami.

Kai įvesties kintamieji yra kiekybiniai, bankas turi kelias galimybes: naudoti pradines nepakeistas reikšmes, suskirstyti reikšmes į intervalus ir kiekvienam intervalui nustatyti atitinkamą pseudokintamąjį, naudoti standartizuotas reikšmes ar taikyti kelis būdus vienu metu. Skirstymas į intervalus gali būti kelių rūšių: ekspertinis, kai banko ekspertai nustato tam tikro įvesties kintamojo, tarkime, skolininko amžiaus reikšmių intervalus remdamiesi atitinkamų amžiaus grupių skolininkų mokumo istorine analize; statistinis (gali būti taikoma

¹⁷ Tikslumo santykio ir ploto po ROC kreive rodikliai yra retai taikomi individualiai įvesties kintamųjų diskriminacinei galiai vertinti, nes tinka tik kiekybiniais įvesties kintamiesiems, pavyzdžiui, finansiniams rodikliams. Fernandez (2005) siūlo atrinkti tuos finansinius rodiklius, kurių AR yra didesnis nei 5 % (atitinkamai AUC – didesnis nei 52,5 %).

klasterinė analizė); mišrus, kai ekspertiškai nustatyti reikšmių intervalai yra tikrinami taikant χ^2 suderinamumo kriterijų ar informacijos vertės metodą.

Kai įvesties kintamieji yra kokybiniai, bankas kiekvienai reikšmei turi nustatyti atitinkamą pseudokintamąjį, tačiau jis gali iš kelių reikšmių sudaryti vieną grupę ir pseudokintamuosius nustatyti jau sudaręs tą grupę. Taip grupuojant gali būti taikomi ekspertinis ir mišrus metodai (pvz., taikant χ^2 suderinamumo kriterijų ar informacijos vertės metodą).

Taikant χ^2 suderinamumo kriterijų, yra pasirenkamas toks įvesties kintamojo reikšmių grupavimas, kurį taikant χ^2 reikšmė yra didžiausia¹⁸. χ^2 reikšmė yra apskaičiuojama pagal šią formulę (Thomas ir kt. 2002; SAS 2008, 2009):

$$\chi^2 = \sum_{i=1}^n \left(\frac{(G_i - TG_i)^2}{TG_i} + \frac{(B_i - TB_i)^2}{TB_i} \right),$$

čia: G_i – faktinis „gerų“ i grupės skolininkų skaičius; TG_i – tikėtinas „gerų“ i grupės skolininkų skaičius, lygus $(G_i + B_i) \cdot GR$, čia GR yra faktinių „gerų“ viso paskolų portfelio skolininkų dažnis ir B_i – faktinis „blogų“ i grupės skolininkų skaičius; TB_i – tikėtinas „blogų“ i grupės skolininkų skaičius, lygus $(G_i + B_i) \cdot BR$, čia BR yra faktinių „blogų“ viso paskolų portfelio skolininkų dažnis; i kinta nuo 1 iki n ; n – grupių skaičius.

Taikant informacijos vertės metodą, yra pasirenkamas toks įvesties kintamojo reikšmių grupavimas, kurį taikant informacijos vertė yra didžiausia (BCBS 2005a; Fritz ir kt. 2006; SAS 2008, 2009):

$$IV = \sum_{i=1}^n (G_i - B_i) \cdot WOE_i; \quad WOE_i = \ln\left(\frac{G_i}{B_i}\right),$$

čia: IV – informacijos vertė; WOE_i – i grupės įtakos svoris; G_i – faktinių „gerų“ i grupės skolininkų dalis, palyginti su visais faktiniais „gerais“ skolininkais; B_i – faktinių „blogų“ i grupės skolininkų dalis, palyginti su visais faktiniais „blogais“ skolininkais; i kinta nuo 1 iki n ; n – grupių skaičius.

Informacijos vertės metodas gali būti taikomas tiek atrenkant įvesties kintamuosius, tiek lyginant įvairius įvesties kintamųjų reikšmių grupavimo variantus. Kuo didesnė informacijos vertė, tuo didesnė įvesties kintamojo diskriminacinė galia. Interpretuojant informacijos vertės reikšmes, gali būti naudojami tokie paaiškinimai (SAS 2008, 2009): $< 0,02$ – neprediktyvus įvesties kintamasis; $[0,02-0,1)$ – maža įvesties kintamojo diskriminacinė galia; $[0,1-0,3]$ – vidutinė įvesties kintamojo diskriminacinė galia; $> 0,3$ – didelė įvesties kintamojo diskriminacinė galia.

¹⁸ χ^2 reikšmės gali būti lyginamos tarpusavyje tik esant vienodam grupių skaičiui. Kai grupių skaičius skiriasi, yra lyginama statistikos p reikšmė su $k - 1$ laisvės laipsniais ir pasirenkamas tas atvejis, kai p reikšmė yra mažiausia.

Grupuoiant įvesties kintamųjų reikšmes, reikėtų atsižvelgti ir į *ekonominių pagrįstumą* (pvz., jeigu įmonės pelningumui didėjant faktinių „blogų“ grupės skolininkų dažnis didėja, toks įvesties kintamasis neturėtų būti naudojamas tolesnei analizei, nes pelningumui didėjant rizika turėtų mažėti), *monotoniškumą* (kiekybinio įvesties kintamojo reikšmei didėjant rizika turi nuosekliai didėti arba mažėti, bent jau iki tam tikro lygio, pavyzdžiui, gali būti U formos skirstinys); *grupę sudarančių skolininkų skaičių* (jei jis per mažas, grupę geriau prijungti prie kitos).

Kodavimo pseudokintamaisiais būdai gali būti įvairūs (Hand, Henley 1997; Čekanavičius, Murauskas 2004; Leung ir kt. 2008; SAS 2008, 2009). Nors labai populiarus yra kodavimas dvireikšmiais pseudokintamaisiais, sparčiai populiarėja ir įtakos svorių metodas, kurio pranašumas yra tai, kad pseudokintamojo reikšmė rodo tos įvesties kintamojo reikšmių grupės rizikingumo laipsnį. Kuo didesnė įtakos svorio reikšmė, tuo mažesne laikoma skolininkų grupės rizika.

Kuriant logistinės regresijos modelį SPSS programa, vartotojui yra pasiūlomi keli įvesties kintamųjų atrankos metodai (Pukėnas 2005, 2009):

- progresinė atranka (angl. *forward stepwise*): į modelį yra laipsniškai įtraukiami įvesties kintamieji, su išvesties kintamuoju siejami stiprių koreliacijos ryšiu. Tada yra tikrinama, kurie įvesties kintamieji turi būti pašalinami iš regresijos lygties;
- atgalinė atranka (angl. *backward stepwise*): skaičiavimas yra pradedamas naudojant visus įvesties kintamuosius, bet vėliau išvesties kintamajam mažai įtakos turintys įvesties kintamieji yra laipsniškai pašalinami;
- visų vartotojo pasirinktų įvesties kintamųjų įtraukimas į modelį (angl. *enter*).

Dažniau yra pasirenkamas vienas iš laipsniškųjų metodų, kad į modelį nepakliūtų mažai įtakos išvesties kintamajam turintys įvesties kintamieji (žr. Hörkkö 2010; Dzidzevičiūtė 2010b). Pasirinkus statistinį metodą ir apskaičiavus įvesties kintamųjų koeficientus, yra atliekamas išankstinis vertinimo balais modelio patikimumo vertinimas (žr. 1.3.1 dalį).

1.1.2. Reitingų skalės sukūrimas

Sukūrus statistinį vertinimo balais modelį, atlikus išankstinį jo patikimumo vertinimą ir gavus palankius rezultatus, banke yra sukuriama nauja reitingų skalė arba sukurtas modelis pritaikomas prie banke jau veikiančios. Pavyzdžiui, jeigu banke buvo taikomas ekspertinis modelis ir penkių reitingų skalė, tai sukūrus individualias PD leidžiantį apskaičiuoti statistinį modelį gali būti paliekama ši reitingų skalė, tačiau skolininkai šiems reitingams turi būti priskiriami remiantis nauju statistiniu modeliu nustatytais individualiomis PD. Banke turi būti

nustatomas optimalus reitingų skaičius, o skolininkai šiems reitingams turi būti priskiriami pagal individualias PD arba kreditingumo balus, nustatytus nauju statistiniu modeliu.

Iki 2003 m. Lietuvos bankai, vadovaudamiesi Lietuvos banko reikalavimais, turėjo naudoti penkių reitingų skalę. Nuo 2003 m. bankams buvo leista grupuojant paskolas priežiūros tikslais naudoti jų pačių susikurtas reitingų skales. Reaguodami į tai, kai kurie bankai padidino savo naudojamų reitingų skaičių (žr. Savickaitė, Valvonis 2007). Tai rodo, jog, tų bankų manymu, penkių reitingų nepakanka skolininkams diferencijuoti. Moksliniuose straipsniuose yra minimas labai įvairus reitingų skaičius – nuo 5 iki 16 (žr. Grigaravičius 2003; Savickaitė, Valvonis 2007; Bandyopadhyay 2007; Mileris, Boguslauskas 2011, Dzidzevičiūtė 2012). Reitingų skaičius priklauso nuo banko veiklos pobūdžio, skolininkų įvairovės ir tikslų, kurių bankas siekia diegdamas reitingų sistemą. Negalima vieno standarto pritaikyti visiems bankams ar skirtingoms reitingų sistemoms, todėl teisės aktuose yra numatytas tik minimalus reitingų skaičius, t. y. kai bankas kapitalo poreikiui skaičiuoti taiko IRB metodą, įmonių paskolų grupei reikia naudoti mažiausiai septynis „gerų“ skolininkų reitingus ir vieną reitingą toms įmonėms, kurios faktiškai tapo „blogos“ (Lietuvos bankas 2006a). Tačiau kai paskolos yra priskiriamos mažmeninių paskolų grupei, minimalus turimų naudoti reitingų skaičius nėra nustatytas.

Bankas turėtų vengti pernelyg didelės vieno reitingo skolininkų koncentracijos ir pernelyg didelio tuo pačiu reitingu vertinamų skolininkų heterogeniškumo, tačiau tokių skolininkų skaičius neturėtų būti per mažas, nes tai neleistų apskaičiuoti reitingo PD ir įvertinti jos patikimumo (Lietuvos bankas 2006a). Bankas gali nustatyti koncentracijos limitus, pavyzdžiui, didžiausios tuo pačiu reitingu vertinamų skolininkų dalies, palyginti su visais skolininkais, arba Herfindahlio ir Hirschmano indekso (toliau – HHI) reikšmės. Kuo didesnis HHI, tuo didesnė skolininkų koncentracija reitinguose. HHI yra apskaičiuojamas taip (Marius, Bogdan 2011):

$$HHI = \sum_{i=1}^n (a_i^2),$$

čia: a_i – i reitingo skolininkų dalis, palyginti su visais skolininkais; i kinta nuo 1 iki n , n – reitingų skaičius.

Bankui yra rekomenduojama labiau diferencijuoti mažesnės rizikos skolininkus, geresniems reitingams nustatyti siauresnius vertinimo balų intervalus, o blogesniems – platesnius. Reitingų sistema turi būti monotoniška, t. y. „blogų“ reitingo skolininkų dalis, palyginti su visais to reitingo skolininkais, ir „blogų“ reitingo skolininkų dalis, palyginti su visais „blogais“ skolininkais, turėtų būti tuo didesnė, kuo blogesnis reitingas. Skolininkų

skirstinys turėtų būti unimodinis ir artimas normaliajam, t. y. didžiausia skolininkų procentinė dalis turėtų telktis viduriniame reitinge. Taip pat gali būti lyginama skirtingų reitingų skalių informacijos vertė arba χ^2 reikšmė taikant χ^2 suderinamumo kriterijų (kaip ir atliekant įvesties kintamųjų analizę) (FIS, CEBS 2006a; SAS 2008, 2009).

Pasirinkus per mažą reitingų skaičių, yra prarandama daugiau informacijos, to paties reitingo skolininkai būna pernelyg heterogeniški, be to, gali būti pernelyg didelė skolininkų koncentracija atskiruose reitinguose. Pasirinkus per didelį reitingų skaičių, gali trūkti duomenų patikimai PD apskaičiuoti ir jos patikimumui įvertinti, skolininkų skirstinys gali neatitikti reikalavimų, reitingų sistema gali būti nemonotoniška ir pan.

Įmonių reitingų skalėse turi būti daugiau reitingų nei fizinių asmenų reitingų skalėse, nes įmonės labiau skiriasi tarpusavyje nei fiziniai asmenys.

Jei bankas turi patrunuojantį banką ir (arba) patrunuojamų bankų, skolininkų riziką reikėtų vertinti taikant tą pačią reitingų skalę, nes tada galima įvertinti paskolų portfelio riziką visos grupės mastu. Tačiau vertinimo balais modeliai, pagal kurių rezultatai skolininkai yra priskiriami reitingams, skirtingose šalyse turėtų būti skirtingi (žr. 2.2 dalį).

Sukūrus reitingų skalę, yra parenkamas reitingų PD apskaičiavimo metodas¹⁹ (žr. 1.2 dalį). Šios disertacijos autorės nuomone, reitingų PD derėtų skaičiuoti visiems, net ir IRB metodo netaikantiems bankams, jie galėtų tokias PD naudoti įvairiuose vidiniuose procesuose (pvz., skaičiuodami vidaus kapitalo poreikį, vertės sumažėjimą ar kredito rizikos maržas ir pan.).

1.2. REITINGŲ ĮSIPAREIGOJIMŲ NEĮVYKDYMO TIKIMYBĖS APSKAIČIAVIMO METODAI

1.2.1. Įprastų reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimo metodai

Reitingo PD gali būti apskaičiuojama taikant vieną iš kelių metodų (žr. 7 lent.). Bankams yra rekomenduojama taikyti aritmetinį skolininkų individualių PD vidurkį arba aritmetinį metinių faktinių „blogų“ tam tikro reitingo skolininkų dažnių vidurkį. Kai skolininkai yra priskiriami reitingams pagal ekspertinio modelio rezultatai arba PD neleidžiančio apskaičiuoti statistinio modelio²⁰ rezultatai, apskritai gali būti taikomas tik pastarasis metodas (t. y. tik PD(4)).

¹⁹ Kapitalo poreikiui skaičiuoti IRB metodą taikantys bankai gali skolininkų nepriskirti reitingams ir naudoti skolininkų individualias PD, tačiau tada tokie bankai turi taikyti individualias PD leidžiantį apskaičiuoti statistinį modelį.

²⁰ Taikant tokį modelį yra nustatomas skolininko kreditingumo balas, o ne jo PD. Pavyzdžiui, diskriminantinės analizės modeliai yra priskiriami prie individualių PD neleidžiančių apskaičiuoti statistinių modelių.

Taikant aritmetinį individualių PD vidurkį, reitingo PD būna labai nepastovi, labai priklauso nuo skolininkų individualių PD, ją reikia nuolat perskaičiuoti. Tačiau šis metodas yra labai tikslus, nes atsižvelgiama į kiekvieną skolininką. Kai yra taikoma laiko momento reitingų sistema, tai blogėjant makroekonominėms sąlygoms reitingų PD(1) išliktų daugmaž stabilios²¹, tačiau kapitalo, reikalingo kredito rizikai padengti, poreikis IRB metoda taikančiame banke padidėtų, skolininkams migruojant iš geresnių reitingų į blogesnius.

Taikant aritmetinį ar geometrinį individualių PD intervalo ribų vidurkį, reitingo PD labai priklauso nuo to, kaip bus sudaryta reitingų skalė (t. y. kokios bus apatinės ir viršutinės ribos). Tačiau taikant šiuos metodus, kaip ir skaičiuojant PD(1), nesusiduriama su sunkumais, kai per metus reitinge būna labai mažai arba visai nebūna faktinių „blogų“ skolininkų ir negalima apskaičiuoti tikslios reitingo PD(4). Be to, kai yra taikoma laiko momento reitingų sistema, tai blogėjant makroekonominėms sąlygoms reitingų PD(2) ir PD(3) išlieka stabilios (nors kapitalo poreikis ir padidėja). Taikyti aritmetinį individualių PD intervalo ribų vidurkį yra konservatyviau nei geometrinį, nes PD(2) gaunamos *ceteris paribus* didesnės už PD(3).

7 lentelė. Reitingų PD apskaičiavimo metodai

Metodas	Formulė	Komentariai
Aritmetinis skolininkų individualių PD vidurkis	$PD(1)_{reitingo} = \frac{\sum_{i=1}^n PD_i}{n},$ <p>čia: PD_i – i skolininko, priskirto tam reitingui, individuali PD; i kinta nuo 1 iki n; n – reitingo skolininkų skaičius</p>	Metodai gali būti taikomi tik tada, kai skolininkai yra priskiriami reitingams pagal individualią PD
Aritmetinis individualių PD intervalo ribų vidurkis	$PD(2)_{reitingo} = \frac{PD_{apatinė} + PD_{viršutinė}}{2},$ <p>čia: $PD_{apatinė}$ – apatinė individualių PD intervalo riba; $PD_{viršutinė}$ – viršutinė individualių PD intervalo riba</p>	
Geometrinis individualių PD intervalo ribų vidurkis	$PD(3)_{reitingo} = \sqrt{(PD_{apatinė} \cdot PD_{viršutinė})}$	
Aritmetinis metinių faktinių „blogų“ skolininkų dažnių vidurkis	$PD(4)_{reitingo} = \frac{\sum_{t=1}^T ODF_t}{T}; ODF_t = \frac{B_t}{N_t},$ <p>čia: ODF_t – faktinių „blogų“ reitingo skolininkų dažnis t metais; B_t – faktinis „blogų“ reitingo skolininkų skaičius per t metus; N_t – reitingo skolininkų skaičius t metų pradžioje; t kinta nuo 1 iki T; T – skaičiuojant PD(4) naudojamas metų skaičius</p>	Metodas gali būti taikomas, kai yra bet kokie statistiniai ar ekspertiniai vertinimo balais modeliai

Šaltinis: sudaryta autorės pagal Blochwitz ir kt. (2004); BCBC (2005a); Fritz ir kt. (2006); Lietuvos bankas (2006a); Dzidzevičiūtė (2010c; 2012).

²¹ O skolininkų individualios PD padidėtų.

Taikant ketvirtąjį metodą, reitingo PD yra apskaičiuojama kaip aritmetinis metinių faktinių „blogų“ skolininkų dažnių (toliau – ODF) vidurkis. Sunkumų kyla, kai per metus reitinge būna labai mažai arba visai nėra faktinių „blogų“ skolininkų. Tada turėtų būti taikomi specialūs reitingų PD apskaičiavimo metodai (žr. 1.2.2 dalį). Taip pat sunkumų kyla, kai paskolos yra trumpalaikės. Pastaruoju atveju kaip ODF_t formulės vardiklį galima pasirinkti suminių visų skolininkų vertinimo tuo reitingu per metus laiką, pavyzdžiui, jeigu paskolos terminas baigiasi birželio mėnesį, skolininkui yra suteikiamas svoris, lygus 0,5, o ne 1, nes tais metais skolininkas tuo reitingu buvo vertinamas tik pusę metų. Metodą paranku taikyti tada, kai naujas statistinis modelis buvo sukurtas naudojant trumpesnį nei penkeri metai laikotarpio duomenis²².

Lietuvos bankas reikalauja, kad IRB metodą taikančiuose bankuose reitingų PD būtų ne mažesnė kaip 0,03 % (Lietuvos bankas 2006a)²³. Jeigu geriausiuose reitinguose yra labai mažai arba visai nėra faktinių „blogų“ skolininkų ir dėl to metiniai ODF yra labai maži (skaičiuojant PD(4)) arba yra labai mažai rizikingesnių geriausio reitingo skolininkų (skaičiuojant PD(1)) ir apskaičiuota pradinė reitingo PD tampa mažesnė nei 0,03 %, bankai, taikantys IRB metodą, privalo tokio reitingo PD prilyginti 0,03 %.

Dažnai apskaičiuojant PD(4) metiniai ODF nedidėja monotoniškai, t. y. geresnių reitingų ODF gali būti didesni už blogesnių reitingų ODF (Fritz ir kt. 2006). Tada galima glodinti ODF ir apskaičiuoti numanomus reitingų ODF. Gali būti taikomas tiesinis glodinimas, tačiau dažniausiai tinka eksponentinis glodinimas:

$$numanomas_ODF_i = a_0 \cdot a_1^i; a_0 = \exp\left(\frac{\sum_{i=1}^n \ln(ODF_i) - \ln(a_1) \cdot \sum_{i=1}^n i}{n}\right);$$

$$a_1 = \exp\left(\frac{n \cdot \sum_{i=1}^n (i \cdot \ln(ODF_i)) - \sum_{i=1}^n i \cdot \sum_{i=1}^n \ln(ODF_i)}{n \cdot \sum_{i=1}^n n^2 - (\sum_{i=1}^n i)^2}\right),$$

čia: a_0 – eksponentinės regresijos lygties laisvasis narys, a_1 – eksponentinės regresijos lygties nuolydis; ODF_i – i reitingo ODF, i kinta nuo 1 iki n ; n – reitingų skaičius.

Eksponentiškai glodinti neįmanoma, kai reitinge visai nėra faktinių „blogų“ skolininkų ir metinis ODF lygus 0,00 %. Tada galima glodinti jau apskaičiuotas PD(4). Jei visais metais kurio nors reitingo ODF yra lygus 0 %, galima glodinti PD(4) naudojant minimalią

²² Kaip minėta 1.1.1.4 dalyje, kai IRB metodą taikantis bankas skaičiuoja PD, kurios bus naudojamos kapitalo poreikiui skaičiuoti, turi būti remiamasi bent penkerių metų praeities duomenų kaupimo laikotarpiu. Tačiau bankai, dar tik įgyvendinantys IRB metodą, tam tikrais atvejais gali šį laikotarpį sutrumpinti iki dvejų metų (Lietuvos bankas 2006a).

²³ Limitas galioja, kai pozicijos yra priskiriamos institucijų, įmonių ir mažmeninių pozicijų grupėms. Pozicija – banko turto arba nebalansinių pretenzijų straipsnis.

reikalaujamą reitingo PD (t. y. 0,03 %). Ir kitais atvejais galima glodinti ne metinius ODF, bet jau apskaičiuotas PD(4).

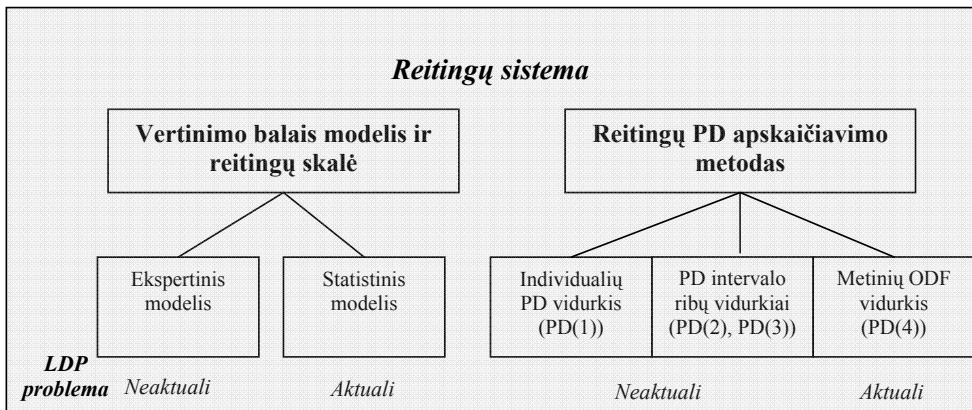
Tiek kapitalo poreikiui skaičiuoti IRB metodą taikančiame banke, tiek vidaus tikslais visuose bankuose gali būti naudojamos ne bendros skolininkų reitingų PD, bet skolininkų individualios PD. Jas galima apskaičiuoti tik taikant individualias PD leidžiantį apskaičiuoti statistinį vertinimo balais modelį. Tokį modelį taikantis bankas gali apskaičiuoti ir naudoti abiejų rūšių PD. Jos gali būti naudojamos skirtingais tikslais, pavyzdžiui, individualios PD gali būti naudojamos priskiriant skolininkus reitingams ir skaičiuojant kapitalo poreikį, o reitingų PD – skaičiuojant vertės sumažėjimą ir kitais tikslais, nes tais tikslais taikant individualias PD pasunkėtų banko informacinių technologijų sistemų darbas.

1.2.2. Reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimo metodai, kai yra žemo „blogų“ skolininkų lygio portfeliai

Bankų priežiūros institucijoms susirūpinimą kelia tai, kad, kai bankų portfeliuose yra labai mažai arba visai nėra faktinių „blogų“ skolininkų, bankai gali nuvertinti skolininkų kredito riziką ir apskaičiuoti mažesnę negu derėtų kapitalo, reikalingo tokių portfelių kredito rizikai padengti, poreikį (BCBS 2005b; CEBS 2006; Lietuvos bankas 2006a). Su šia problema susiduria bankai, kapitalo poreikiui skaičiuoti taikantys IRB metodą. Tačiau, kaip minėta, net ir šio metodo netaikantys bankai gali pasirinktu būdu (t. y. PD(1), PD(2), PD(3) ar PD(4)) skaičiuoti reitingų PD. PD(1), PD(2) ir PD(3) galima apskaičiuoti tik iš skolininkų individualių PD. Tačiau Lietuvos komercinių bankų ir Lietuvoje veikiančių užsienio bankų skyrių apklausos rezultatai parodė, kad statistiniai vertinimo balais modeliai nėra labai populiarūs Lietuvos bankuose. Tik vienas bankas apklausos vykdymo metu taikė individualias PD leidžiantį apskaičiuoti statistinį modelį (logistinę regresiją) (žr. II skyrių). Taigi, daugumai Lietuvos bankų vienintelis tinkamas metodas apskaičiuoti reitingo PD yra naudoti reitingo metinius ODF, t. y. apskaičiuoti PD(4). Tačiau tiek Lietuvos, tiek kitų šalių bankuose geresniuose reitinguose dažnai yra labai mažai arba visai nėra faktinių „blogų“ skolininkų, todėl įprastu būdu apskaičiuotos PD(4) gali būti netikslios, taigi, reikėtų taikyti specialius reitingų PD apskaičiavimo, kai yra žemo „blogų“ skolininkų lygio portfeliai (toliau – LDP), metodus.

Su LDP problema bankai dažnai susiduria ir kurdami statistinius vertinimo balais modelius, pagal kurių rezultataus skolininkai bus priskiriami reitingams, tačiau tada galima padidinti faktinį „blogų“ skolininkų skaičių pakartojant kiekvieną „blogų“ skolininkų įrašą (ar tik kai kuriuos atsitiktiniu būdu atrinktus „blogų“ skolininkų įrašus) kelis kartus, sumažinti faktinį „gerų“ skolininkų skaičių, naudoti keletą skirtingų stebėjimo laikotarpio

atskaitos datų, „blogais“ skolininkais laikyti blogiausio „gerų“ skolininkų reitingo skolininkus, naudoti kitą griežtesnį „blogo“ skolininko apibrėžimą arba ilgesnį stebėjimo laikotarpį, naudoti kelių bankų ar kelių panašia rizika pasižyminčių paskolų rūšių duomenis ir t. t. (BCBS 2005b; Lietuvos bankas 2006a). Tačiau kai skolininkai jau yra priskirti reitingams ir reikia apskaičiuoti reitingų PD, LDP problema yra aktuali tik skaičiuojant PD(4), ypač geresniuose reitinguose (žr. 17 pav.).



17 pav. LDP problemos aktualumas

Šaltinis: sudaryta autorės.

Kai reitinge yra labai mažai arba visai nėra faktinių „blogų“ skolininkų, tarptautinės ir nacionalinės bankų priežiūros institucijos rekomenduoja sujungti kelis reitingus, vienerių metų PD apskaičiuoti iš kelerių metų PD, pridėti konservatyvumo maržas, naudoti išorines PD (t. y. sugretinant vidaus reitingų skalę su kurios nors iš tarptautinių reitingų agentūrų reitingų skale arba su kurio nors iš išorinių paskolų registrų reitingų skale ir pan.), naudoti kelių bankų ar kelių panašia rizika pasižyminčių paskolų rūšių duomenis ir t. t. Taip pat, kaip minėta 1.2.1 dalyje, reitingų, kurių pradinė apskaičiuota PD tampa mažesnė nei 0,03 %, PD galima prilyginti 0,03 % (BCBS 2005b; FSA 2005; CEBS 2006; Lietuvos bankas 2006a). Tačiau pastaruoju atveju iškyla sunkumų, kai daugiau nei vieno reitingo PD tenka prilyginti 0,03 %. Sunkumų kyla ir pasirenkant kitas išeitis. Kai banke jau yra taikoma reitingų skalė, bankas gali nenorėti jos keisti, sujungdamas kelis reitingus, be to, tokia nauja reitingų skalė gali neatitinkti optimalios reitingų skalės sudarymo principų (žr. 1.1.2 dalį). Skaičiuojant kelerių metų PD, „blogų“ skolininkų gali trūkti ir per ilgesnį laikotarpį, sunkiau, kai yra trumpalaikės paskolos, be to, iš kelerių metų PD apskaičiavus vienerių metų PD net keliuose reitinguose iš eilės šios PD gali būti mažesnės nei 0,03 %. Bankui gali būti neaišku, kaip

nustatyti konservatyvumo maržas. Taip pat gali paprasčiausiai nebūti tinkančių išorinių PD. Naudojant kelių bankų ar kelių panašia rizika pasižyminčių paskolų rūšių duomenis apskaičiuotos PD yra nereprezentatyvios vieno konkretaus banko ar vienos konkrečios paskolų rūšies atžvilgiu, be to, banke gali nebūti panašia rizika pasižyminčių paskolų rūšių arba kai kurie bankai gali nenorėti pateikti savo duomenis kitiems bankams.

Dėl to vis populiariesni tampa specialūs LDP reitingų PD apskaičiavimo metodai. Nors yra net keletas tokių metodų, nesutariama, kuris iš jų tinkamiausias. Įvairūs autoriai siūlo metodus, susijusius su reitingų pasikeitimo matricomis ir saviranka, faktinių „blogų“ skolininkų skaičiaus skirstiniu ir simuliacijomis, CAP ir ROC kreivėmis, makroekonominiais rodikliais ir t. t. Lietuvos mokslininkai iki šiol neanalizavo problemų, kylančių skaičiuojant LDP reitingų PD. Taigi, šioje dalyje yra išanalizuoti keleto autorių pasiūlyti LDP reitingų PD apskaičiavimo metodai.

Įvairūs autoriai ir bankų priežiūros institucijos naudoja skirtingus LDP apibrėžimus (žr. BBA ir kt. 2004, 2005; FSA 2005, 2006; CEBS 2006; Lietuvos bankas 2006a). FSA (2006) pasiūlė apibrėžiant LDP naudoti konkretų faktinių „blogų“ skolininkų skaičių, neatsižvelgiant į viso paskolų portfelio skolininkų skaičių. Buvo pasiūlyta naudoti 20 faktinių „blogų“ skolininkų reitingo lygiu, toks apibrėžimas yra naudojamas toliau šioje dalyje; jis buvo pritaikytas ir praktiškai (žr. 3.2.2 dalį).

Metodai, pagrįsti reitingų pasikeitimo matricomis ir saviranka. Reitingo PD galima apskaičiuoti pagal skolininkų migravimus iš to reitingo į kitus reitingus per tam tikrą laikotarpį. Reitingų pasikeitimo matricos yra sudaromos dviem būdais (Schuermann, Hanson 2004): taikant kohortų ir trukmės metodus. Taikant kohortų metodą yra atsižvelgiama tik į konkretaus reitingo skolininkų skaičių metų pradžioje ir į tai, kiek procentų to reitingo skolininkų yra kiekviename kitame reitinge metų pabaigoje, tačiau į reitingų pasikeitimus per metus nėra atsižvelgiama:

$$P_{ij} = \frac{N_{ij}}{N_i},$$

čia: P_{ij} – tikimybė, kad skolininkas, kuris metų pradžioje buvo i reitinge, metų pabaigoje bus j reitinge; N_{ij} – bendras skolininkų, kurie metų pradžioje buvo i reitinge, bet metų pabaigoje buvo j reitinge, skaičius; N_i – bendras i reitingo skolininkų skaičius metų pradžioje.

Taikant trukmės metodus yra atsižvelgiama į reitingų pasikeitimus per metus. Migravimo į „blogą“ skolininko būklę tikimybės gali būti naudojamos kaip PD. Lando, Skødeberg (2002) pasiūlė du trukmės metodus: parametrinį, homogeninio laiko, ir neparametrinį, nehomogeninio laiko.

Taikant parametrinį, homogeninio laiko, metodą, pirmajame etape reikia sudaryti generatoriaus matricą A , kurios elementai yra nustatomi taip:

$$\lambda_{ij} \geq 0; i \neq j; \lambda_{ii} = -\sum_{j \neq i} \lambda_{ij}; \tilde{\lambda}_{ij} = \frac{N_{ij}(T)}{\int_0^T Y_i(s) ds},$$

čia: $\lambda_{ij}, \lambda_{ij}$ – generatoriaus matricos A elementai, žymintys intensyvumą; $N_{ij}(T)$ – migravimų iš i reitingo į j reitingą skaičius per metus; $Y_i(s)$ – i reitingo skolininkų skaičius laiko momentu s ; trupmenos vardiklis rodo suminį visų skolininkų vertinimo i reitingu per metus laiką.

Antrajame etape yra apskaičiuojamos migravimo tikimybės:

$$P(t) = \exp(\Lambda t) = I + t\Lambda + \frac{(t\Lambda)^2}{2!} + \frac{(t\Lambda)^3}{3!} + \frac{(t\Lambda)^4}{4!} + \dots,$$

čia: I – $N \times N$ vienetinė matrica; A – generatoriaus matrica.

Taikant neparimetrinį, nehomogeninio laiko, metodą (naudojant Aaleno ir Johanseno skaičiuoklį), pirmajame etape taip pat reikia apskaičiuoti pagalbines matricas $\Delta A(T_i)$, o antrajame etape – migravimo tikimybes:

$$\hat{P}(s, t) = \prod_{i=1}^m (I + \Delta \hat{A}(T_i)),$$

čia: I – $N \times N$ vienetinė matrica; T_i – i migravimo laiko momentas intervale $[s, t]$; i kinta nuo 1 iki m ; m – migravimų per laikotarpį nuo s iki t skaičius.

2 intarpas. Trukmės metodų taikymo pavyzdžiai

Tarkime, kad turime tik du reitingus ir „blogo“ skolininko būklę. Metų pradžioje kiekviename iš dviejų reitingų yra 20 skolininkų, visi jie – „geri“. Po trijų mėnesių vienas skolininkas iš 2 reitingo migruoja į 1 reitingą ir pasilieka jame iki metų galo. Po šešių mėnesių vienas skolininkas iš 1 reitingo migruoja į 2 reitingą, o po devynių mėnesių vienas skolininkas iš 2 reitingo tampa „blogas“. Per kitus tris mėnesius nėra jokių kitų migravimų. Taikant parametrinį, homogeninio laiko, trukmės metodą, buvo sudaryta tokia generatoriaus matrica:

$$\tilde{\Lambda} = \begin{pmatrix} -0,0494 & 0,0494 & 0 \\ 0,0513 & -0,1026 & 0,0513 \\ 0 & 0 & 0 \end{pmatrix};$$

$$\tilde{\lambda}_{12} = \frac{N_{12}(1)}{\int_0^1 Y_1(s) ds} = \frac{1}{19 + \frac{9}{12} + \frac{6}{12}} = 0,0494; \tilde{\lambda}_{21} = \frac{N_{21}(1)}{\int_0^1 Y_2(s) ds} = \frac{1}{18 + \frac{3}{12} + \frac{6}{12} + \frac{9}{12}} = 0,0513;$$

$$\tilde{\lambda}_{2D} = \frac{N_{2D}(1)}{\int_0^1 Y_2(s) ds} = \frac{1}{18 + \frac{3}{12} + \frac{6}{12} + \frac{9}{12}} = 0,0513.$$

Generatoriaus matricos eilučių sumos turi būti lygios 0, o įstrižainės reikšmės – neigiamos.

Taikant neparimetrinį, nehomogeninio laiko, trukmės metodą, buvo sudarytos pagalbinės matricos $\Delta A(T_{3/12})$, $\Delta A(T_{6/12})$, $\Delta A(T_{9/12})$, nes buvo trys migravimai trimis laiko momentais, t. y. po trijų, šešių ir devynių mėnesių:

$$\Delta A(T_{3/12}) = \begin{pmatrix} 0 & 0 & 0 \\ 0,05 & -0,05 & 0 \\ 0 & 0 & 0 \end{pmatrix}; \Delta A(T_{6/12}) = \begin{pmatrix} -0,0476 & 0,0476 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix};$$

$$\Delta A(T_{9/12}) = \begin{pmatrix} 0 & 0 & 0 \\ 0 & -0,05 & 0,05 \\ 0 & 0 & 0 \end{pmatrix}.$$

Toliau yra pateiktos migravimo tikimybės, apskaičiuotos iš generatoriaus matricos A , taikant parametrinį, homogeninio laiko, trukmės metodą, taip pat migravimo tikimybės, apskaičiuotos taikant neparimetrinį, nehomogeninio laiko, trukmės metodą ir paprastą kohortų metodą. Migravimo tikimybės paskutiniame matricų stulpelyje gali būti naudojamos kaip ODF PD(4) formulėje. Matyti, kad kohortų metodu apskaičiuotas, pavyzdžiui, 2 reitingo 5 % ODF, taikant trukmės metodus yra paskirstomas tarp 1 ir 2 reitingų (0,12 % 1 reitingui ir 4,88 % 2 reitingui, taikant parametrinį, homogeninio laiko, trukmės metodą, arba 0,24 % 1 reitingui ir 4,76 % 2 reitingui, taikant neparimetrinį, nehomogeninio laiko, trukmės metodą). Taigi, taikant trukmės metodus blogesnių reitingų ODF yra santykinai sumažinami, o geresnių – padidinami.

$$P_{param.m.} = \begin{pmatrix} 95,30\% & 4,58\% & 0,12\% \\ 4,76\% & 90,37\% & 4,88\% \\ 0,00\% & 0,00\% & 100,00\% \end{pmatrix};$$

$$P_{neparam.m.} = \begin{pmatrix} 95,24\% & 4,52\% & 0,24\% \\ 4,76\% & 90,48\% & 4,76\% \\ 0,00\% & 0,00\% & 100,00\% \end{pmatrix};$$

$$P_{kohortu.m.} = \begin{pmatrix} 95,00\% & 5,00\% & 0,00\% \\ 5,00\% & 90,00\% & 5,00\% \\ 0,00\% & 0,00\% & 100,00\% \end{pmatrix}.$$

Taikant trukmės metodus galima apskaičiuoti PD(4) netgi tokiems reitingams, kuriuose visai nebuvo faktinių „blogų“ skolininkų.

Šaltinis: autorės skaičiavimai.

Jafry, Schuermann (2004) tyrimo rezultatai parodė, kad, nors taikant neparimetrinį, nehomogeninio laiko, metodą galioja mažiau prielaidų, abiem trukmės metodais galima sudaryti statistiškai reikšmingai nesiskiriančias reitingų pasikeitimo matricas. Be to, taikant neparimetrinį, nehomogeninio laiko, trukmės metodą, skaičiavimai yra sudėtingesni, todėl autoriai rekomenduoja taikyti parametrinį, homogeninio laiko, trukmės metodą. Taikant kohortų metodą neįmanoma apskaičiuoti PD, kai reitinge visai nėra faktinių „blogų“ skolininkų.

Schuermann, Hanson (2004), Christensen ir kt. (2004) siūlo taikyti saviranką skaičiuojant pasikliautinusius migravimo tikimybių intervalus. Tada galima nustatyti PD net ir tada, kai reitinge visai nėra faktinių „blogų“ skolininkų ir yra taikomas kohortų metodas (tada yra naudojama viršutinė PD intervalo riba). Pasikliautiniai intervalai gali būti apskaičiuojami ir analitiškai, naudojant Voldo intervalą, tačiau autoriai nerekomenduoja to daryti, nes yra gaunamos pernelyg plačios PD ribos.

Metodai, susiję su CAP ir ROC kreivėmis. Burgt (2007) pasiūlė alternatyvų būdą CAP kreivei išvesti, t. y.:

$$y(x) = \frac{1 - \exp^{-kx}}{1 - \exp^{-k}},$$

čia: x – rizikingiausių pagal modelį skolininkų kaupiamoji dalis, palyginti su visais skolininkais; $y(x)$ – rizikingiausių pagal modelį skolininkų dalyje x esančių faktinių „blogų“ skolininkų dalis, palyginti su visais faktiniais „blogais“ skolininkais; k – CAP kreivės įgaubtumo parametras, apibūdinantis CAP kreivės nuolydį; kai k artėja prie 0, CAP kreivė artėja prie įstrižainės linijos.

PD yra apskaičiuojama taip (kai tikslumo santykis $> 60\%$ (ar plotas po ROC kreive $> 80\%$):

$$PD_R = \frac{k \cdot ODF_{\text{portfelio}}}{1 - \exp^{-k}} \cdot \exp(-kx_R); \quad k \approx \frac{2}{1 - AR}; \quad k \approx \frac{1}{1 - AUC};$$

$$x_R = \frac{z_N + z_{N-1} + \dots + z_{R+1} + (z_R/2)}{z},$$

čia: x_R – skolininkų nuo blogiausio reitingo iki R reitingo (įskaitytinai) dalis, palyginti su visais skolininkais; $ODF_{\text{portfelio}}$ – paskolų portfelio ODF; AR – tikslumo santykis naudojant CAP kreivę; AUC – plotas po ROC kreive; z – visų skolininkų skaičius; z_R – R reitingo skolininkų skaičius (kai didesni reitingai reiškia didesnę riziką); z_N – blogiausio reitingo skolininkų skaičius.

Iš pirmiau pateiktų formulių matyti, kad taikant CAP kreivės metodą visame paskolų portfelyje reikia bent keleto faktinių „blogų“ skolininkų, t. y. metodo taikyti negalima, kai visame paskolų portfelyje nėra nė vieno faktinio „blogo“ skolininko, bet užtenka, kad faktinių „blogų“ skolininkų būtų bent viename iš reitingų.

Tasche (2009) pasiūlė dviejų parametru ROC kreivės metodą. ROC kreivei išvesti reikia naudotis šiomis lygtimis:

$$R_{a,b}(F_N(s)) = \Phi(a + b \cdot \Phi^{-1}(F_N(s))); F_N(s) \in (0,1); b = \frac{\sigma_N}{\sigma_D}; a = \frac{\mu_N - \mu_D}{\sigma_D};$$

$$F_N(s) = \frac{P[\{S \geq s\} \cap N]}{1 - ODF_{portfolio}}$$

čia: $R_{a,b}(F_N(s))$ – faktinių „blogų“ skolininkų nuo blogiausio reitingo iki s reitingo (įskaitytinai) dalis, palyginti su visais faktiniais „blogais“ skolininkais; $ODF_{portfolio}$ – paskolų portfelio ODF; $F_N(s)$ – faktinių „gerų“ skolininkų nuo blogiausio reitingo iki s reitingo (įskaitytinai) dalis, palyginti su visais faktiniais „gerais“ skolininkais (trupmenos skaitiklis yra apskaičiuojamas kaip dviejų tikimybių sandauga, t. y. tikimybės, kad skolininko reitingas yra ne mažesnis nei s (jeigu didesni reitingai reiškia didesnę riziką), ir tikimybės, kad skolininkas, kurio reitingas yra ne mažesnis nei s , yra faktinis „geras“ skolininkas; μ_N, σ_N – faktinių „gerų“ skolininkų reitingų vidurkis ir standartinis nuokrypis; μ_D, σ_D – faktinių „blogų“ skolininkų reitingų vidurkis ir standartinis nuokrypis; $\Phi()$ – standartinio normaliojo dydžio pasiskirstymo funkcija²⁴; $\Phi^{-1}()$ – atvirkštinė standartinio normaliojo dydžio pasiskirstymo funkcija²⁵.

Reitingo PD yra apskaičiuojama taip:

$$P[D|S = s] = \frac{ODF_{portfolio} \cdot R'_{a,b}(F_N(s))}{ODF_{portfolio} \cdot R'_{a,b}(F_N(s)) + 1 - ODF_{portfolio}}; R'_{a,b}(F_N(s)) = b \cdot \frac{\varphi(a + b\Phi^{-1}(F_N(s)))}{\varphi(\Phi^{-1}(F_N(s)))},$$

čia: $\varphi()$ – standartinio normaliojo dydžio tikimybinio tankio funkcija²⁶.

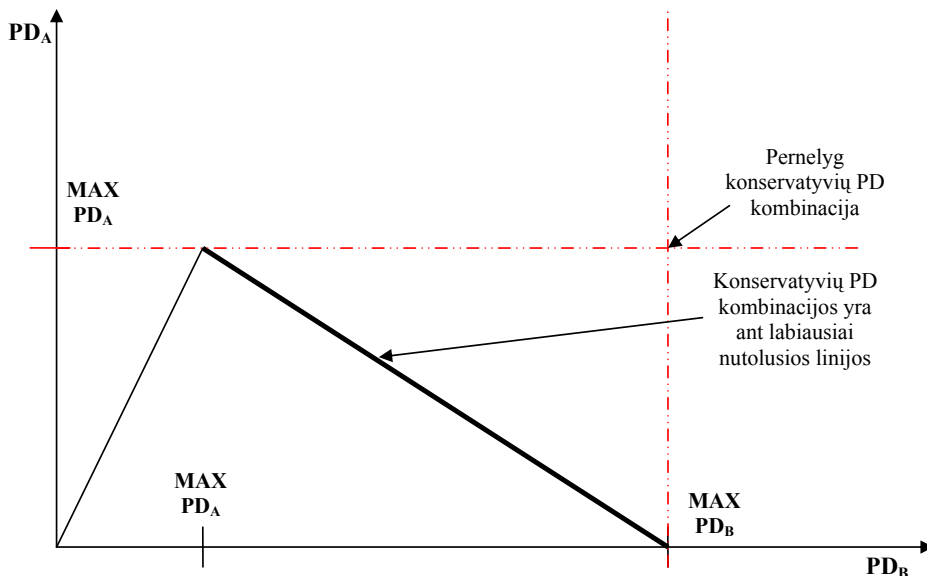
Metodai, susiję su „blogų“ skolininkų skaičiaus skirstiniu ir simuliacija. Forrest (2005) pasiūlė dviejų rūšių metodus LDP reitingų PD apskaičiuoti: be koreliacijos (žr. 5 priedą) ir su koreliacija. Pagrindinė idėja yra tokia, kad pasirinkus pasiklovimo lygmenį yra nustatomas PD intervalas (o ne konkreti PD). Autorius rekomenduoja iš šio intervalo pasirinkti konservatyvias PD. Be to, ir tarptautinės bankų priežiūros institucijos rekomenduoja naudoti viršutinę PD intervalo ribą arba bent jau reikšmę iš viršutinės PD intervalo dalies (BCBS 2005b; FSA 2005). Kai dviejuose iš eilės reitinguose nėra faktinių „blogų“ skolininkų, PD kombinacijas galima pasirinkti iš trikampio apibrėžiamo ploto (žr. 18 pav.). Tačiau metodo autorius siūlo pasirinkti vieną iš konservatyvių PD kombinacijų ant labiausiai koordinatų pradžios atžvilgiu nutolusios trikampio linijos. Kadangi net ir

²⁴ Reikšmę galima apskaičiuoti taikant „MS Excel“ funkciją = NORMSDIST().

²⁵ Reikšmę galima apskaičiuoti taikant „MS Excel“ funkciją = NORMSINV().

²⁶ Reikšmę galima apskaičiuoti taikant „MS Excel“ funkciją = NORMDIST(x;0;1;false).

pasirinkus konkretų pasiklovimo lygmenį yra ne viena konservatyvių PD kombinacija, išskyla klausimas, kaip išsirinkti vieną. Autorius siūlo pasirinkti tą kombinaciją, kurią naudojant kapitalo, reikalingo kredito rizikai padengti, poreikis yra didžiausias.



18 pav. Dviejų iš eilės LDP reitingų, kai nėra faktinių „blogų“ skolininkų, PD
Šaltinis: Forrest (2005).

Kai dviejuose iš eilės LDP reitinguose yra keli faktiniai „blogi“ skolininkai, PD kombinacijas galima pasirinkti iš figūros 19 pav. apibrėžiamo ploto, jame turi galioti sąlyga: $-2\ln(LR(PD)) \leq CHIINV((100\% - \text{pasiklovimo lygmuo}); 2)$. Tačiau metodo autorius siūlo pasirinkti vieną iš konservatyvių PD kombinacijų ant labiausiai koordinacių pradžios atžvilgiu nutolusios linijos. Kiekvieno reitingo minimalios ir maksimalios PD yra apskaičiuojamos atskirai, naudojant kaupiamąjį visų skolininkų ir visų faktinių „blogų“ skolininkų iki to reitingo (įskaitytinai) skaičių, pavyzdžiui, reitingo A:

$$LR(PD) = \frac{L(PD)}{ML}; L(PD) = PD_A^{DA+DB} (1 - PD_A)^{NA+NB-DA-DB};$$

$$ML = ODF_{\text{portfelio}}^{DA+DB} (1 - ODF_{\text{portfelio}})^{NA+NB-DA-DB}.$$

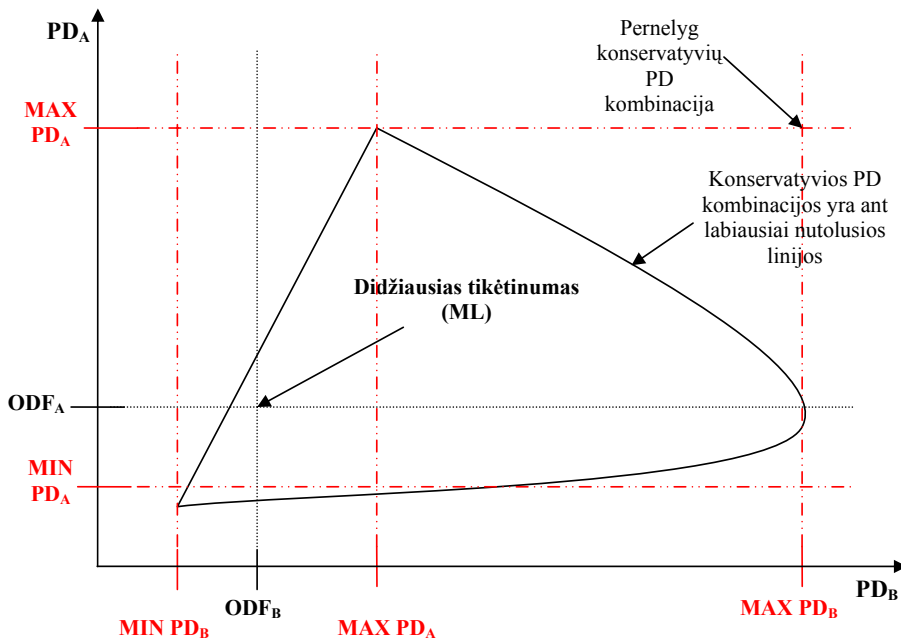
Reitingo B:

$$LR(PD) = \frac{L(PD)}{ML}; L(PD) = PD_B^{DB} (1 - PD_B)^{NB-DB};$$

$$ML = ODF_B^{DB} (1 - ODF_B)^{NB-DB}.$$

Šiuo atveju laisvės laipsnių skaičius yra lygus dviem, nes yra du iš eilės LDP reitingai.

Iš visų konservatyvių PD kombinacijų ant labiausiai koordinacių pradžios atžvilgiu nutolusios linijos reikėtų pasirinkti tokią, kurią naudojant yra gaunamas didžiausias kapitalo, reikalingo kredito rizikai padengti, poreikis.



19 pav. Dviejų iš eilės LDP reitingų, kai yra keli faktiniai „blogi“ skolininkai, PD

Šaltinis: Forrest (2005).

Jeigu Forrest (2005) metodas yra modifikuojamas įtraukiant koreliaciją, PD kombinacijų pasirinkimo plotai išsiplėčia, todėl konservatyvių PD reikšmės gali būti pernelyg didelės. Todėl praktiškai buvo pritaikytas tik Forrest (2005) metodas be koreliacijos (žr. 3.2.2 dalį).

Pluto, Tasche (2005) pasiūlė tris variantus konservatyvioms PD apskaičiuoti: 1) be koreliacijos, 2) su koreliacija 3) daugiaperiodį atvejį. Jeigu viename LDP reitinge nėra faktinių „blogų“ skolininkų, metodas be koreliacijos yra identiškas Forrest (2005) metodui be koreliacijos. Tačiau jeigu yra keli LDP reitingai iš eilės be faktinių „blogų“ skolininkų, Pluto, Tasche (2005) siūlo naudoti maksimalias PD reikšmes (atitinka $MAX PD_A$ ir $MAX PD_B$ 19 pav.). Kai yra keli faktiniai „blogi“ skolininkai ir tapsmo „blogais“ skolininkais atvejai yra nepriklausomi, autoriai daro prielaidą, kad faktinių „blogų“ skolininkų skaičius yra pasiskirstęs pagal binominį skirstinį. Pavyzdžiui, trijų LDP reitingų A, B ir C konservatyvios PD_A , PD_B ir PD_C gali būti išreiškiamos iš šių formulių:

$$1 - \gamma = \sum_{i=0}^{DA+DB+DC} \left[\binom{NA+NB+NC}{i} \cdot PD_A^i \cdot (1 - PD_A)^{NA+NB+NC-i} \right];$$

$$1 - \gamma = \sum_{i=0}^{DB+DC} \left[\binom{NB+NC}{i} \cdot PD_B^i \cdot (1 - PD_B)^{NB+NC-i} \right];$$

$$1 - \gamma = \sum_{i=0}^{DC} \left[\binom{NC}{i} \cdot PD_C^i \cdot (1 - PD_C)^{NC-i} \right].$$

čia: $\binom{n}{i} = C_n^i = \frac{n!}{i!(n-i)!}$, t. y. galimų i kombinacijų iš n stebėjimų skaičius; γ – pasirinktas pasiklovimo lygmuo.

Dešinioji lygybių pusė rodo tikimybes, kad bus atitinkamai ne daugiau kaip $DA + DB + DC$ faktinių „blogų“ skolininkų, ne daugiau kaip $DB + DC$ faktinių „blogų“ skolininkų ir ne daugiau kaip DC faktinių „blogų“ skolininkų. Binominio skirstinio „uodega“ gali būti išreiškiama beta skirstinio funkcija²⁷. Jeigu yra įtraukiamos koreliacijos, analogiškai kaip ir taikant Forrest (2005) metodą, konservatyvios PD yra didesnės.

Kai atvejis daugiaperiodis, autoriai įtraukia papildomą koreliacijos rodiklį – skirtingų laikotarpių koreliaciją. Yra daroma nereali prielaida, kad skolininkų skaičius kiekvienais metais yra lygus skolininkų skaičiui pirmais metais. Be to, taikant šį metodą apskaičiuotos PD yra pernelyg mažos, netgi palyginti su PD, apskaičiuotomis taikant pirmąjį šio metodo variantą be koreliacijos. Konservatyvios metinės PD yra apskaičiuojamos viso laikotarpio. Tačiau atsižvelgiant į tai, kad šioje disertacijoje yra naudojamas Lietuvos banko (2006a) reikalaujamas taikyti PD(4) apibrėžimas, daugiaperiodis atvejis daugiau nėra analizuojamas. Praktiškai buvo pritaikytas tik Pluto, Tasche (2005) metodo variantas be koreliacijos (žr. 3.2.2 dalį).

Kiefer (2006), apskaičiuodamas LDP reitingų PD, naudoja Bajeso formulę. Reitingo PD yra tokia, kuriai esant posteriorinis skirstinys įgyja didžiausią reikšmę, t. y. $\bar{\theta} = E(\theta|D, e)$. Posteriorinis skirstinys $p(\theta|D, e)$, apibūdinantis nežinomybę dėl θ , kai reitinge yra N skolininkų, iš jų – D faktinių „blogų“ skolininkų, ir kai yra atsižvelgiama į ekspertų informaciją e , yra išreiškiamas taip:

$$p(\theta|D, e) = \frac{p(D|\theta, e) \cdot p(\theta|e)}{p(D|e)},$$

²⁷ Konservatyvios reitingo PD gali būti apskaičiuojamos taikant „MS Excel“ funkciją =BETAINV(γ ; $D + 1$; $N - D$), čia: γ – pasirinktas pasiklovimo lygmuo; D – faktinių „blogų“ reitingo skolininkų skaičius; N – reitingo skolininkų skaičius.

čia: $p(D|\theta, e)$ – D faktinių „blogų“ skolininkų skirstinys, kai PD yra lygi θ (t. y. „sėkmės“ tikimybė atliekant kiekvieną bandymą), ir kai yra atsižvelgiama į ekspertų informaciją e .

Naudojant Bernulio schemą, dešinioji toliau pateiktos lygybės pusė rodo tikimybę, kad reitinge, kuriame yra N skolininkų, bus D faktinių „blogų“ skolininkų:

$$p(D|\theta, e) = \binom{N}{D} \theta^D (1 - \theta)^{N-D}.$$

$p(\theta|e)$ yra apriorinis θ skirstinys. Dažniausiai yra naudojama parametrinė forma; Kiefer (2006) siūlo naudoti beta skirstinį. Dviejų parametru beta skirstinio tikimybinio tankio funkcija atsitiktiniam kintamajam $\theta \in [0, 1]$ yra:

$$p(\theta|\alpha, \beta) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha-1} (1 - \theta)^{\beta-1},$$

čia: $\Gamma(n)$ – gama funkcija (kai n yra teigiamasis sveikasis skaičius, $\Gamma(n) = (n-1)!$); α, β – parametrai, kurie gali būti apskaičiuojami taip:

$$\hat{\alpha} = \bar{\theta} \left(\frac{\bar{\theta}(1 - \bar{\theta})}{\nu} - 1 \right); \hat{\beta} = (1 - \bar{\theta}) \left(\frac{\bar{\theta}(1 - \bar{\theta})}{\nu} - 1 \right),$$

čia: $\bar{\theta}$ – imties vidurkis; ν – imties dispersija.

$p(D|e)$ – nesąlyginis faktinių „blogų“ skolininkų skaičiaus skirstinys. Kai yra naudojamas dviejų parametru beta skirstinys, tai:

$$p(D|e) = \frac{\Gamma(D + \alpha)\Gamma(N - D + \beta)\Gamma(\alpha + \beta)\Gamma(N + 1)}{\Gamma(D + 1)\Gamma(N - D + 1)\Gamma(\alpha)\Gamma(\beta)\Gamma(N + \alpha + \beta)}.$$

Kiefer (2006) siūlo naudoti keturių parametru beta skirstinį, nes tada yra užtikrinamas didesnis lankstumas PD intervale $[a, b]$, tačiau kai kuriais atvejais toks skirstinys gali būti pernelyg ribotas. Autorius siūlo naudoti ir septynių parametru skirstinį. Tačiau tada metodas tampa sudėtingesnis, sunku apskaičiuoti nesąlyginį faktinių „blogų“ skolininkų skaičiaus skirstinį $p(D|e)$. Kiefer pasiūlė ir kitokių savo metodo modifikacijų (žr. Kiefer 2007, 2008).

Praktiškai buvo pritaikytas Kiefer (2006) metodas naudojant dviejų parametru beta skirstinį $p(D|e)$ apibrėžti (žr. 2.2 dalį).

Kiti metodai. Wilde, Jackson (2006) pasiūlė apskaičiuoti PD *CreditRisk+* metodą pritaikant prie Mertono faktinių „blogų“ skolininkų elgesio modelio. Metodas tinka, kai yra penkerių ar daugiau metų duomenys, be to, galima apskaičiuoti PD , net kai visame paskolų portfelyje nėra nė vieno faktinio „blogo“ skolininko. Tačiau PD yra gaunamos pernelyg didelės, netgi didesnės nei taikant Pluto, Tasche (2005) metodą su koreliacija.

Sabato (2006) pasiūlė PD skaičiavimą susieti su nedarbo lygiu atitinkamose skolininkų amžiaus ar išsilavinimo grupėse. Tačiau metodas tinka tik skaičiuojant fizinių asmenų PD. Galima pritaikyti metodą įmonių PD skaičiuoti, pavyzdžiui, galima naudoti bendrus skirtingų ekonominės veiklos rūšių rodiklius ir pan., tačiau tos pačios ekonominės veiklos rūšies įmonės gali pasižymėti skirtinga rizika. Be to, PD yra nustatomos tik tam tikroms įvesties kintamųjų reikšmių grupėms, bet ne reitingams.

Kai bankai patys renkasi metodą, skirtinguose bankuose reitingų, turinčių tiek pat faktinių „gerų“ ir tiek pat faktinių „blogų“ skolininkų, PD gali reikšmingai skirtis, nes bankai gali pasirinkti ne tik skirtingus metodus, bet ir skirtingus to paties metodo parametrus (pasiklovimo lygmenis, koreliacijos dydžius ir t. t.). Todėl bankų priežiūros institucijos negali palyginti skirtingų bankų PD. Priežiūros institucijos galėtų taikyti FSA (2006) pasiūlytą metodą, kai bankai lygina savo PD su priežiūros institucijos parengtose lentelėse pateiktomis lyginamosiomis PD. Jeigu svertinis PD vidurkis yra mažesnis už lyginamąją PD, bankas svertinį PD vidurkį padidina iki lyginamosios PD dydžio.

1.3. REITINGŲ SISTEMŲ PATIKIMUMO VERTINIMAS

1.3.1. Išankstinis patikimumo vertinimas

Prieš pradėdant reitingų sistemą taikyti banko veikloje turi būti atliekamas išankstinis jos patikimumo vertinimas. Vėliau, jau pradėjus reitingų sistemą taikyti banko veikloje, reguliariai turi būti atliekamas ir pakartotinis patikimumo vertinimas (Lietuvos bankas 2006b). Išankstinis patikimumo vertinimas apima du etapus: gautos lygties tinkamumo (jos ir empirinių duomenų atitikimo) tikrinimą ir kitų reitingų sistemos aspektų tikrinimą taikant 20 pav. pateiktus metodus.

Taikant logistinę regresiją, gautos lygties tinkamumo tikrinimas apima šiuos etapus (Kleinbaum, Klein 2002; Čekanavičius, Murauskas 2004; Fernandes 2005; Pukėnas 2005, 2009; Hand 2009):

- koeficientų algebrinių ženklų ekonominio pagrįstumo tikrinimą (pvz., pelningumui didėjant, skolininko individuali PD turi *ceteris paribus* mažėti ir atvirkščiai);
- koeficientų nelygybės 0 reikšmingumo analizę taikant Omnibus ir Voldo kriterijus;
- koeficientų standartinių paklaidų analizę;
- modelio suderinamumo su empiriniais duomenimis analizę taikant Hosmerio ir Lemešou kriterijų;
- determinacijos ir multikolinearumo analizę;
- teisingo klasifikavimo analizę (žr. 8 lent.).

Taikant logistinę regresiją, skolininkas pagal modelį yra priskiriamas prie „blogų“ skolininkų, jeigu jo individuali PD > 50 %, priešingu atveju – prie „gerų“ skolininkų.

Taikant klasifikacinę lentelę yra analizuojamas ne tik bendras teisingo klasifikavimo rodiklis, bet ir modelio jautrumas, specifiškumas, klaidų tikimybės.

8 lentelė. Klasifikacinė lentelė

Faktas		Progozė		
		Skolininkų skaičius		Teisingo klasifikavimo rodikliai, %
		„Geri“	„Blogi“	
Skolininkų skaičius	„Geri“	<i>TN</i>	<i>FP</i>	$\frac{TN}{TN + FP}$
	„Blogi“	<i>FN</i>	<i>TP</i>	$\frac{TP}{FN + TP}$
Bendras teisingo klasifikavimo rodiklis, %				$\frac{TN + TP}{TN + FP + FN + TP}$

Šaltinis: Engelmann ir kt. (2003a); Čekanaivičius, Murauskas (2004); Stein 2005; Pukėnas 2005, 2009; Hand (2009).

Modelio jautrumas parodo faktinių „blogų“ skolininkų ir pagal modelį priskirtų prie „blogų“ skolininkų dalį (angl. *sensitivity*, *hit rate*):

$$Se = 1 - \alpha = \frac{TP}{FN + TP},$$

čia: *Se* – modelio jautrumas, α – I rūšies klaidos tikimybė.

Modelio specifiškumas parodo faktinių „gerų“ skolininkų ir pagal modelį priskirtų prie „gerų“ skolininkų dalį (angl. *specificity*):

$$Sp = 1 - \beta = \frac{TN}{TN + FP},$$

čia: *Sp* – modelio specifiškumas, β – II rūšies klaidos tikimybė.

I rūšies klaidos tikimybė (α) parodo faktinių „blogų“ skolininkų, pagal modelį priskirtų prie „gerų“ skolininkų, dalį (angl. *false negative rate*):

$$\alpha = \frac{FN}{FN + TP}.$$

II rūšies klaidos tikimybė (β) parodo faktinių „gerų“ skolininkų, pagal modelį priskirtų prie „blogų“ skolininkų, dalį (angl. *false positive rate*, *false alarm rate*):

$$\beta = \frac{FP}{TN + FP}.$$

Jeigu lygties tinkamumo tikrinimo rezultatai netenkina, bankas gali grįžti atgal į bet kurį iš ankstesnių modelio kūrimo etapų, pavyzdžiui, kitaip sugrupuoti ir (arba) užkoduoti įvesties kintamųjų reikšmes, pasirinkti kitus (ar įtraukti papildomus) įvesties kintamuosius, kurti modelį kitu lygiu, susiaurinti skolininkų grupę, pasirinkti kitą statistinį metodą ir pan.

1.3.2. Vertinimo balais modelio ir reitingų skalės patikimumo vertinimas

Kai lygties tinkamumo tikrinimo rezultatai tenkina, turi būti įvertinama modelio diskriminacinė galia (žr. 9 lent.).

Tik vėliau, jeigu modelio diskriminacija yra bent jau priimtina, turėtų būti kuriama reitingų skalė, apskaičiuojamos reitingų PD, vertinamas jų kalibravimo tikslumas (žr. 20 pav.).


<i>Vertinimo balais modelio ir reitingų skalės patikimumo vertinimas</i>	<i>Reitingų PD patikimumo vertinimas</i>
Diskriminacinės galios analizė <ol style="list-style-type: none"> 1. CAP, ROC kreivės 2. Briero balų metodas 3. Bajeso klaidos tikimybė 4. I ir II rūšies klaidų tikimybių vidurkis 5. Informacijos vertė (ir kt. entropija pagrįsti metodai, pvz. CIER, MIE*) 	PD kalibravimo tikslumo vertinimas <ol style="list-style-type: none"> 1. Normalieji kriterijai 2. Binominiai kriterijai 3. Hosmerio ir Lemešou kriterijus 4. Eismo šviesos metodas 5. Patikimumo diagramos
Reitingų skalės analizė <ol style="list-style-type: none"> 1. Vertinimo balų intervalai 2. Monotoniškumas 3. Koncentracija reitinguose 4. Skolininkų skirstinys 5. Diskriminacija 	Stabilumo analizė <ol style="list-style-type: none"> 1. PD kalibravimo tikslumo pokyčiai 2. Duomenų, įvesties kintamųjų, prielaidų, apskaičiavimo metodų ir kiti pokyčiai
Stabilumo analizė <ol style="list-style-type: none"> 1. Diskriminacinės galios stabilumas 2. Reitingų pasikeitimo matricos 3. Reitingų skalės stabilumas 4. Įvesties kintamųjų stabilumas 	Lyginamoji analizė Vidinės PD lyginamos su išorinėmis PD
Įvesties kintamųjų analizė** <ol style="list-style-type: none"> 1. Vienfaktorinė 2. Dvifaktorinė 3. Daugiafaktorinė 	
Lyginamoji analizė Reitingų lyginimas su išorės reitingais	

20 pav. Reitingų sistemos patikimumo vertinimas

Šaltinis: sudaryta autorės pagal Stein (2002); Blochwitz ir kt. (2004); ONB (2004); BCBS (2005a); Fritz ir kt. (2006); Lietuvos bankas (2006b); Banca D'Italia (2006); Tasche (2006); Lingo, Winkler (2008); Medema ir kt. (2009). *CIER – sąlyginės informacijos entropijos lygis; MIE – savitarpio informacijos entropija; **vienfaktorė analizė – trūkstatų verčių, išskirčių ir pan. analizė; dvifaktorė analizė – individualios diskriminacinės galios, ryšio su išvesties kintamuoju ar atskirais įvesties kintamaisiais ir pan. analizė; daugiafaktorė analizė – multikolinearumo ir pan. analizė (pvz., dispersijos mažėjimo daugiklis (VIF) ir kt.).

Tik tada turėtų būti analizuojamas reitingų sistemos stabilumas ir įvesties kintamieji naudojant patikimumo vertinimo imtį, atliekama lyginamoji analizė su išorės lyginamaisiais dydžiais.

Išanalizavus per 15 metų (nuo 1996 iki 2011 m.) autorių iš įvairių pasaulio šalių parašytus 89 straipsnius matyti, kad dažniausiai taikomi patikimumo vertinimo metodai yra CAP ir ROC kreivės ir teisingo klasifikavimo analizė, tačiau sparčiai populiarėja ir entropija pagrįsti metodai, ypač informacijos vertės metodas, taip pat Briero balų metodas (žr. 21 pav.). CAP ir ROC kreivės taikomos ir Lietuvos bankuose (žr. 17 lent.), jas taip pat rekomenduoja taikyti Lietuvos bankas (Lietuvos bankas 2006b).



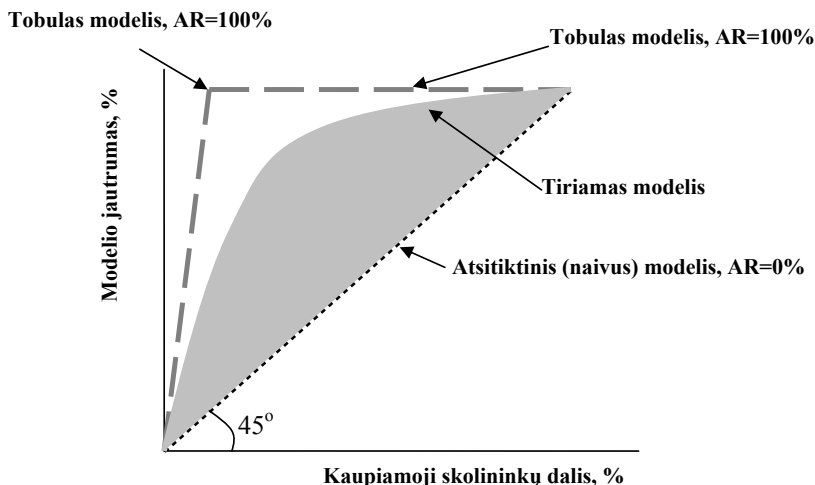
21 pav. Patikimumo vertinimo metodų²⁸ taikymo dažnumas, %

Šaltinis: sudaryta autorės pagal 3; 4; 8; 10; 11; 13; 15; 16; 22; 29; 32; 33; 40; 41; 45; 47; 48; 49; 51; 53; 54; 64; 68; 69; 71; 75; 78; 80; 86; 87; 88; 94; 101; 102; 103; 104; 105; 106; 109; 111; 112; 113; 114; 115; 118; 119; 120; 124; 125; 126; 138; 140; 141; 142; 144; 148; 157; 159; 163; 169; 176; 179; 180; 181; 182; 190; 191; 193; 196; 197; 198; 201; 204; 207; 212; 213; 215; 216; 217; 221; 223; 224; 227; 233; 234; 239; 241; 244.

CAP kreivės metodas. Brėžiant CAP kreivę, iš pradžių skolininkai yra išrikiuojami vertinimo balo gerėjimo tvarka. x ašyje yra pavaizduojama skolininkų kaupiamoji dalis, pradedant nuo rizikingiausių skolininkų ir palaipsniui įtraukiant vis geresnius, o y ašyje yra pavaizduojamas modelio jautrumas (žr. 22 pav.). Kitaip nei atliekant teisingo klasifikavimo

²⁸ Autorių taikomi patikimumo vertinimo metodai dažniausiai apima tik lygties tinkamumo tikrinimo ir diskriminacinės galios vertinimo metodus, nes jie nekūrė reitingų skalės ir neskaičiavo reitingų PD. Santrumpos: *MSE* – vidutinė kvadratinė paklaida; *KS* – Kolmogorovo ir Smirnovo metodas; *CIER* – sąlyginės informacijos entropijos lygis; *MIE* – savitarpio informacijos entropija; *MAPE* – vidutinė absoliutinė procentinė paklaida; *K-L* atstumas – Kullbacko ir Leiblerio atstumas.

analizę, skolininkas pagal modelį yra priskiriamas prie „blogų“ skolininkų, jeigu jis patenka į atitinkamą rizikingiausių skolininkų kaupiamąją dalį, t. y. lūžio taškas paslenkamas vis aukščiau.



22 pav. CAP kreivė


Šaltinis: Engelmann ir kt. (2003a, b).

Modelis yra laikomas tobulu, jei, išrikiavus visus skolininkus vertinimo balo gerėjimo tvarka, pirmiausia iš eilės išsidėsto visi faktiniai „blogi“ skolininkai ir tik vėliau – faktiniai „geri“ skolininkai (tobulo modelio CAP kreivę vaizduoja brūkšninė linija). Modelis yra laikomas atsitiktiniu (naiviu), jei faktinių „blogų“ skolininkų kaupiamoji dalis didėja proporcingai, pavyzdžiui, 10-yje % pačių rizikingiausių skolininkų yra 10 % visų faktinių „blogų“ skolininkų ir t. t. (atsitiktinio (naivaus) modelio CAP kreivę vaizduoja taškinė linija). Tiriama modelio diskriminacinė galia tuo didesnė, kuo jo kreivė yra arčiau tobulo modelio kreivės ir kuo toliau nuo atsitiktinio (naivaus) modelio kreivės, t. y. kuo tikslumo santykio reikšmė yra arčiau 100 %. Grafiškai tikslumo santykis yra apskaičiuojamas pagal šią formulę (Engelmann ir kt. 2003a, b):

$$AR = \frac{a_R}{a_P},$$

čia: AR – tikslumo santykis; a_R – plotas nuo tiriamo modelio CAP kreivės iki atsitiktinio (naivaus) modelio CAP kreivės; a_P – plotas nuo tobulo modelio CAP kreivės iki atsitiktinio (naivaus) modelio CAP kreivės.

ROC kreivės metodas. Brėžiant ROC kreivę, x ašyje yra pavaizduojama II rūšies klaidos tikimybė (β) konkrečioje rizikingiausių skolininkų kaupiamajoje dalyje, o y ašyje – modelio jautrumas (žr. 23 pav.). Kaip ir brėžiant CAP kreivę, skolininkas pagal modelį yra priskiriamas prie „blogų“ skolininkų, jeigu jis patenka į atitinkamą rizikingiausių skolininkų kaupiamąją dalį.



23 pav. ROC kreivė

Šaltinis: Engelmann ir kt. (2003a, b).

Diskriminacinė modelio galia yra vertinama atsižvelgiant į plotą po ROC kreive, kuris gali būti apskaičiuojamas pagal šią formulę:

$$AUC = \sum_{i=1}^n (Se_i \cdot \frac{1}{n}),$$

čia: AUC – plotas po ROC kreive; Se_i – faktinių „blogų“ skolininkų nuo rizikingiausios grupės iki i grupės (įskaitytinai) dalis, palyginti su visais faktiniais „blogais“ skolininkais, t. y. modelio jautrumas; i kinta nuo 1 iki n ; n – grupių skaičius.

Žinant plotą po ROC kreive (toliau – AUC), tikslumo santykį (toliau – AR) galima apskaičiuoti pagal šią formulę (ONB 2004; BCBS 2005a; Tache 2006; Fritz ir kt. 2006; SAS 2008, 2009):

$$AR = 2 \cdot AUC - 1.$$

Šie du rodikliai iš esmės rodo tą patį, jų reikšmės yra susijusios tiesine priklausomybe. Yra laikoma, kad modelis diskriminuoja blogai, kai AR yra mažesnis nei 40 % (o AUC – mažesnis nei 70 %), tačiau jei šie rodikliai yra mažesni atitinkamai nei 0 ir 50 %, diskriminacijos iš viso nėra (žr. 9 lent.). Siekdamas būti visiškai tikras, bankas gali apskaičiuoti pasikliautinusius AR ir AUC intervalus ir patikrinti, ar apatinė AR ir AUC intervalo riba nėra mažesnė atitinkamai nei 0 ir 50 % (žr. Engelmann ir kt. 2003a, b).

9 lentelė. AUC ir AR interpretacija

AUC	AR	Diskriminacijos kokybė
$0\% < AUC < 50\%$	$AR < 0\%$	Nėra diskriminacijos
$50\% \leq AUC < 70\%$	$0\% \leq AR < 40\%$	Bloga diskriminacija
$70\% \leq AUC < 80\%$	$40\% \leq AR < 60\%$	Priimtina diskriminacija
$80\% \leq AUC < 90\%$	$60\% \leq AR < 80\%$	Puiki diskriminacija
$90\% \leq AUC < 100\%$	$80\% \leq AR < 100\%$	Išskirtinė diskriminacija

Šaltinis: SAS (2009).

ONB (2004) atlikto tyrimo rezultatai parodė, kad ekspertinių vertinimo balais modelių su kokybiniais įvesties kintamaisiais AR dažniausiai būna mažesnis nei 50 %, o statistinių vertinimo balais modelių AR būna gerokai didesnis (žr. 10 lent.).

10 lentelė. Praktikoje pasiekiami AR

Statistinis metodas	AR
Vienfaktoriniai modeliai (atskiri balanso / pelno (nuostolių) ataskaitos straipsniai)	Taikant atskirus balanso / pelno (nuostolių) ataskaitos straipsnius, AR gali būti 30–40 %, o specifinėse imtyse – net 55 %
Ekspertiniai modeliai (klausymynai, kokybinio vertinimo sistemos)	Dažniausiai $AR < 50\%$
Opcionų įkainojimo modeliai	Vertinant įmones, kurių akcijos yra kotiruojamos vertybinių popierių biržose, AR būna $> 65\%$
Daugiafaktoriniai modeliai (diskriminantinė analizė ir logistinė regresija)	Praktinių modelių su kiekybiniais įvesties kintamaisiais AR yra apytikriai 60–70 %
Daugiafaktoriniai modeliai su kiekybiniais ir kokybiniais įvesties kintamaisiais	Praktinių modelių su kiekybiniais ir kokybiniais įvesties kintamaisiais AR yra 70–80 %
Dirbtiniai neuroniniai tinklai	Gali būti iki 80 %, tačiau praktikoje sunku pasiekti .

Šaltinis: ONB (2004).

Informacijos vertės metodas gali būti taikomas tiek vertinant individualią įvesties kintamųjų, tiek viso modelio diskriminacinę galią. Kuo didesnė modelio informacijos vertė, tuo didesnė jo diskriminacinė galia.

Briero balas yra apskaičiuojamas pagal šią formulę (ONB 2004; BCBS 2005a; Tasche 2006; SAS 2009):

$$\frac{1}{n} \sum_{i=1}^n (PD_i - \theta_i)^2,$$

čia: PD_i – i skolininko PD; θ_i – 1, jei i skolininkas tapo „blogas“, arba 0, jei i skolininkas tapo „geras“; i kinta nuo 1 iki n ; n – skolininkų skaičius.

Kuo mažesnis Briero balas, tuo didesnė modelio diskriminacinė galia. Matyti, kad šis metodas labiau tinka PD leidžiančių įvertinti statistinių vertinimo balais modelių diskriminacinei galiai vertinti, nes reikia žinoti skolininkų individualias PD. Tačiau metodas gali būti taikomas ir kai yra individualių PD neleidžiantis apskaičiuoti modelis. Tada i skolininko individuali PD formulėje yra pakeičiama reitingo, kuriam yra priskirtas i skolininkas, PD.

Reitingų skalės analizė. Ji yra atliekama kuriant reitingų skalę (žr. 1.1.2 dalį).

Stabilumo analizė. Yra vertinami atitinkami pokyčiai laikui bėgant arba, naudojant skirtingas imtis, pavyzdžiui, gali būti lyginama modelio diskriminacinė galia prieš pradėdant taikyti modelį ir po metų, įtraukiant duomenis apie naujus banko skolininkus, arba modelio diskriminacinė galia gali būti lyginama naudojant kūrimo imties ir patikimumo vertinimo imties duomenis. Jeigu modelio diskriminacinė galia gerokai sumažėjo, vadinasi, dabartiniai banko skolininkai (ar patikimumo vertinimo imties skolininkai) nereprezentuoja tų skolininkų, kurių duomenys buvo naudoti modeliui kurti. Kai modeliui kurti taikomas statistinis metodas pasižymi didele „persimokymo“ rizika, dažnai sukurtas modelis puikiai diskriminuoja kūrimo imties skolininkus, bet kur kas prasčiau – patikimumo vertinimo imties skolininkus. Modelio AR naudojant skirtingas imtis (ar skirtingais metais) neturėtų skirtis daugiau kaip dešimčia procentinių punktų (o AUC – daugiau kaip penkiais procentiniais punktais). Be to, bankas, siekdamas nustatyti, ar modelio AUC vienais metais (ar naudojant kūrimo imties duomenis) statistiškai reikšmingai skiriasi nuo modelio AUC kitais metais (ar naudojant patikimumo vertinimo imties duomenis), gali taikyti specialų kriterijų (žr. Engelmann ir kt. 2003a, b).

Bankas turėtų reguliariai sudaryti reitingų pasikeitimo matricas ir vertinti jų savybes, pavyzdžiui, gali būti skaičiuojamas matricų mobilumo indeksas, bankas gali nustatyti, ar matrica yra monotoniška (ar reitingų pasikeitimų procentinės dalys didėja nuosekliai iki įstrižainės, o paskui nuosekliai mažėja), ar matricos reikšmės jos viršutinėje dalyje nėra didesnės nei apatinėje dalyje arba atvirkščiai, bei pokyčių priežastis (blogėjančios

makroekonominės sąlygos, banko strategijos ir kreditavimo standartų pokyčiai ir t. t.) (Bank of Japan 2005; Sun, Wang 2007).

Analizuodamas reitingų skalės stabilumą, bankas turėtų įvertinti, ar yra laikomasi tų pačių principų, kuriais buvo vadovautasi kuriant reitingų skalę, t. y. ar naudojant naujų banko skolininkų duomenis reitingų skalė išlieka monotoniška, ar koncentracija nėra pernelyg didelė ir pan. Taip pat galima palyginti to paties reitingo ODF naudojant naujus duomenis ir modeliui kurti naudotus duomenis. Thomas ir kt. (2002) rekomenduoja apskaičiuoti skolininkų stabilumo indeksą. Šio indekso reikšmė, mažesnė nei 0,1, rodo, kad dabartinių banko skolininkų skirstinys pagal reitingus atitinka tų skolininkų, kurių duomenys buvo naudoti modeliui kurti, skirstinį pagal reitingus. Reikšmė intervale nuo 0,1 iki 0,25 rodo, kad derėtų smulkiau išanalizuoti įvesties kintamųjų reikšmių skirstinių poslinkius. O reikšmė, viršijanti 0,25, rodo, kad dabartinių banko skolininkų skirstinys pagal reitingus reikšmingai skiriasi nuo tų skolininkų, kurių duomenys buvo naudoti modeliui kurti, skirstinio pagal reitingus, ir yra rekomenduojama modelį pakoreguoti.

Atlikdamas įvesties kintamųjų stabilumo analizę, bankas turėtų įvertinti, kaip pasikeitė individuali įvesties kintamųjų diskriminacinė galia, taip pat skolininkų kiekvienoje įvesties kintamojo reikšmių grupėje dalis ir pan.

Lyginamoji analizė. Bankas turėtų palyginti savo reitingus (ar vertinimo balus) su lyginamaisiais reitingais (ar vertinimo balais). Pavyzdžiui, bankas gali kartą per metus iš išorinio paskolų registro įsigyti tam tikros reikšmingo dydžio skolininkų imties išorės reitingus, palyginti juos su savo nustatytais tų pačių skolininkų vidaus reitingais ir apskaičiuoti ryšio tarp išorės ir vidaus reitingų koeficientus (pvz., Spirmeno ir Kendalo ranginės koreliacijos koeficientus) (BCBC 2005a; Jacobson ir kt. 2006; Hornik ir kt. 2006).

1.3.3. Reitingų įsipareigojimų neįvykdymo tikimybės patikimumo vertinimas

PD kalibravimo tikslumo vertinimas. Populiariausi PD kalibravimo tikslumo vertinimo metodai yra binominiai, normalieji, Hosmerio ir Lemešou kriterijai, eismo šviesos metodas (ONB 2004; BCBS 2005a; Boegelein 2006; Tasche 2006; Burgt 2007; SAS 2008, 2009), šiuos metodus rekomenduoja taikyti ir Lietuvos bankas (2006b). PD kalibravimo tikslumui vertinti gali būti taikomas ir Briero balų metodas, tada skolininko individuali PD formulėje yra pakeičiama reitingo, kuriam yra priskirtas tas konkretus skolininkas, PD.

Taikant ONB (2004), BCBS (2005a), SAS (2008, 2009) pasiūlytą binominį (vienpusį) kriterijų, kad reitingo PD būtų laikoma tikslia, turi galioti ši sąlyga, t. y. H_0 hipotezei, kai

pasiklovimo lygmuo γ , priimti apskaičiuotas pasiklovimo lygmuo turi būti ne didesnis už pasirinktą pasiklovimo lygmenį γ :

$$\sum_{n=0}^{D_i} \left[\binom{N_i}{n} \cdot PD_i^n \cdot (1 - PD_i)^{N_i-n} \right] \leq \gamma,$$

čia: PD_i – i reitingo PD; D_i – faktinių „blogų“ i reitingo skolininkų skaičius; N_i – i reitingo skolininkų skaičius; H_0 hipotezė šiame ir kituose kriterijuose – reitingo PD yra tiksli, o H_1 alternatyva šiame ir kituose vienpusiuose kriterijuose – reitingo PD yra per maža.

Šis kriterijus ypač tinka, kai atskiruose reitinguose yra mažai skolininkų ir yra maži reitingų ODF. Tačiau kai N_i yra didelis, o $PD_i \cdot N_i > 5$ ir $(1 - PD_i) \cdot N_i > 5$, tai, remiantis centrine ribine teorema, galima taikyti binominį (vienpusį) kriterijų su normaliaja aproksimacija, t. y. H_0 hipotezei, kai pasiklovimo lygmuo γ , priimti turi galioti ši sąlyga:

$$ODF_i \leq PD_i + \Phi^{-1}(\gamma) \cdot \sqrt{\frac{PD_i \cdot (1 - PD_i)}{N_i}},$$

čia: $\Phi^{-1}()$ – atvirkštinė standartinio normaliojo dydžio pasiskirstymo funkcija.

Taikant binominį (Voldo) kriterijų yra vertinama, ar apskaičiuota reitingo PD patenka į tam tikrą ODF intervalą, kai pasirinktas pasiklovimo lygmuo γ . H_1 alternatyva šiame ir kituose dvipusiuose kriterijuose – reitingo PD yra arba per maža, arba per didelė. H_0 hipotezei, kai pasiklovimo lygmuo γ , priimti apskaičiuota i reitingo PD turi patekti į šį intervalą (Burgt 2007):

$$\left[ODF_i - \Phi^{-1}\left(\frac{1+\gamma}{2}\right) \cdot \sqrt{\frac{ODF_i \cdot (1-ODF_i)}{N_i}}; ODF_i + \Phi^{-1}\left(\frac{1+\gamma}{2}\right) \cdot \sqrt{\frac{ODF_i \cdot (1-ODF_i)}{N_i}} \right].$$

Taikant ONB (2004) pasiūlytą normalųjį (dvipusį) kriterijų, H_0 hipotezei, kai pasiklovimo lygmuo γ , priimti turi galioti ši sąlyga:

$$|ODF_i - PD_i| \leq \Phi^{-1}\left(\frac{\gamma+1}{2}\right) \cdot \sqrt{\frac{PD_i \cdot (1 - PD_i)}{N_i}}.$$

Gali būti taikomas ir ilgo laikotarpio normalusis kriterijus (Blochwitz ir kt. 2004; BCBS 2005a; SAS 2009). H_0 hipotezei, kai pasiklovimo lygmuo γ , priimti turi galioti ši sąlyga:

$$\frac{\sum_{i=1}^T (ODF_i - PD_i)}{\sqrt{T}\tau} < \Phi^{-1}(\gamma); \tau^2 = \frac{1}{T-1} \left(\sum_{i=1}^T (ODF_i - PD_i)^2 - \frac{1}{T} \left(\sum_{i=1}^T (ODF_i - PD_i) \right)^2 \right),$$

čia: τ – standartinis nuokrypis; t – metai, t kinta nuo 1 iki T ; T – metų, naudojamų vertinant PD kalibravimo tikslumą, skaičius.

Šie kriterijai yra kritikuojami dėl to, kad juos taikant galima įvertinti tik kiekvieno atskiuro reitingo PD kalibravimo tikslumą, tačiau vienas bendras visų reitingų rodiklis nėra skaičiuojamas. O taikant Hosmerio ir Lemešou (toliau – H ir L) kriterijų, bendrai visiems reitingams yra apskaičiuojama χ^2 reikšmė ir statistikos p reikšmė su k laisvės laipsniais (BCBS 2005a; Boegelein 2006; Tache 2006; SAS 2008, 2009):

$$\chi^2 = \sum_{i=1}^n \left(\frac{(G_i - TG_i)^2}{TG_i} + \frac{(B_i - TB_i)^2}{TB_i} \right),$$

čia: G_i – faktinis „gerų“ i reitingo skolininkų skaičius; TG_i – tikėtinas „gerų“ i reitingo skolininkų skaičius, lygus $(G_i + B_i) \cdot (1 - PD_i)$, čia PD_i yra i reitingo PD, kurios kalibravimo tikslumą reikia įvertinti, ir B_i – faktinis „blogų“ i reitingo skolininkų skaičius; TB_i – tikėtinas „blogų“ i reitingo skolininkų skaičius, lygus $(G_i + B_i) \cdot PD_i$; i kinta nuo 1 iki n ; n – reitingų skaičius.

Taikant H ir L kriterijų, kad visų reitingų PD būtų laikomos tikslomis (t. y. H_0 hipotezei, kai pasirinktas pasiklovimo lygmuo γ , priimti) statistikos p reikšmė turi būti ne mažesnė už reikšmingumo lygmenį α . Lyginant tarpusavyje keliais skirtingais metodais apskaičiuotas PD, patikimesniu yra laikomas tas metodas, kurio χ^2 reikšmė yra mažesnė (o statistikos p reikšmė – didesnė)²⁹. Paprastai šį kriterijų yra rekomenduojama taikyti, kai i reitingo skolininkų skaičius N_i yra pakankamai didelis, t. y. kai yra tenkinamos šios sąlygos:

$$PD_i \cdot N_i > 5; (1 - PD_i) \cdot N_i > 5.$$

Taikant pirmiau aprašytus kriterijus yra daroma prielaida, kad tapsmo „blogais“ skolininkais atvejai yra tarpusavyje nepriklausomi, t. y. koreliacija yra lygi 0. Yra pasiūlyta keletas kriterijų, kuriuos taikant atsižvelgiama į koreliaciją (žr. ONB 2004; BCBS 2005a; SAS 2009), tačiau tuomet kriterijai tampa mažiau konservatyvūs, nes yra taikomi platesni intervalai, į kuriuos turi patekti reitingo PD ar ODF, kad PD būtų laikoma tikslia. Pavyzdžiui, taikant binominį (vienpusį) kriterijų (su normaliaja aproksimacija), jeigu įtraukiame koreliaciją ρ , PD dispersija yra didesnė, t. y. H_0 hipotezei, kai pasiklovimo lygmuo γ , priimti turi galioti ši sąlyga:

$$ODF_i \leq PD_i + \Phi^{-1}(\gamma) \cdot \sqrt{\frac{PD_i \cdot (1 - PD_i) + \rho \cdot (N_i - 1) \cdot PD_i \cdot (1 - PD_i)}{N_i}}.$$

Išplėstinis eismo šviesos metodas, kaip ir H ir L kriterijus, gali būti taikomas bendrai visų reitingų PD kalibravimo tikslumui vertinti vienais metais, be to, gali būti taikomas vieno reitingo PD kalibravimo tikslumui vertinti ilgu laikotarpiu. Kai yra daugiau nei keturi

²⁹ Reikšmės yra interpretuojamos priešingai nei tuo atveju, kai χ^2 suderinamumo kriterijus yra taikomas įvesties kintamiesiems analizuoti ar reitingų skalei sudaryti.

reitingai, šio metodo taikyti nerekomenduojama (Blochwitz ir kt. 2004, 2005; BCBS 2005a; Blochwitz 2008). Todėl šis metodas nebuvo taikomas praktiškai (žr. 3.2 dalį).

Stabilumo analizė. Bankas turėtų nustatyti, kokią įtaką skaičiuojant PD naudotų duomenų, parametru ir daromų prielaidų arba apskaičiavimo metodų pokyčiai daro PD (pvz., taikant LDP reitingų PD apskaičiavimo metodus galima įtraukti koreliaciją arba jos neįtraukti, naudoti skirtingus koreliacijos ir pasiklivimo lygmens dydžius) (Lietuvos bankas 2006b).

Lyginamoji analizė. Bankas gali savo vidines reitingų PD palyginti su išorinėmis tos pačios paskolų rūšies reitingų PD, tačiau tuomet reikia atsižvelgti į galimus reitingų skalių skirtumus (reitingų skaičių, apatinę ir viršutinę PD ribas) ir kitus skirtumus.

Atliekant pakartotinį patikimumo vertinimą, kaip ir atliekant išankstinį patikimumo vertinimą, yra siūloma laikytis šios eigos: diskriminacinės galios vertinimas → PD kalibravimo tikslumo vertinimas → reitingų sistemos stabilumo vertinimas (ONB 2004; BCBS 2005a; Banca D'Italia 2006). Įvesties kintamųjų ir lyginamąją analizę yra siūloma atlikti pabaigoje, jų rezultatai gali padėti surasti taisytinas reitingų sistemos vietas. Tačiau lyginamoji analizė gali būti atliekama ir kaip atskira diskriminacinės galios ir PD kalibravimo tikslumo vertinimo dalis (t. y. grįžtamasis patikrinimas + lyginamoji analizė³⁰). Kai grįžtamajam patikrinimui atlikti nepakanka istorinių duomenų, diskriminacinė galia ir PD kalibravimo tikslumas gali būti vertinami vien tik lyginamosios analizės būdu. Lietuvos bankas reikalauja, kad IRB metodą taikantys bankai reguliariai vertintų savo reitingų sistemų patikimumą. Netgi tie bankai, kurie IRB metodo netaiko, turi *mutatis mutandis* laikytis Lietuvos banko keliamų patikimumo vertinimo reikalavimų (Lietuvos bankas 2006b, 2008).

³⁰ Grįžtamasis patikrinimas (angl. *backtesting*) – patikimumo vertinimo metodų grupė, kai prognozuotos vidinės banko reikšmės yra lyginamos su faktinėmis vidinėmis reikšmėmis, o lyginamoji analizė (angl. *benchmarking*) – patikimumo vertinimo metodų grupė, kai prognozuotos vidinės reikšmės yra lyginamos su išorinėmis reikšmėmis.

II. STATISTINIŲ VERTINIMO BALAIS MODELIŲ TAIKYMAS

LIETUVOS BANKUOSE

Siekiant išsiaiškinti vertinimo balais modelių taikymo mažmeninių paskolų paraiškoms vertinti mastą ir ypatumus, 2008 m. sausį–lapkritį buvo atlikta šalyje veikiančių komercinių bankų ir užsienio bankų skyrių apklausa. Ji buvo atlikta elektroniniu paštu – visų bankų kredito rizikos valdymo specialistams autorė išsiuntė savo sudarytą standartizuotą anketą (žr. 6 priedą). Apklausoje savanoriškai sutiko dalyvauti devyni bankai (aštuoni komerciniai ir vienas užsienio banko skyrius).

Atliekant bankų apklausą, buvo tiriami ne tik statistinių, bet ir ekspertinių bei mišrių vertinimo balais modelių kūrimo, taikymo ir patikimumo vertinimo aspektai, kurie gali būti pravartūs kuriant statistinius vertinimo balais modelius. Kadangi bankams yra daug svarbiau nesuteikti paskolų rizikingiems skolininkams, o ne reguliariai vertinti jau suteiktų paskolų riziką, t. y. jie daugiau dėmesio skiria paraiškų, o ne elgsenos modeliams, šis tyrimas buvo orientuotas tik į paraiškų modelius. Tačiau jo rezultatai gali būti naudingi ir elgsenos modelius kuriantiems bankams. Atliekant bankų apklausą, buvo siekiama iširti:

- kokie kriterijai ir kiek jų yra taikoma priskiriant paskolas mažmeninių paskolų grupei;
- ar bankas taiko statistinius vertinimo balais modelius, kokia jų aprėptis;
- kokie modeliai kokioms paskolų rūšims yra taikomi, jei netaikomi statistiniai vertinimo balais modeliai – kodėl;
- kokie duomenys ir įvesties kintamieji naudojami kuriant statistinius vertinimo balais modelius;
- ar banke yra taikomi ekspertiniai ir mišrūs vertinimo balais modeliai, kokia jų aprėptis;
- jei banke yra taikomi ekspertiniai ir (ar) mišrūs vertinimo balais modeliai, kokie yra naudojami įvesties kintamieji; taip buvo siekiama nustatyti, į kokius kriterijus bankas atkreipia dėmesį, vertindamas skolininką (ar paskolą), ir šią patirtį panaudoti kuriant statistinį Lietuvos įmonių vertinimo balais modelį;
- kokių lygiu – paskolos ar skolininko – vertinimo balais modeliai yra taikomi;
- ar patronuojamame banke yra taikomi tokie patys kaip patronuojančiame banke statistiniai vertinimo balais modeliai, duomenys ir pan.;
- kokie banke yra taikomi vertinimo balais modelių patikimumo vertinimo metodai;
- kokiose banko veiklos srityse sukurti vertinimo balais modeliai yra taikomi;
- kokie yra numatomi vertinimo balais modelių taikymo pokyčiai.

Šiame skyriuje iš pradžių yra aptariami paskolų priskyrimo mažmeninių paskolų grupei kriterijai, paskui yra analizuojamos bankuose taikomų mažmeninių paraiškų vertinimo balais modelių rūšys, 2.3 dalyje yra nagrinėjami šių modelių įvesties kintamieji, o 2.4 dalyje – modelių patikimumo vertinimo metodai, taikymo sritys ir numatomi taikymo pokyčiai.

2.1. PASKOLŲ PRISKYRIMO MAŽMENINIŲ PASKOLŲ GRUPEI KRITERIJAI

Aštuoni bankai, priskirdami paskolas mažmeninių paskolų grupei, taikė visos paskolos sumos limitą, t. y. šiai grupei priskyre tik tas paskolas, kurių visa suma neviršija tam tikro paties banko nusistatyto dydžio, ir tik vienas bankas tokio limitu netaikė (žr. 11 lent.). Net keturi bankai taikė didesnę nei 700 tūkst. litų limitą, tik dviejų bankų taikomas visos paskolos sumos limitas nesudarė nė 100 tūkst. litų.

11 lentelė. Bankų taikomi visos paskolos sumos limitai

Visos paskolos sumos limitas, Lt	Netaikomi papildomi kriterijai įmonėms	Taikomi papildomi kriterijai įmonėms	Iš viso
<= 100 000	1 bankas	1 bankas	2 bankai
(100 000–300 000]	–	–	–
(300 000–500 000]	–	1 bankas	1 bankas
(500 000–700 000]	1 bankas	–	1 bankas
> 700 000	1 bankas	3 bankai	4 bankai
Netaikomas	1 bankas	–	1 bankas
Iš viso	4 bankai	5 bankai	

Šaltinis: sudaryta autorės.

Dauguma apklaustų bankų, taikiusių didžiausią visos paskolos sumos limitą, mažmeninių paskolų grupei priskirdami įmonių paskolas, taikė papildomus kriterijus.

Iš keturių papildomų kriterijų netaikiusių bankų net trys įmonių paskolų šiai grupei nepriskyre, nustatytą visos paskolos sumos limitą taikė tik fiziniams asmenims. Ketvirtasis papildomų kriterijų netaikęs bankas kapitalo poreikiui skaičiuoti tuo metu taikė IRB metodą, taigi, jis turėjo visos paskolos sumos limitą taikyti smulkiojo ir vidutinio verslo subjektams³¹. Šis bankas niekaip kitaip, išskyrus visą paskolos sumą, smulkiojo ir vidutinio

³¹ Tas IRB metodą pasirinkęs bankas vertinimo balais modelius taikė mažmeninių paskolų kapitalo poreikiui skaičiuoti, todėl paskolas turėjo grupuoti laikydamasis Lietuvos banko reikalavimų, t. y. jis turėjo nustatyti visos paskolos sumos limitą ir prie mažmeninių paskolų priskirti tik tas smulkaus ir vidutinio verslo subjektų paskolas, kurių visa suma neviršija šio limitu. O IRB metodo netaikantys bankai vidaus tikslais visų įmonių paskoloms vertinti gali taikyti tą patį modelį.

verslo subjektų neapibrėžė. Kiti trys papildomų kriterijų netaikė bankai IRB metodo netaikė, jie visų įmonių paskoloms vertinti taikė tą patį modelį, neatsižvelgdami nei į visą paskolos sumą, nei į įmonės dydį.

Nustatydami, kokių įmonių paskolos bus priskiriamos mažmeninių paskolų grupei, bankai vidaus tikslais gali taikyti ir bankų priežiūros institucijos nustatytojo neatitinkantį visos paskolos sumos limitą. Pavyzdžiui, jie gali nustatyti 5 mln. litų limitą, tačiau skaičiuodami kapitalo poreikį vis tiek turėtų taikyti 1 mln. eurų ribą³². Iš penkių papildomus kriterijus įmonių paskoloms taikiusių bankų tik vienas taikė IRB metodą, tačiau ir kiti keturi įmonių paskolas diferencijavo – dalį jų priskyrė mažmeninių paskolų grupei.

12 lentelė. Įmonėms taikomi papildomi kriterijai

Kriterijus	Kriterijų taikančių bankų skaičius
Įmonės pardavimo pajamos, Lt	
<= 100 000	–
(100 000–300 000]	–
(300 000–500 000]	–
(500 000–700 000]	1 bankas
> 700 000	2 bankas
Iš viso	3 bankai
Įmonės turtas, Lt	
<= 100 000	–
(100 000–300 000]	–
(300 000–500 000]	–
(500 000–700 000]	1 bankas
> 700 000	3 bankai
Iš viso	4 bankai
Įmonės darbuotojų skaičius	
> 250	–
(100–250]	1 bankas
(50–100]	–
(10–50]	2 bankai
<= 10	–
Iš viso	3 bankai
Įmonės teisinė forma	
UAB	1 bankas

Šaltinis: sudaryta autorės.

³² Anksčiau Lietuvos bankas reikalavo, kad paskolas, siekiant apskaičiuoti kapitalo poreikį, priskiriant mažmeninių paskolų grupei, visa suma, kurią skolininkas ar tarpusavyje susijusių skolininkų grupė skolingi bankui, jo patrunuojančiajam bankui ir banko kontroliuojamoms finansų įmonėms, įskaitant pradelstas paskolas, bet neįskaitant paskolų arba galimų paskolų, užtikrintų įkeistu gyvenamosios paskirties nekilnojamoju turtu, neviršytų 1 mln. litų. Daugelyje kitų Europos Sąjungos šalių buvo taikoma 1 mln. eurų riba. Tačiau vėliau ir Lietuvos bankas minėtąjį limitą padidino iki 1 mln. eurų (žr. EP 2006; Lietuvos bankas 2006a).

Kaip matyti iš 12 lentelės, keturi Lietuvos bankai taikė įmonės turto kriterijų, trys – įmonės pardavimo pajamų, kiti trys – darbuotojų skaičiaus kriterijų. Tik viename banke buvo taikomas įmonės teisinės formos kriterijus, t. y. mažmeninių paskolų grupei buvo priskiriamos banko nustatyto visos paskolos sumos limito neviršijančios uždarujų akcinių bendrovių paskolos. Bankai buvo linkę taikyti aukštesnes pardavimo pajamų ir turto ribas: nė vienas bankas nebuvo nustatęs pardavimo pajamų ar įmonės turto limito, mažesnio nei 500 tūkst. litų.

Didesnė dalis apklausoje dalyvavusių bankų įmonėms teikiamas paskolas buvo linkę diferencijuoti, t. y. įmonių paskoloms, priskiriamoms mažmeninių paskolų grupei, vertinti jie taikė kitokius modelius. Taigi, kurdamas naujus statistinius vertinimo balais modelius įmonių mažmeninių paskolų rizikai vertinti, bankas į duomenų imtį turėtų įtraukti tik tam tikrus kriterijus atitinkančių įmonių paskolas, t. y. paskolas, suteiktas įmonėms, kurių pardavimo pajamos, turtas ar darbuotojų skaičius neviršija tam tikrų ribų. Šios ribos bankuose būna skirtingos. Nustatydami jas, bankai galėtų remtis tokiais pačiais pardavimo grynujų pajamų, turto ir darbuotojų skaičiaus rodikliais, kuriais yra remiamasi nustatant, ar įmonė gali pateikti sutrumpintas finansines ataskaitas³³. Tada kuriant modelį būtų galima apsiriboti tik tokiais finansiniais santykiniais rodikliais, kuriuos galima apskaičiuoti pagal sutrumpintas finansines ataskaitas. Tačiau būtina atsižvelgti ir į banko veiklos ypatumus: dideliame banke mažmeninių paskolų grupei gali būti priskiriamos ir paskolos, suteiktos įmonėms, kurių pardavimo grynosios pajamos, turtas ar darbuotojų skaičius reikšmingai didesni nei įmonių, galinčių pateikti sutrumpintas finansines ataskaitas, jeigu tokios įmonės yra smulkios, palyginti su kitomis to banko kredituojamomis įmonėmis. Be to, būtina aiškiai apibrėžti visos paskolos sumos limitą, kuris gali būti taikomas ne tik įmonių, bet ir fizinių asmenų paskoloms³⁴.

2.2. VERTINIMO BALAIS MODELIŲ RŪŠYS

Šalyje veikiančių komercinių bankų ir užsienio bankų skyrių apklausos rezultatai parodė, kad statistinius paraiškų vertinimo balais modelius taikė keturi bankai, du iš jų – tik fizinių asmenų paraiškoms vertinti (žr. 13 lent.). O ankstesnio tyrimo rezultatai, gauti

³³ Sudaryti sutrumpintą balansą, sutrumpintą pelno (nuostolių) ataskaitą, sutrumpintą aiškinamąjį raštą ir nesudaryti pinigų srautų ataskaitos gali įmonės, kurių ne mažiau kaip du rodikliai paskutinę finansinių metų dieną neviršija tam tikrų dydžių dvejus iš eilės finansinius metus. Įmonės pardavimo grynosios pajamos per ataskaitinius finansinius metus turi būti ne didesnės nei 10 mln. litų, balanse nurodyta turto vertė – ne didesnė nei 6 mln. litų, vidutinis metinis darbuotojų skaičius pagal sąrašą per ataskaitinius finansinius metus – ne didesnis nei 15 (LRS 2008).

³⁴ IRB metodą taikantys bankai, skaičiuodami kapitalo poreikį, visos paskolos sumos limitą turi taikyti tik įmonių paskoloms. Standartizuotą metodą taikantys bankai jį turi taikyti ir fizinių asmenų paskoloms (Lietuvos bankas 2006a). Tačiau IRB metodą taikantys bankai tiek kapitalo poreikiui skaičiuoti, tiek kitais tikslais visos paskolos sumos limitą gali pasirinktinai taikyti ir fizinių asmenų paskoloms. Pavyzdžiui, stambių įmonių reitingų sistema gali būti taikoma labai didelės paskolas paėmusiems fiziniams asmenims.

nagrinėjant šalyje veikusių bankų kredito rizikos valdymą (žr. Valvonis 2004), parodė, kad bent iki 2004 metų statistinių paskolų rizikos vertinimo modelių netaikė nė vienas iš šešių tuometiniame tyrime dalyvavusių bankų.

13 lentelė. Vertinimo balais modelių taikymo patirtis

Modelio rūšis	Įmonių paskolos	Fizinių asmenų paskolos	Iš viso ⁺
Statistiniai	2 bankai	4 bankai	4 bankai
Mišrūs	1 bankas	2 bankai	2 bankai
Ekspertiniai	6 bankai	6 bankai	6 bankai

Šaltinis: sudaryta autorės. ⁺Tas pats bankas kartu gali taikyti ir statistinius, ir mišrius, ir ekspertinius vertinimo balais modelius.

Abu bankai, taikę statistinius įmonių paraiškų modelius, juos taikė visoms įmonių paraiškų rūšims, jų neskirstydami (žr. 14 lent.). Tačiau fizinių asmenų paraiškoms vertinti skirtus modelius bankai buvo labiau linkę diferencijuoti: paskolas jie suskirstė pagal rūšis ir skirtingų rūšių paraiškoms vertinti kūrė atskirus modelius. Tokie modeliai gerokai skyrėsi tiek pagal įvesties kintamuosius ir jų skaičių, tiek pagal jų reikšmių grupes ir koeficientus (kai buvo įtraukti tokie patys įvesties kintamieji). Beje, ir kitų tyrimų rezultatai parodė, kad skirtingoms fizinių asmenų paskolų rūšims būna būdinga skirtinga rizika (žr. 1.1.1.3 dalį), todėl, jei bankas turi pakankamai duomenų, derėtų ir ateityje kiekvienai paskolų rūšiai kurti atskirą modelį.

14 lentelė. Statistinių modelių taikymas

	Įmonių paskolos			Fizinių asmenų paskolos				
	Investicinė s paskolos	Apyvartinių lėšų finansavimas, kredito linija	Vienas modelis visoms įmonėms	Būsto paskolos	Išperkamoji nuoma	Vartojimo paskolos	Kredito kortelės, kredito limitas	Vienas modelis visiems fiziniams asmenims
1 bankas	–	–	2 modeliai ⁺	1 modelis	1 modelis	–	1 modelis	1 modelis
2 bankas	–	–	–	–	–	–	–	1 modelis
3 bankas	–	–	1 modelis	–	–	–	–	1 modelis
4 bankas	–	–	–	–	–	1 modelis	–	–
Iš viso	–	–	3 modeliai	1 modelis	1 modelis	1 modelis	1 modelis	3 modeliai

Šaltinis: sudaryta autorės. ⁺Šiame banke vienas modelis buvo taikomas smulkiųjų, kitas – vidutinių įmonių paskoloms vertinti, tačiau modeliai pagal paskolos rūšį nebuvo diferencijuojami.

Vieno iš apklaustų bankų taikomi statistiniai paraiškų modeliai buvo sukurti taikant logistinę regresiją, kito – diskriminantinę analizę, dar du tokius modelius taikė bankai pasirinkto statistinio metodo nenurodė. Vienas jų kaip priežastį nurodė, kad modelis buvo sukurtas patronuojančiojo banko visos bankų grupės mastu, naudojant visos bankų grupės duomenis, todėl patronuojamasis bankas ir neturėjo informacijos apie tai, koks statistinis metodas buvo taikytas.

Atliekant apklausą, buvo užduotas klausimas, ar tokie patys statistiniai vertinimo balais modeliai yra taikomi ir Lietuvoje veikiančiame patronuojamame banke, ir visoje bankų grupėje. Du tokius modelius taikę bankai nebuvo patronuojamieji. Iš kitų dviejų viename buvo taikomi patronuojančiojo banko pateikti modeliai, sukurti naudojant visos bankų grupės duomenis, kito banko taikomi modeliai vieni buvo sukurti naudojant vietinio banko duomenis, kiti – naudojant visos bankų grupės duomenis, nes vietinio banko turimų duomenų atskiram modeliui sukurti neužteko. Tame banke tiek vieni, tiek kiti modeliai patronuojančiojo banko buvo sukurti taikant tą patį statistinį metodą – logistinę regresiją. Palyginus skirtingose šalyse veikiančių šios grupės bankų tos pačios paskolų rūšies modelius, pagrįstus tik vietiniais vienos ar kitos šalies duomenimis, matyti, kad tiek tarp modelių įvesties kintamųjų ir jų skaičiaus, tiek tarp jų reikšmių grupių ir koeficientų (kai buvo įtraukti tokie patys įvesties kintamieji) buvo gerokų skirtumų. Tai tik patvirtina įvairių autorių atliktų tyrimų rezultatus, kad naudojant skirtingų šalių duomenis sukurti tos pačios paskolų rūšies modeliai labai skiriasi (žr. 1.1.1.3 dalį), ir rodo, kad modelius geriau kurti naudojant vietinius duomenis: skirtingų šalių skolininkų savybės skiriasi, ir banko turimi vietiniai duomenys tos šalies skolininkus reprezentuoja daug geriau negu visos bankų grupės duomenys.

Vis dėlto nepakankama duomenų imtis skatino kurti statistinius modelius, skirtus keliems bankams. Kai tos rūšies paskolų vietiniame banke nepakako, siekiant didesnio modelio patikimumo, buvo naudojami kelių grupės bankų duomenys. Beje, apklausos metu Lietuvos bankų taikyti modeliai buvo sukurti naudojant ekonominio pakilimo laikotarpio duomenis (2004–2007 m.), todėl kai kurių paskolų rūšių modeliams sukurti nebūtų pakakę faktinių „blogų“ skolininkų. Įtraukus ir vėlesnių, ekonominio nuosmukio metus apimančių laikotarpių duomenis, ši problema bus ne tokia aktuali.

Statistinius modelius taikę du bankai juos kurdami naudojo ne tik vidinius, bet ir išorinius duomenis, gautus iš išorinių paskolų registrų, išieškojimo įmonių ir pan. Daugiau informacijos (įmonės registracijos data, darbuotojų skaičius, finansiniai duomenys, išorinė mokėjimų istorija) buvo perkama kuriant įmonių modelius. Kuriant fizinių asmenų modelius buvo perkami tik išorinės mokėjimų istorijos duomenys. Trečiojo statistinius modelius taikiusio banko modeliai buvo sukurti patronuojančiojo banko, naudojant visos bankų grupės duomenis, todėl vietinis bankas tiesiog neturėjo informacijos apie tai, ar buvo naudotasi patronuojančiojo banko šalies ar kitų šalių išoriniais paskolų registrais. Vis dėlto, išanalizavus į to banko taikomą modelį įtrauktus įvesties kintamuosius, matyti, kad išorinių paskolų registrų informacija nebuvo naudotasi. Ketvirtajame statistinius modelius taikiusiame banke išorinių paskolų registrų duomenys nebuvo naudoti.

Trijuose statistinius modelius taikiusiuose bankuose visi statistiniai modeliai buvo sukurti ir taikomi skolininko lygiu, t. y. buvo vertinama skolininko, o ne paskolos rizika. Ketvirtajame banke tik įmonių modeliai buvo sukurti ir taikomi skolininko lygiu, o fizinių asmenų modeliai – paskolos lygiu.

Mišrūs modeliai buvo taikomi dviejuose bankuose, viename jų – tik fizinių asmenų paraiškoms dėl vartojimo paskolų vertinti, kitame vienas modelis buvo taikomas įmonių, kitas – visų fizinių asmenų paraiškoms vertinti (žr. 15 lent.). Abiejų bankų mišrūs modeliai buvo taikomi skolininko lygiu.

15 lentelė. Mišrių modelių taikymas

	Įmonių paskolos			Fizinių asmenų paskolos				
	Investicinės paskolos	Apyvartinių lėšų finansavimas, kredito linija	Vienas modelis visoms įmonėms	Būsto paskolos	Išperkamoji nuoma	Vartojimo paskolos	Kredito kortelės, kredito limitas	Vienas modelis visiems fiziniams asmenims
1 bankas	–	–	1 modelis	–	–	–	–	1 modelis
2 bankas	–	–	–	–	–	1 modelis	–	–
Iš viso	–	–	1 modelis			1 modelis		1 modelis

Šaltinis: sudaryta autorės.

Plačiausiai Lietuvos bankuose buvo taikomi ekspertiniai modeliai (net šešiuose bankuose), be to, jie visi buvo taikomi tiek fizinių asmenų, tiek įmonių paraiškoms vertinti (žr. 16 lent.). Apklausa rezultatai parodė, kad bankai ekspertinių (kaip ir statistinių ar mišrių) modelių, skirtų įmonių paraiškoms vertinti, nediferencijavo pagal paskolų rūšis, todėl tas pats modelis buvo taikomas visoms įmonių mažmeninių paskolų rūšims arba įmonių paskoloms bendrai, nes, kaip jau minėta, trys bankai įmonių paskolų nepriskyrė mažmeninių paskolų grupei. Visi tie bankai pateko į šešių ekspertinius modelius taikiusių bankų grupę.

16 lentelė. Ekspertinių modelių taikymas

	Įmonių paskolos			Fizinių asmenų paskolos				
	Investicinės paskolos	Apyvartinių lėšų finansavimas, kredito linija	Vienas modelis visoms įmonėms	Būsto paskolos	Išperkamoji nuoma	Vartojimo paskolos	Kredito kortelės, kredito limitas	Vienas modelis visiems fiziniams asmenims
1 bankas	–	–	1 modelis	1 modelis	–	1 modelis	–	–
2 bankas	–	–	1 modelis	–	–	–	–	1 modelis
3 bankas	–	–	1 modelis	–	–	–	–	1 modelis
4 bankas	–	–	1 modelis	1 modelis			1 modelis	
5 bankas	–	–	1 modelis					1 modelis
6 bankas	–	–	1 modelis					2 modeliai ⁺
Iš viso	–	–	6 modeliai	2 modeliai	1 modelis	2 modeliai	1 modelis	5 modeliai

Šaltinis: sudaryta autorės. ⁺Bankas taiko skirtingus modelius rezidentams ir nerezidentams.

Visi bankai, išskyrus vieną, šiuos modelius taikė skolininko lygiu. Kita vertus, ekspertiniai modeliai, skirti fizinių asmenų paraiškoms vertinti, dažnai buvo skirstomi pagal paskolų rūšis, du bankai modelius taikė paskolos lygiu, kiti – skolininko lygiu.

2.3. VERTINIMO BALAIS MODELIŲ ĮVESTIES KINTAMIEJI

Šalyje veikę bankai, kurdami statistinius modelius, neįtraukė makroekonominių rodiklių, taip pat su įmonės ekonominės veiklos rūšimi ir padėtimi rinkoje susijusių rodiklių (žr. 7 priedo 1 lent.). Tačiau tai dar nerodo, kad tie modeliai nebuvo laiko momento modeliai, nes atliekant apklausą bankų nebuvo klausiama, ar jie kaip nors keičia taikomų modelių įvesties kintamuosius, be to, ir įvairių kitų įvesties kintamųjų, pavyzdžiui, finansinių rodiklių, reikšmės gali būti jautrios ekonominiam ciklui. Vieno banko naudojami įvesties kintamieji apėmė įvairesnę informaciją apie įmonę (darbuotojų skaičių, gyvavimo laiką, sąskaitų balansą, mokėjimų istoriją, finansinius rodiklius), kito – tik finansinius rodiklius.

Fizinių asmenų paraiškoms vertinti skirtuose statistiniuose modeliuose dažniausiai naudojami įvesties kintamieji buvo skolininko lojalumą bankui apibūdinantys rodikliai: ar skolininkas naudojasi kitais to paties banko produktais, ar jis tame banke turi turto, skolininko amžius, vidinė ir išorinė mokėjimų istorija. Taip pat dažnai buvo įtraukiami su kitais skolininko finansiniais išipareigojimais susiję rodikliai, grynosios pajamos vienam šeimos nariui, paskolos vertės likučio ir pajamų santykis, skolininko išsilavinimas.

Abu mišrius modelius taikę bankai kartu taikė ir statistinius modelius. Vieniems vidiniams procesams jie taikė tik statistinius, kitiems – mišrius modelius; pastarieji buvo sukurti statistinius modelius papildant tam tikrais įvesties kintamaisiais, kurių svoriai buvo nustatyti ekspertiniu būdu (žr. 7 priedo 2 lent.). Vienas bankas, vertindamas įmonių paraiškas, įtraukė įmonių ekonominės veiklos rūšies ir jų padėties rinkoje, verslo plano ir vadovų vertinimo rodiklius, o vertindamas fizinių asmenų paraiškas – informaciją apie skolininko lojalumą, finansinius išipareigojimus ir mokėjimų istoriją. Kitame banke iš išorinio paskolų registro buvo perkama informacija apie fizinių asmenų išorinę mokėjimų istoriją.

Ekspertinių modelių įvesties kintamųjų spektras buvo įvairesnis nei statistinių, nes kuriant ekspertinius modelius nereikia turėti sukaupus praeities duomenų (žr. 7 priedo 3 lent.). Į tris įmonių paraiškoms vertinti skirtus ekspertinius modelius buvo įtraukti makroekonominiai ir įmonių ekonominės veiklos rūšį apibūdinantys rodikliai, net į penkis – įmonės padėties rinkoje rodikliai (į statistinius modelius jie nebuvo įtraukti). Visi į anketos klausimus atsakę bankai naudojo gyvavimo laiko, išorinės ir vidinės mokėjimų istorijos rodiklius, trumpalaikio turto ir trumpalaikių išipareigojimų santykį. Bankai naudojo skirtingus finansinius santykinus rodiklius:

be minėtojo santykio, dažniausiai buvo naudoti turto gražos ir nuosavo kapitalo gražos, nuosavo kapitalo (arba išpareigojimų) ir turto santykio, apyvartinio kapitalo ir turto santykio, grynojo pelno (nuostolių) ir pardavimo pajamų santykio rodikliai.

Į ekspertinius modelius, skirtus fizinių asmenų paraiškoms vertinti, makroekonominiai rodikliai nebuvo įtraukti. Visi šeši bankai įtraukė informaciją apie grynąsias pajamas vienam šeimos nariui, skolininko amžių, šeiminei padėti, vaikų ir išlaikytinių skaičių, išsilavinimą, pareigas, vidinę mokėjimų istoriją. Kuriant ekspertinius modelius buvo naudoti tokie patys įvesties kintamieji, kaip ir statistiniams modeliams, nors pirmiesiems dažniau buvo naudota informacija apie skolininko šeiminei padėti, vaikų ir išlaikytinių skaičių, darbinės pareigas, gyvenamąją vietą (t. y. ar skolininkas turi nuosavą būstą, ar jį nuomoja ir pan.). Tikėtina, kad šie įvesties kintamieji buvo tikrinami ir visuose keturiuose statistinius modelius kūrusiuose bankuose, tik jie ne visais atvejais buvo įtraukti į modelius.

Palyginus į įmonių mažmeninių paskolų modelius (tiek į ekspertinius ir mišrius, tiek į statistinius) įtrauktus įvesties kintamuosius su į stambių įmonių paskolų modelius įtrauktais įvesties kintamaisiais (žr. Savickaitė, Valvonis 2007) matyti, kad pagrindiniai finansiniai santykiniai rodikliai buvo panašūs: dažniausiai buvo įtrauktas trumpalaikio turto ir trumpalaikių išpareigojimų, grynojo pelno (nuostolių) ir pardavimo pajamų, nuosavo kapitalo ir turto santykis, turto graža ir nuosavo kapitalo graža. Vis dėlto kuriant įmonių mažmeninių paskolų modelius mažiau dėmesio buvo skirta kokybiniais įvesties kintamiesiems, jie skyrėsi nuo tų, kurie buvo įtraukti į stambių įmonių paskolų modelius (sutapo tik kelios įvesties kintamųjų grupės, t. y. tiek į stambių įmonių paskolų modelius, tiek į įmonių mažmeninių paskolų modelius buvo įtraukti įvesties kintamieji, susiję su įmonės ekonominės veiklos rūšimi, jos padėtimi rinkoje, vadovų vertinimu), be to, įvesties kintamųjų buvo mažiau negu stambių įmonių paskolų modeliuose.

Tiek įmonių mažmeninių paskolų modeliuose, tiek fizinių asmenų paskolų modeliuose naudoti įvesties kintamieji buvo panašūs į tuos, kurie dažniausiai buvo nurodomi daugelio tokių modelių pateikiančių ir juos analizuojančių autorių (žr. 6 lent.). Kuriant fizinių asmenų modelius, dažniausiai buvo įtraukta informacija apie skolininko amžių, pajamas, šeiminei padėti, vaikų ir išlaikytinių skaičių, lojalumą skolinančiam bankui, mokėjimų istoriją. Kuriant įmonių mažmeninių paskolų modelius, dažniausiai buvo įtraukti turto gražos ir nuosavo kapitalo gražos, trumpalaikio turto ir trumpalaikių išpareigojimų, apyvartinio kapitalo ir turto santykio, gyvavimo laiko rodikliai. Tačiau šalyje veikiantys bankai į modelius neįtraukė turto ir pardavimo pajamų logaritminės transformacijos rodiklių, o jų paprastai įtrauktas grynojo pelno (nuostolių) ir pardavimo pajamų santykis nepateko tarp dažniausiai įvairių autorių sukurtuose modeliuose

naudotų rodiklių. Kuriant statistinius modelius šalyje veikiantiems bankams derėtų vertinti ne tik santykinius, bet ir absoliučius finansinius rodiklius, logaritmines jų transformacijas. Tokie rodikliai buvo įtraukti į išorės modelį, sukurtą naudojant Lietuvos įmonių duomenis (žr. III skyrių).

2.4. VERTINIMO BALAIS MODELIŲ PATIKIMUMAS IR JŲ TAIKYMO SRITYS

Modelių diskriminacinė galia ir PD kalibravimo tikslumas buvo vertinami tik keturiuose bankuose, skolininkų (paskolų) struktūra ir modelio stabilumas – penkiuose bankuose, o įvesties kintamųjų analizę atlikdavo tik du bankai. Tik viename iš visų Lietuvos bankų patikimumo vertinimo procesas apėmė visus keturis patikimumo vertinimo etapus (žr. 17 lent.).

Vertindami modelių diskriminacinę galią, šalyje veikę bankai taikė tokius metodus, kurie ir moksliniuose straipsniuose yra aptinkami dažniausiai, t. y. CAP ir ROC kreives (žr. 21 pav.). Juos taikyti rekomenduoja ir Lietuvos bankas (2006b). PD kalibravimo tikslumui nustatyti bankai taip pat buvo labiau linkę taikyti populiariausius ir Lietuvos banko (2006b) rekomenduojamus metodus (eismo šviesos metodą, H ir L ir binominius kriterijus), tačiau apskritai taikomų metodų įvairovė buvo didesnė.

Plačiausiai modelių patikimumo vertinimo metodus taikė IRB metodą įdiegę šalies bankai. Jie turėjo vertinti tiek savo taikomų modelių diskriminacinę galią, tiek PD kalibravimo tikslumą, skolininkų (paskolų) struktūrą bei stabilumą, įvesties kintamuosius (Lietuvos bankas 2006b). Tačiau ir IRB metodo netaikę bankai turi *mutatis mutandis* laikytis Lietuvos banko keliamų patikimumo vertinimo reikalavimų (Lietuvos bankas 2008)³⁵.

Banko modelių patikimumo vertinimas turėtų apimti visus keturis 17 lentelėje pateiktus etapus, nes tinkamai atliekamas jis padeda laiku nustatyti modelio trūkumus ir prireikus jį patobulinti. Tačiau kai IRB metodo netaikantis bankas neskaičiuoja skolininkų (paskolų) PD (reitingo ar individualių), jam kalibravimo tikslumo vertinimo metodų taikyti nėra prasmės. Pavyzdžiui, IRB metodo netaikantis bankas vidaus tikslais gali naudoti ekspertinį arba individualių PD neleidžiantį apskaičiuoti statistinį modelį. IRB metodo netaikantys bankai, taikantys ekspertinius modelius, atlikdami patikimumo vertinimą gali susidurti su problema, kaip apibrėžti „blogą“ skolininką³⁶. Pavyzdžiui, bankas, kuris nori įvertinti ekspertinio modelio diskriminacinę galią, visų pirma turi apibrėžti, koks skolininkas atliekant patikimumo vertinimą

³⁵ Vykdam apklaušą dar nebuvo išgaliojusios Lietuvos banko *Vidaus kontrolės ir rizikos vertinimo (valdymo) organizavimo nuostatos*, kuriomis remiantis, visi bankai turi reguliariai vertinti su kredito rizika susijusiuose procesuose taikomų metodų patikimumą vadovaudamiesi, kiek tinka, Lietuvos banko patvirtintomis *Patikimumo vertinimo ir jo tikrinimo nuostatomis*.

³⁶ Statistinius modelius taikantys bankai „blogą“ skolininko apibrėžimą turi pasirinkti jau kurdami modelį.

bus laikomas „blogu“. Bankams yra rekomenduojama pasirinkti įsipareigojimų neįvykdymo apibrėžimą įtraukiant mokėjimo termino pradelsimą daugiau kaip 90 kalendorinių dienų ir kitus tikėtino įsipareigojimų neįvykdymo požymius (žr. 1 lent.). Tačiau bankas gali taikyti ir kitus mokslinių straipsnių autorių dažnai naudojamus apibrėžimus (žr. 1.1.1.2 dalį).

17 lentelė. Patikimumo vertinimo metodai

Metodas	Taikymas
<i>Diskriminacinės galios vertinimo metodai:</i>	4 bankai
CAP kreivė	3 bankai
ROC kreivė	3 bankai
Briero balų metodas	–
I ir II rūšies klaidų tikimybių vidurkis	–
Entropija pagrįsti metodai (pvz., informacijos vertė)	–
Kiti metodai	–
<i>PD kalibravimo tikslumo vertinimo metodai:</i>	4 bankai
H ir L kriterijus	1 bankas
Binominiai kriterijai	1 bankas
Normalieji kriterijai	–
Eismo šviesos metodas	2 bankai
Koreliacijų modeliavimas	1 bankas
Patikimumo diagramos	1 bankas
Kiti metodai	1 bankas [†]
<i>Skolininkų (paskolų) struktūros ir stabilumo vertinimas:</i>	5 bankai
Reitingų pasikeitimo matricos	2 bankai
Stabilumo indeksas	1 bankas
Rizikos ir rinkos ciklų atitikimo analizė	1 bankas
Diskriminacinės galios stabilumo vertinimas	1 bankas
PD kalibravimo tikslumo pokyčių vertinimas	–
Skolininkų (paskolų) koncentracijos pagal reitingus analizė, koncentracijos laiko atžvilgiu analizė	4 bankai
Skolininkų (paskolų) skirstinio pagal reitingus monotoniškumo analizė	1 bankas
Kiti metodai	–
<i>Ivesties kintamųjų analizė</i>	2 bankai
<i>Kiti kiekybiniai metodai</i>	1 bankas

Šaltinis: sudaryta autorės. [†]Bankas, naudodamas savo ir kitų tos bankų grupės patronuojamųjų bankų duomenis, taikė lyginamosios analizės metodą.

Modelių taikymo Lietuvos bankuose sritys buvo pačios įvairiausios (žr. 18 lent.). Apklausos rezultatai parodė, kad net aštuoniuose bankuose modeliai buvo taikomi priimant sprendimus suteikti paskolą (nesuteikti paskolos), daugumoje bankų – kainodarai ir skaičiuojant vertės sumažėjimą. Kapitalo poreikiui skaičiuoti modelius taikė trys šalyje veikę bankai, tačiau tik du iš jų buvo pasirinkę IRB metodą. Todėl tikėtina, kad trečiasis bankas modelius taikė vertindamas vidaus kapitalo poreikį. Nė vienas bankas nenurodė, kad taikytų modelius kituose vidiniuose procesuose nei buvo nurodyta anketoje, pavyzdžiui, vykdydamas paskolų išieškojimą, atlikdamas testavimą nepalankiausiomis sąlygomis ar pan.

Ateityje bankai turėtų modelius vis labiau sieti su kitais procesais, pavyzdžiui, jeigu bankas, šiuo metu netaikantis IRB metodo, pradėtų jį taikyti, jo modeliai būtų naudojami ir skaičiuojant kapitalo poreikį. Be to, bankams, planuojantiems taikyti šį metodą, būtina laikytis Lietuvos banko reikalavimo: dar iki pateikdamas Lietuvos bankui prašymą leisti taikyti IRB metodą kapitalo poreikiui skaičiuoti bankas turi būti vidaus reitingų sistemas ne mažiau kaip trejus metus taikęs kitiems vidaus procesams (Lietuvos bankas 2006a).

18 lentelė. Modelių taikymo sritys

Procesas	Statistiniai modeliai	Mišrūs modeliai	Ekspertiniai modeliai	Iš viso
Kainodaros procesai	3 bankai	1 bankas	3 bankai	6 bankai
Vertės sumažėjimo apskaičiavimas	2 bankai	1 bankas	4 bankai	5 bankai
Sprendimų suteikti paskolą (nesuteikti paskolos) priėmimas	3 bankai	2 bankai	5 bankai	8 bankai
Kapitalo poreikio skaičiavimas	1 bankas	–	2 bankai	3 bankai
Strategijos numatymas	2 bankai	–	1 bankas	3 bankai
Kapitalo paskirstymas	–	–	–	–
Pelningumo ir efektyvumo vertinimas	2 bankai ⁺	1 bankas	2 bankai	3 bankai
Ataskaitų pateikimas	2 bankai	–	2 bankai	4 bankai
Kiti procesai	–	–	–	–

Šaltinis: sudaryta autorės. ⁺Vienas iš dviejų bankų atsakė, kad dar tik planuoja taikyti paties sukurtą statistinį modelį kapitalo paskirstymo, pelningumo ir efektyvumo vertinimo procesuose.

Visi statistinių modelių netaikę bankai nurodė, kad duomenų kaupimo laikotarpis būtų buvęs per trumpas, kad būtų galima sukurti statistinį modelį. Bankai paminėjo ir kitas priežastis: nepakankamą skolininkų (paskolų) imtį (2 bankai), naujas paskolų rūšis, apie kurias banke nebuvo kaupiama duomenų (2 bankai), informacijos apie rodiklius nepakankamumą (2 bankai), nepatikimus praeities duomenis (1 bankas), tai, kad taikant statistinius modelius būtų nepakankamas ekspertinio vertinimo vaidmuo (2 bankai).

19 lentelė. Numatomi modelių taikymo pokyčiai

Pokytis	Bankų skaičius
Planuojami taikyti nauji statistiniai modeliai	2 bankai
Planuojami taikyti nauji mišrūs modeliai	–
Planuojami taikyti nauji ekspertiniai modeliai	–
Planuojama tikslinti dabar taikomus modelius	5 bankai
įtraukiant vietinius duomenis	2 bankai
įtraukiant išorinių paskolų registrų duomenis	3 bankai
įtraukiant grupės duomenis	–
Planuojami kiti pokyčiai	–
Neplanuojama jokių pokyčių	3 bankai

Šaltinis: sudaryta autorės.

Nors statistiniai modeliai Lietuvos bankuose ir nebuvo plačiai paplitę, ne visi jų netaikę bankai ketino šiuos modelius įdiegti ateityje (žr. 19 lent.). Dauguma bankų tik ketino patikslinti savo taikomus modelius – įtraukti papildomų vietinių ar išorės duomenų. Matyti, kad Lietuvos bankuose padidėjo duomenų, perkamų iš išorinių paskolų registru, poreikis. Patikslinti taikomus modelius įtraukdami tokius duomenis planavo net trys bankai. Taip pat tikėtina, kad du bankai, planavę kurti naujus statistinius modelius, juos kurdami įtrauks išorinių paskolų registru informaciją.

III. LOGISTINĖS REGRESIJOS MODELIU PAGRĮSTA LIETUVOS ĮMONIŲ REITINGŲ SISTEMA

Šiame skyriuje sprendžiami du paskutiniai mokslinio tyrimo uždaviniai. Pirmojoje šio skyriaus dalyje yra aprašytas statistinio Lietuvos įmonių vertinimo balais modelio ir reitingų skalės kūrimas. Antrojoje dalyje rašoma, kaip buvo apskaičiuotos įmonių reitingų PD, įvertinti šioms PD apskaičiuoti taikyti metodai. Trečiojoje analizuojamos sukurtos Lietuvos įmonių reitingų sistemos taikymo Lietuvos bankuose galimybės.

3.1. STATISTINIO LIETUVOS ĮMONIŲ VERTINIMO BALAIS MODELIO IR REITINGŲ SKALĖS SUKŪRIMAS

3.1.1. Statistinis Lietuvos įmonių vertinimo balais modelis

Šioje dalyje yra aprašyti modeliuojant naudoti duomenys, pateiktas detalus modeliavimo proceso aprašymas, apimantis visus etapus: „blogos“ įmonės ir stebėjimo laikotarpio apibrėžimą, įmonių grupės ir statistinio metodo pasirinkimą, imties sudarymą, įvesties kintamųjų analizę, koeficientų apskaičiavimą ir išankstinį patikimumo vertinimą.

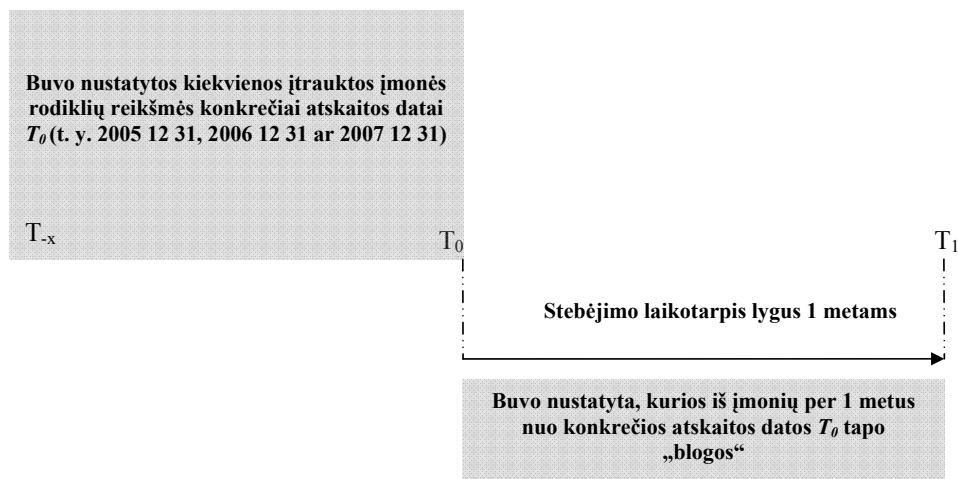
3.1.1.1. Duomenys

Iš išorinio paskolų registro UAB „Creditinfo Lietuva“ buvo gauti 2005–2008 metų Lietuvos įmonių visų ekonominės veiklos rūšių duomenys. UAB „Creditinfo Lietuva“ renka ir saugo informaciją apie įmonių gyvavimo laiką, vietą, teisinį statusą ir teisinę formą, ekonominės veiklos rūšį, metinę apyvartą, darbuotojų skaičių, vadovus, valdybos narius, patrunuojamąsias įmones ir filialus, pretenzijas, areštus ir teisinius procesus, bankrotus, skolas, įmonių pavadinimo ir adreso keitimus, spaudos reitingą, akcijas, užklausas dėl jų ir kitą informaciją iš bankų, išperkamosios nuomos ir telekomunikacijų, komunalinių paslaugų įmonių, viešųjų registrų ir t. t.

Kuriant modelį kiekviena įmonė buvo priskirta vienai iš dviejų galimų įmonių grupių: prie „gerų“ arba prie „blogų“. „Blogai“ įmonei apibrėžti buvo naudotas įsipareigojimų neįvykdymo požymis. Įsipareigojimų neįvykdymas buvo apibrėžtas kaip įmonės būklė, kai jos mokėjimai bent vienam bankui yra pradelsti daugiau kaip 90 kalendorinių dienų arba yra prasidėjęs įmonės bankroto procesas³⁷, t. y. „bloga“ buvo laikyta įmonė, atitikusi bent vieną

³⁷ Lietuvos banko teisės aktai pateikia šiek tiek platesnį įsipareigojimų neįvykdymo apibrėžimą (žr. 1 lent.). Tačiau UAB „Creditinfo Lietuva“ nekaupia informacijos apie paskolų persvarstymą, paskolų vertės tikslinimą, nemokumą ir kitus papildomus apibrėžiant įsipareigojimų neįvykdymą naudojamus požymius, todėl šioje disertacijoje buvo naudotas siauresnis apibrėžimas.

iš šių dviejų kriterijų: 1) įmonės mokėjimai bent vienam bankui yra pradelsti daugiau kaip 90 kalendorinių dienų; 2) yra prasidėjęs įmonės bankroto procesas. Konkreti įmonė buvo priskirta prie „blogų“, jeigu ji bent kartą neįvykdė išsipareigojimų per vienerių metų stebėjimo laikotarpį nuo atitinkamų metų pabaigos, t. y. nuo atskaitos datos T_0 (žr. 24 pav.). Vienerių metų stebėjimo laikotarpis buvo pasirinktas atsižvelgiant į pagal Naująjį kapitalo susitarimą parengtus Europos Sąjungos ir Lietuvos teisės aktus, be to, tokios trukmės stebėjimo laikotarpis buvo pasirenkamas dažniausiai (žr. 1.1.1.2 dalį).



24 pav. Įmonių duomenų rinkimo schema

Šaltinis: sudaryta autorės.

Buvo naudotos trys atskaitos datos: 2005 m. gruodžio 31 d., 2006 m. gruodžio 31 d. ir 2007 m. gruodžio 31 d. Nebuvo įtrauktos tos įmonės, kurios konkrečią atskaitos datą jau buvo „blogos“. Įmonių kreditingumą apibūdinančių rodiklių reikšmės buvo nustatytos konkrečiai atskaitos datai T_0 , tačiau rodikliai galėjo būti momentiniai (pvz., naudojant balansų duomenis apskaičiuoti finansiniai santykiniai rodikliai) arba laikotarpio x nuo T_{-x} iki T_0 (pvz., vidutinė pradelsimų per paskutinius metus trukmė). Tada buvo nustatyta, kurios įmonės per vienerius metus nuo konkrečios atskaitos datos T_0 tapo „blogos“. Sudarant duomenų masyvą, „blogomis“ tapusioms įmonėms buvo priskirtas faktinis išvesties kintamasis, lygus 1, o kitoms įmonėms – faktinis išvesties kintamasis, lygus 0.

Kiekvienių atskirų metų duomenys buvo sujungti į vieną bendrą duomenų masyvą, tolesnei analizei buvo naudoti „įmonių metai“, kai buvo pateikti visų trejų metų duomenys apie konkrečią įmonę, tai šios įmonės duomenys buvo „trigubinti“ ir naudoti kaip trijų atskirų įmonių duomenys. Bendras duomenų masyvas susidėjo iš 29 597 įrašų („įmonių metų“).

3.1.1.2. Modelio kūrimo metodika

Statistinio Lietuvos įmonių vertinimo balais modelio kūrimas apėmė kelis etapus: apibrėžus „blogą“ įmonę ir stebėjimo laikotarpį, buvo pasirinkta įmonių grupė ir statistinis metodas, sudarytos modelio kūrimo ir patikimumo vertinimo imtys, išanalizuoti įvesties kintamieji, jų reikšmės užkoduotos pseudokintamaisiais, apskaičiuoti įvesties kintamųjų koeficientai ir atliktas išankstinis patikimumo vertinimas.

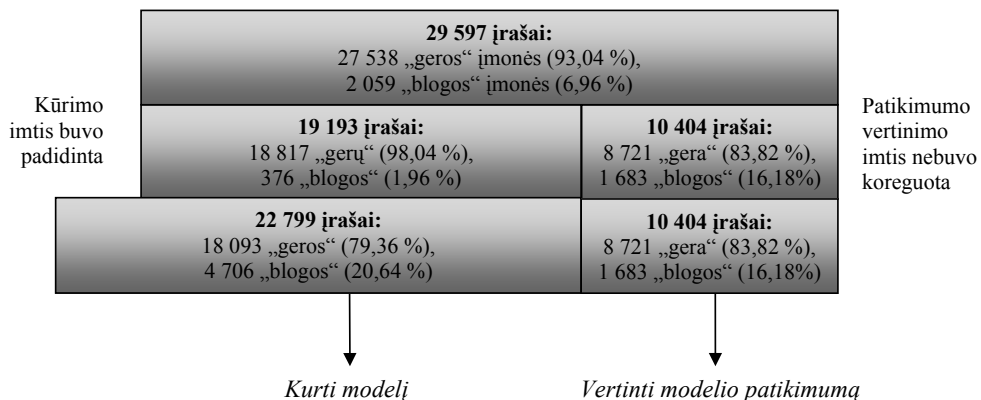
Įmonių grupės pasirinkimas. Lietuvos įmonių vertinimo balais modelis yra bendrasis (išorės) modelis, nes buvo naudoti ne vieno kurio nors banko, o daugelio bankų duomenys. Be to, buvo naudoti visų ekonominės veiklos rūšių įmonių duomenys, todėl modelis yra rekomenduojamas įvairių įmonių rizikai vertinti.

Modelis yra elgsenos, t. y. jį rekomenduojama taikyti reguliariai pakartotinai vertinant esamų skolininkų riziką. UAB „Creditinfo Lietuva“ nekaupia informacijos apie konkrečių paskolų suteikimo datas, taigi, nebuvo įmanoma sukurti paraiškų modelio. Kuriant modelį stebėjimo laikotarpis buvo nustatytas nuo atitinkamų metų pabaigos, o ne nuo paskolos suteikimo datos. Tačiau, nors modelis yra elgsenos (o ne paraiškų), jį galima taikyti ir teikiant paskolas.

Modelis buvo sukurtas įmonės (o ne paskolos) lygiu, t. y. jis yra skirtas vertinti įmonių, o ne atskirų jų paskolų riziką. Be to, modelis gali būti taikomas įvairių rūšių paskolas (investicines, apyvartinių lėšų finansavimo paskolas, kredito linijas ir kt.) imančioms įmonėms vertinti.

Statistinio metodo pasirinkimas. Buvo pasirinkta logistinė regresija, atsižvelgiant į jos pranašumus, palyginti su kitais statistiniais metodais (žr. 1.1.1.5 dalį). Buvo svarstyta ir kita alternatyva – išlikimo analizės modeliai, tačiau, atsižvelgiant į tai, kad nebuvo gauta informacijos apie datas, kada konkrečios įmonės tapo „blogos“, išlikimo analizės modeliai buvo atmesti. Be to, buvo gauti tik trejų metų duomenys, o taikant išlikimo analizę reikėtų turėti ilgesnio laikotarpio duomenis. Be to, įtraukus tik tas įmones, apie kurias buvo gauta visų trejų metų informacija, vis tiek būtų susidariusi pernelyg maža duomenų imtis.

Imties sudarymas. Bendras duomenų masyvas buvo išskaidytas į kūrimo imtį, susidedančią iš 19 193 įrašų (64,85 %, palyginti su bendru duomenų masyvu), ir patikimumo vertinimo imtį, susidedančią iš 10 404 įrašų (35,15 %, palyginti su bendru duomenų masyvu). Patikimumo vertinimo imties įrašai buvo atrinkti atsitiktiniu būdu. Kad patikimumo vertinimo imties ODF nebūtų pernelyg mažas, atsitiktiniu būdu iš bendro duomenų masyvo buvo atrinktos 1 683 faktinės „blogos“ įmonės; likusios patikimumo vertinimo imties įmonės – faktinės „geros“ įmonės (žr. 25 pav.). Patikimumo vertinimo imtis daugiau nebuvo koreguota ir buvo naudota tik jau sukurto modelio patikimumui vertinti.



25 pav. Kūrimo ir patikimumo vertinimo imtys

Šaltinis: autorės skaičiavimai.

Pradinėje kūrimo imtyje, susidedančioje iš 19 193 įrašų, buvo 18 817 faktinių „gerų“ įmonių ir 376 faktinės „blogos“ įmonės. Pradinė kūrimo imtis buvo pakoreguota, taikant kelis metodus:

- 1) Apskaičiuotas reikiamas imties dydis buvo palygintas su pradiniu imties dydžiu.

Reikiamam imties dydžiui n apskaičiuoti buvo taikyta ši formulė:

$$n = \left(\frac{\Phi^{-1}\left(\frac{\alpha}{2}\right) \cdot \sqrt{PD_{MAX}(1 - PD_{MAX})}}{\Delta PD} \right)^2,$$

čia: PD_{MAX} – viršutinė PD riba (pradinės kūrimo imties ODF buvo 1,96 %, tačiau siekiant konservatyvumo buvo pasirinkta šiek tiek didesnė PD_{MAX} – 2,4 %); α – reikšmingumo lygmuo, lygus 0,05; $\Phi^{-1}()$ – atvirkštinė standartinio normaliojo dydžio pasiskirstymo funkcija; ΔPD – procentinis PD paklaidos režis, lygus 20 bazinių punktų.

Sakykime, disertacijos autorė norėjo būti 95 % tikra, kad aritmetinis individualių pagal modelį apskaičiuotų PD vidurkis nenukryps nuo PD_{MAX} daugiau kaip 20 bazinių punktų. Tada reikiamas imties dydis, apskaičiuotas pagal formulę, buvo lygus 22 496. Galima pasakyti, kad apskaičiuotas reikiamas imties dydis viršijo pradinės kūrimo imties dydį, t. y. buvo tik 19 193 įmonės, nors reikėjo 22 496 įmonių.

- 2) Buvo analizuotos faktinių „gerų“ ir „blogų“ įmonių dalys ir nustatytos optimalios. Faktinės „geros“ įmonės sudarė 98,04 % visų pradinės kūrimo imties įmonių, o faktinės „blogos“ – 1,96 %. Kuriant logistinės regresijos modelį faktinės „blogos“ įmonės turėtų sudaryti bent 20 % visų įmonių. „Gerų“ ir „blogų“ įmonių dalims koreguoti buvo taikytas mišrus imties padidinimo ir sumažinimo metodas, t. y. faktinių

„gerų“ įmonių skaičius buvo sumažintas (kiekvienas 26-as įrašas buvo panaikintas), o faktinių „blogų“ įmonių skaičius – padidintas (kiekvienas įrašas buvo įtrauktas 12,516 karto). Po šių korekcijų buvo 18 093 „geros“ (79,36 %) ir 4 706 „blogos“ įmonės (20,64 %). Iš viso susidarė 22 799 įrašai, o tai netgi viršijo pagal formulę apskaičiuotą reikiamą imties dydį.

Įvesties kintamųjų analizė ir koeficientų apskaičiavimas. Modelyje esantys įvesties kintamieji buvo atrinkti trimis ciklais:

- Pirmajame cikle buvo sudaryti 57 įvesties kintamieji.
- Antrajame cikle iš jų, atsižvelgiant į keletą kriterijų (ekonominį pagrįstumą, monotoniškumą, individualią įvesties kintamojo diskriminacinę galią), buvo atrinkti 48 įvesties kintamieji.
- Trečiajame cikle 22 799 įrašai, susidedantys iš 48 įvesties kintamųjų kodinių reikšmių ir išvesties kintamojo reikšmių (0 arba 1), buvo suvesti į SPSS programą ir taikant progresinės atrankos (Voldo) procedūrą buvo sukurta iš 19 įvesties kintamųjų susidedanti logistinės regresijos lygtis.

Pirmasis ciklas: Iš pradžių buvo sudaryti 57 įvesties kintamieji, apibūdinantys visus įmonės bruožus (žr. 8 prieda): finansiniai santykiniai rodikliai, išorinės mokėjimų istorijos rodikliai, įmonės gyvavimo laikas, teisinė forma, dydis, apskritis, ekonominės veiklos rūšis, informacija apie įmonės vadovus, adreso ir pavadinimo keitimus, neigiamos informacijos apie įmonę įrašai išoriniame paskolų registre, skolų išieškojimo įmonių pretenzijos ir t. t.

Visų kiekybinių įvesties kintamųjų reikšmės pagal procentiles buvo sujungtos į dešimt grupių (tam tikrais atvejais neigiamoms reikšmėms buvo sudaryta atskira grupė, pvz., neigiamos įvesties kintamojo *Turtas iš viso / Nuosavas kapitalas* reikšmės rodo labai rizikingą įmonės situaciją, o mažos teigiamos reikšmės, priešingai, rodo nerizikingą situaciją, taigi, jos negalėjo būti sujungtos į vieną grupę). Pradinės įvesties kintamųjų *Metinė apyvarta* ir *Darbuotojų skaičius* reikšmių grupės buvo nustatytos pagal tai, kaip šias reikšmes grupuoja išorinis paskolų registras, o ne pagal procentiles. Pradinės įvesties kintamųjų *Gyvavimo laikas* ir *Visų per paskutinius metus pradelstų įmokų skaičius* reikšmių grupės buvo nustatytos remiantis ekspertiniu vertinimu. Išskirčių analizė nebuvo atlikta, nes visų kiekybinių įvesties kintamųjų reikšmės buvo sugrupuotos ir užkoduotos. Reikšmėms koduoti buvo taikytas įtakos svorių (toliau – WOE) metodas, nes taikant šį metodą priskirti pseudokintamieji tiksliai atspindi konkrečios reikšmių grupės rizikingumą.

20 lentelėje yra pateikti įvesties kintamojo *Apskritis* pseudokintamieji. Kuo didesnis WOE, tuo mažesnė konkrečios reikšmių grupės rizika. Kai „gerų“ atitinkamos grupės

įmonių dalis, palyginti su visomis „geromis“ įmonėmis, viršija „blogų“ tos grupės įmonių dalį, palyginti su visomis „blogomis“ įmonėmis, WOE bus didesnis už 0 ir atvirksčiai. Matyti, kad rizikingiausia yra Panevėžio apskritis, jos WOE yra mažiausias iš visų³⁸.

Pradinės įvesties kintamųjų reikšmių grupės buvo pakoreguotos, atsižvelgiant į:

- ekonominį pagrįstumą, t. y. grupių rizika turi atspindėti lūkesčius prieš modeliavimą, pavyzdžiui, neigiamų įvesties kintamojo *Turtas iš viso / Nuosavas kapitalas* reikšmių grupės WOE turėjo būti labai mažas, nes neigiamos reikšmės rodo labai rizikingą įmonės situaciją;
- monotoniškumą, t. y. ODF turi arba mažėti, arba didėti didėjant kiekybinio įvesties kintamojo reikšmei (bent jau iki tam tikro lygio, pvz., gali būti U formos skirstinys);
- visų įmonių ir faktinių „blogų“ įmonių skaičių grupėje, t. y. kai grupėje yra labai mažai įmonių, geriau tą grupę prijungti prie kurios nors kitos grupės, kurios ODF panašus. Pavyzdžiui, iš pradžių buvo sudaryta atskira įvesties kintamojo *Turtas iš viso / Nuosavas kapitalas* trūkstatų reikšmių grupė, tačiau buvo labai mažai tokių reikšmių, todėl vėliau ši grupė buvo prijungta prie kitos grupės, kurios ODF panašus (žr. 9 priedą). Kai grupėje visai nebuvo faktinių „blogų“ įmonių, ta grupė buvo prijungta prie kurios nors kitos grupės;
- individualią įvesties kintamojo diskriminacinę galią, t. y. įvairūs grupavimo variantai buvo lyginti tarpusavyje atsižvelgiant į jų informacijos vertę (toliau – IV) ir buvo pasirinktas tas variantas, kurio IV didžiausia. Neprediktyvūs įvesties kintamieji iš tolesnės analizės buvo pašalinti (žr. 8 priedą). Buvo taikytas ir χ^2 suderinamumo kriterijus³⁹.

21 lentelėje yra pateikta pradinių įvesties kintamojo *Grynas pelnas (nuostolia) / Turtas iš viso* reikšmių grupių korekcija. Kai kurios pradinės pagal procentiles sudarytos grupės buvo sujungtos, kad ODF monotoniškai mažėtų, o WOE – didėtų (žr. procentiles nuo 0,2 iki 0,4, nuo 0,6 iki 0,7 ir nuo 0,9 iki 1), t. y. kuo didesnės rodiklio reikšmės grupėje, tuo mažesnis turi būti grupės ODF ir tuo didesnis WOE. Šio grupavimo varianto IV ir χ^2 reikšmės yra didžiausios (t. y. atitinkamai 0,429 ir 1506,13), palyginti su kitais variantais.

³⁸ Kokybinis įvesties kintamasis *Įmonės apskritis* turėjo tik dešimt galimų reikšmių, taigi, WOE buvo apskaičiuotas kiekvienai šių reikšmių atskirai. Tačiau kai yra daug kokybinio įvesties kintamojo, matuojamo pagal pavadinimų skalę, reikšmių, visas reikšmes galima išrikiuoti ODF didėjimo tvarka ir tada sugrupuoti.

³⁹ Kai grupių skaičius buvo toks pats, buvo lygintos χ^2 reikšmės (kuo didesnė, tuo geriau), o kai grupių skaičius skyrėsi, buvo lygintos statistikos p reikšmės su $k-1$ laisvės laipsniais (kuo mažesnė, tuo geriau).

20 lentelė. Įvesties kintamojo Apskritis analizė

Apskritis	Alytaus	Kauno	Klaipėdos	Marijampolės	Panevėžio + trūkstamos reikšmės	Šiaulių	Tauragės	Telšių	Utenos	Vilniaus	Iš viso
„Geros“	519	3 921	2 315	467	996	1 070	235	498	398	7 674	18 093
„Blogos“	143	1 053	533	247	546	312	52	130	156	1 534	4 706
Iš viso	662	4 974	2 848	714	1 542	1 382	287	628	554	9 208	22 799
ODF	21,60 %	21,17 %	18,71 %	34,59 %	35,41 %	22,58 %	18,12 %	20,70%	28,16%	16,66%	20,64%
WOE	-0,0576	-0,0320	0,1220	-0,7097	-0,7456	-0,1143	0,1617	-0,0036	-0,4100	0,2633	
IV											
χ² reikšmė											
0,100											
410,33											

Šaltinis: autorės skaičiavimai.

21 lentelė. Įvesties kintamojo Grynasis pelnas (nuostoliai) / Turtas iš viso analizė

Procentilis	0,1 procentilė < -16,69 %	0,2-0,4 procentilės (-16,69 % - 1,43 %)	0,5 procentilė [1,44 % - 3,34 %]	0,6-0,7 procentilės [3,35 % - 9,96 %]	0,8 procentilė [9,97 % - 15,52 %]	0,9-1 procentilės > 15,52%	Trūkstamos reikšmės	Iš viso
„Geros“	1 384	4 788	1 749	3 897	2 036	4 157	82	18 093
„Blogos“	884	2 015	520	637	234	377	39	4 706
Iš viso	2 268	6 803	2 269	4 534	2 270	4 534	121	22 799
ODF	38,98 %	29,62 %	22,92 %	14,05 %	10,31%	8,31%	32,23%	20,64%
WOE	-0,8984	-0,4812	-0,1337	0,4645	0,8167	1,0536	-0,6035	
IV								
χ² reikšmė								
1506,13								

Šaltinis: autorės skaičiavimai.

Antrasis ciklas: Iš pradinių 57 įvesties kintamųjų, atsižvelgiant į ekonominį pagrįstumą, monotoniškumą, individualią diskriminacinę galią, buvo atrinkti 48 įvesties kintamieji, kurie buvo naudoti modeliuojant. Individualiai įvesties kintamųjų diskriminacinei galiai vertinti buvo taikytas IV metodas (pvz., iš 20 ir 21 lentelių matyti, kad įvesties kintamųjų *Apskritis* ir *Grynasis pelnas (nuostoliai) / Turtas iš viso* IV yra lygi atitinkamai 0,100 ir 0,429). Interpretuojant IV reikšmes, buvo naudoti tokie paaiškinimai: < 0,020 – neprediktyvus įvesties kintamasis; [0,020 – 0,100) – maža įvesties kintamojo diskriminacinė galia; [0,100 – 0,300) – vidutinė įvesties kintamojo diskriminacinė galia; >= 0,300 – didelė įvesties kintamojo diskriminacinė galia. Kaip matyti iš 20–21 lentelių, įvesties kintamojo *Apskritis* diskriminacinė galia yra vidutinė, tačiau įvesties kintamojo *Grynasis pelnas (nuostoliai) / Turtas iš viso* – didelė. 8 priede yra pateikta visų analizuotų pradinių 57 įvesties kintamųjų IV.

Trečiasis ciklas: Antrajame cikle atrinkti 48 įvesties kintamieji buvo toliau analizuoti. Įvesties kintamųjų reikšmių WOE ir faktiniai išvesties kintamieji (0 arba 1) buvo suvesti į SPSS programą. Taikant progresinės atrankos (Voldo) procedūrą, įvesties kintamieji, turintys stiprų ryšį su išvesties kintamuoju, buvo laipsniškai įtraukti į modelį, o paskui buvo tikrinta, kurie įvesties kintamieji turėtų būti pašalinti iš regresijos lygties. Iš viso buvo atliktas 21 žingsnis; baigus procedūrą lygtyje liko 19 įvesties kintamųjų (žr. 22 lent. ir 9 priedą). Pagal sukurtą modelį įmonių individualios PD yra apskaičiuojamos taikant šias formules:

$$PD_i = \frac{1}{1 + e^{-z_i}};$$

$$Z_i = \ln\left(\frac{PD_i}{1-PD_i}\right) = -1,352 - 0,677 \cdot X_{1i} - 0,958 \cdot X_{2i} - 0,821 \cdot X_{3i} - 0,831 \cdot X_{4i} - 0,423 \cdot X_{5i} - 0,755 \cdot X_{6i} - 0,911 \cdot X_{7i} - 0,135 \cdot X_{8i} - 0,145 \cdot X_{9i} - 0,164 \cdot X_{10i} - 0,403 \cdot X_{11i} - 0,460 \cdot X_{12i} - 0,257 \cdot X_{13i} - 0,336 \cdot X_{14i} - 0,155 \cdot X_{15i} - 0,774 \cdot X_{16i} - 0,668 \cdot X_{17i} - 0,330 \cdot X_{18i} - 0,561 \cdot X_{19i},$$

čia: PD_i – tikimybė, kad i įmonė taps „bloga“ per vienerius metus nuo vertinimo datos; $X_{1i} \dots X_{ni}$ – i įmonės įvesties kintamųjų reikšmių pseudokintamieji (WOE), pateikti 9 priede; Z_i – i įmonės galimybės tapti „bloga“ natūrinis logaritmas, dar vadinamas *logit*.

9 priede yra pateiktos įvesties kintamųjų reikšmių grupės ir jų pseudokintamieji (WOE), taip pat žingsnis, kai konkretus įvesties kintamasis buvo įtrauktas į lygtį. Įvesties kintamasis *Vidutinė pradelsimų per paskutinius metus trukmė*, kuris į lygtį buvo įtrauktas pirmame žingsnyje ir joje pasiliko, turi patį stipriausią koreliacinį ryšį su išvesties kintamuoju, nors individuali šio įvesties kintamojo diskriminacinė galia nėra pati didžiausia iš visų tikrintų įvesties kintamųjų (žr. 8 priedą). O įvesties kintamasis *Turtas iš viso* /

Nuosavas kapitalas, pasižymintis didžiausia individualia diskriminacine galia, į lygtį buvo įtrauktas tik antrame žingsnyje. Taip yra todėl, kad skaičiuojant individualią diskriminacinę galią nėra atsižvelgiama į kitų įvesties kintamųjų įtaką.

22 lentelė. Įvesties kintamieji* logistinės regresijos modelyje

21(t) žingsnis	b	S. E.	Waldo	df	Sig.	Exp(b)
X1	-0,677	0,068	99,362	1	0,000	0,508
X2	-0,958	0,060	258,601	1	0,000	0,384
X3	-0,821	0,050	272,159	1	0,000	0,440
X4	-0,831	0,052	256,913	1	0,000	0,435
X5	-0,423	0,066	41,038	1	0,000	0,655
X6	-0,755	0,056	179,921	1	0,000	0,470
X7	-0,911	0,073	154,938	1	0,000	0,402
X10	-0,135	0,058	5,451	1	0,020	0,874
X11	-0,145	0,061	5,609	1	0,018	0,865
X18	-0,164	0,048	11,707	1	0,001	0,849
X20	-0,403	0,065	38,234	1	0,000	0,668
X25	-0,460	0,036	162,623	1	0,000	0,631
X26	-0,257	0,044	33,345	1	0,000	0,774
X29	-0,336	0,048	48,871	1	0,000	0,714
X39	-0,155	0,076	4,102	1	0,043	0,857
X42	-0,774	0,086	80,440	1	0,000	0,461
X43	-0,668	0,070	92,007	1	0,000	0,513
X46	-0,330	0,058	32,956	1	0,000	0,719
X47	-0,561	0,052	114,683	1	0,000	0,571
Laisvasis narys	-1,352	0,020	4 468,535	1	0,000	0,259

Šaltinis: autorės skaičiavimai. *Šioje lentelėje ir 8 priede įvesties kintamieji yra pažymėti pagal pirmame cikle nustatytą eilę. Regresijos lygtyje įvesties kintamieji yra pažymėti iš eilės.

Lygtyje pasilikę įvesties kintamieji apibūdina visus įmonės bruožus: *gyvavimo laiką, dydį* (metinė apyvarta, darbuotojų skaičius ir iš dalies natūriniai grynojo pelno bei po vienerių metų mokėtinų sumų ir įsipareigojimų logaritmai, nes didesnės įmonės gauna daugiau pelno ir ima didesnius kreditus nei mažesnės įmonės), *finansinę padėtį* (įtraukti net aštuoni finansiniai santykiniai rodikliai), *vietą* (įmonės buvo suskirstytos pagal apskritis), *ekonominės veiklos rūšį* (įmonės buvo suskirstytos pagal Lietuvos statistikos departamento patvirtintą ekonominės veiklos rūšių klasifikatorių (EVRK 2)), *išorinę mokėjimų istoriją* (visų per vienerius metus iki vertinimo datos pradelstų įmonės įmokų kredito įstaigoms, išperkamosios nuomos, telekomunikacijų, komunalinių paslaugų ir kitoms įmonėms skaičius

bei vidutinė visų šių pradelsimų trukmė), *viešą neigiamą informaciją apie įmonę, skolos išieškojimo įmonių pretenzijas.*

Šis modelis turi daugiau laiko momento, o ne ekonominio ciklo modelio bruožų, nes jame yra nemažai ekonominiam ciklui jautrių įvesties kintamųjų: finansiniai santykiniai rodikliai, mokėjimų istorijos rodikliai, informacija apie tai, ar išoriniame paskolų registre yra neigiamos informacijos apie įmonę įrašų ir ar yra įrašų iš skolų išieškojimo įmonių apie pretenzijas įmonei. Tačiau jame nėra makroekonominių rodiklių, todėl šis modelis nėra visiškai laiko momento modelis.

3.1.1.3. Išankstinis patikimumo vertinimas

Nors reikia atlikti tiek išankstinį, tiek pakartotinį statistinio vertinimo balais modelio patikimumo vertinimą, pastarasis gali būti atliekamas tik vėliau, jau pradėjus taikyti modelį banko veikloje. Todėl buvo atliktas tik išankstinis patikimumo vertinimas, apimantis du etapus:

- gautos regresijos lygties tinkamumo (jos ir empirinių duomenų atitikimo) tikrinimą;
- kitų reitingų sistemos aspektų tikrinimą taikant 20 pav. pateiktus metodus.

Gautos regresijos lygties tinkamumo (jos ir empirinių duomenų atitikimo) tikrinimas.

- *Koeficientų algebrinių ženklų ekonominio pagrįstumo tikrinimas:* koeficiento algebrinis ženklas turi atitikti ekonominę logiką, kuria buvo vadovautasi kuriant modelį. Logistinės regresijos lygties koeficientai turi būti teigiami, kai didėjanti įvesties kintamojo (ar pseudokintamojo) reikšmė reiškia *ceteris paribus* didėjančią įmonės riziką, ir, atvirkščiai, turi būti neigiami, kai didėjanti įvesties kintamojo (ar pseudokintamojo) reikšmė reiškia *ceteris paribus* mažėjančią įmonės riziką. Kuriant šį modelį visų įvesties kintamųjų reikšmių grupės buvo užkoduotos WOE, o didėjanti WOE reikšmė reiškia *ceteris paribus* mažėjančią įmonės riziką. Taigi, visi koeficientai logistinės regresijos lygtyje turi būti neigiami⁴⁰. Kaip matyti iš 22 lentelės, visi koeficientai stulpelyje „b“ iš tikrųjų yra neigiami, kaip ir buvo galima tikėtis.
- *Koeficientų nelygybės 0 reikšmingumo analizė taikant Omnibus kriterijų:* taikant šį kriterijų apskaičiuota statistikos p reikšmė (Sig.) yra mažesnė už pasirinktą reikšmingumo lygmenį 0,05 (žr. 23 lent.).

⁴⁰ Laisvasis narys b_0 taip pat turėjo būti neigiamas, nes viso paskolų portfelio kūrimo imties ODF = 20,64 % (t. y. < 50 %). Kūrimo imties įmonių vidutinės galimybės tapti „blogomis“ natūrinis logaritmas buvo lygus – 1,352, t. y. $\ln(ODF/(1 - ODF)) \approx -1,352$.

23 lentelė. Koeficientų nelygybės 0 reikšmingumo analizė

		χ^2 reikšmė	df	Sig.
21 žingsnis	Žingsnis	4,115	1	0,043
	Blokas	6 037,752	19	0,000
	Modelis	6 037,752	19	0,000

Šaltinis: autorės skaičiavimai.

Tai reiškia, kad H_0 hipotezė turi būti atmesta (t. y. bent vienas lygties koeficientas yra statistiškai reikšmingai nelygus 0).

- *Koeficientų nelygybės 0 reikšmingumo analizė taikant Voldo kriterijų:* taikant šį kriterijų apskaičiuotos statistikos p reikšmės (Sig.) įrodo visų koeficientų nelygybės 0 reikšmingumą. Kaip matyti iš 22 lentelės, visos statistikos p reikšmės stulpelyje „Sig.“ yra mažesnės už pasirinktą reikšmingumo lygmenį 0,05. Vadinasi, kad H_0 hipotezė turi būti atmesta (t. y. visi koeficientai yra statistiškai reikšmingai nelygūs 0).
- *Koeficientų standartinių paklaidų analizė:* matyti, kad koeficientų standartinės paklaidos, pateiktos 22 lentelės „S. E“ stulpelyje, nėra didelės, o tai reiškia, kad koeficientai buvo tiksliai įvertinti. Koeficientų pasikliautinieji intervalai buvo apskaičiuoti pagal šią formulę:

$$\hat{b}_j \pm \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot s_{\hat{b}_j},$$

čia: $\Phi^{-1}()$ – atvirkštinė standartinio normaliojo dydžio pasiskirstymo funkcija; α – reikšmingumo lygmuo.

Kai pasiklovimo lygmuo 95 %, visų koeficientų apatinė riba buvo didesnė už 0.

- *Modelio suderinamumo su empiriniais duomenimis analizė taikant H ir L kriterijų:* visų įmonių individualių PD variacinė eilutė buvo padalyta į dešimt grupių, kiekvienos grupės individualios PD buvo sudėtos.

Gautos sumos buvo vertintos kaip skaičiai, rodantys, kiek kiekvienoje grupėje turėtų būti „blogų“ įmonių, jeigu modelis būtų suderintas su duomenimis (žr. 24 lentelės C stulpelį). Taip pat buvo nustatytas faktinis „blogų“ kiekvienos grupės įmonių skaičius (žr. 24 lentelės B stulpelį). Dydžių B ir C stulpeliuose (ir atitinkamai D ir E stulpeliuose) skirtumą aprašo χ^2 skirstinys su 8 laisvės laipsniais (t. y. $k - 2$ laisvės laipsnių, kai k yra grupių skaičius). Kadangi H ir L statistikos p reikšmė yra lygi 0,094, tai logistinės regresijos modelis yra gana gerai suderintas su empiriniais duomenimis, nes statistikos p reikšmė yra didesnė už pasirinktą reikšmingumo lygmenį 0,05.

24 lentelė. Suderinamumo su empiriniais duomenimis analizė

A	B	C	D	E	F	G	H	I
Grupė	Faktinis „blogų“ įmonių skaičius	Tikėtinas „blogų“ įmonių skaičius	Faktinis „gerų“ įmonių skaičius	Tikėtinas „gerų“ įmonių skaičius	$= (B - C)^2$	$= (D - E)^2$	$= F/C$	$= G/E$
1	30	33,10	2 251	2 247,90	9,627	9,627	0,291	0,004
2	49	72,04	2 231	2 207,96	530,649	530,649	7,366	0,240
3	102	114,87	2 178	2 165,13	165,671	165,671	1,442	0,077
4	183	167,19	2 097	2 112,81	249,920	249,920	1,495	0,118
5	245	234,94	2 035	2 045,06	101,203	101,203	0,431	0,049
6	349	329,41	1 931	1 950,59	383,950	383,950	1,166	0,197
7	454	469,14	1 826	1 810,86	229,111	229,111	0,488	0,127
8	677	676,48	1 603	1 603,52	0,272	0,272	0,000	0,000
9	990	985,65	1 290	1 294,35	18,934	18,934	0,019	0,015
10	1 627	1 622,70	651	655,30	18,473	18,473	0,011	0,028
Iš viso:	4 706	4 706	18 093	18 093	χ^2 reikšmė			13,565
Statistikos <i>p</i> reikšmė*								0,094

Šaltinis: autorės skaičiavimai. *Statistikos *p* reikšmė su 8 laisvės laipsniais buvo apskaičiuota taikant „MS Excel“ funkciją =CHIDIST).

- *Determinacijos analizė*: kuo determinacijos koeficientai didesni, tuo logistinė regresija yra geriau suderinta su duomenimis. SPSS programa apskaičiuotas *Cox & Snell R Square* pseudodeterminacijos koeficientas yra lygus 0,44, o normuotas šio koeficiento variantas, *Nagelkerke R Square*, yra lygus 0,69. Šie koeficientai rodo tą dispersijos dalį, kurią paaiškina logistinės regresijos modelis.
- *Multikolinearumo analizė*: buvo sukurtas tiesinės regresijos modelis naudojant tą patį išvesties kintamąjį ir tuos pačius 19 įvesties kintamųjų WOE, ir kiekvienam įvesties kintamajam buvo apskaičiuoti dispersijos mažėjimo daugikliai (VIF) ir tolerancija (žr. 10 priedą). Nė vienas įvesties kintamasis nėra per daug multikolinearus, nes visų jų dispersijos mažėjimo daugiklis (VIF) yra mažesnis nei 4, o tolerancija – didesnė nei 0,25.
- *Teisingo klasifikavimo analizė*: tikrinant, ar logistinės regresijos modelis tinka prognozėms, būtina nustatyti, kaip dažnai faktinės reikšmės sutampa su pagal modelį prognozuotomis reikšmėmis. Bendras modelio teisingo klasifikavimo rodiklis yra lygus 83,2 %. Modelio specifiškumas yra lygus 91,8 % (t. y. 91,8 % visų faktinių „gerų“ įmonių ir pagal modelį buvo priskirtos prie „gerų“), o modelio jautrumas yra lygus 50,3 % (t. y. 50,3 % visų faktinių „blogų“ įmonių ir pagal modelį buvo priskirtos prie „blogų“) (žr. 25 lent.). Modelio I rūšies klaidos ir II rūšies klaidos tikimybės yra lygios atitinkamai 49,7 % ir 8,2 %. Paprastai, kad galima būtų taikyti modelį, yra reikalaujama, kad kiekvienos grupės teisingo klasifikavimo rodiklis būtų ne mažesnis nei 50 % (t. y.

kad kiekvienos iš klaidų tikimybė nebūtų didesnė kaip 50 %), taigi, ši logistinės regresijos modelį galima taikyti.

25 lentelė. Lietuvos įmonių klasifikacinė lentelė*

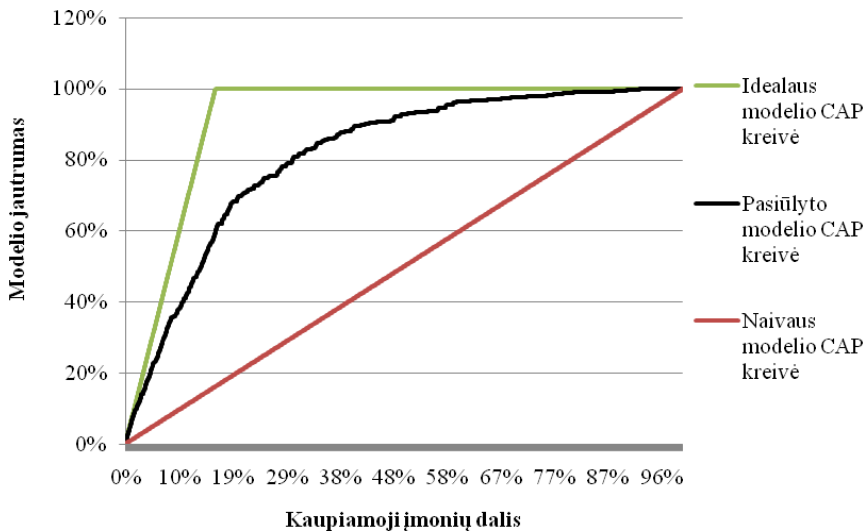
Faktas		Prognozė		
		Įmonių skaičius		Teisingo klasifikavimo rodikliai
		„Geros“	„Blogos“	
Įmonių skaičius	„Geros“	16 612	1 481	91,8 %
	„Blogos“	2 339	2 367	50,3 %
Bendras teisingo klasifikavimo rodiklis				83,2 %

Šaltinis: autorės skaičiavimai. *Lūžio taškas yra 0,500.

Taigi, logistinės regresijos lygties koeficientų algebriniai ženklai atitinka ekonominę logiką, visi koeficientai yra statistiškai reikšmingai nelygūs 0, logistinės regresijos modelis su empiriniais duomenimis yra suderintas, įvesties kintamieji nėra per daug multikolinearūs. Be to, aukštas ne tik bendras modelio teisingo klasifikavimo rodiklis, bet ir teisingo klasifikavimo rodikliai atskirose grupėse (t. y. modelio specifiškumas ir jautrumas).

Kitų reitingų sistemos aspektų tikrinimas naudojant atskirą patikimumo vertinimo imtį. Kadangi iš išorinio paskolų registro nebuvo gauta duomenų apie įmonių įsipareigojimų neįvykdymus 2009–2010 metais, tai atliekant išankstinį patikimumo vertinimą buvo naudoti to paties 2005–2008 metų laikotarpio, bet į kūrimo imtį neįtrauktą „įmonių metų“ duomenys. Atsitiktiniu būdu buvo sudaryta patikimumo vertinimo imtis, susidedanti iš 10 404 įrašų (žr. 25 pav.).

Diskriminacinės galios analizė. Modelio diskriminacinei galiai vertinti buvo taikyti keturi metodai: CAP kreivė, ROC kreivė, IV metodas ir Briero balų metodas (žr. 26–27 pav. ir 26 lent.). Visos įmonės buvo išrikiuotos individualios PD mažėjimo tvarka ir suskirstytos į dešimt lygių grupių. 26 lentelės *D* stulpelyje yra pateikta faktinių „blogų“ įmonių nuo pirmos, pačios rizikingiausios, grupės iki *i* grupės (įskaitytinai) dalis, palyginti su visomis faktinėmis „blogomis“ įmonėmis, t. y. modelio jautrumas (*i* kinta nuo 1 iki 10). Modelio AUC buvo apskaičiuotas šias kaupiamąsias faktinių „blogų“ įmonių dalis padauginus iš 0,1 ir sudėjus visas gautas sandaugas (žr. 26 lentelės *E* stulpelį). Kai AUC reikšmė patenka į intervalą nuo 80 % iki 90 % (o AR reikšmė – į intervalą nuo 60 % iki 80 %), yra laikoma, kad modelio diskriminacija yra puiki (žr. 9 lent.). Modelio AUC yra lygus 86,11 %, o AR – 72,23 %; tai reiškia, kad jo diskriminacija yra puiki.



26 pav. Pasiūlyto modelio CAP kreivė

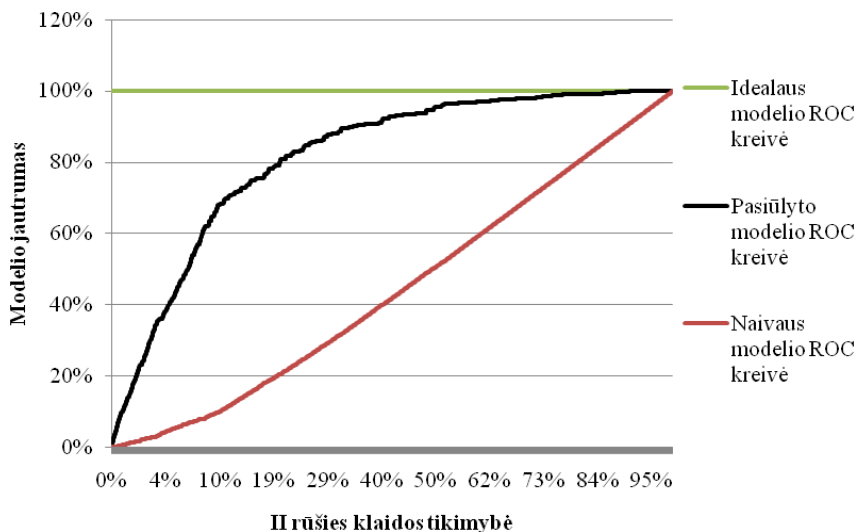
Šaltinis: autorės skaičiavimai.

Pasiūlyto modelio diskriminacinė galia atitinka daugelyje pasaulio šalių taikomų logistinės regresijos modelių, kuriems naudojami kiekybiniai ir kokybiniai įvesties kintamieji, diskriminacinę galią (dažniausiai tokių modelių AR būna lygus 70–80 %) (žr. 10 lent.).

Pasiūlyto modelio IV irgi yra didelė (2,460), Briero balų metodo rezultatas – 0,0922. Be to, faktinių „gerų“ grupės įmonių dalis, palyginti su visomis faktinėmis „geromis“ įmonėmis, tuo didesnė, kuo geresnė grupė, o faktinių „blogų“ grupės įmonių dalis, palyginti su visomis faktinėmis „blogomis“ įmonėmis, priešingai, tuo mažesnė, kuo geresnė grupė. To ir buvo tikėtasi, prieš pradėdant modeliuoti (žr. 26 lentelės *F* ir *G* stulpelius).

Verta paanalizuoti ir skaičiuojant IV rodiklį naudotus grupių WOE, taip pat grupių ODF. Konkrečios grupės rizikingumą rodantis WOE buvo apskaičiuotas logaritmuojant 26 lentelės *F* ir *G* stulpeliuose pateiktų dydžių santykį, jis turėtų būti tuo didesnis, kuo geresnė grupė (t. y. nuo pirmos iki dešimtos grupės), o ODF – tuo mažesnis, kuo geresnė grupė. Iš *H* ir *J* stulpelių matyti, kad taip ir yra.

Nors regresijos lygtis yra tinkama ir modelis puikiai diskriminuoja skolininkus, konkreti finansų įstaiga (pvz., bankas, vartojimo kreditų, smulkiųjų vartojimo kreditų, išperkamosios nuomos, draudimo įmonė), prieš pradėdama taikyti pasiūlytą modelį savo veikloje, turėtų įvertinti jo patikimumą, naudodama savus duomenus. Be to, netgi ir įdiegus modelį reguliariai turi būti atliekamas pakartotinis patikimumo vertinimas.



27 pav. Pasiūlyto modelio ROC kreivė

Šaltinis: autorės skaičiavimai.

26 lentelė. Pasiūlyto modelio diskriminacinės galios analizė*

A	B	C	D	E	F = B/8 721	G = C/1 683	H = ln(F/G)	I = H· (F - G)	J = C/ (B + C)	K
Grupė	„Geros“ įmonės	„Blogos“ įmonės	Modelio jautrumas	= D·0,1	„Geros“, palyginti su visomis „geromis“	„Blogos“, palyginti su visomis „blogomis“	WOE	IV	ODF	Briero balas
1	385	656	38,98 %	0,0390	4,41 %	38,98 %	-2,18	0,750	63,02 %	235,83
2	540	501	68,75 %	0,0688	6,19 %	29,77 %	-1,57	0,370	48,13 %	254,26
3	852	188	79,92 %	0,0799	9,77 %	11,17 %	-0,13	0,000	18,08 %	158,69
4	905	136	88,00 %	0,0880	10,38 %	8,08 %	0,25	0,010	13,06 %	117,49
5	959	81	92,81 %	0,0928	11,00 %	4,81 %	0,83	0,050	7,79 %	75,16
6	978	62	96,49 %	0,0965	11,21 %	3,68 %	1,11	0,080	5,96 %	58,62
7	1 021	20	97,68 %	0,0977	11,71 %	1,19 %	2,29	0,240	1,92 %	20,25
8	1 021	19	98,81 %	0,0988	11,71 %	1,13 %	2,34	0,250	1,83 %	18,83
9	1 026	15	99,70 %	0,0997	11,76 %	0,89 %	2,58	0,280	1,44 %	14,79
10	1 034	5	100,00 %	0,1000	11,86 %	0,30 %	3,69	0,430	0,48 %	4,97
Iš viso	8 721	1 683	AUC	86,11 %	100,00 %	100,00 %		2,460		0,0922
			AR	72,23 %						

Šaltinis: autorės skaičiavimai. *Grupės yra pateiktos rizikos mažėjimo kryptimi.

Reitingų skalės, jos stabilumo, įvesties kintamųjų ir lyginamoji analizė yra pateikta 3.1.2 dalyje, reitingų PD patikimumo vertinimas – 3.2 dalyje.

3.1.2. Lietuvos įmonių reitingų skalė

Kad modelį būtų galima taikyti banke, buvo sukurta iš devynių reitingų susidedanti reitingų skalė. Kiekvienam iš reitingų buvo nustatyti individualių PD intervalai. Kūrimo imties įmonės pagal sukurtu modeliu apskaičiuotas individualias PD buvo priskirtos atitinkamiems reitingams.

Reitingų skalės analizė. Iš pradžių buvo sudarytos kelios reitingų skalės, reitingų skaičius jose įvairavo (nuo 6 iki 10 reitingų) (žr. 11 priedą), o vėliau buvo pasirinkta geriausia iš jų, atsižvelgiant į:

- *individualių PD intervalus*: taikant pasirinktą reitingų skalę mažesnės rizikos įmonės yra diferencijuojamos labiau už didesnės rizikos įmones, nes geresniems reitingams buvo nustatyti siauresni PD intervalai nei blogesniems;
- *monotoniškumą*: tiek reitingo ODF, tiek reitingo „blogų“ įmonių dalis, palyginti su visomis „blogomis“ įmonėmis, turi būti tuo didesnė, kuo blogesnis reitingas. Kaip matyti iš 27 lentelės, stulpeliuose $F-G$, taikant pasirinktą reitingų skalę abu šie rodikliai didėja. Tos reitingų skalės, kurias taikant šie du rodikliai nedidėjo, buvo atmestos.
- *koncentraciją*: nė viename iš reitingų nėra per didelės įmonių koncentracijos. Tačiau kiekvieno reitingo įmonių yra užtektinai, kad būtų galima apskaičiuoti PD ir įvertinti jų patikimumą. Tos reitingų skalės, kurių bent vieno reitingo įmonių dalis sudarė daugiau nei 25 % visų įmonių, buvo atmestos. Taip buvo išvengta pernelyg didelio vienam reitingui priskiriamų įmonių heterogeniškumo;
- *įmonių skirstinį*: jis turėtų būti unimodinis ir artimas normaliajam, t. y. didžiausia įmonių procentinė dalis turėtų telktis viduriniame reitinge. Kaip matyti iš 27 lentelės, H stulpelio, didžiausia įmonių procentinė dalis yra 5-ajame reitinge. Iki 5-o reitingo įmonių procentinė dalis didėja, o paskui ima mažėti.
- χ^2 reikšmė: buvo taikytas χ^2 suderinamumo kriterijus ir buvo pasirinkta ta reitingų skalė, kurios χ^2 reikšmė yra didžiausia (o kai buvo lygintos nevienodo reitingų skaičiaus skalės – ta, kurios p vertė yra mažiausia su $k-1$ laisvės laipsniais).

27 lentelė. Lietuvos įmonių reitingų skalė

A	B	C	D	E	F = E/D	G = E/4 706	H = D/22 799	I	J
Rei-tingas	Apatinė PD riba	Viršutinė PD riba	Įmonės	„Blogos“ įmonės	Reitingo ODF	„Blogos“ įmonės, palyginti su visomis „blogomis“ įmonėmis	Reitingo įmonės, palyginti su visomis įmonėmis	HHI	χ^2 reikšmė
1	0,01 %	1,00 %	568	13	2,29 %	0,28 %	2,49 %	0,0006	116,79
2	1,01 %	2,20 %	1 543	40	2,59 %	0,85 %	6,77 %	0,0046	306,86
3	2,21 %	3,70 %	2 023	55	2,72 %	1,17 %	8,87 %	0,0079	396,70
4	3,71 %	8,00 %	4 439	203	4,57 %	4,31 %	19,47 %	0,0379	699,66
5	8,01 %	16,00 %	4 675	573	12,26 %	12,18 %	20,51 %	0,0420	200,64
6	16,01 %	28,00 %	3 529	697	19,75 %	14,81 %	15,48 %	0,0240	1,71
7	28,01 %	40,50 %	2 288	811	35,45 %	17,23 %	10,04 %	0,0101	306,14
8	40,51 %	61,00 %	2 075	1085	52,29 %	23,06 %	9,10 %	0,0083	1 268,75
9	61,01 %	99,99 %	1 659	1229	74,08 %	26,12 %	7,28 %	0,0053	2 892,28
Iš viso			22 799	4 706		100,00 %	100,00 %	0,1406	6 189,53

Šaltinis: autorės skaičiavimai.

Nors pasirinkta reitingų skalė susideda iš devynių reitingų, banke turėtų būti ir dešimtas reitingas – įmonėms, kurios jau yra tapusios „blogos“ (jų PD = 100 %). „Geroms“ įmonėms diferencijuoti būtų naudojami devyni reitingai, tačiau jei įmonė pavėluotų sumokėti įmoką daugiau kaip 90 kalendorinių dienų arba jai būtų pradėta bankroto procedūra, ji automatiškai būtų priskiriama 10-am reitingui.

Reitingų skalės stabilumo analizė⁴¹. Patikimumo vertinimo imtį sudarantys 10 404 įrašai buvo priskirti reitingams pagal individualią PD. Šie įrašai nebuvo naudoti modeliui kurti, taigi, buvo padaryta prielaida, kad tai yra hipotetinio banko naujų skolininkų įrašai. Stabilumo analizės etapai:

- monotoniškumo, koncentracijos, įmonių skirstinio ir diskriminacijos pokyčių analizė;
- tų pačių reitingų ODF naudojant skirtingas duomenų imtis as
- įmonių stabilumo indekso analizė.

Monotoniškumo, koncentracijos, įmonių skirstinio ir diskriminacijos pokyčių analizė. Matyti, kad naudojant patikimumo vertinimo imtį, reitingų ODF tuo didesnis, kuo blogesnis reitingas (žr. 28 lentelės F stulpelį). Tačiau faktinių „blogų“ reitingo įmonių dalis, palyginti su visomis faktinėmis „blogomis“ įmonėmis, ne visada tuo didesnė, kuo blogesnis reitingas: faktinių „blogų“ trečio reitingo įmonių dalis mažesnė už antro reitingo, septinto – už šešto, o devinto – už 8 (žr. 28 lentelės G stulpelį).


⁴¹ Stabilumo, įvesties kintamųjų ir lyginamoji analizė buvo atlikta tik įvertinus PD kalibravimo tikslumą (žr. 3.2 dalį).

28 lentelė. Reitingų skalės stabilumo analizė

A	B	C	D	E	F = E/D	G = E/1 683	H = D/10 404	I	J
Reitingas	Apatinė PD riba	Viršutinė PD riba	Įmonės	„Blogos“ įmonės	Reitingo ODF	„Blogos“ įmonės, palyginti su visomis „blogomis“ įmonėmis	Reitingo įmonės, palyginti su visomis įmonėmis	HHI	χ^2 reikšmė
1	0,01 %	1,00 %	690	2	0,29 %	0,12 %	6,63 %	0,0000	128,43
2	1,01 %	2,20 %	1 552	20	1,29 %	1,19 %	14,92 %	0,0200	253,69
3	2,21 %	3,70 %	964	19	1,97 %	1,13 %	9,27 %	0,0100	143,46
4	3,71 %	8,00 %	2 281	113	4,95 %	6,71 %	21,92 %	0,0500	211,86
5	8,01 %	16,00 %	1 468	132	8,99 %	7,84 %	14,11 %	0,0200	55,88
6	16,01 %	28,00 %	1 148	193	16,81 %	11,47 %	11,03 %	0,0100	0,34
7	28,01 %	40,50 %	421	116	27,55 %	6,89 %	4,05 %	0,0000	40,19
8	40,51 %	61,00 %	1 169	595	50,90 %	35,35 %	11,24 %	0,0100	1 039,36
9	61,01 %	99,99 %	711	493	69,34 %	29,29 %	6,83 %	0,0000	1 481,94
Iš viso:			10 404	1 683				0,1343	3 355,16

Šaltinis: autorės skaičiavimai.

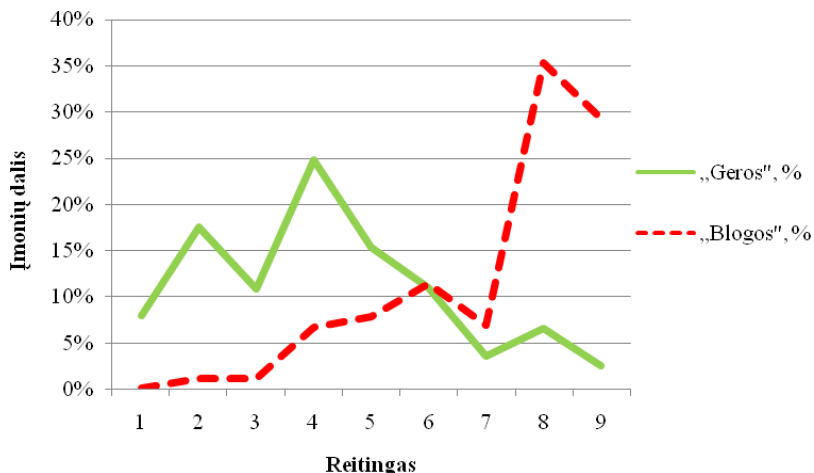
Tačiau kūrimo ir patikimumo vertinimo imtyse atitinkamai faktinių „gerų“ ir faktinių „blogų“ įmonių skirstiniai yra labai panašūs (žr. 28 ir 29 pav.).



28 pav. „Gerų“ ir „blogų“ kūrimo imties įmonių skirstiniai

Šaltinis: autorės skaičiavimai.

Abiejose imtyse faktinių „gerų“ šešto reitingo įmonių dalis, palyginti su visomis faktinėmis „geromis“ įmonėmis, maždaug sutampa su faktinių „blogų“ įmonių dalimi, palyginti su visomis faktinėmis „blogomis“ įmonėmis. Iki šešto reitingo faktinių „gerų“ įmonių dalis yra didesnė už faktinių „blogų“ įmonių dalį, o nuo šešto reitingo – mažesnė.



29 pav. „Gerų“ ir „blogų“ patikimumo vertinimo imties įmonių skirstiniai

Šaltinis: autorės skaičiavimai.


Patikimumo vertinimo imties įmonių skirstinys nėra unimodinis, tai iš dalies paaiškina, kodėl faktinių „blogų“ reitingo įmonių dalis, palyginti su visomis faktinėmis „blogomis“ įmonėmis, ne visada tuo didesnė, kuo blogesnis reitingas (žr. 28 lentelės *H* ir *G* stulpelius). Nė vieno reitingo įmonių dalis nesudaro daugiau kaip 25 % visų įmonių (t. y. neviršija kuriant reitingų skalę naudoto limitu). Bendra koncentracija netgi sumažėjo (HHI = 0,1343, o kūrimo imtį sudarančių įmonių HHI = 0,1406).

Taikant χ^2 suderinamumo kriterijų gauta χ^2 reikšmė yra lygi 3 355,16 (mažesnė nei naudojant kūrimo imtį (žr. 27 ir 28 lentelių *J* stulpelį)). Tai rodo, kad taikant pasiūlytą reitingų sistemą patikimumo vertinimo imties įmonės yra diskriminuojamos prasčiau nei kūrimo imties įmonės.

Nors monotoniškumo, koncentracijos, įmonių skirstinio ir diskriminacijos pokyčių analizė atskleidė keletą trūkumų (faktinių „blogų“ reitingo įmonių dalis, palyginti su visomis faktinėmis „blogomis“ įmonėmis, ne visada tuo didesnė, kuo blogesnis reitingas, įmonių skirstinys nėra unimodinis, patikimumo vertinimo imties įmonės yra diskriminuojamos prasčiau), tačiau rezultatai yra tenkinantys, ypač geri įmonių koncentracijos reitinguose rezultatai. Jeigu pradėjus taikyti šią reitingų sistemą konkrečiame banke ir toliau kelerius metus iš eilės išliktų tokie patys trūkumai, galima būtų pakoreguoti reitingų apatines ir viršutines PD ribas. Tačiau derėtų atsižvelgti ir į tai, kad ši reitingų sistema – labiau laiko momento, o ne ekonominio ciklo reitingų sistema, todėl ekonominėms sąlygoms blogėjant, įmonės migruos į blogesnius reitingus, o joms gerėjant – į geresnius. Jeigu motoniškumas,

koncentracija, įmonių skirstinys ir diskriminacija keičiasi ne dėl vidinių banko priežasčių (pvz., pasikeitusių kreditavimo standartų, rinkodaros strategijos ir pan.), bet dėl besikeičiančių ekonominių sąlygų, geriau koreguoti ne pačią reitingų skalę, bet pakeisti lūžio reitingą, nuo kurio paskolos nebus suteikiamos.

Tų pačių reitingų ODF naudojant skirtingas duomenų imtis palyginimas. ODF kūrimo ir patikimumo vertinimo imtyse yra labai panašūs (žr. 30 pav.). Tai rodo, kad modelis ir reitingų skalė yra stabilūs.



30 pav. ODF kūrimo ir patikimumo vertinimo imtyse palyginimas

Šaltinis: autorės skaičiavimai.

Įmonių stabilumo indekso analizė. Kaip minėta, patikimumo vertinimo imties įrašai nebuvo naudoti modeliui kurti, taigi, buvo padaryta prielaida, kad tai yra hipotetinio banko naujų skolininkų įrašai. Stabilumo indekso reikšmė yra 0,21. Didžiausią įtaką šiam rodikliui turėjo įmonių dalies padidėjimas 1–2 reitinguose ir sumažėjimas 5–7 reitinguose (žr. 29 lent.). Kaip minėta 1.3.2 dalyje, reikšmė intervale nuo 0,1 iki 0,25 rodo, kad derėtų smulkiau išanalizuoti įvesties kintamųjų reikšmių skirstinių poslinkius.

Siekiant nustatyti, kurių įvesties kintamųjų reikšmių skirstinių pokyčiai nulėmė įmonių skirstinio pagal reitingus pokyčius, buvo apskaičiuoti ir kiekvieno įvesties kintamojo stabilumo indeksai.

29 lentelė. Įmonių stabilumo indekso apskaičiavimas naudojant patikimumo vertinimo imtį

A	B	C	D	E	F	G	H
Reitingas	Įmonių dalis (modelio kūrimo imtis)	Įmonių dalis (patikimumo vertinimo imtis)	= C - B	= C/B	= ln(E)	= D·F	Pokytis
1	2,49 %	6,63 %	0,04	2,66	0,98	0,04	↑
2	6,77 %	14,92 %	0,08	2,20	0,79	0,06	↑
3	8,87 %	9,27 %	0,00	1,04	0,04	0,00	↑
4	19,47 %	21,92 %	0,02	1,13	0,12	0,00	↑
5	20,51 %	14,11 %	-0,06	0,69	-0,37	0,02	↓
6	15,4 %	11,03 %	-0,04	0,71	-0,34	0,02	↓
7	10,04 %	4,05 %	-0,06	0,40	-0,91	0,05	↓
8	9,10 %	11,24 %	0,02	1,23	0,21	0,00	↑
9	7,28 %	6,83 %	0,00	0,94	-0,06	0,00	↓
	100,00 %	100,00 %		Stabilumo indeksas		0,21	

Šaltinis: autorės skaičiavimai.

Įvesties kintamųjų diskriminacinės galios ir stabilumo analizė. Skaičiavimų rezultatai parodė, kad tik vieno įvesties kintamojo (x_{12}) stabilumo indeksas didesnis nei 0,25, kitų įvesties kintamųjų stabilumo indeksai neviršija net 0,1 (žr. 30 lent.). Matyti, kad įmonių, kurių blogesnės įvesties kintamojo *Pinigai ir pinigų ekvivalentai / Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai* reikšmės ($< 0,1123$) dalis sumažėjo, o įmonių, kurių geresnės reikšmės ($\geq 0,1123$) – gerokai padidėjo (žr. 31 lent.).

22 lentelės *Exp(b)* stulpelyje yra pateiktos galimybių santykio reikšmės. Galimybių santykis rodo, kaip kinta išvesties kintamojo galimybė įgyti reikšmę 1. Jis yra apskaičiuojamas kaip $exp(b)$, tačiau kai įvesties kintamieji (ar pseudokintamieji) yra kiekybiniai ir tolydieji, galimybių santykio reikšmė apskaičiuojama kaip $exp(b \cdot C)$, čia C – įvesties kintamojo (ar pseudokintamojo) reikšmių pokyčio vienetai. Pavyzdžiui, įmonė, kurios *Pinigų ir pinigų ekvivalentų / Per vienerius metus mokėtinų sumų ir trumpalaikių įsipareigojimų* santykis sumažėjo ir reikšmė iš intervalo $[0,1123-0,1807]$ pakliuvo į intervalą $[0,0375-0,1122]$ (o pseudokintamasis WOE sumažėjo 0,0808 vieneto nuo 0,2429 iki 0,1621) (žr. 31 lent.), padidino savo galimybę tapti „bloga“ 0,964 karto (nes $e^{-0,460 \cdot 0,0808} = 0,964$).

Taigi, įvesties kintamojo x_{12} reikšmių skirstinio pokyčiai, lyginant kūrimo ir patikimumo vertinimo imtis, turėjo didelę įtaką įmonių skirstinio pagal reitingus pokyčiams.

Taip pat buvo įvertinta kiekvieno įvesties kintamojo diskriminacinė galia, ji buvo palyginta su kuriant modelį apskaičiuota įvesties kintamųjų diskriminacine galia.

30 lentelė. Įvesties kintamųjų diskriminacinės galios ir stabilumo analizė

Įvesties kintamasis		Diskriminacinė galia			Stabilumo analizė
		IV kūrimo imtyje	IV patikimumo verinimo imtyje	Pokytis	Stabilumo indeksas
x1	Metinė apyvarta, tūkst. Lt	0,096	0,470	↑	0,0346
x2	Apskritis	0,100	0,252	↑	0,0078
x3	Ekonominės veiklos rūšis	0,178	0,484	↑	0,0201
x4	Gyvavimo laikas, metais	0,154	0,367	↑	0,0188
x5	Yra / nėra neigiamos informacijos apie vertinamą įmonę įrašų išoriniame paskolų registre per paskutinius metus	0,101	0,202	↑	0,0013
x6	Yra / nėra įrašų iš skolų išieškojimo įmonių apie pretenzijas vertinamai įmonei per paskutinius metus	0,146	0,234	↑	0,0002
x7	Darbuotojų skaičius	0,091	0,373	↑	0,0231
x8	Pelnas (nuostoliai) prieš apmokestinimą / Pardavimo pajamos	0,339	0,620	↑	0,0230
x9	Grynasis pelnas (nuostoliai) / Turtas iš viso	0,429	0,746	↑	0,0266
x10	Trumpalaikis turtas / Mokėtinos sumos ir įsipareigojimai	0,428	0,834	↑	0,0438
x11	Ln (grynasis pelnas)	0,335	0,656	↑	0,0336
x12	Pinigai ir pinigų ekvivalentai / Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai	0,344	0,556	↑	0,3269
x13	Turtas iš viso / Nuosavas kapitalas	0,528	0,901	↑	0,0468
x14	Bendrasis pelnas (nuostoliai) / Turtas iš viso	0,202	0,342	↑	0,0101
x15	Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai / Turtas iš viso	0,130	0,291	↑	0,0145
x16	Ln (po vienerių metų mokėtinos sumos ir ilgalaikiai įsipareigojimai)	0,102	0,245	↑	0,0095
x17	Pardavimo pajamos / Trumpalaikis turtas	0,089	0,130	↑	0,0040
x18	Visų per paskutinius metus pradelstų įmokų skaičius	0,355	0,300	↓	0,0013
x19	Vidutinė pradelsimų per paskutinius metus trukmė (dienomis)	0,409	0,441	↑	0,0024

Šaltinis: autorės skaičiavimai.

Matyti, kad tik vieno įvesties kintamojo – *Visų per paskutinius metus pradelstų įmokų skaičiaus (x18)* – IV sumažėjo (tačiau diskriminacinė šio įvesties kintamojo galia vis tiek išliko didelė), o kitų įvesties kintamųjų – netgi padidėjo (žr. 30 lent.).

31 lentelė. Įvesties kintamojo Pinigai ir pinigų ekvivalentai / Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai *reikšmių skirstinio pokyčiai*

A	B	C	D	E	F	G	H	I
Įvesties kintamojo reikšmė	WOE	Įmonių dalis (modelio kūrimo imtis)	Įmonių dalis (patikimumo vertinimo imtis)	= D – C	= D/C	= ln(F)	= E·G	Pokytis
< = 0,0055	-1,049	9,89 %	8,53 %	-0,01	0,86	-0,15	0,00	↓
0,0056 – 0,0190	-0,5456	19,66 %	8,40 %	-0,11	0,43	-0,85	0,10	↓
0,0191 – 0,0374	-0,4332	19,70 %	8,23 %	-0,11	0,42	-0,87	0,10	↓
0,0375 – 0,1122	0,1621	9,86 %	8,66 %	-0,01	0,88	-0,13	0,00	↓
0,1123 – 0,1807	0,2429	9,85 %	18,32 %	0,08	1,86	0,62	0,05	↑
0,1808 – 1,108	0,5672	19,70 %	31,49 %	0,12	1,60	0,47	0,06	↑
> 1,108	0,8585	9,85 %	13,73 %	0,04	1,39	0,33	0,01	↑
Trūkstamos reikšmės	-0,5417	1,50 %	2,65 %	0,01	1,77	0,57	0,01	↑
		100,00 %	100,00 %	Stabilumo indeksas			0,33	

Šaltinis: autorės skaičiavimai.

Lyginamoji analizė. Nebuvo lyginamajai analizei atlikti tikusių lyginamųjų dydžių. Geriausia būtų buvę patikimumo vertinimo imtį sudarančių įmonių vidaus reitingus lyginti su iš išorinių paskolų registru arba iš komercinių bankų gautais tų pačių įmonių išorės reitingais (arba vertinimo balais). Tačiau pirkti tokią informaciją iš išorinių paskolų registru yra brangu, o komerciniai bankai tokio pobūdžio informaciją laiko konfidencialia ir jos neteikia. Todėl buvo pasirinkti šeši kitų tiek Lietuvos, tiek užsienio autorių skirtingais laikotarpiais sukurti statistiniai vertinimo balais modeliai ir jais buvo įvertinta patikimumo vertinimo imties įmonių kredito rizika (žr. 12 priedą). Šio vertinimo rezultatai buvo palyginti su tais, kurie buvo gauti taikant šioje disertacijoje pasiūlytą statistinį Lietuvos įmonių vertinimo balais modelį ir reitingų skalę. Taikant visus šešis modelius buvo nustatytos įmonės, pagal atitinkamą modelį pasižymėjusios didele bankroto rizika (žr. 13 priedą). Tada tokios įmonės buvo priskirtos reitingams pagal šioje disertacijoje pasiūlytą reitingų sistemą. Papildomai buvo įvertinta kiekvieno modelio diskriminacinė galia naudojant patikimumo vertinimo imties įmones. Matyti, kad beveik visada daugiau kaip 60 % didele bankroto rizika pasižymėjusių įmonių pateko į blogesnius reitingus (nuo 5 iki 9). Tai rodo, kad yra ryšys tarp pagal pasiūlytą reitingų sistemą nustatytų Lietuvos įmonių reitingų ir kitų autorių sukurtais modeliais nustatytų tų pačių įmonių vertinimo balų. Vienintelis modelis, kurį taikant iš visų didele bankroto rizika pasižymėjusių įmonių tik 42,36 % pateko į blogesnius reitingus – Stoškaus ir kt. (2007) diskriminantinės analizės modelis. Tačiau šis modelis nediskriminuoja įmonių (AR yra artimas 0), todėl kliautis jo rezultatais neverta. Visų kitų modelių AR didesnis nei 40 % (AUC didesnis nei 70 %), o tai reiškia, kad šių modelių diskriminacija yra priimtina, taigi, jie gali būti taikomi lyginamajai analizei atlikti.

3.2. ĮMONIŲ REITINGŲ ĮSIPAREIGOJIMŲ NEĮVYKDYMO TIKIMYBĖS APSKAIČIAVIMAS

3.2.1. Reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimas iš įmonių individualių įsipareigojimų neįvykdymo tikimybių

Reitingo PD galima apskaičiuoti tiek iš įmonių individualių PD, tiek iš metinių reitingų ODF. Naudojant įmonių individualias PD, reitingo PD galima gauti trimis metodais: skaičiuojant PD(1), PD(2) ar PD(3). 10 404 patikimumo vertinimo imties įrašai buvo išskaidyti į tris dalis ir pasirinkus tris vertinimo datas (2005 m. gruodžio 31 d., 2006 m. gruodžio 31 d. ir 2007 m. gruodžio 31 d.) priskirti reitingams pagal įmonių individualią PD. Tada imant 2007 m. gruodžio 31 d. duomenis buvo apskaičiuotos reitingų PD (žr. 32 lent.).

Matyti, kad PD(1), PD(2) ir PD(3) reikšmės yra labai panašios tarpusavyje, ypač antrame–septintame reitinguose. PD(1) yra lygios atitinkamam reitingui priskirtų įmonių individualių PD vidurkiui, todėl jos atspindi vidutinę konkretaus reitingo įmonių riziką 2007 m. gruodžio 31 d. PD(2) ir PD(3) yra lygios apatinės ir viršutinės PD ribų vidurkiams (atitinkamai aritmetiniam ir geometriniam). Nė viena iš šių PD neatspindi faktinių tapsmo „blogomis“ įmonėmis atvejų 2006–2007 metais, nes jas skaičiuojant metiniai reitingų ODF nebuvo naudoti.

PD kalibravimo tikslumo vertinimas. Įmones priskyrus reitingams ir apskaičiavus reitingų PD, buvo galima įvertinti PD kalibravimo tikslumą. Informacija apie įmones, kurios tapo „blogos“ 2008 metais (per 1 metų stebėjimo laikotarpį nuo 2007 m. gruodžio 31 d.) (t. y. 2008 m. ODF), buvo naudota reitingų PD patikimumui vertinti.

Buvo taikytas Briero balų metodas ir keli kiti kriterijai:

- H ir L;
- binominis (Voldo);
- binominis (vienpusis);
- binominis (vienpusis) su normaliaja aproksimacija, be koreliacijos;
- binominis (vienpusis) su normaliaja aproksimacija, su koreliacija;
- normalusis (dvipusis);
- ilgo laikotarpio normalusis kriterijus.

Pirmuose trijuose reitinguose dažnai negaliojo sąlyga, kad $PD \cdot N_i > 5$ ir $(1 - PD_i) \cdot N_i > 5$, čia: N_i – i reitingo įmonių skaičius, tačiau buvo taikyti ir tie kriterijai, kuriuos taikant ši sąlyga turėtų galioti (žr. 14 priedą). Apibendrinus gautus rezultatus matyti, kad tik PD(1) visada yra tikslios. Nors visais trimis metodais apskaičiuotos PD yra labai panašios tarpusavyje, PD(2) ir PD(3) kai kuriems reitingams yra per mažos arba per didelės. Todėl tolesnei analizei buvo pasirinktos PD(1).

32 lentelė. Lietuvos įmonių reitingų PD

Reitingas	Apatinė PD riba	Viršutinė PD riba	2006 metai				2007 metai				2008 metai			PD(1)	PD(2)	PD(3)	PD(4)
			Įmonės 2005-12-31	Tapo „blogos“ iki 2006-12-31	ODF ₂₀₀₆	Įmonės 2006-12-31	Tapo „blogos“ iki 2007-12-31	ODF ₂₀₀₇	Įmonės 2007-12-31	Tapo „blogos“ iki 2008-12-31	ODF ₂₀₀₈						
A	B	C	D	E	F = E/D	G	H	I = H/G	J	K	L = K/J	M	N=(B+C)/2	O=v(B-C)	P=(F+I)/2		
1	0,01 %	1,00 %	99	0	0,00 %	222	0	0,00 %	369	2	0,54 %	0,58 %	0,51 %	0,10 %	0,00 %		
2	1,01 %	2,20 %	292	3	1,03 %	554	7	1,26 %	706	10	1,42 %	1,50 %	1,61 %	1,49 %	1,15 %		
3	2,21 %	3,70 %	344	0	0,00 %	259	8	3,09 %	361	11	3,05 %	2,98 %	2,96 %	2,86 %	1,54 %		
4	3,71 %	8,00 %	732	31	4,23 %	660	33	5,00 %	889	49	5,51 %	5,48 %	5,86 %	5,45 %	4,62 %		
5	8,01 %	16,00 %	726	44	6,06 %	278	36	12,95 %	464	52	11,21 %	11,50 %	12,01 %	11,32 %	9,51 %		
6	16,01 %	28,00 %	568	78	13,73 %	254	47	18,50 %	326	68	20,86 %	20,76 %	22,01 %	21,17 %	16,12 %		
7	28,01 %	40,50 %	333	90	27,03 %	38	9	23,68 %	50	17	34,00 %	34,61 %	34,26 %	33,68 %	25,36 %		
8	40,51 %	61,00 %	275	64	23,27 %	412	259	62,86 %	482	272	56,43 %	53,45 %	50,76 %	49,71 %	43,07 %		
9	61,01 %	99,99 %	151	70	46,36 %	184	144	78,26 %	376	279	74,20 %	76,25 %	80,50 %	78,10 %	62,31 %		
Iš viso			3 520	380	10,80 %	2 861	543	18,98 %	4 023	760							

Šaltinis: autorės skaičiavimai.

3.2.2. Reitingų įsipareigojimų neįvykdymo tikimybės apskaičiavimas iš metinių faktinių „blogų“ įmonių dažnių

Kaip minėta ankstesnėje dalyje, reitingo PD galima apskaičiuoti tiek iš įmonių individualių PD, tiek iš metinių reitingų ODF. PD(4) buvo apskaičiuotos kaip aritmetinis 2006 metų ODF ir 2007 metų ODF vidurkis. Informacija apie įmones, kurios tapo „blogos“ 2008 metais (per vienerių metų stebėjimo laikotarpį nuo 2007 m. gruodžio 31 d.) (t. y. 2008 m. ODF), buvo naudota tik jau apskaičiuotų reitingų PD patikimumui vertinti, bet jas skaičiuojant – neįtraukta. Faktinių „blogų“ įmonių 2006–2007 metais buvo nedaug, todėl PD(4) yra mažos, jos yra kur kas mažesnės už kitais metodais apskaičiuotas reitingų PD (žr. 32 lent.). Ypač rimta problema buvo 1 reitinge – jame faktinių „blogų“ įmonių nebuvo nei 2006, nei 2007 metais, todėl 1 reitingo PD(4) yra lygi 0 %. Ši PD negalėtų būti naudojama IRB metodą taikančiame banke kapitalo poreikiui skaičiuoti. Toks bankas turėtų ją pakeisti Lietuvos banko nustatyta minimalia PD reikšme – 0,03 %. Tačiau net ir tada Lietuvos bankui susirūpinimą keltų tai, kad bankas, kapitalo poreikiui skaičiuoti naudojantis šias PD(4), gali gauti mažesnę negu derėtų kapitalo poreikį. Atsižvelgiant į tai, buvo pritaikyti keli įvairių autorių pasiūlyti LDP reitingų PD apskaičiavimo metodai, išnagrinėti 1.2.2 dalyje.

Buvo naudotas FSA (2006) pasiūlytas LDP apibrėžimas, t. y. LDP – reitingas, kuriame yra ne daugiau kaip 20 faktinių „blogų“ įmonių. LDP apibrėžimas buvo taikytas reitingo, o ne viso portfelio lygiu, be to, apibrėžiant LDP reitingą nebuvo atsižvelgta į visų konkretaus reitingo įmonių skaičių ar viso portfelio įmonių skaičių. Tų reitingų, kurie neatitiko LDP apibrėžimo (t. y. kuriuose buvo daugiau kaip 20 faktinių „blogų“ įmonių), PD(4) buvo apskaičiuotos įprastu būdu, t. y. kaip aritmetinis metinių reitingo ODF vidurkis.

Pirmame–trečiame reitinguose tiek 2006, tiek 2007 metais buvo ne daugiau kaip 20 faktinių „blogų“ įmonių. Septintas reitingas 2006 metais nebuvo LDP reitingas, tačiau 2007 metais – buvo. Taigi, pirmo–trečio ir septinto reitingų PD(4) turėjo būti perskaičiuotos atitinkamus ODF_{2006} ir ODF_{2007} PD(4) formulėje pakeičiant PD_{2006} ir PD_{2007} , apskaičiuotomis taikant keletą metodų (žr. 33 lent.):

- Burgt (2007) CAP kreivės metodą;
- Tasche (2009) ROC kreivės metodą;
- Forrest (2005) metodą be koreliacijos;
- Pluto, Tasche (2005) metodą be koreliacijos;
- Kiefer (2006) Bajeso metodą.

Kaip matyti, buvo pasirinkti ne visi 1.2.2 dalyje išnagrinėti LDP reitingų PD apskaičiavimo metodai. Nebuvo gauta informacijos apie įmonių rodiklių pokyčius per metus


ir tiksliai datas, kada įmonės tapo „blogos“, todėl nebuvo galima taikyti keleto metodų, susijusių su reitingų pasikeitimo matricomis ir saviranka.

Forrest (2005) ir Pluto, Tasche (2005) metodai su koreliacija buvo atmesti, nes juos taikant konservatyvios PD gali būti pernelyg didelės.

Daugiaperiodžiai Wilde, Jackson (2006) ir Pluto, Tasche (2005) metodai taip pat buvo atmesti, nes juos taikant yra gaunamos arba pernelyg didelės, arba pernelyg mažos PD, be to, rašant šią disertaciją PD(4) buvo apskaičiuotos laikantis Lietuvos banko pagal Naująjį kapitalo susitarimą nustatyto apibrėžimo, t. y. kaip aritmetinis metinių ODF vidurkis. Kadangi LDP reitingų metiniai ODF gali būti netikslūs, jie PD(4) formulėje buvo pakeisti PD₂₀₀₆ ir PD₂₀₀₇. O taikant daugiaperiodžius metodus, PD(4) iš viso nebūtų skaičiuojama, ji būtų pakeičiama kita atitinkamu daugiaperiodžiu metodu apskaičiuota reitingo PD.

Su makroekonominiais rodikliais susijęs metodas labiau tinka fizinių asmenų PD apskaičiuoti, be to, jis labiau tinka nustatant atskirų įvesties kintamojo reikšmių grupių PD, o ne reitingų PD.

Burgt (2007) CAP kreivės ir Tasche (2009) ROC kreivės metodai. Nors taikant abu šiuos metodus yra užtikrinamas PD monotoniškumas (t. y. pirmo reitingo PD < antro reitingo PD < trečio reitingo PD ir t. t.), PD₂₀₀₆ ir PD₂₀₀₇ yra pernelyg mažos (žr. 15 priedą). Geresnių reitingų PD₂₀₀₆ ir PD₂₀₀₇ yra reikšmingai mažesnės už tų metų ODF, ypač taikant Tasche (2009) ROC kreivės metodą. Taikant šį metodą, pirmo ir antro reitingų PD₂₀₀₆ ir PD₂₀₀₇ yra pernelyg mažos, netgi palyginti su PD₂₀₀₆ ir PD₂₀₀₇, gautomis taikant Burgt (2007) CAP kreivės metodą. Pavyzdžiui, antro reitingo ODF₂₀₀₆ yra lygus 1,03 %, CAP kreivės PD₂₀₀₆ yra lygi 0,37 %, o ROC kreivės PD₂₀₀₆ yra dar mažesnė – 0,18 % (žr. 31 pav.).



31 pav. Pirmų trijų LDP reitingų ODF₂₀₀₆ ir PD₂₀₀₆

Šaltinis: autorės skaičiavimai.

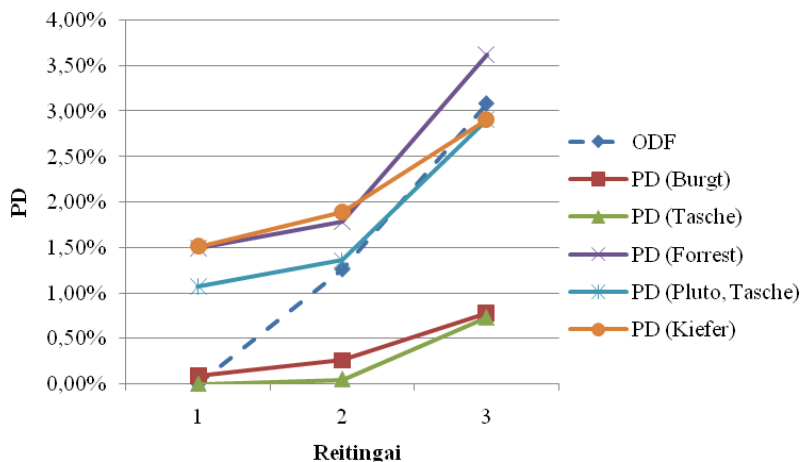
33 lentelė. Reitingų PD(4) palyginimas*

Reitingas	Burgt (2007) CAP kreivės metodas			Tasche (2009) ROC kreivės metodas			Forrest (2005) metodas			Pluto, Tasche (2005) metodas			Kiefer (2006) Bajeso metodas		
	PD ₂₀₀₆ arba ODF ₂₀₀₆	PD ₂₀₀₇ arba ODF ₂₀₀₇	PD(4)	PD ₂₀₀₆ arba ODF ₂₀₀₆	PD ₂₀₀₇ arba ODF ₂₀₀₇	PD(4)	PD ₂₀₀₆ arba ODF ₂₀₀₆	PD ₂₀₀₇ arba ODF ₂₀₀₇	PD(4)	PD ₂₀₀₆ arba ODF ₂₀₀₆	PD ₂₀₀₇ arba ODF ₂₀₀₇	PD(4)	PD ₂₀₀₆ arba ODF ₂₀₀₆	PD ₂₀₀₇ arba ODF ₂₀₀₇	PD(4)
1 LDP	0,28 %	0,09 %	0,19 %	0,06 %	0,00 %	0,03 %	0,85 %	1,49 %	1,17 %	0,35 %	1,07 %	0,71 %	0,60 %	1,51 %	1,06 %
2 LDP	0,37 %	0,26 %	0,32 %	0,18 %	0,05 %	0,12 %	0,88 %	1,78 %	1,33 %	0,40 %	1,36 %	0,88 %	0,68 %	1,89 %	1,29 %
3 LDP	0,61 %	0,78 %	0,70 %	0,80 %	0,73 %	0,77 %	0,88 %	3,63 %	2,26 %	0,43 %	2,91 %	1,67 %	0,44 %	2,91 %	1,68 %
4	4,23 %	5,00 %	4,62 %	4,23 %	5,00 %	4,62 %	4,23 %	5,00 %	4,62 %	4,23 %	5,00 %	4,62 %	4,23 %	5,00 %	4,62 %
5	6,06 %	12,95 %	9,51 %	6,06 %	12,95 %	9,51 %	6,06 %	12,95 %	9,51 %	6,06 %	12,95 %	9,51 %	6,06 %	12,95 %	9,51 %
6	13,73 %	18,50 %	16,12 %	13,73 %	18,50 %	16,12 %	13,73 %	18,50 %	16,12 %	13,73 %	18,50 %	16,12 %	13,73 %	18,50 %	16,12 %
7 LDP	27,03 %	28,06 %	27,54 %	27,03 %	34,63 %	30,83 %	27,03 %	38,64 %	32,83 %	27,03 %	17,31 %	22,17 %	27,03 %	24,57 %	25,80 %
8	23,27 %	62,86 %	43,07 %	23,27 %	62,86 %	43,07 %	23,27 %	62,86 %	43,07 %	23,27 %	62,86 %	43,07 %	23,27 %	62,86 %	43,07 %
9	46,36 %	78,26 %	62,31 %	46,36 %	78,26 %	62,31 %	46,36 %	78,26 %	62,31 %	46,36 %	78,26 %	62,31 %	46,36 %	78,26 %	62,31 %

Šaltinis: autorės skaičiavimai. *Reitingų PD(4) buvo apskaičiuotos pagal vieną iš formulių: $PD(4)_{LDP_reitingo} = \frac{PD_{2006} + PD_{2007}}{2}$ arba

$$PD(4)_{NE_LDP_reitingo} = \frac{ODF_{2006} + ODF_{2007}}{2}$$

Nors, kai reitingas yra pripažįstamas LDP reitingu, yra manoma, kad jo ODF gali būti netikslus, todėl su juo lyginti PD₂₀₀₆ nederėtų, be to, skaičiuojant PD₂₀₀₆, antro reitingo ODF reikšmė yra tarsi padalijama pirmam, antram ir trečiam reitingams, nes yra trys LDP reitingai iš eilės, tačiau net ir atsižvelgus į tai, šios PD₂₀₀₆ ir PD₂₀₀₇ vis tiek yra pernelyg mažos, ypač palyginti su PD₂₀₀₆ ir PD₂₀₀₇, apskaičiuotomis taikant kitus metodus (žr. 33 lent., 31 ir 32 pav.).



32 pav. Pirmų trijų LDP reitingų ODF₂₀₀₇ ir PD₂₀₀₇

Šaltinis: autorės skaičiavimai.

Blogesnių reitingų PD₂₀₀₆ ir PD₂₀₀₇ reikšmės nėra pernelyg mažos, ypač tos, kurių reikia (t. y. septinto LDP reitingo CAP kreivės PD₂₀₀₇ ir ROC kreivės PD₂₀₀₇) (žr. 15 priedą). Matyti, kad taikant abu šiuos metodus geresnių reitingų PD yra pernelyg sumažinamos, o būtent geresni reitingai dažniausiai ir būna LDP reitingai. Be to, metodų rezultatai labai priklauso nuo taikomo vertinimo balais modelio diskriminacinės galios. Kadangi 2007 metais modelis skolininkus diskriminuoja geriau (AR 2007 metais yra 73,85 %, o 2006 metais – tik 63,21 %), tai geresnių reitingų PD₂₀₀₇ yra mažesnės už tų reitingų PD₂₀₀₆. O taikant kitus metodus pirmo, antro ir trečio reitingų PD₂₀₀₇ yra didesnės už PD₂₀₀₆, ir tai atrodo pagrįsta, nes pirmų trijų reitingų įmonių portfelio ODF 2007 metais buvo didesnis nei 2006 metais.

Pluto, Tasche (2005) metodas be koreliacijos. Pirmų trijų LDP reitingų PD₂₀₀₆ ir PD₂₀₀₇ buvo apskaičiuotos kaupiamuoju būdu: sudedant visas įmones ir visas faktines „blogas“ įmones iki atitinkamo reitingo (įskaitytinai), t. y. 2006 metais „blogų“ pirmo reitingo įmonių skaičius buvo lygus 3, o visų to reitingo įmonių skaičius – 735, „blogų“ antro reitingo įmonių skaičius buvo lygus 3, o visų to reitingo įmonių skaičius – 636,

„blogų“ trečio reitingo įmonių skaičius buvo lygus 0, o visų to reitingo įmonių skaičius – 344 (žr. 32 lent.). Tačiau septinto reitingo PD₂₀₀₇ buvo apskaičiuota atskirai, nes šis reitingas nepatenka tarp kelių kitų LDP reitingų (šeštas ir aštuntas reitingai – ne LDP reitingai). 16 priede yra pateiktos PD₂₀₀₆, PD₂₀₀₇ ir jas naudojant apskaičiuotos PD(4) esant skirtingiems pasiklovimo lygmenims. Matyti, kad apskaičiuotos PD₂₀₀₆ nedidėja monotoniškai, esant beveik visiems pasiklovimo lygmenims trečio reitingo PD₂₀₀₆ yra mažesnė už antro reitingo PD₂₀₀₆ (išskyrus tik 99,99 % pasiklovimo lygmenį, tačiau tada PD₂₀₀₆ yra pernelyg didelės). Taip pat buvo apskaičiuotos koreguotos PD₂₀₀₆ ir PD₂₀₀₇, kaip siūlo šio metodo autoriai:

$$\text{koreguota_} PD_i = K \cdot PD_i; K = \frac{ODF_{\text{portfelio}}}{\sum_{i=1}^n (PD_i \cdot N_i) / \sum_{i=1}^n N_i},$$

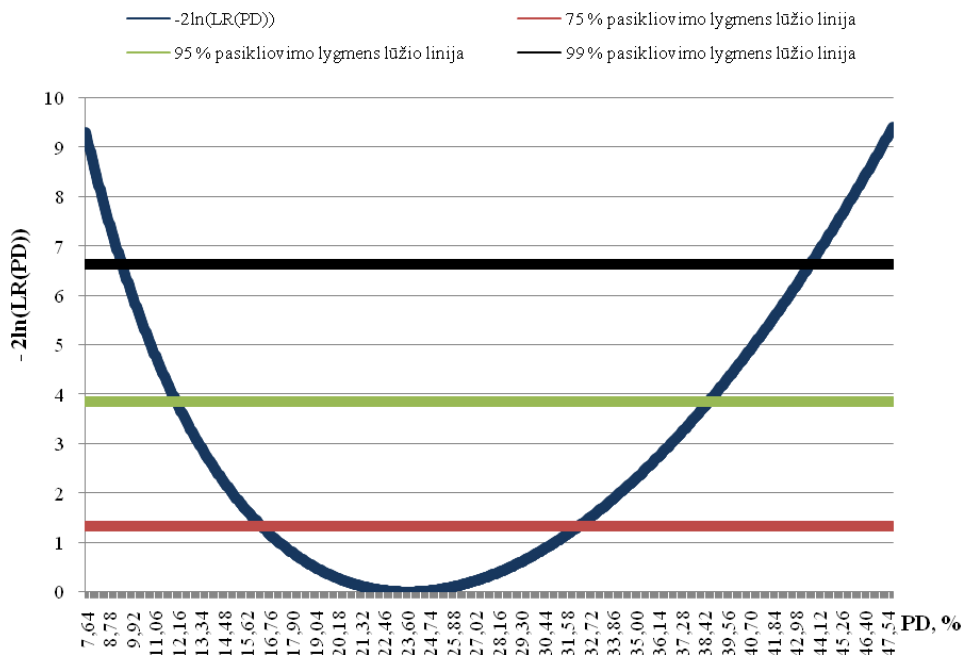
čia: PD_i – i -tojo LDP reitingo PD₂₀₀₆ ar PD₂₀₀₇, apskaičiuotos taikant Pluto, Tasche (2005) metodą be koreliacijos; K – korekcijos veiksnys; N_i – visų i -tojo LDP reitingo įmonių skaičius; n – LDP reitingų portfelyje skaičius; i kinta nuo 1 iki n ; $ODF_{\text{portfelio}}$ – portfelio, susidedančio tik iš LDP reitingų, ODF (2006 m. portfelį sudaro pirmi trys reitingai, todėl $ODF_{\text{portfelio}}$ yra lygus 0,41 % (3/735), o 2007 metais – pirmi trys reitingai ir septintas reitingas, todėl $ODF_{\text{portfelio}}$ yra lygus 2,24 % (24/1073)).

Tolesnei analizei buvo pasirinktos koreguotos PD₂₀₀₆ ir PD₂₀₀₇, kai pasiklovimo lygmuo yra 99,99 %. Šios reikšmės monotoniškai didėja ir nėra pernelyg didelės (žr. 33 lent.).

Forrest (2005) metodas be koreliacijos. Septinto reitingo PD₂₀₀₇ buvo apskaičiuotos atskirai, nes šis reitingas nepatenka tarp kelių kitų LDP reitingų. Grafiškai konservatyvi PD₂₀₀₇ gali būti surandama dešiniajame $-2\ln(LR(PD))$ kreivės ir atitinkamo pasiklovimo lygmens lūžio linijos susikirtimo taške⁴² (žr. 33 pav.). Forrest (2005) siūlo naudoti 95 % pasiklovimo lygmenį, todėl būtent toks pasiklovimo lygmuo buvo pasirinktas tolesnei analizei. Tokiu atveju konservatyvi PD₂₀₀₇ yra lygi 38,64 %. Nors PD₂₀₀₇ galėtų būti pasirenkama iš intervalo [12,16 %; 38,64 %], buvo nuspręsta naudoti konservatyvias PD.

Pirmų trijų reitingų PD₂₀₀₆ ir PD₂₀₀₇ buvo apskaičiuotos kaupiamuoju būdu, nes yra trys LDP reitingai iš eilės. Iš pradžių buvo apskaičiuotos minimalios ir maksimalios PD₂₀₀₆ ir PD₂₀₀₇ (žr. 34 lent.).

⁴² Lūžio linijos buvo išvestos taikant „MS Excel“ funkciją =CHIINV(100 % – pasiklovimo lygmuo;1) (žr. 5 priedą).



33 pav. Septinto reitingo PD_{2007} apskaičiavimas

Šaltinis: autorės skaičiavimai.

34 lentelė. Minimalios ir maksimalios PD_{2006} ir PD_{2007}

Reitingas	2006		2007	
	MIN PD	MAX PD	MIN PD	MAX PD
1 LDP	0,05 %	1,45 %	0,64 %	2,74 %
2 LDP	0,05 %	1,68 %	0,82 %	3,49 %
3 LDP	0,00 %	1,13 %	0,96 %	7,07 %

Šaltinis: autorės skaičiavimai.

Kaip matyti iš 1.2.2 dalyje atliktos analizės, galimų PD kombinacijų taškai gali išeiti už minimalių PD linijų apibrėžiamo ploto ribų (žr. 19 pav.), todėl žingsninė paieška ieškant konservatyvių PD_{2006} ir PD_{2007} buvo pradėta nuo mažesnių už minimalias PD reikšmių (nuo 0,01 % pirmo reitingo, nuo 0,02 % – antro ir nuo 0,03 % – trečio) ir tęsta iki atitinkamo reitingo maksimalios PD. Iš visų galimų PD kombinacijų buvo atrinktos konservatyvios, t. y. tenkinančios šias sąlygas:

- $PD_1 < PD_2 < PD_3$,
- $-2\ln(LR(PD)) = \text{CHIINV}((100\% - 95\%); 3)$,
- PD kombinacija turi būti ant labiausiai nutolusios figūros linijos (žr. 19 pav.).

Vėliau iš visų konservatyvių PD kombinacijų kiekvienų metų buvo pasirinkta tik viena, kurią naudojant yra gaunamas didžiausias kapitalo, reikalingo kredito rizikai padengti, poreikis (tokia PD₂₀₀₆ kombinacija yra 0,85 %/0,879 %/0,88 %, o PD₂₀₀₇ kombinacija – 1,49 %/1,78 %/3,63 %). Kapitalo poreikis buvo apskaičiuotas taikant mažmeninių paskolų grupės formules (žr. 3.3.1 dalį), 45 % LGD ir 100 tūkst. Lt EAD.

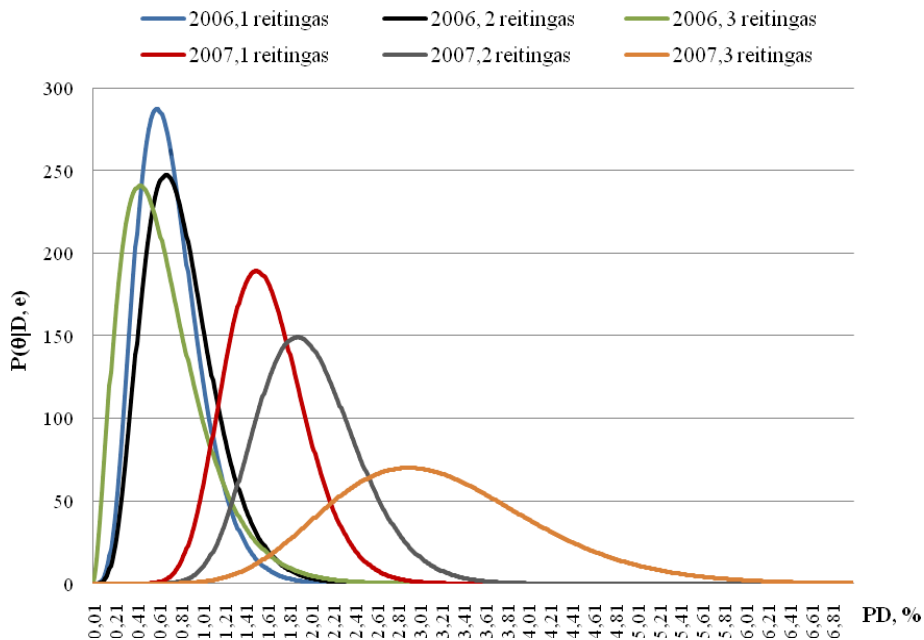
Kiefer (2006) Bajeso metodus. Iš pradžių reikėjo pasirinkti apriorinio θ skirstinio $p(\theta|e)$ ir nesąlyginio faktinių „blogų“ skolininkų skaičiaus skirstinio $p(D|e)$ formą. Kaip minėta 1.2.2 dalyje, keturių parametrų beta skirstinys kai kuriose situacijose gali būti pernelyg ribotas, todėl buvo pasirinktas dviejų parametrų beta skirstinys. Pirmiems trims LDP reitingams buvo naudotos hipotetinės PD₂₀₀₆ ir PD₂₀₀₇ nuo 0,01 % iki 7,00 % ir žingsnis, lygus 0,01 %. Taip apskaičiuoti parametrai α ir β yra lygūs atitinkamai 3 ir 79. Tačiau skaičiuojant septinto reitingo PD₂₀₀₇ reikėjo naudoti kitus α ir β parametrus, nes šio reitingo PD₂₀₀₇ turi būti kur kas didesnė už pirmų trijų LDP reitingų PD₂₀₀₇. Taigi, septintam reitingui buvo naudotos hipotetinės PD₂₀₀₇ nuo 12,00 % iki 45,00 % ir žingsnis, lygus 0,01 %. Taip apskaičiuoti parametrai α ir β yra lygūs atitinkamai 6 ir 15.

Kaip ir taikant Pluto, Tasche (2005) metodą be koreliacijos, pirmų trijų LDP reitingų PD₂₀₀₆ ir PD₂₀₀₇ buvo apskaičiuotos kaupiamuoju būdu – sudedant visas įmones ir visas faktines „blogas“ įmones iki atitinkamo reitingo (įskaitytinai). Septinto reitingo PD₂₀₀₇ buvo apskaičiuota atskirai, nes šis reitingas nepatenka tarp kelių kitų LDP reitingų. Buvo pasirinktos tos PD₂₀₀₆ ir PD₂₀₀₇, kurioms esant posteriorinis skirstinys $p(\theta|D,e)$ įgyja didžiausią reikšmę (žr. 34 ir 35 pav.).

Matyti, kad pirmų trijų LDP reitingų PD₂₀₀₆ nedidėja monotoniškai (trečio reitingo posteriorinis PD₂₀₀₆ skirstinys yra labiau pasislinkęs į kairę nei pirmo ir antro reitingų posterioriniai PD₂₀₀₆ skirstiniai).


Septinto reitingo PD₂₀₀₇ yra lygi 24,57 % (nes posteriorinis skirstinys $p(\theta|D,e)$ šiame taške įgyja didžiausią reikšmę).

PD(4) kalibravimo tikslumo vertinimas. PD(4) kalibravimo tikslumui vertinti buvo taikyti tokie patys metodai kaip ir vertinant PD(1), PD(2) ir PD(3) kalibravimo tikslumą (žr. 17 priedą). Apibendrinus PD kalibravimo tikslumo vertinimo rezultatus galima daryti išvadą, kad tiksliausias LDP reitingų PD(4) yra taikant Forrest (2005) metodą be koreliacijos (taikant šį metodą LDP reitingų PD(4) yra tikslios pagal visų binominių ir normaliųjų kriterijų rezultatus). Be to, taikant šį metodą yra automatiškai užtikrinamas kelių iš eilės LDP reitingų PD monotoniškumas. O štai Burgt (2007) CAP kreivės ir Tasche (2009) ROC kreivės metodai tinka mažiausiai, nes, nors juos taikant ir yra užtikrinamas PD monotoniškumas, PD yra pernelyg mažos, ypač geresniuose reitinguose, be to, rezultatai yra pernelyg priklausomi nuo modelio diskriminacinės galios.



34 pav. Posterioriniai pirmo, antro ir trečio reitingų PD_{2006} ir PD_{2007} skirstiniai $p(\theta|D,e)$

Šaltinis: autorės skaičiavimai.



35 pav. Posteriorinis septinto reitingo PD_{2007} skirstinys $p(\theta|D,e)$

Šaltinis: autorės skaičiavimai.

Pluto, Tasche (2005) metodo be koreliacijos ir Kiefer (2006) Bajeso metodo trūkumas yra tai, kad PD gali būti nemonotoniškos. Nors ir galima eksponentiškai glodinti PD₂₀₀₆ ir PD₂₀₀₇ arba PD(4) (žr. 18 priedą), tada ilgiau trunka skaičiuoti galutines reitingų PD, skaičiavimo procesas tampa sudėtingesnis. Be to, net ir naudojant glodintas PD₂₀₀₆ ir PD₂₀₀₇ arba PD(4), ne visų taikytų kriterijų atveju buvo priimta H_0 hipotezė (t. y. kad PD(4) yra tiksli). Tačiau reikėtų atsižvelgti ir į tai, kad, taikant Forrest (2005) metodą be koreliacijos, reikia turėti programavimo įgūdžių, nes priešingu atveju žingsninė konservatyvių PD₂₀₀₆ ir PD₂₀₀₇ paieška užimtų labai daug laiko, ypač kai yra trys ar daugiau LDP reitingų iš eilės.

Lyginant tarpusavyje PD(1), PD(2), PD(3) ir PD(4) kalibravimo tikslumą, matyti, kad tiksliausias yra PD(1). Šios PD buvo pasirinktos tolesnei analizei.

3.2.3. Stabilumo ir lyginamoji analizė

Stabilumo analizė. Atliekant PD stabilumo analizę reikia nustatyti, kokią įtaką skaičiuojant PD naudojamų duomenų, parametrų ir daromų prielaidų arba apskaičiavimo metodų pokyčiai daro PD. Ankstesnėse šios disertacijos dalyse PD buvo skaičiuotos keliais skirtingais metodais – PD(1), PD(2), PD(3) ir PD(4). Be to, LDP reitingų PD(4) buvo perskaičiuotos taikant įvairius specialius tokių reitingų PD apskaičiavimo metodus prie skirtingų pasiklovimo lygmenų. PD buvo palygintos tarpusavyje, įvertintas kiekvienos jų kalibravimo tikslumas ir pasirinktas geriausias metodas – PD(1). Tačiau derėtų atsižvelgti ir į tai, kokią įtaką skaičiuojant PD(1) naudotų įmonių imties pokyčiai daro PD(1) reikšmei. Todėl PD(1) buvo perskaičiuotos naudojant tris papildomas duomenų imtis:

- kūrimento imties duomenis iki 2005 m. gruodžio 31 d.;
- kūrimento imties duomenis iki 2006 m. gruodžio 31 d.;
- kūrimento imties duomenis iki 2007 m. gruodžio 31 d.

Matyti, kad naudojant visas keturias duomenų imtis (tiek pradinę, tiek tris papildomas) apskaičiuotos PD(1) yra labai panašios (žr. 35 lent.). Buvo įvertintas kitų trijų PD(1) kalibravimo tikslumas taikant visus anksčiau aprašytus kalibravimo tikslumo vertinimo metodus naudojant patikimumo vertinimo imties 2008 metų duomenis. Kai pasiklovimo lygmuo 99,99 %, nė vienam reitingui nebuvo atmesta nė vieno iš binominių ir normaliųjų kriterijų H_0 hipotezė, o tai rodo, kad ir kitos PD(1) visiems reitingams yra tikslios. Briero balas, apskaičiuotas naudojant pradinę PD(1), yra tik šiek tiek mažesnis už Briero balus, apskaičiuotus naudojant kitas tris PD(1). Kuo mažesnis Briero balas, tuo tikslesnės PD(1). Taikant H ir L kriterijų, χ^2 reikšmės, apskaičiuotos naudojant kitas tris PD(1), yra didesnės

už χ^2 reikšmę, apskaičiuotą naudojant pradinę PD(1), tačiau H_0 hipotezė nebuvo atmesta net ir kai pasiklivimo lygmuo 95 % (nes statistikos p reikšmės visada yra didesnės už 0,05). Taigi, visa tai rodo, kad PD(1) – stabilios ir nepriklauso tik nuo vienos specifinės skaičiuojant pradinę PD(1) naudotos duomenų imties.

35 lentelė. PD(1) stabilumo analizė

Reitingas	PD(1) (pradinės)	PD(1) (2005 12 31)	PD(1) (2006 12 31)	PD(1) (2007 12 31)
1	0,58 %	0,70 %	0,67 %	0,69 %
2	1,50 %	1,65 %	1,63 %	1,65 %
3	2,98 %	2,92 %	2,91 %	2,95 %
4	5,48 %	5,65 %	5,74 %	5,68 %
5	11,50 %	11,55 %	11,48 %	11,52 %
6	20,76 %	21,28 %	21,74 %	21,12 %
7	34,61 %	34,44 %	33,79 %	33,89 %
8	53,45 %	49,30 %	50,01 %	49,10 %
9	76,25 %	72,87 %	76,27 %	77,09 %
χ^2 reikšmė	2,70	10,64	9,42	12,64
Statistikos p reikšmė	0,975	0,301	0,399	0,180
Briero balas	0,0922	0,0927	0,0926	0,0928

Šaltinis: autorės skaičiavimai.

Lyginamoji analizė. Nebuvo išorės lyginamųjų dydžių, su kuriais būtų buvę galima lyginti PD(1). Buvo galima iš išorinių paskolų registų arba komercinių bankų pirkti tų pačių įmonių, kurių duomenys buvo naudoti skaičiuojant PD(1), individualias PD, tada priskirti įmones reitingams ir apskaičiuoti aritmetinį individualių PD vidurkį. Toks vidurkis būtų buvęs tinkamas lyginamasis dydis. Taip pat buvo galima rasti išorinį paskolų registrą arba komercinį banką, kuris taiko įmonių reitingų sistemą, susidedančią iš devynių reitingų „geroms“ įmonėms ir vieno reitingo „blogoms“ įmonėms, ir tada palyginti jų nustatytas reitingų PD su šioje disertacijoje pateiktomis PD(1). Tačiau pirkti tokią informaciją iš išorinių paskolų registų yra brangu, o komerciniai bankai tokio pobūdžio informaciją laiko konfidencialia ir jos neteikia. Todėl PD(1) buvo palygintos su kitų dviejų Lietuvos autorių apskaičiuotomis Lietuvos įmonių reitingų PD (žr. 36 lent.).

Dvi reitingų skalės skiriasi reitingų skaičiumi. Lyginamajai analizei naudotoje reitingų sistemoje yra aštuoni reitingai „geroms“ įmonėms, o devintas reitingas, D2, yra skirtas įmonėms, kurios jau faktiškai tapo „blogos“. Šioje disertacijoje pasiūlytoje reitingų sistemoje yra devyni reitingai „geroms“ įmonėms, o dešimtas reitingas – įmonėms, kurios jau faktiškai tapo „blogos“. Sugretinus abi reitingų skales matyti, kad esama panašumų, pavyzdžiui, trečio reitingo PD(1) nedaug skiriasi nuo A reitingo pradinės PD, ketvirto

reitingo PD(1) – nuo BBB reitingo pradinės PD, o šešto reitingo PD(1) – nuo C reitingo modifikuotos PD. Be to, reikia turėti omenyje, jog skiriasi ne tik modeliui kurti ir PD apskaičiuoti naudotų įmonių imtis (kuriant šioje disertacijoje pasiūlytą reitingų sistemą buvo naudota kur kas daugiau įmonių – 22 799 įmonės modeliui kurti ir 4 023 įmonės PD(1) apskaičiuoti, o lyginamajai analizei naudotos PD buvo apskaičiuotos tik naudojant 100 įmonių duomenis), bet ir „blogos“ įmonės apibrėžimas.

36 lentelė. PD(1) lyginamoji analizė

Šioje disertacijoje pasiūlyta reitingų sistema		Lyginamajai analizei naudota reitingų sistema		
Reitingai	PD(1)	Reitingai	Pradinės PD	Modifikuotos PD
1	0,58 %	AAA	–*	0,00 %
2	1,50 %	AA	0,00 %	0,00 %
3	2,98 %	A	3,80 %	0,00%
4	5,48 %	BBB	6,10 %	3,00 %
		BB	1,90 %	3,70%
5	11,50 %	B	8,30 %	7,30 %
6	20,76 %	C	14,30 %	20,00 %
7	34,61 %			
8	53,45 %			
9	76,25 %	D	91,10 %	91,10 %
„Blogos“ įmonės	100,00 %	D2	100,00 %	100,00 %

Šaltinis: autorės skaičiavimai ir Mileris, Boguslauskas (2011). *Nebuvo įmonių.

3.3. SUKURTOS REITINGŲ SISTEMOS TAIKYMAS BANKE


3.3.1. Reitingų sistemos taikymo sritys

Reitingų sistemos taikymas teikiant paskolas. Pasiūlyta reitingų sistema gali būti taikoma ir kaip paraiškų reitingų sistema. Renkantis lūžio reitingą, nuo kurio besikreipiančių dėl paskolos įmonių paraiškos turėtų būti atmetamos, buvo analizuota:

- viso portfelio ODF priklausomybė nuo paraiškų atmetimo lygio;
- kaupiamojo faktinių „gerų“ įmonių skaičiaus pokyčio ir kaupiamojo faktinių „blogų“ įmonių skaičiaus pokyčio santykis;
- portfelio grynoji dabartinė vertė;
- faktinių „gerų“ ir faktinių „blogų“ įmonių skirstiniai ir reitingų ODF.

Viso portfelio ODF priklausomybė nuo paraiškų atmetimo lygio. Kūrimo imties įmonių portfelio ODF buvo lygus 20,64 %, tačiau jeigu bankai 2005–2007 metais nebūtų

suteikę paskolų dešimčiai procentų pačių rizikingiausių įmonių, t. y. jeigu būtų buvę atmesta 10 % pačių rizikingiausių paraiškų⁴³, ODF būtų sumažėjęs iki 15,35 % ir t. t. Trikampis 36 pav. žymi hipotetinio banko, kuris pasirinktų taikyti šią reitingų sistemą, įmonių portfelio ODF ir atmetimo lygį. Tarkime, kad šis bankas praėjusiais metais, taikydamas savo reitingų sistemą, atmetė 30 % visų besikreipusių įmonių paraiškų, o jo praėjusių metų portfelio ODF buvo lygus 15 %. Prieš pradėdamas taikyti pasiūlytą reitingų sistemą, bankas turėtų nustatyti lūžio reitingą. Bankas galėtų rinktis tašką žemiau trikampio, išlaikydamas tokį patį atmetimo lygį, bet sumažindamas ODF, arba tašką į kairę nuo trikampio, išlaikydamas tokį patį ODF, bet sumažindamas atmetimo lygį.



36 pav. Portfelio ODF priklausomybė nuo atmetimo lygio

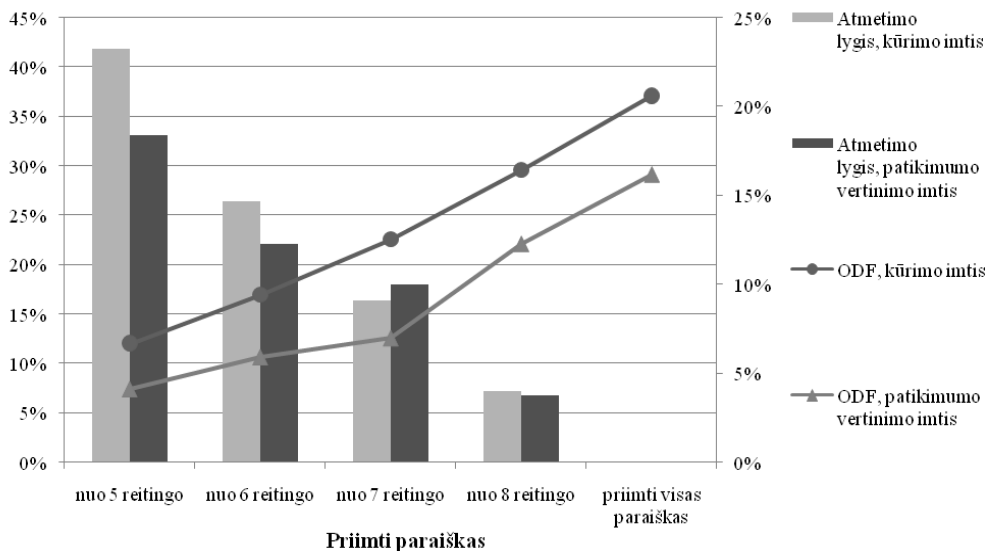
Šaltinis: autorės skaičiavimai.

Iš 37 pav. matyti, kad jei paraiškos būtų buvusios priimanos tik nuo penkto reitingo, atmetimo lygis kūrimo imtyje būtų buvęs 41,89 %, o patikimumo vertinimo imtyje – 33,15 %. Jei paraiškos būtų buvusios priimanos nuo šešto reitingo, atmetimo lygis kūrimo imtyje būtų buvęs 26,41 %, o patikimumo vertinimo imtyje – 22,12 %. Taigi, minėtasis bankas galėtų lūžio reitingu pasirinkti septintą arba šeštą reitingą, t. y. priimti paraiškas nuo šešto reitingo arba tik nuo penkto reitingo.

⁴³Paprastumo dėlei buvo padaryta prielaida, jog kiekviena įmonė kiekvienais metais pateikė tik po vieną paraišką paskolai gauti, t. y. kad reitingų sistema yra taikoma paskolos, o ne skolininko lygiu.

Atmetimo lygis

ODF



37 pav. Lūžio reitingo pasirinkimas

Šaltinis: autorės skaičiavimai.

Be abejo, bankas galėtų savo nuožiūra pakoreguoti pasiūlytą reitingų skalę – nustatyti kitokias individualių PD ribas ar netgi pakeisti reitingų skaičių. Tuomet jis galėtų nustatyti lūžio reitingą, atsižvelgdamas į savo individualius poreikius. Be to, bankas turėtų 36–37 pav. pateiktą analizę atlikti ir su savais duomenimis. Tačiau derėtų turėti omenyje, kad kuriant pasiūlytą reitingų sistemą buvo naudoti išorinio paskolų registro duomenys, todėl jie reprezentuoja tiek priimtas, tiek atmestas paraiškas, nes įmonė, negavusi paskolos viename banke, galėjo kreiptis į kitą banką ir ten ją gauti. O atskiras bankas, kuris atliktų analizę tik naudodamas savus duomenis, įtrauktų tik informaciją apie savo priimtas paraiškas ir hipotetiškai paslinktų atmetimo lygį aukščiau. Be abejo, bankas galėtų įtraukti ir atmestas paraiškas, jas priskyręs prie „gerų“ arba prie „blogų“, taikydamas šios disertacijos 1.1.1.7 ir 3.3.3 dalyse pateiktus atmetimų paraiškų įtraukimo metodus.

Kaupiamojo faktinių „gerų“ įmonių skaičiaus pokyčio ir kaupiamojo faktinių „blogų“ įmonių skaičiaus pokyčio santykis. Kaip minėta 1.1.1.1 dalyje, paprastai lūžio reitingu yra pasirenkamas toks reitingas, nuo kurio atmestus paraiškas, šis santykis yra nuo 5:1 iki 3:1.

Iš 37 ir 38 lentelių matyti, kad naudojant kūrimo imties duomenis toks santykis yra lūžio reitingu pasirinkus septintą reitingą (t. y. priimant paraiškas tik nuo šešto reitingo), o naudojant patikimumo vertinimo imties duomenis, toks santykis yra tiek lūžio reitingu pasirinkus septintą, tiek aštuntą reitingą (t. y. priimant paraiškas tik nuo šešto arba septinto reitingo).

37 lentelė. Lūžio reitingas naudojant kūrimo imtį

A	B	C	D	E	F=D/E
Lūžio reitingas	Kaupiamasis „gerų“ įmonių skaičius	Kaupiamasis „blogų“ įmonių skaičius	Kaupiamojo „gerų“ įmonių skaičiaus pokytis	Kaupiamojo „blogų“ įmonių skaičiaus pokytis	Pokyčių santykis
1	0	0	–	–	–
2	555	13	555	13	43
3	2 058	53	1 503	40	38
4	4 026	108	1 968	55	36
5	8 262	311	4 236	203	21
6	12 364	884	4 102	573	7
7	15 196	1 581	2 832	697	4
8	16 673	2 392	1 477	811	2
9	17 663	3 477	990	1 085	1

Šaltinis: autorės skaičiavimai.


38 lentelė. Lūžio reitingas naudojant patikimumo vertinimo imtį

A	B	C	D	E	F = D/E
Lūžio reitingas	Kaupiamasis „gerų“ įmonių skaičius	Kaupiamasis „blogų“ įmonių skaičius	Kaupiamojo „gerų“ įmonių skaičiaus pokytis	Kaupiamojo „blogų“ įmonių skaičiaus pokytis	Pokyčių santykis
1	0	0	–	–	–
2	688	2	688	2	344
3	2 220	22	1 532	20	77
4	3 165	41	945	19	50
5	5 333	154	2 168	113	19
6	6 669	286	1 336	132	10
7	7 624	479	955	193	5
8	7 929	595	305	116	3
9	8 503	1 190	574	595	1

Šaltinis: autorės skaičiavimai.


Portfelio grynoji dabartinė vertė. Kaip minėta 1.1.1.1 dalyje, lūžio reitingu galima pasirinkti ir tokį reitingą, nuo kurio atmetus paraiškas, portfelio grynoji dabartinė vertė (toliau – NPV) yra didžiausia.

Tarkime, bankas būtų nusprendęs nesuteikti paskolos nė vienai iš kūrimo imties įmonių. Tokiu atveju šis bankas būtų patyręs alternatyviasias sąnaudas (t. y. jis nebūtų gavęs tam tikrų pajamų, nes nebūtų suteikęs paskolų toms įmonėms, kurios būtų tapusios „geros“) ir būtų gavęs alternatyviasias pajamas (t. y. jis būtų išvengęs tam tikrų sąnaudų, nes nebūtų suteikęs paskolų toms įmonėms, kurios būtų tapusios „blogos“), tačiau nebūtų patyręs jokių faktinių sąnaudų ir nebūtų gavęs jokių faktinių pajamų. Kaip matyti iš 38 pav., jei nebūtų buvusi suteikta nė viena paskola, alternatyviosios sąnaudos būtų viršijusios alternatyviasias pajamas, todėl portfelio NPV būtų buvusi neigiama. Bankas neturėtų rinktis tokių variantų, kuriems esant NPV būtų neigiama. Bankui geriausia rinktis tokį variantą, kuriam esant portfelio NPV būtų didžiausia. Didžiausia kūrimo imties įmonių portfelio NPV būtų lūžio reitingu pasirinkus septintą reitingą (t. y. priimant paraiškas tik nuo šešto reitingo).



38 pav. NPV analizė (kūrimo imtis)

Šaltinis: autorės skaičiavimai.



39 pav. NPV analizė (patikimumo vertinimo imtis)

Šaltinis: autorės skaičiavimai.

Didžiausia patikimumo vertinimo imties įmonių portfelio NPV būtų lūžio reitingu pasirinkus aštuntą reitingą (t. y. priimant paraiškas tik nuo reitingo) (žr. 39 pav. ir 19 priedą).

Faktinių „gerų“ ir faktinių „blogų“ įmonių skirstiniai ir reitingų ODF. Iš 28 ir 29 pav. matyti, kad abiejose imtyse „gerų“ šešto reitingo įmonių dalis, palyginti su visomis „geromis“ įmonėmis, maždaug sutampa su „blogų“ šešto reitingo įmonių dalimi, palyginti su visomis „blogomis“ įmonėmis. Iki šešto reitingo „gerų“ įmonių dalis yra didesnė už „blogų“ įmonių dalį, o nuo šešto reitingo – mažesnė.

Iš 27, 28 lentelių ir 30 pav. matyti, kad reitingo ODF pradeda reikšmingai didėti nuo septinto reitingo.

39 lentelė. Reitingų sistema teikiant paskolas

Reitingas	Apatinė PD riba	Viršutinė PD riba	Rizikos apibūdinimas	Veiksmai teikiant paskolas
1	0,01 %	1,00 %	Puiki būklė	Priimti paraišką
2	1,01 %	2,20 %	Labai gera būklė	
3	2,21 %	3,70 %	Gera būklė	
4	3,71 %	8,00 %	Nuosaiki rizika	
5	8,01 %	16,00 %	Patenkinama rizika	
6	16,01 %	28,00 %	Būtina stebėti	„Pilkoji zona“: reikia vertinti papildomai
7	28,01 %	40,50 %	Didesnė nei vidutinė rizika	
8	40,51 %	61,00 %	Didelė rizika	Atmesti paraišką
9	61,01 %	99,99 %	Didžiausia rizika	
10	100 %		Faktinės „blogos“ įmonės	Nenaudojamas

Šaltinis: sudaryta autorės.

Taigi, atlikus analizę matyti, kad lūžio reitingas turėtų būti šeštas, septintas arba aštuntas reitingas. Buvo nuspręsta „kieto“ lūžio reitingu pasirinkti aštuntą reitingą, t. y. siūloma iš karto atmesti dėl paskolos besikreipiančių aštuntam ir devintam reitingams priskirtų įmonių paraiškas. „Minkšto“ lūžio reitingu buvo pasirinktas šeštas reitingas. Tai reiškia, kad įmonių, priskirtų pirmam–penktam reitingams, paraiškas derėtų priimti, o įmonių, priskirtų šeštam ir septintam reitingams, paraiškas reikėtų vertinti papildomai (pvz., suteikti paskolą tik taikant papildomas kredito rizikos mažinimo priemones ir pan.). Reitingų skalėje turėtų būti dar ir dešimtas reitingas, kuris teikiant naujas paskolas nebūtų naudojamas, bet į jį patektų tos įmonės, kurioms paskola buvo suteikta anksčiau ir jos jau tapo „blogos“ (žr. 39 lent.).

Ši reitingų sistema yra tinkamesnė vertinant įmones, kurių paskolos banke yra priskiriamos mažmeninių paskolų grupei, nes įmonių priskyrimas reitingams yra pagrįstas ne laisvai interpretuojamais kriterijais, bet iš anksto apibrėžtais įvesties kintamaisiais. Tačiau banko ekspertai, atsižvelgdami į papildomą informaciją apie įmonę (įmonės padėtį rinkoje, jos vadovus, akcininkus, visos įmonių grupės, kuriai priklauso įmonė, riziką ir t. t.), paskolą (sumą, terminą, tikslą ir t. t.) ir užtikrinimo priemones, galėtų pagal šią reitingų sistemą nustatytus įmonių reitingus peržiūrėti ir, jei reikėtų, juos arba sprendimą suteikti paskolą (nesuteikti paskolos) pakoreguoti. Tada ši reitingų sistema tikėtų ir vertinant įmones, kurių paskolos nėra priskiriamos mažmeninių paskolų grupei, juolab kad reitingų skaičius atitinka tokiu atveju Lietuvos banko keliamus reikalavimus (t. y. kad būtų bent septyni reitingai „geroms“ įmonėms ir vienas reitingas „blogoms“ įmonėms).


Paskolų teikimo procesas taikant pasiūlytą reitingų sistemą turėtų būti visiškai arba iš dalies automatizuotas. Jeigu papildomas vertinimas (pvz., „pilkosios zonos“ arba ir kitiems reitingams priskirtų įmonių) būtų atliekamas banko informacinių technologijų sistemose naudojant iš anksto numatytus kriterijus, tada paskolų teikimo procesas būtų visiškai automatizuotas ir įmonė atsakymą, ar jai bus suteikta paskola, ar ne, gautų iš karto. Tačiau jeigu papildomą vertinimą („pilkosios zonos“ arba ir kitiems reitingams priskirtų įmonių) atliktų banko ekspertai ir (arba) aukštesnis banko organas, tada paskolų teikimo procesas būtų tik iš dalies automatizuotas. Kaip matyti iš 3 pav., įmonių paskolų teikimas paprastai nebūna visiškai automatizuotas, tačiau mažų sumų paskolų teikimas smulkioms ir vidutinėms įmonėms galėtų toks būti.

Bankas galėtų numatyti paskolų sumas, kuri priklausytų nuo įmonės reitingo, limitus, t. y. įmonei, turinčiai tam tikrą reitingą, nebūtų suteikiama didesnė nei tam tikra suma.

Pasiūlyta reitingų sistema gali būti taikoma ne tik kaip pagrindinė teikiant paskolas, bet ir kaip pagal kitą banko taikomą reitingų sistemą nustatyto reitingo peržiūrėjimo priemonė arba kaip lyginamosios analizės priemonė.

Tačiau bankui, pasirinkusiam šią reitingų sistemą, reikėtų atlikti šioje dalyje aprašytą analizę ir naudojant savus duomenis.


Reitingų sistemos taikymas kainodaros procese. Taikant 1.1.1 dalyje pateiktą kredito rizikos maržos formulę ir naudojant kūrimo ir patikimumo vertinimo imties duomenis bei kelis skirtingus LGD dydžius, buvo apskaičiuotos visų reitingų įmonių kredito rizikos maržos (žr. 40 ir 41 pav.):



40 pav. Kredito rizikos marža (kūrimo imtis)

Šaltinis: autorės skaičiavimai.

Matyti, kad kuo blogesnis įmonės reitingas ir kuo didesnę nuostolį patirtų bankas tai įmonei tapus „blogai“, tuo didesnę kredito rizikos maržą reikėtų pridėti prie pradinės palūkanų normos.



41 pav. Kredito rizikos marža (patikimumo vertinimo imtis)

Šaltinis: autorės skaičiavimai.

LGD įtaka kredito rizikos maržai ypač sustiprėja nuo septinto reitingo. Nors taikant pasiūlytą reitingų sistemą yra rekomenduojama neteikti paskolų aštuntam ir devintam reitingams priskirtoms įmonėms, jei didelė tolerancija rizikai pasižymintis bankas nuspręstų teikti paskolas ir tokioms įmonėms, prie pradinių palūkanų normų reikėtų pridėti labai dideles kredito rizikos maržas (ypač kai LGD = 100 %).

Reitingų sistemos taikymas skaičiuojant kapitalo, reikalingo kredito rizikai padengti, poreikį. Ši reitingų sistema gali būti taikoma IRB metodu įdiegusiuose bankuose kapitalo poreikiui skaičiuoti. Ji labiau tinka tų įmonių paskolų, kurios pagal Lietuvos banko reikalavimus yra priskiriamos mažmeninių paskolų grupei, kapitalo poreikiui skaičiuoti. Tačiau ši reitingų sistema gali būti taikoma ir tų įmonių paskolų, kurios nėra priskiriamos mažmeninių paskolų grupei, kapitalo poreikiui skaičiuoti.

Taigi, naudojant kūrimo ir patikimumo vertinimo imčių įmonių duomenis, trimis variantais buvo apskaičiuotas kapitalo, reikalingo jų kredito rizikai padengti, poreikis (žr. 42 ir 43 pav.). Buvo padaryta prielaida, kad kūrimo ir patikimumo vertinimo imčių įmonės yra hipotetinio banko skolininkės. Kuriant šią reitingų sistemą iš išorinio paskolų registro nebuvo gauta informacija apie visas paskolų sumas, todėl, kad būtų paprasčiau, buvo

padaryta prielaida, jog visa kiekvienos paskolos suma yra lygi 100 tūkst. litų, o kiekviena įmonė kiekvienais metais yra paėmusi po vieną paskolą.

- *mišrus portfelis*: įmonės buvo padalytos į tris grupes. Pirmiausia, tų įmonių, kurių pardavimo pajamos ne didesnės nei 10 mln. litų, turtas ne didesnis nei 6 mln. litų, o darbuotojų skaičius ne didesnis nei 29, paskolos buvo priskirtos mažmeninių paskolų grupei. Likusios įmonės buvo padalytos į dvi grupes: kai pardavimo pajamos mažesnės nei 50 mln. eurų, buvo naudota atskira koreliacijos formulė taikant pardavimo pajamų korekciją, o kai ne mažesnės – naudota nekoreguota koreliacijos formulė (žr. 40 lent.).


40 lentelė. Kūrimo ir patikimumo vertinimo imčių įmonių paskolos

	Kūrimo imties įmonių paskolos	Patikimumo vertinimo imties įmonių paskolos
Mažmeninės paskolos	53,28 %	49,91 %
Paskolos, nepriskirtos prie mažmeninių; pardavimo pajamos < 50 mln. litų	43,92 %	48,14 %
Paskolos, nepriskirtos prie mažmeninių; pardavimo pajamos > = 50 mln. litų	2,80 %	1,95 %

Šaltinis: autorės skaičiavimai.

- *visos paskolos buvo priskirtos mažmeninių paskolų grupei*: Lietuvos bankų apklausos rezultatai parodė, kad dauguma bankų taikė didesnę nei 100 tūkst. litų visos paskolos sumos limitą. Todėl labai tikėtina, kad iš visų Lietuvos bankų atsitiktinai išsirinkus vieną banką, jis taikytų didesnę nei 100 tūkst. litų visos paskolos sumos limitą. Tokiu atveju, jeigu šis bankas netaikytų papildomų kriterijų, visų abiejų imčių įmonių paskolos būtų priskirtos mažmeninių paskolų grupei. Jei šis bankas taikytų papildomus kriterijus (pvz., pardavimo pajamas, turtą, darbuotojų skaičių) ir šių kriterijų ribos būtų labai didelės, taip pat galėtų atsitikti taip, kad visos paskolos patektų į mažmeninių paskolų grupę.
- *nė viena paskola nebuvo priskirta mažmeninių paskolų grupei*: Lietuvos bankų apklausos rezultatai parodė, kad du bankai taikė ne didesnę nei 100 tūkst. litų visos paskolos sumos limitą. Tarkime, kad hipotetinis bankas taiko mažesnę nei 100 tūkst. litų visos paskolos sumos limitą. Tokiu atveju, jeigu šis bankas netaikytų papildomų kriterijų, tai nė viena paskola nebūtų priskirta mažmeninių paskolų grupei. Jeigu šis bankas taikytų papildomus kriterijus ir jų ribos būtų labai mažos, taip pat galėtų atsitikti taip, kad nė viena paskola nepatektų į mažmeninių paskolų grupę.

■ Visos paskolos - mažmeninės ■ Nei viena paskola nėra mažmeninė ■ Mišrus portfelis




42 pav. Kapitalo poreikis (kūrimo imtis)*

Šaltinis: autorės skaičiavimai. *Prielaidos: EAD = 100 tūkst. litų, LGD = 45 %, M = 2,5 m.

Matyti, kad kapitalo poreikis yra didžiausias, kai nėra viena paskola nepatenka į mažmeninių paskolų grupę, mažiausias – kai visos paskolos patenka į mažmeninių paskolų grupę. Kapitalo poreikis yra labai jautrus banko taikomiems paskolų priskyrimo mažmeninių paskolų grupei kriterijams. Nors nei įmonių reitingai, nei kiti prielaidose naudoti dydžiai (EAD, LDG, M) nebuvo keičiami, skirtingais variantais apskaičiuotas kapitalo poreikis labai skiriasi vien dėl skirtingų priskyrimo kriterijų. Tai rodo, kad IRB metodą taikantys bankai, nustatydami paskolų priskyrimo mažmeninių paskolų grupei kriterijus, turėtų būti atsargūs ir atlikti nuodugnią analizę, be to, daugiau dėmesio bankų taikomiems priskyrimo kriterijams turėtų skirti ir Lietuvos bankas.

■ Visos paskolos - mažmeninės ■ Nei viena paskola nėra mažmeninė ■ Mišrus portfelis




43 pav. Kapitalo poreikio (patikimumo vertinimo imtis)*

Šaltinis: autorės skaičiavimai.

Tik IRB metodą įdiegę bankai galėtų taikyti šią reitingų sistemą kapitalo poreikiui skaičiuoti, nes standartizuotą metodą taikantiems bankams skaičiuojant kapitalo poreikį nereikia rizikos koeficientų sieti su savo skolininkų vidaus reitingais. Tačiau visi bankai, net ir taikantys standartizuotą metodą, galėtų šią reitingų sistemą taikyti skaičiuodami vidaus kapitalo poreikį, reitingų PD(1) galėtų būti naudojamos taikant vidinius paskolų portfelio rizikos vertinimo metodus.

Reitingų sistemos taikymas atliekant testavimą nepalankiausiomis sąlygomis.


Bankai, siekdami įvertinti tam tikrų konkrečių įvykių ar būsimų ekonominių sąlygų pokyčių poveikį visam savo kapitalo poreikiui, turi reguliariai atlikti kredito rizikos testavimą nepalankiausiomis sąlygomis. Šią reitingų sistemą galima taikyti modeliuojant įmonių skirstinio pagal reitingus pokyčius. Pavyzdžiui, galima apskaičiuoti, kiek padidės kapitalo, reikalingo kredito rizikai padengti, poreikis, jeigu prasidėjus ekonominiam nuosmukiui dvigubai padidės kiekvienos įmonės individuali PD. Įmonių dalis geresniuose reitinguose sumažėtų, o blogesniuose reitinguose – padidėtų (žr. 44 pav.). Tam tikra kiekvieno reitingo rizikingiausių įmonių dalis migruotų į blogesnį reitingą, todėl vėliau apskaičiuotos galutinės reitingų PD(1) beveik nesiskirtų nuo pradinių reitingų PD(1). Tačiau kapitalo poreikis vis tiek padidėtų, nes dėl įmonių migracijos į blogesnius reitingus didesnei daliai įmonių būtų priskirtos blogesnių reitingų PD(1).



44 pav. Įmonių skirstinio ir reitingų PD(1) pokyčiai (kūrimo imtis)*

Šaltinis: autorės skaičiavimai. *Įmonės, kurių galutinės individualios PD tampa didesnės nei 100 % arba lygios 100 %, buvo priskirtos dešimtam reitingui ir šiai analizei nebuvo naudotos.

Kapitalo poreikio pokytis yra didžiausias, visas paskolas priskyrus mažmeninių paskolų grupei, o mažiausias – nė vienos paskolos nepriskyrus mažmeninių paskolų grupei (žr. 45 pav.). Matyti, kad kapitalo, reikalingo mažmeninių paskolų kredito rizikai padengti, poreikis yra ypač jautrus įmonių PD pokyčiams.



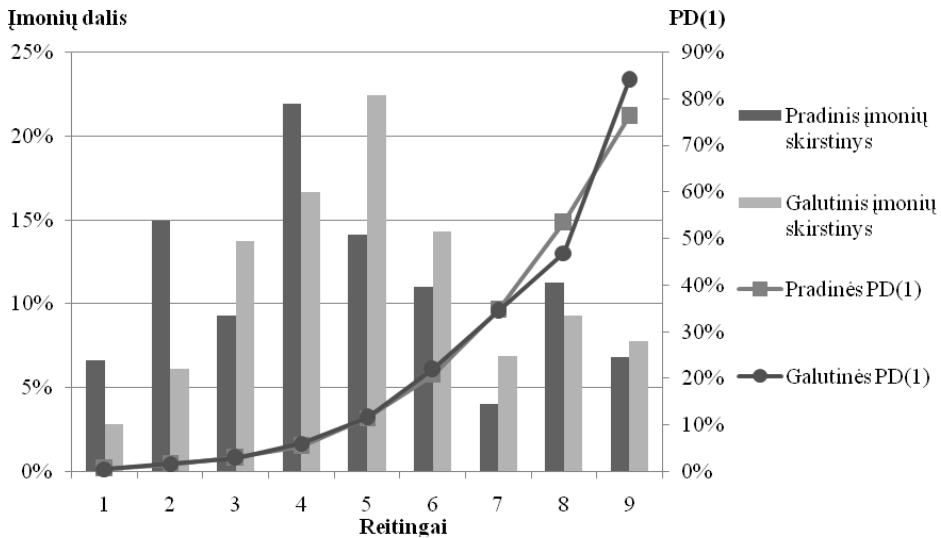
45 pav. Kapitalo poreikis esant ekonominiam nuosmukiui (kūrimo imtis)*

Šaltinis: autorės skaičiavimai. *10 reitingui priskirtų įmonių RW buvo apskaičiuoti pagal formulę:
 $RW = \text{Max} \{0; 12,5 \cdot (LGD - EL_{BE})\}$; $EL_{BE} = 10 \%$.

Naudojant patikimumo vertinimo imtį, rezultatai yra panašūs, kaip ir naudojant kūrimo imtį – daugelyje blogesnių reitingų įmonių procentinė dalis padidėjo, o galutinė reitingų PD(1) beveik nesiskiria nuo pradinės reitingų PD(1) (išskyrus reikšmingesnę pokytį aštuntame ir devintame reitinguose) (žr. 46 pav.).


Tokios pačios išvados ir dėl kapitalo poreikio pokyčio: pokytis yra didžiausias, visas paskolas priskyrus mažmeninių paskolų grupei, o mažiausias – nė vienos paskolos nepriskyrus mažmeninių paskolų grupei (žr. 47 pav.).

Bankas, taikydamas pasiūlytą reitingų sistemą, galėtų pasirinkti ir įvairius kitus testavimo nepalankiausiomis sąlygomis scenarijus, pavyzdžiui, apskaičiuoti, kiek padidės kapitalo, reikalingo kredito rizikai padengti, poreikis, jeigu prasidėjus ekonominiam nuosmukiui iš kiekvieno reitingo 20 % įmonių migruos per du reitingus žemyn arba iš kiekvieno reitingo 50 % įmonių migruos per vieną reitingą žemyn ir t. t.



46 pav. Įmonių skirstinio ir reitingų PD(1) pokyčiai (patikimumo vertinimo imtis)

Šaltinis: autorės skaičiavimai.



47 pav. Kapitalo poreikis esant ekonominiam nuosmukiui (patikimumo vertinimo imtis)

Šaltinis: autorės skaičiavimai.

Taip pat galima sudaryti regresijos lygtį naudojant įmonių portfelio ODF kaip išvesties kintamąjį ir pasirinktus makroekonominčius rodiklius kaip įvesties kintamuosius. Tuomet galima įvairiai keisti makroekonominių rodiklių reikšmes, apskaičiuoti stresinį portfelio

ODF ir pridėti atitinkamą dedamąją prie logistinės regresijos lygties laisvojo nario⁴⁴. Tačiau tam reikėtų turėti sukaupus bent pastarųjų keliolikos metų duomenis, o rašant disertaciją buvo gauti tik trejų metų duomenys, todėl ši analizė nebuvo atlikta.

Reitingų sistemos taikymas kitose banko veiklos srityse. Reitingų sistema gali būti taikoma ne tik kaip paraiškų, bet ir kaip elgsenos reitingų sistema pakartotinai apskaičiuojant įmonių individualias PD ir, jeigu reikia, koreguojant jų reitingus. Tada būtų naudojami ir aštuntas bei devintas reitingai. Nors įmonėms, patenkančioms į aštuntą ir devintą reitingus, paskolos neturėtų būti teikiamos, į juos įmonės gali patekti vėliau, kai joms jau buvo suteikta paskola. Įmonių reitingų peržiūrų dažnumas taip pat turėtų būti siejamas su jų reitingu: blogesnių reitingų įmonių elgseną derėtų vertinti dažniau, pavyzdžiui, kartą per ketvirtį.

Ši reitingų sistema taip pat gali būti taikoma skaičiuojant paskolų vertės sumažėjimą (įmonių reitingai gali būti naudojami skaičiuojant paskolų NPV) ir pateikiant ataskaitas banko vadovams (yra siūloma reguliariai teikti ataskaitas apie skolininkų skirstinį pagal reitingus ir stabilumo indeksą (žr. 28 ir 29 lent.), reitingų ODF pokyčius (žr. 30 pav.), reitingų pasikeitimus (žr. 2 intarpa), portfelio ODF priklausomybę nuo atmetimo lygio (žr. 36 ir 37 pav.); kredito rizikos maržas (žr. 40 ir 41 pav.); testavimo nepalankiausiomis sąlygomis rezultatus (žr. 44–47 pav.) ir kt.).

Kita šios reitingų sistemos taikymo sritis – banko strategijos formavimas. Informacija apie įmonių skirstinį pagal reitingus, įmonių reitingų pasikeitimus ir galimus šių pasikeitimų pokyčius ateityje, apie tai, kokia viso portfelio rizika, kokios rizikos tendencijos ir t. t., gali būti naudojama nustatant tikslines skolininkų rinkas ir pan. Tačiau reikėtų atsižvelgti į tai, kad ši reitingų sistema yra labiau laiko momento, nei ekonominio ciklo reitingų sistema, todėl ekonominėms sąlygoms blogėjant, įmonių reitingai blogės, o joms gerėjant – gerės (žr. 41 lent.).

41 lentelė. Reitingų ir PD pokyčiai blogėjant ekonominėms sąlygoms

	Reitingai (ir kartu individualios PD)	Reitingų PD
Laiko momento reitingų sistema	Blogėja (individualios PD – didėja)	Nesikeičia (dėl skolininkų migracijos)
Ekonominio ciklo reitingų sistema	Nesikeičia (nes eliminuota cikliškumodedamoji)	Didėja

Šaltinis: sudaryta autorės.

⁴⁴ Kūrimo imties įmonių portfelio ODF $\approx 20,6\%$, todėl logistinės regresijos lygties laisvasis narys b_0 lygus $-1,352$ (t. y. $\ln(20,6\% / (100\% - 20,6\%)) \approx -1,352$). Tačiau jeigu apskaičiuotas stresinis portfelio ODF lygus, sakysime, 35% , tada laisvasis narys b_0 lygus $-0,619$. Pakeitus vieną lygties laisvąjį narį kitu, visų įmonių individualios PD padidėtų ir būtų galima apskaičiuoti kapitalo poreikio pokytį.

Todėl sudarant ilgalaikę banko veiklos strategiją labiau tiktų taikyti kitą, naują, ekonominio ciklo reitingų sistemą. Kad naujas statistinis vertinimo balais modelis įgytų ekonominio ciklo modelio bruožų, reikėtų sukaupti bent 14 metų ekonominiam ciklui jautrių įvesties kintamųjų reikšmių dinamikos eilutes ir atimti periodiškai kintančias cikliškumo (ir sezoniškumo, jei duomenys ketvirtiniai) dedamąsias, paliekant tik tendą ir atsitiktinius nuokrypius.

Lietuvos bankuose gali būti taikoma nebūtinai visa šioje disertacijoje pasiūlyta reitingų sistema, bet ir atskiros jos dalys: Lietuvos įmonių logistinės regresijos modelis, kiekviename šio modelio kūrimo etape taikyti metodai, įvesties kintamieji ir t. t. (žr. 20 priedą). Pavyzdžiui, savą statistinį įmonių modelį kuriantis bankas galėtų pasirinkti taikyti šioje disertacijoje pasiūlytą Lietuvos įmonių reitingų skalę, susidedančią iš devynių reitingų. Tačiau jeigu jis nuspręstų sudaryti savą reitingų skalę, galėtų pasinaudoti optimalios reitingų skalės sudarymo principais. Tokiame banke Lietuvos įmonių logistinės regresijos modelis ir šioje disertacijoje pateiktos reitingų PD galėtų būti taikomi lyginamosios analizės tikslais.

3.3.2. Pakartotinis patikimumo vertinimas

Nors buvo atliktas pasiūlytos reitingų sistemos išankstinis patikimumo vertinimas, be to, konkretus bankas, norėdamas šią reitingų sistemą taikyti savo veikloje, turėtų atlikti išankstinį patikimumo vertinimą naudodamas savus duomenis, jau pradėjęs ją taikyti konkrečiame banke reikėtų ir toliau reguliariai (bent kartą per metus) vertinti jos patikimumą naudojant naujus banko skolininkų duomenis. Iš pradžių turėtų būti vertinama modelio diskriminacinė galia. Jeigu modelis blogai diskriminuoja skolininkus ($AR < 40\%$, $AUC < 70\%$), reikėtų sukurti naują statistinį vertinimo balais modelį (žr. 48 pav.). Tik tada, kai modelio diskriminacinė galia tenkina, turėtų būti skaičiuojamos reitingų PD ir vertinamas jų kalibravimo tikslumas. Šios disertacijos autorė, atlikdama išankstinį patikimumo vertinimą, naudojo 95 % pasiklovimo lygmenį, tačiau bankui, atliekančiam pakartotinį patikimumo vertinimą, yra rekomenduojama naudoti liberalesnį – 99,99 % – pasiklovimo lygmenį. Jeigu bent vieno iš kriterijų H_0 hipotezė, kai pasiklovimo lygmuo 99,99 %, yra atmetama, tada galima sukurti naują reitingų skalę (pakeisti reitingų skaičių ir (arba) apatinę ir viršutinę individualių PD ribas) arba prie reitingų PD pridėti konservatyvumo maržas (kai H_0 hipotezė yra atmetama tik vienam iš reitingų), iš naujo apskaičiuoti reitingų PD ir įvertinti šių naujų PD kalibravimo tikslumą.

Tik tada yra siūloma vertinti reitingų sistemos stabilumą. Jeigu modelio diskriminacinės galios rodikliai, palyginti su praėjusiais metais, nedaug tesumažėjo, turėtų

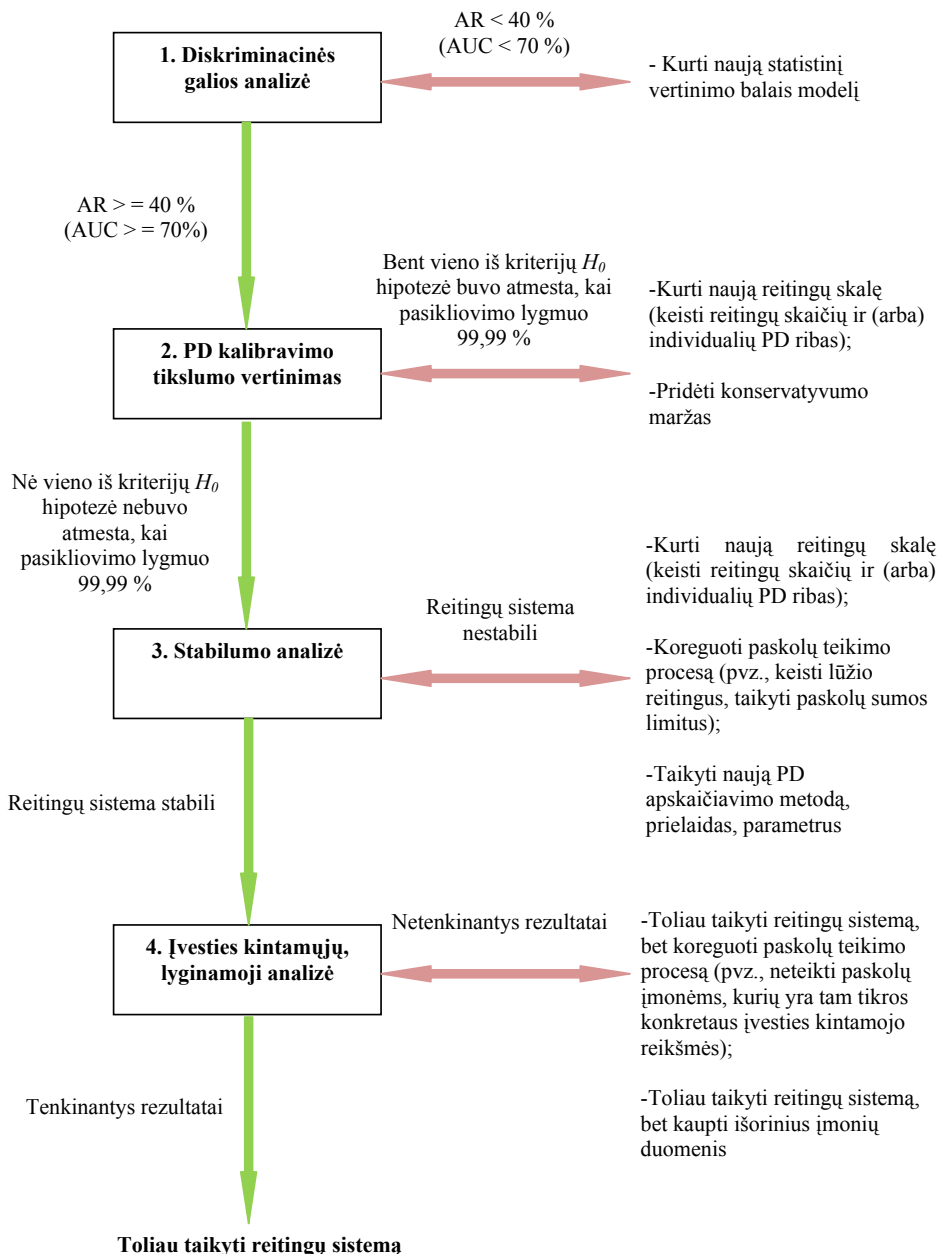
būti laikoma, kad diskriminacinė galia yra stabili. Pavyzdžiui, gali būti, kad pastarųjų metų AR ir AUC rodikliai yra gana geri, bet palyginus juos su kelerių praėjusių metų rodikliais matyti aiški mažėjimo tendencija (AR kasmet sumažėja daugiau kaip dešimčia procentinių punktų), todėl derėtų nustatyti šios tendencijos priežastis. Taip pat yra rekomenduojama įvertinti reitingų pasikeitimo matricių savybes, monotoniškumo, koncentracijos, įmonių skirstinio pagal reitingus, diskriminacijos ir reitingų ODF pokyčius laikui bėgant (lyginti šių metų duomenis su praėjusių metų duomenimis, taip pat šių metų duomenis su kūrimo imties duomenimis), apskaičiuoti skolininkų stabilumo indeksą, įvertinti PD kalibravimo tikslumo pokyčius, apskaičiuoti reitingų PD taikant kitus metodus ir prielaidas, naudojant kitus parametrus ar kitus duomenis. Pavyzdžiui, gali būti, kad tam tikrais metais taikant H ir L kriterijų H_0 hipotezė, kai pasiklivimo lygmuo 99,99 %, nėra atmetama, bet palyginus tų metų χ^2 reikšmę su kelerių praėjusių metų χ^2 reikšme matyti aiški didėjimo tendencija, todėl derėtų nustatyti šios tendencijos priežastis. Viena išiečių būtų sukurti naują reitingų skalę (pakeisti reitingų skaičių ir (arba) apatinę ir viršutinę individualių PD ribas), tačiau galima pradėti taikyti naują reitingų PD apskaičiavimo metodą, prielaidas ar parametrus (pvz., skaičiuoti ne PD(1), bet PD(4)), taip pat galima koreguoti paskolų teikimo procesą. Tarkime, kad gerokai padidėjo faktinių „blogų“ septinto reitingo įmonių dalis, palyginti su visomis faktinėmis „blogomis“ įmonėmis, ir tai yra pagrindinė reitingų sistemos nestabilumo priežastis. Tada „kieto“ lūžio taškas gali būti paslenkamas aukštyje ir ateityje septintam reitingui priskiriamoms įmonėms paskolos neteikiamos.

Kai yra neprediktyvių ir (arba) nestabilių įvesties kintamųjų, reitingų sistemą galima taikyti, bet derėtų pakoreguoti paskolų teikimo procesą. Pavyzdžiui, jeigu labai padidėjo vieno įvesties kintamojo rizikingiausių reikšmių dalis, galima neteikti paskolų įmonėms, kurių yra tokios šio įvesties kintamojo reikšmės, arba teikti tik mažų sumų paskolas, nustatant papildomas kredito rizikos mažinimo priemones, ir pan.

Kai lyginamosios analizės rezultatai rodo, jog nėra ryšio tarp banko skolininkų vidaus reitingų ir (arba) PD ir tinkamai parinktų lyginamųjų dydžių, t. y. tų pačių skolininkų išorės reitingų ir (arba) PD, yra siūloma pradėti kaupti išorinius duomenis apie įmones ir vėliau įtraukti tokią informaciją kuriant naują modelį arba naudoti ją atliekant individualų vertinimą „pilkojoje zonoje“ (taip pat peržiūrint įmonės vidaus reitingą arba sprendimą suteikti paskolą (nesuteikti paskolos).

Galima iš išorinio paskolų registro pirkti naujų skolininkų išorės reitingus ir naudoti juos kaip papildomą informaciją atliekant individualų vertinimą „pilkojoje zonoje“ (taip pat peržiūrint įmonės vidaus reitingą arba sprendimą suteikti paskolą (nesuteikti paskolos). Kai

yra sukaupta pakankamai duomenų, išorės reitingas gali būti įtraukiamas į naują modelį kaip įvesties kintamasis.



48 pav. Reitingų sistemos pakartotinio patikimumo vertinimo schema

Šaltinis: sudaryta autorės.

3.3.3. Atmestų paraiškų įtraukimas kuriant naujus statistinius vertinimo balais modelius

Jei gavus nepalankius patikimumo vertinimo rezultatus yra nusprendžiama kurti naują statistinį modelį, reikia apsispręsti, ar įtraukti atmestų paraiškų duomenis, ir, jei taip, tai kokiū būdu. Todėl buvo sukurti 34 logistinės regresijos modeliai, taikant įvairius skirtingus atmestų paraiškų įtraukimo metodus arba atmestų paraiškų neįtraukiant visai, ir buvo palyginta modelių diskriminacinė galia bei pasiūlyti tinkamiausi atmestų paraiškų įtraukimo metodai.

Kad pasiūlytai reitingų sistemai kurti naudotus duomenis būtų galima taikyti paskolos lygiu, paprastumo dėlei buvo padaryta prielaida, jog kiekviena įmonė kiekvienais metais paėmė tik po vieną paskolą. Kadangi duomenys buvo gauti iš išorinio paskolų registro, kaupiančio informaciją apie skolininkus iš bankų, vartojimo kredito įmonių ir pan., galima daryti prielaidą, jog šie duomenys reprezentuoja tiek priimtas, tiek atmestas paraiškas, nes įmonė, negavusi paskolos viename banke, galėjo kreiptis į kitą ir ten ją gauti. Iš pradžių reikėjo pasirinkti vertinimo balais modelį, pagal kurio rezultatą įmonių paraiškos būtų hipotetiškai priimtos arba atmestos. Buvo pasirinktas vienas iš Shumway (1999) sukurtų logistinės regresijos modelių⁴⁵ ir jį taikant apskaičiuotos paraiškų individualios PD. Buvo padaryta prielaida, kad įmonių paraiškos buvo priimtos arba atmestos remiantis šiomis PD, t. y. hipotetinis bankas, 2005–2007 metais priimdamas sprendimus suteikti paskolą (nesuteikti paskolos), taikė šį Shumway modelį, o vėliau nusprendė sukurti naują modelį, įtraukdamas ir atmestas paraiškas. Pagalbinio vertinimo balais modeliu taikant didinimą ir ekstrapoliacijos metodus atmestoms paraiškoms įtraukti buvo pasirinktas šioje disertacijoje pasiūlytas Lietuvos įmonių logistinės regresijos modelis ir reitingų skalė (žr. 9 priedą ir 39 lent.).

Kaip minėta 1.1.1.7 dalyje, taikant papildomą modelį paraiškoms pakartotinai vertinti, yra susiduriama su modelio rizika, nes nepatikimas pagalbinis modelis gali netiksliai paskirstyti paraiškas tarp reitingų. Tačiau šiuo atveju pagalbiniam modeliui kurti buvo naudoti išorinio paskolų registro duomenys, kurie reprezentuoja tiek priimtas, tiek atmestas paraiškas, todėl rizikos, kad jis netiksliai paskirsto paraiškas pagal reitingus, buvo išvengta. Be to, modelis puikiai diskriminuoja paraiškas, o reitingų skalė yra optimali, sudaryta atsižvelgiant į reitingų skalėms sudaryti keliamus reikalavimus (žr. 26 ir 27 lent.).

⁴⁵ Shumway (1999) logistinės regresijos modelis naudojant Zmijewskio kintamuosius (2) (žr. 12 priedą). Nebuvo rasta tinkamų Lietuvos autorių sukurtų modelių, todėl renkantis modelį buvo analizuoti trys Shumway (1999) straipsnyje pateikti modeliai, įtraukiantys Zmijewskio įvesties kintamuosius. Įvertinus jų patikimumą naudojant patikimumo vertinimo imtį buvo gauta, kad šis, pasirinktas, modelis paraiškas diskriminuoja geriausiai (žr. 13 priedą).

Kuriant naujus modelius buvo atsižvelgta į paraiškų atmetimo lygį. Buvo taikyti du paraiškų atmetimo lygiai: žemas, t. y. buvo atmesta 10,92 % kūrimo imties įrašų (buvo atmestos tos paraiškos, kurių PD, nustatyta pagal Shumway modelį, yra ne mažesnė nei 50 %), ir aukštas – buvo atmesta 50 % kūrimo imties įrašų (buvo atmestos tos paraiškos, kurių PD, nustatyta pagal Shumway modelį, yra ne mažesnė nei 8,34 %).

3.3.3.1. Žemas paraiškų atmetimo lygis

Atmetus paraiškas, kurių PD yra ne mažesnė nei 50 %, įmonėms suteiktų paskolų yra 20 309, iš jų – 18,88 % yra „blogos“. Buvo taikyti šie 1.1.1.7 dalyje nagrinėti atmetų paraiškų įtraukimo metodai: didinimas, visų atmetų paraiškų priskyrimas prie „blogų“ paskolų, septinto ekstrapoliacijos metodo variantai (perklasifikavimas, poliarizuotas, atsitiktinis ir dvigubas atmetų paraiškų dalijimas bendrai ir reitingams). Be to, buvo sukurtas ir tik priimtų paraiškų duomenimis pagrįstas modelis, jo gebėjimas diferencijuoti paraiškas buvo palygintas su kitų modelių, kuriuos kuriant buvo įtrauktos atmestos paraiškos, gebėjimais diferencijuoti paraiškas.

Didinimas. Pagalbinio modeliu buvo pakartotinai nustatytos tiek priimtų, tiek atmetų paraiškų PD, paskui paraiškos buvo priskirtos reitingams. Matyti, kad pagalbinio modeliu daug priimtų paraiškų buvo priskirta blogesniems reitingams. Dauguma tokių reitingų paskolų iš tikrųjų tapo „blogos“ (žr. 42 lent., C–D stulpelius). Tai patvirtina šio metodo tinkamumą.

42 lentelė. Didinimas (atmesta 10,92 % paraiškų)

A	B	C	D	E	$F = \frac{C + D + E}{C + D}$	$G = C \cdot F$	$H = D \cdot F$
Reitingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmestos paraiškos	Didinimo veiksnys	Padidintas „blogų“ paskolų sk.	Padidintas „gerų“ paskolų sk.
1	1,00 %	14	505	49	1,09	15,32	552,68
2	2,20 %	51	1 379	113	1,08	55,03	1 487,97
3	3,70 %	66	1 823	134	1,07	70,68	1 952,32
4	8,00 %	221	3 889	329	1,08	238,69	4 200,31
5	16,00 %	551	3 721	403	1,09	602,98	4 072,02
6	28,00 %	643	2 533	353	1,11	714,47	2 814,53
7	40,50 %	687	1 298	303	1,15	791,87	1 496,13
8	61,00 %	768	892	415	1,25	960,00	1 115,00
9	99,99 %	834	434	391	1,31	1 091,17	567,83
Iš viso		3 835	16 474	2 490		4 540,21	18 258,79

Šaltinis: autorės skaičiavimai.

Informacijos apie atmestas paraiškas reikėjo tik didinimo veiksniai apskaičiuoti. Kuriant naują statistinį vertinimo balais modelį, į kūrimo imtį buvo įtraukti tik priimtų

paraiškų duomenys, didinimo veiksnio „pasveriant“ kiekvieną įrašą. Pavyzdžiui, priimtoms paraiškoms, priskirtoms pirmajam reitingui, buvo suteiktas 1,09 svoris. Tai reiškia, kad kuriant naują modelį kiekvienos šiam reitingui priskirtos priimtose paraiškose informacija buvo įtraukta ne šimtu procentų, bet šimtu devyniais procentais. Kuriant modelį SPSS programa, duomenims buvo suteiktas svorio formatas (angl. *weight cases*).

Modelių patikimumas buvo vertintas naudojant patikimumo vertinimo imtį iš 10 404 įrašų, keturis rodiklius – AR, AUC, IV ir Briero balų rodiklį. Taikant didinimą sukurtas modelis pasiekia 68,72 % AR ir 84,36 % AUC, kiti du rodikliai taip pat yra geri. Tačiau diskriminacinė galia vis tiek yra mažesnė už tik priimtų paraiškų duomenimis pagrįsto modelio diskriminacinę galią (žr. 51 lent.).

Visų atmestų paraiškų priskyrimas prie „blogų“ paskolų. Visos 2 490 hipotetiškai atmestų paraiškų buvo priskirtos prie „blogų“ paskolų. Kitaip nei taikant didinimą, šiuo atveju kuriant modelį buvo įtraukti ir atmestų paraiškų įrašai. Sukurto modelio diskriminacinė galia yra mažiausia iš visų, reikšmingai mažesnė nei tada, kai atmestos paraiškos buvo visai neįtrauktos (žr. 51 lent.).

Perklasifikavimas. Dalis atmestų paraiškų, kurioms pagalbinio modeliu buvo nustatytos didžiausios PD, buvo priskirtos prie „blogų“, kitos atmestos paraiškos buvo visiškai neįtrauktos (žr. 43 ir 44 lent.). Į modelio kūrimo imtį buvo įtraukti ir atmestų paraiškų įrašai.

43 lentelė. Perklasifikavimas (1) (atmesta 10,92 % paraiškų)

A	B	C	D	E	F	G
Reitingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmestos paraiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	14	505	49	0	0
2	2,20 %	51	1 379	113	0	0
3	3,70 %	66	1 823	134	0	0
4	8,00 %	221	3 889	329	0	0
5	16,00 %	551	3 721	403	0	0
6	28,00 %	643	2 533	353	0	0
7	40,50 %	687	1 298	303	0	0
8	61,00 %	768	892	415	314	0
9	99,99 %	834	434	391	391	0
Iš viso		3 835	16 474	2 490	705	0

Šaltinis: autorės skaičiavimai.

Atmestų paraiškų, priskirtų prie „blogų“ paskolų, skaičius buvo nustatytas dviem būdais: iš padidinto „blogų“ paskolų skaičiaus (42 lent.) atėmus suteiktų „blogų“ paskolų skaičių buvo gauta 705 (žr. 43 lent.), o į paskutinius tris blogiausius reitingus patekusias atmestas paraiškas

priskyrus prie „blogų“, buvo gauta 1 109 (žr. 44 lent.). Ir visos kitos ekstrapoliacijos metodo modifikacijos buvo taikytos abiem variantais – naudojant 705 ir 1 109.

44 lentelė. Perklasifikavimas (2) (atmesta 10,92 % paraiškų)

A	B	C	D	E	F	G
Rei-tingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmestos paraiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	14	505	49	0	0
2	2,20 %	51	1 379	113	0	0
3	3,70 %	66	1 823	134	0	0
4	8,00 %	221	3 889	329	0	0
5	16,00 %	551	3 721	403	0	0
6	28,00 %	643	2 533	353	0	0
7	40,50 %	687	1 298	303	303	0
8	61,00 %	768	892	415	415	0
9	99,99 %	834	434	391	391	0
Iš viso		3 835	16 474	2 490	1 109	0

Šaltinis: autorės skaičiavimai.

Į duomenų imtį įtraukus mažesnių skaičių atmestų paraiškų, modelis paraiškas skiria geriau. Abiem variantais (tiek prie „blogų“ paskolų priskyrus 705, tiek 1 109 atmestas paraiškas) sukurtų modelių diskriminacinė galia yra didesnė nei tada, kai visos atmestos paraiškos buvo priskirtos prie „blogų“ (žr. 51 lent.).

Perklasifikuoti paraiškas galima ne tik pagal vertinimo balą, bet ir pagal banko kreditavimo politikoje numatytus atmetimo kriterijus. Pavyzdžiui, jei joje yra numatyta, kad įmonių, kurių nuosavas kapitalas neigiamo ženklo, paraiškas reikia atmesti, tai paraiška gali būti atmetama bendram vertinimo balui esant nemažam. Kuriant statistinį vertinimo balais modelį, tokias atmestas paraiškas galima priskirti prie „blogų“, o kitų atmestų paraiškų galima visai neįtraukti.

Lūžio taško metodas (poliarizuotas visų atmestų paraiškų dalijimas bendrai). Metodas panašus į perklasifikavimą, tačiau skiriasi tuo, kad į modelio kūrimo imtį yra įtraukiamos ir tos atmestos paraiškos, kurios nėra priskiriamos prie „blogų“ paskolų, jos kuriant naują modelį yra priskiriamos prie „gerų“ (žr. 45 ir 46 lent.). Šio metodo, kaip ir visų kitų metodų, buvo pasirinkti du variantai: vienu atveju prie „blogų“ buvo priskirtos 705 atmestos paraiškos (žr. 45 lent.), o kitu atveju – 1 109 atmestos paraiškos (žr. 46 lent.).

Dviem variantais sukurtų modelių AR ir AUC skirtumai nedideli, tačiau IV ir Briero balo rodikliai, prie „blogų“ paskolų priskyrus 705 atmestas paraiškas, yra gerokai geresni (žr. 51 lent.).

Taikant lūžio taško metodą rezultatai yra kur kas geresni nei taikant perklasifikavimą, bet blogesni nei taikant didinimą.

Poliarizuotas atmestų paraiškų dalijimas reitinguose. Skirtumas nuo ankstesnio metodo yra tas, kad lūžio taškas yra nustatomas ne visam paskolų portfeliui, o kiekvienam reitingui. Kiekviename reitinge prie „blogų“ paskolų yra priskiriama atmestų paraiškų dalis, atitinkanti suteiktą to reitingo paskolų ODF (žr. 47 lent.). Matyti, kad atmestas paraiškas kiekviename reitinge paskirsčius pagal suteiktą to reitingo „gerų“ ir „blogų“ paskolų santykį, bendras atmestų paraiškų, kurias reikia priskirti prie „blogų“, skaičius atitinka iš anksto nustatytą 705.

Šį metodą galima taikyti ir konservatyviai, nes paskolas gavusių įmonių ir tų, kurių paraiškos buvo atmestos, elgsena gali ir neatitikti. Kad nepakistų bendras atmestų paraiškų, kurias reikia priskirti prie „blogų“, skaičius (1 109), atmestoms paraiškoms buvo nustatytas 2,61 karto mažesnis „gerų“ ir „blogų“ paskolų santykis negu suteiktoms paskoloms (žr. 48 lent.).

45 lentelė. Lūžio taško metodas (1) (atmesta 10,92 % paraiškų)

A	B	C	D	E	F	G
Rei-tingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmestos paraiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	14	505	49	0	49
2	2,20 %	51	1 379	113	0	113
3	3,70 %	66	1 823	134	0	134
4	8,00 %	221	3 889	329	0	329
5	16,00 %	551	3 721	403	0	403
6	28,00 %	643	2 533	353	0	353
7	40,50 %	687	1 298	303	0	303
8	61,00 %	768	892	415	314	101
9	99,99 %	834	434	391	391	0
Iš viso		3 835	16 474	2 490	705	1 785

Šaltinis: autorės skaičiavimai.

46 lentelė. Lūžio taško metodas (2) (atmesta 10,92 % paraiškų)

A	B	C	D	E	F	G
Rei-tingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmestos paraiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	14	505	49	0	49
2	2,20 %	51	1 379	113	0	113
3	3,70 %	66	1 823	134	0	134
4	8,00 %	221	3 889	329	0	329
5	16,00 %	551	3 721	403	0	403
6	28,00 %	643	2 533	353	0	353
7	40,50 %	687	1 298	303	303	0
8	61,00 %	768	892	415	415	0
9	99,99 %	834	434	391	391	0
Iš viso		3 835	16 474	2 490	1 109	1 381

Šaltinis: autorės skaičiavimai.

47 lentelė. Proporcingas poliarizuotas dalijimas reitinguose (atmesta 10,92 % paraišku)

A	B	C	D	$E = C/(C + D)$	$F = D/(C + D)$	G	$H = G \cdot E$	$I = G \cdot F$
Rei-tingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmes-tos pa-raiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	14	505	2,70 %	97,30 %	49	1	48
2	2,20 %	51	1 379	3,57 %	96,43 %	113	4	109
3	3,70 %	66	1 823	3,49 %	96,51 %	134	5	129
4	8,00 %	221	3 889	5,38 %	94,62 %	329	18	311
5	16,00 %	551	3 721	12,90 %	87,10 %	403	52	351
6	28,00 %	643	2 533	20,25 %	79,75 %	353	71	282
7	40,50 %	687	1 298	34,61 %	65,39 %	303	105	198
8	61,00 %	768	892	46,27 %	53,73 %	415	192	223
9	99,99 %	834	434	65,77 %	34,23 %	391	257	134
Iš viso		3 835	16 474			2 490	705	1 785

Šaltinis: autorės skaičiavimai.

48 lentelė. Konservatyvus poliarizuotas dalijimas reitinguose (atmesta 10,92 % paraišku)

A	B	C	D	$E = D/C$	F	G	$H = G \cdot (1/(1 + E/F))$	$I = G - H$
Rei-tingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	„Geros“ / „blogos“	Mažinimo koeficientas	Atmes-tos pa-raiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	14	505	36,07	2,61	49	3	46
2	2,20 %	51	1 379	27,04	2,61	113	10	103
3	3,70%	66	1 823	27,62	2,61	134	12	122
4	8,00%	221	3 889	17,60	2,61	329	42	287
5	16,00 %	551	3 721	6,75	2,61	403	112	291
6	28,00 %	643	2 533	3,94	2,61	353	141	212
7	40,50 %	687	1 298	1,89	2,61	303	176	127
8	61,00 %	768	892	1,16	2,61	415	287	128
9	99,99%	834	434	0,52	2,61	391	326	65
Iš viso		3 835	16 474			2 490	1 109	1 381

Šaltinis: autorės skaičiavimai.

Kiekviename reitinge atmestos paraiškos buvo išrikiuotos PD didėjimo tvarka ir reikiamas skaičius pačių rizikingiausių to reitingo atmestų paraiškų buvo priskirtas prie „blogų“, kitos paraiškos buvo priskirtos prie „gerų“. Dviem variantais sukurtų modelių diskriminacinės galios rodiklių skirtumai yra nedideli (žr. 51 lent.).

Atsitiktinis visų atmestų paraiškų dalijimas bendrai. Atmestos paraiškos buvo atsitiktiniu būdu, neatsižvelgiant į jų reitingą, priskirtos prie „gerų“ ir „blogų“ paskolų. Pirmuoju atveju prie „blogų“ paskolų buvo priskirtos 705 atmestos paraiškos (o kitos – prie „gerų“), antruoju – 1 109.

Atsitiktinis atmestų paraiškų dalijimas reitinguose. Atmestos paraiškos priskirtos prie „gerų“ ir „blogų“ buvo taip pat atsitiktiniu būdu, tačiau dar buvo atsižvelgta į jų reitingą. Kiekvienam reitingui buvo nustatytas atmestų paraiškų, kurios turėjo būti priskirtos atitinkamai prie „gerų“ ir „blogų“ paskolų, skaičius (žr. 47 ir 48 lent.). Atsitiktinį dalijimą bendrai arba reitinguose galima kartoti daugiau nei vieną kartą, t. y. atsitiktiniu būdu paskirstant atmestas paraiškas sukurti keletą modelių ir iš jų išsirinkti tą, kurio diskriminacinė galia yra didžiausia⁴⁶. Šio tyrimo rezultatai parodė, jog taikant paprastesnį metodą, kai atsitiktinai buvo dalytos visos atmestos paraiškos bendrai, modelių diskriminacinė galia yra vos mažesnė arba net didesnė nei taikant atsitiktinį dalijimą reitinguose (žr. 51 lent.).

Dvigubas visų atmestų paraiškų dalijimas bendrai. Viena kiekvienos atmestos paraiškos dalis buvo priskirta prie „gerų“ paskolų, kita – prie „blogų“ (žr. 49 ir 50 lent.).

Kuriant modelį, atmestų paraiškų įrašai buvo dubliuoti „pasveriant“ juos atitinkamai *E* ir *F* stulpeliuose nurodytais svoriais, neatsižvelgiant į paraiškos reitingą.

Šis metodas yra paprastas, nes, kaip ir atsitiktinai dalijant visas atmestas paraiškas bendrai, nereikia taikyti pagalbinio vertinimo balais modelio, o sukurtų modelių diskriminacinė galia nedaug mažesnė arba net didesnė nei taikant dvigubą dalijimą reitinguose (žr. 51 lent.).

49 lentelė. Dvigubas dalijimas bendrai (1) (atmesta 10,92 % paraiškų)

A	B	C	D	E = 705/2 490	F = 1785/2 490	G	H = G · E	I = G · F
Rei- tingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmes- tos pa- raiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	14	505	28,32 %	71,68 %	49	13,88	35,12
2	2,20 %	51	1 379			113	32,00	81,00
3	3,70 %	66	1 823			134	37,95	96,05
4	8,00 %	221	3 889			329	93,18	235,82
5	16,00 %	551	3 721			403	114,14	288,86
6	28,00 %	643	2 533			353	99,98	253,02
7	40,50 %	687	1 298			303	85,81	217,19
8	61,00 %	768	892			415	117,54	297,47
9	99,99 %	834	434			391	110,74	280,26
Iš viso		3 835	16 474			2 490	705,21	1 784,79

Šaltinis: autorės skaičiavimai.

⁴⁶ Tačiau jei modelio patikimumas yra vertinamas naudojant tik priimtų paraiškų duomenis, rezultatai gali būti netikslūs. Todėl į patikimumo vertinimo imtį reikėtų įtraukti ir atmestų paraiškų duomenis.

50 lentelė. Dvigubas dalijimas bendrai (2) (atmesta 10,92 % paraiškų)

A	B	C	D	E = 1 109/2 490	F = 1 381/2 490	G	H = G · E	I = G · F
Reitingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmestos paraiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	14	505	44,54 %	55,46 %	49	21,82	27,18
2	2,20 %	51	1 379			113	50,33	62,67
3	3,70 %	66	1 823			134	59,68	74,32
4	8,00 %	221	3 889			329	146,53	182,47
5	16,00 %	551	3 721			403	179,49	223,51
6	28,00 %	643	2 533			353	157,22	195,78
7	40,50 %	687	1 298			303	134,95	168,05
8	61,00 %	768	892			415	184,83	230,17
9	99,99 %	834	434			391	174,14	216,86
Iš viso		3 835	16 474			2 490	1 109,00	1 381,00

Šaltinis: autorės skaičiavimai.

51 lentelė. Modelių diskriminacinė galia (atmesta 10,92 % paraiškų)*

	AR	AUC	IV	Briero balas
Visi duomenys (pagalbinis modelis)	72,23 %	86,11 %	2,460	0,0922
Tik priimtų paraiškų duomenys	69,22 %	84,61 %	2,366	0,0993
Didinimas	68,72 %	84,36 %	2,252	0,0998
Lūžio taško metodas (705)	68,32%	84,16 %	2,293	0,1009
Dvigubas atmestų paraiškų dalijimas reitinguose (705)	68,28 %	84,14 %	2,282	0,1010
Lūžio taško metodas (1 109)	68,26 %	84,13 %	2,055	0,1015
Poliarizuotas atmestų paraiškų dalijimas reitinguose (705)	68,26%	84,13 %	2,122	0,1024
Dvigubas visų atmestų paraiškų dalijimas bendrai (705)	68,20 %	84,10 %	2,152	0,1020
Atsitiktinis atmestų paraiškų dalijimas reitinguose (705)	68,09%	84,05 %	2,126	0,1009
Poliarizuotas atmestų paraiškų dalijimas reitinguose (1 109)	68,09 %	84,05 %	2,146	0,1027
Dvigubas atmestų paraiškų dalijimas reitinguose (1 109)	67,95 %	83,98 %	2,016	0,1025
Dvigubas visų atmestų paraiškų dalijimas bendrai (1 109)	67,77 %	83,89 %	2,064	0,1039
Atsitiktinis atmestų paraiškų dalijimas reitinguose (1 109)	67,72%	83,86 %	2,038	0,1028
Atsitiktinis visų atmestų paraiškų dalijimas bendrai (705)	67,61 %	83,80 %	2,208	0,1028
Perklasifikavimas (705)	67,53 %	83,77 %	2,024	0,1046
Atsitiktinis visų atmestų paraiškų dalijimas bendrai (1 109)	67,46 %	83,73 %	1,998	0,1047
Perklasifikavimas (1 109)	65,48 %	82,74 %	1,883	0,1122
Visų atmestų paraiškų priskyrimas prie „blogų“ paskolų	61,50 %	80,75 %	1,718	0,1379

Šaltinis: autorės skaičiavimai. *Modeliai yra išrikiuoti AR ir AUC mažėjimo tvarka; šie du rodikliai iš esmės rodo tą patį, jų reikšmės yra susijusios tiesine priklausomybe. Kuo didesni AR, AUC ir IV ir kuo mažesnis Briero balas, tuo didesnė modelio diskriminacinė galia.

Dvigubas atmestų paraiškų dalijimas reitinguose. Viena kiekvienos atmestos paraiškos dalis buvo priskirta prie „gerų“, kita – prie „blogų“ paskolų, tačiau svoriai, taikyti „pasveriant“ dubliuotus atmestų paraiškų įrašus, kiekvienam reitingui buvo nustatyti skirtingi (*E–F* stulpeliai 47 lent. ir *H/G* ir *I/G* 48 lent.).

Apibendrinus visų modelių diskriminacinės galios tyrimo rezultatus matyti, kad tik priimtų paraiškų duomenimis pagrįsto modelio diskriminacinė galia yra didesnė nei modelių, sukurtų bet kuriuo iš būdų įtraukiant atmestas paraiškas (žr. 51 lent.) Be to, tik priimtų paraiškų duomenimis pagrįsto modelio diskriminacinė galia pernelyg daug nesiskiria nuo modelio, sukurto naudojant visus duomenis, diskriminacinės galios (pvz., AR yra tik 3,01 procentinio punkto mažesnis). Lyginant skirtingus modelius, sukurtus įtraukiant atmestas paraiškas, matyti, kad pagal AR ir AUC geriausiai paraiškas diskriminuoja modelis, sukurtas taikant didinimą, tačiau didžiausia IV pasižymi modelis, sukurtas taikant lūžio taško metodą ir prie „blogų“ paskolų priskiriant 705 atmestas paraiškas. Modelis, sukurtas visas atmestas paraiškas priskyrus prie „blogų“ paskolų, paraiškas skiria prasčiau nei visi kiti modeliai. Galima daryti išvadą, kad šį metodą derėtų taikyti tik tada, kai paraiškų atmetimo lygis yra labai žemas ir kai bankas yra tikras, kad atmeta tikrai pačias rizikingiausias paraiškas (kaip minėta 1.1.1.7 dalyje, limitas galėtų būti 3 % atmetimo lygis). Prie „blogų“ paskolų priskiriant 705 atmestas paraiškas, modelio diskriminacinė galia visada būna didesnė nei priskiriant 1 109 atmestas paraiškas, išskyrus atvejį, kai taikant poliarizuotą dalijimą reitinguose prie „blogų“ paskolų buvo priskirtos 1 109 atmestos paraiškos – tada modelio IV (2,146) yra didesnė nei priskiriant 705 atmestas paraiškas (2,122).

Ne visada sudėtingesni metodai, kuriems reikia pagalbinio modelio, didina modelių diskriminacinę galią. Taikant atsitiktinį ir dvigubą dalijimą bendrai sukurtų modelių diskriminacinė galia yra nedaug mažesnė arba netgi didesnė nei taikant atitinkamai atsitiktinį ir dvigubą dalijimą reitinguose.

3.3.3.2. Aukštas paraiškų atmetimo lygis

Atmetus 50 % paraiškų, įmonėms suteiktų paskolų yra 11 400, iš jų –10,91 % yra „blogos“. Kaip ir taikant žemą paraiškų atmetimo lygį, buvo sukurta 16 modelių įvairiais būdais įtraukiant atmestas paraiškas ir vienas tik priimtų paraiškų duomenimis pagrįstas modelis.

Atmestų paraiškų įtraukimo metodai (išskyrus didinimą ir visų atmestų paraiškų priskyrimą prie „blogų“) buvo taikyti atmestų paraiškų, kurias reikia priskirti prie „blogų“, skaičių nustatant dviem būdais: 1) iš padidinto „blogų“ paskolų skaičiaus (52 lent.) buvo atimtas suteiktų „blogų“ paskolų skaičius ir gauta 1 860; 2) konservatyviai taikant poliarizuotą dalijimą reitinguose, buvo pasirinktas toks pats mažinimo koeficientas, koks buvo naudotas taikant analogišką metodą esant žemam paraiškų atmetimo lygiui, t. y. 2,61 (žr. 48 lent.). Naudojant šį mažinimo koeficientą, buvo apskaičiuotas bendras atmestų paraiškų, kurias reikia priskirti prie „blogų“ paskolų, skaičius – 3 607 (žr. 53 lent.). Šis skaičius buvo naudotas ir taikant visus kitus atmestų paraiškų įtraukimo metodus.

52 lentelė. Didinimas (atmesta 50 % paraišku)

A	B	C	D	E	$F = (C + D + E) / (C + D)$	$G = C \cdot F$	$H = D \cdot F$
Reitingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	Atmestos paraiškos	Didinimo veiksnys	Padidintas „blogų“ paskolų sk.	Padidintas „gerų“ paskolų sk.
1	1,00 %	12	380	176	1,45	17,39	550,61
2	2,20 %	32	1 027	484	1,46	46,63	1 496,37
3	3,70 %	59	1 305	659	1,48	87,51	1 935,49
4	8,00 %	134	2 646	1 659	1,60	213,97	4 225,03
5	16,00 %	251	2 206	2 218	1,90	477,58	4 197,42
6	28,00 %	265	1 348	1 916	2,19	579,78	2 949,22
7	40,50 %	193	649	1 446	2,72	524,45	1 763,55
8	61,00 %	162	427	1 486	3,52	570,71	1 504,29
9	99,99 %	101	203	1 355	5,46	551,18	1 107,82
Iš viso		1 209	10 191	11 399		3 069,19	19 729,81

Šaltinis: autorės skaičiavimai.

53 lentelė. Konservatyvus poliarizuotas dalijimas reitinguose (atmesta 50 % paraišku)

A	B	C	D	$E = D/C$	F	G	$H = G \cdot (1/(1 + E/F))$	$I = G - H$
Reitingas	Aukštesnė PD riba	Suteiktos „blogos“ paskolos	Suteiktos „geros“ paskolos	„Geros“ / „blogos“	Mažinimo koeficientas	Atmestos paraiškos	Atmestos paraiškos, priskirtos prie „blogų“	Atmestos paraiškos, priskirtos prie „gerų“
1	1,00 %	12	380	31,67	2,61	176	13	163
2	2,20 %	32	1 027	32,09	2,61	484	36	448
3	3,70 %	59	1 305	22,12	2,61	659	70	589
4	8,00 %	134	2 646	19,75	2,61	1 659	194	1 465
5	16,00 %	251	2 206	8,79	2,61	2 218	508	1 710
6	28,00 %	265	1 348	5,09	2,61	1 916	650	1 266
7	40,50 %	193	649	3,36	2,61	1 446	632	814
8	61,00 %	162	427	2,64	2,61	1 486	739	747
9	99,99 %	101	203	2,01	2,61	1 355	766	589
Iš viso		1 209	10 191			11 399	3 607	7 792

Šaltinis: autorės skaičiavimai.

Tyrimo rezultatai parodė, kad, kitaip nei esant žemam atmetimo lygiui, pagal AR ir AUC net septynių modelių, sukurtų įtraukus atmestas paraiškas, diskriminacinė galia yra didesnė nei tik priimtų paraiškų duomenimis pagrįsto modelio. Pagal Briero balą tik penkių modelių, sukurtų įtraukus atmestas paraiškas, diskriminacinė galia yra didesnė nei tik priimtų paraiškų duomenimis pagrįsto modelio (žr. 54 lent.). Tačiau pagal IV rodiklį bet kuris iš modelių, sukurtų įtraukiant atmestas paraiškas, paraiškas atskiria prasčiau nei tik priimtų paraiškų duomenimis pagrįstas modelis. Kitos išvados pagal visus keturis rodiklius panašios. Geriausias atmestų paraiškų įtraukimo metodas yra dvigubas arba atsitiktinis dalijimas reitinguose, prie „blogų“ paskolų priskiriant 3 607 atmestas paraiškas. Kitaip nei esant žemam atmetimo lygiui, ne visada prie „blogų“ paskolų priskyrimas mažesnių atmestų

paraiškų skaičių modelio diskriminacinė galia būna didesnė. Be to, yra daug didesnis atotrūkis tarp modelio, sukurto visas atmestas paraiškas priskyrus prie „blogų“ paskolų, diskriminacinės galios rodiklių ir kitų modelių diskriminacinės galios rodiklių. Toks rezultatas patvirtina ankstesnę išvadą, kad visas paraiškas priskirti prie „blogų“ paskolų derėtų tik esant labai mažam paraiškų atmetimo lygiui. Gana blogi perklasifikavimo ir lūžio taško metodo rezultatai rodo, jog, kai atmetama daug paraiškų, netinka atmestas paraiškas priskirti prie „gerų“ ir „blogų“ paskolų bendrai, geriau skirstyti reitinguose. Tą pačią išvadą patvirtina ir didesnė modelių, sukurtų taikant atsitiktinį ir dvigubą dalijimą reitinguose, diskriminacinė galia, palyginus su modelių, sukurtų taikant atsitiktinį ir dvigubą dalijimą bendrai, diskriminacine galia. Be to, prie „blogų“ paskolų priskyrus 3 607 atmestas paraiškas diskriminacinės galios rodiklių atotrūkis tarp dalijimo reitinguose ir atitinkamo dalijimo bendrai būna didesnis nei priskyrus tik 1 860 atmestų paraiškų.

54 lentelė. Modelių diskriminacinė galia (atmesta 50 % paraiškų)

	AR	AUC	IV	Briero balas
Visi duomenys (pagalbinis modelis)	72,23 %	86,11 %	2,460	0,0922
Dvigubas atmestų paraiškų dalijimas reitinguose (3 607)	66,39 %	83,20 %	2,152	0,1070
Atsitiktinis atmestų paraiškų dalijimas reitinguose (3 607)	66,07 %	83,04 %	2,035	0,1064
Didinimas	66,05 %	83,02 %	2,013	0,1088
Polarizuotas atmestų paraiškų dalijimas reitinguose (1 860)	66,04 %	83,02 %	2,142	0,1095
Dvigubas atmestų paraiškų dalijimas reitinguose (1 860)	65,57 %	82,79 %	2,128	0,1126
Polarizuotas atmestų paraiškų dalijimas reitinguose (3 607)	65,38 %	82,69 %	2,099	0,1071
Dvigubas visų atmestų paraiškų dalijimas bendrai (1 860)	65,22 %	82,61 %	2,106	0,1170
Tik priimtų paraiškų duomenys	65,16 %	82,58 %	2,339	0,1102
Atsitiktinis atmestų paraiškų dalijimas reitinguose (1 860)	65,13 %	82,57 %	2,134	0,1129
Atsitiktinis visų atmestų paraiškų dalijimas bendrai (3 607)	64,31 %	82,16 %	1,918	0,1115
Lūžio taško metodas (3 607)	64,05 %	82,03 %	1,883	0,1115
Perklasifikavimas (1 860)	62,98 %	81,49 %	2,026	0,1673
Atsitiktinis visų atmestų paraiškų dalijimas bendrai (1 860)	62,52 %	81,26 %	1,963	0,1184
Lūžio taško metodas (1 860)	62,28 %	81,14 %	1,755	0,1139
Dvigubas visų atmestų paraiškų dalijimas bendrai (3 607)	61,73 %	80,87 %	1,781	0,1139
Perklasifikavimas (3 607)	60,86 %	80,43 %	1,916	0,2153
Visų atmestų paraiškų priskyrimas prie „blogų“ paskolų	53,07 %	76,54 %	1,062	0,3247

Šaltinis: autorės skaičiavimai.

Pagal AR, AUC ir Briero balą, esant aukštam paraiškų atmetimo lygiui, modelių, sukurtų tiek taikant bet kurį iš atmestų paraiškų įtraukimo metodų, tiek naudojant tik priimtų paraiškų duomenis, diskriminacinė galia yra mažesnė nei esant žemam paraiškų atmetimo lygiui. Taip ir turėtų būti, nes turime daugiau trūkstamų išvesties kintamojo reikšmių, todėl

bet kuris iš atmestų paraiškų įtraukimo metodų, taikomas trūkstamai informacijai „atkurti“, yra mažiau patikimas.

Taigi bankas, kurdamas statistinį vertinimo balais modelį, turėtų atsižvelgti į paraiškų atmetimo lygį (žr. 49 pav.). Kai atmetimo lygis yra labai žemas ($\leq 3\%$), atmestos paraiškos yra laikytinos išties labai rizikingomis ir tikėtina, kad visos pagal jas suteiktos paskolos taptų „blogos“, todėl tokias atmestas paraiškas, jei jų duomenų kokybė yra gera, galima priskirti prie „blogų“ paskolų. Jei atmestų paraiškų duomenų kokybė yra bloga (pvz., banko darbuotojai neįvedė į banko informacinių technologijų sistemas dalies informacijos apie atmestas paraiškas), atmestų paraiškų galima visai neįtraukti ir modelį kurti naudojant tik priimtų paraiškų duomenis.

Kai paraiškų atmetimo lygis yra didesnis nei 3% , bet atmestų paraiškų duomenų kokybė yra bloga, siūloma taikyti didinimą, nes į naujo modelio kūrimo imtį nereikia įtraukti atmestų paraiškų įrašų, jie yra naudojami tik didinimo veiksniumi apskaičiuoti. Trūkstant kai kurių atmestų paraiškų rodiklių, į pagalbinį modelį galima įtraukti tik esamus rodiklius. Bloga atmestų paraiškų duomenų kokybė nekels problemų kuriant naują modelį.

		<i>Atmetimo lygis</i>	
		$\leq 3\%$	$> 3\%$
<i>Atmestų paraiškų duomenų kokybė</i>	<i>Gera</i>	Priskirti prie „blogų“ paskolų	Ekstrapoliacija
	<i>Bloga</i>	Neįtraukti visai	Didinimas

49 pav. *Atmestų paraiškų įtraukimo metodo pasirinkimas*

Šaltinis: sudaryta autorės.

Kai atmetimo lygis yra didesnis nei 3% ir atmestų paraiškų duomenų kokybė gera, reikėtų rinktis vieną iš ekstrapoliacijos metodų. Prie ekstrapoliacijos metodų galima priskirti ir klasterizaciją, nes, taikant šį metodą, nustačius atmestos paraiškos PD vėliau vis tiek yra pereinama prie pasirinkto ekstrapoliacijos metodo. Tyrimo rezultatai parodė, kad paraiškų atmetimo lygiui esant $10,92\%$, bet kurie įtraukiant atmestas paraiškas sukurti modeliai paraiškas skiria prasčiau nei tik priimtų paraiškų duomenimis pagrįstas modelis. Tačiau skirtumas tarp diskriminacinei galiai vertinti taikomų rodiklių reikšmių yra nedidelis, todėl,

kai atmetimo lygis yra didesnis nei 3 %, vis dėlto yra siūloma taikyti atmestų paraiškų įtraukimo metodus. Kuo atmetimo lygis yra aukštesnis, tuo geriau taikyti dalijimo reitinguose metodus, ypač dvigubą ir atsitiktinį dalijimą, nes taikant šiuos metodus sukurtų modelių diskriminacinė galia yra viena didžiausių. Kuo daugiau atmestų paraiškų, tuo didesnė pagalbinio vertinimo balais modelio taikymo svarba, nes geriau atmestas paraiškas tarp „gerų“ ir „blogų“ paskolų skirstyti reitinguose, o ne bendrai. Tačiau kuo atmetimo lygis yra žemesnis, tuo tinkamesni yra dalijimo bendrai metodai, ypač lūžio taško metodas.

Atmestų paraiškų duomenis derėtų įtraukti ne tik kuriant naują modelį, bet ir vertinant naujai kuriamo ar seniau sukurto modelio patikimumą.

IŠVADOS IR PASIŪLYMAI

1. Taikant statistiniu vertinimo balais modeliu pagrįstą reitingų sistemą banke yra susiduriama su dviem procesais: skolininkai pagal modelio rezultatą yra priskiriami reitingams ir yra apskaičiuojama reitingų PD. Statistinis vertinimo balais modelis yra kuriamas keliais etapais: iš pradžių analizuojamos galimybės įgyvendinti projektą, tada apibrėžiamas „blogas“ skolininkas ir stebėjimo laikotarpis, pasirenkama skolininkų grupė ir statistinis metodas, sudaroma imtis, analizuojami įvesties kintamieji ir apskaičiuojami koeficientai, atliekamas išankstinis modelio patikimumo vertinimas. Išanalizavus kitų autorių sukurtus statistinius įmonių vertinimo balais modelius matyti, kad apibrėžiant „blogą“ įmonę bankroto požymis yra pasirenkamas beveik taip pat dažnai, kaip ir įsipareigojimų neįvykdymo požymis, rečiau yra pasirenkamas finansinių sunkumų (nemokumo) požymis. Kuriant fizinių asmenų modelius, „blogas“ skolininkas dažniausiai yra apibrėžiamas kaip daugiau nei 90 kalendorinių dienų mokėjimo terminą pradėsęs skolininkas. Tačiau galimi ir įvairūs kiti apibrėžimai – dvi iš eilės įmokos pradėsęs skolininkas, šešis mėnesius pradėsęs sumokėti įmoką skolininkas ir t. t. Autoriai, kurdami statistinius modelius, dažniausiai taiko logistinę regresiją, o diskriminantinės analizės ir probito regresijos populiarumas yra gerokai mažesnis. Nors pastaraisiais metais ir daugėja tyrimų, susijusių su naujos kartos mašininio mokymosi ir programavimo metodais (dirbtiniais neuroniniais tinklais, atramos vektorių mašinomis), šie metodai vis dar yra tiriami, jų tinkamumas skolininkų kredito rizikai vertinti dar nėra iki galo išaiškintas, nėra standartizuotų kompiuterinių paketų. Be to, tyrimų rezultatai parodė, kad, nors taikant šiuos metodus modelių jautrumas dažniausiai būna didesnis nei taikant grynuosius statistinius metodus, bendras teisingo klasifikavimo rodiklis – panašus kaip ir taikant grynuosius statistinius metodus.
2. Bankams sunku pasirinkti tinkamą atmestų paraiškų įtraukimo metodą. Pirkti informaciją iš išorinių paskolų registru yra brangu. Be to, bankuose gali būti taikomi skirtingi „blogos“ paskolos apibrėžimai, nustatomos nevienodos kreditavimo sąlygos ir pan. Kai bankas nusprendžia remtis vidiniais duomenimis apie kitas atmestam skolininkui suteiktas paskolas, irgi kyla nemažai problemų: gali gerokai skirtis skirtingų paskolų rūšių rizika, paskolų suteikimo ir paraiškos atmetimo datos, kai kurie atmesti skolininkai tame pačiame banke paskolų gali neturėti. Dėl to yra gana populiarūs tokie atmestų paraiškų įtraukimo metodai, kai atmestos paraiškos yra hipotetiškai priskiriamos prie „gerų“ ir „blogų“. Bene dažniausiai bankų yra taikomi

didinimo ir ekstrapoliacijos metodai. Tačiau įvairių autorių atliktų tyrimų rezultatai parodė, kad taikant didinimą sukurti modeliai dažniausiai yra mažiau patikimi nei tik priimtų paraiškų duomenimis pagrįsti modeliai. O štai modeliai, sukurti taikant ekstrapoliaciją, dažniausiai yra patikimesni už tik priimtų paraiškų duomenimis pagrįstus modelius.

3. Banke turi būti nustatomas optimalus reitingų skaičius, o skolininkai šiems reitingams turi būti priskiriami pagal individualias PD arba kreditingumo balus. Moksliniuose straipsniuose yra aptinkamas labai įvairus reitingų skaičius – nuo 5 iki 16. Bankas, sudarydamas reitingų skalę, turėtų atsižvelgti į keletą veiksnių: individualių PD ar kreditingumo balų intervalus, monotoniškumą, skolininkų koncentraciją ir skirstinį, diskriminaciją.
4. Reitingo PD gali būti apskaičiuojama tiek iš individualių PD, tiek iš metinių faktinių „blogų“ skolininkų dažnių. Tačiau reitingo PD apskaičiuoti iš individualių PD galima tik tada, kai yra taikomas individualias PD leidžiantis apskaičiuoti statistinis modelis (pvz., logistinė, *cloglog* regresijos ar išlikimo analizės modeliai).
5. Išanalizavus kitų autorių taikytus patikimumo vertinimo metodus matyti, kad dažniausiai taikomi patikimumo vertinimo metodai yra CAP, ROC kreivės ir teisingo klasifikavimo analizė, tačiau sparčiai populiarėja ir informacijos entropija pagrįsti metodai, ypač informacijos vertės metodas, taip pat Briero balų metodas. Populiariausi PD kalibravimo tikslumo vertinimo metodai yra H ir L, binominiai, normalieji kriterijai, eismo šviesos metodas. Daugelis šių metodų buvo taikomi ir Lietuvos bankuose, juos taip pat rekomenduoja taikyti Lietuvos bankas.
6. Autorės atliktos šalyje veikiančių komercinių bankų ir užsienio bankų skyrių apklausos rezultatai parodė, kad:
 - Lietuvos bankuose statistiniai mažmeninių paraiškų modeliai nebuvo plačiai taikomi, juos taikė tik keturi bankai. Statistiniai modeliai Lietuvos bankuose buvo sukurti taikant logistinę regresiją ir diskriminantinę analizę. Dažniausiai bankų paminėta statistinių modelių netaikymo priežastis – nepakankamas praeities duomenų kaupimo laikotarpis. Mišrius modelius buvo pasirinkę tik du bankai, jie taip pat taikė statistinius modelius. Plačiausiai bankų buvo taikomi ekspertiniai modeliai, iš juos taikiusių bankų tik du planavo ateityje kurti naujus statistinius modelius. Įmonių paraiškų modeliai Lietuvoje dažniausiai buvo sukurti skolininko, o ne paskolos lygiu, be to, jie buvo sukurti bendrai visoms įmonių mažmeninių paskolų rūšims. Fizinių asmenų paraiškų modelių buvo

sukurta tiek skolininko, tiek paskolos lygiu, šiuos modelius bankai buvo labiau linkę diferencijuoti, t. y. fizinių asmenų paskolas skirstyti į tam tikras rūšis ir joms kurti atskirus modelius.

- Padidėjo duomenų, kuriuos bankai gali įsigyti iš išorinių paskolų registru, poreikis. Nors naudotis išorinių paskolų registru duomenimis bankams trukdė didelės tokios informacijos pirkimo išlaidos, net trys bankai planavo patikslinti savo taikomus modelius, įtraukdami išorinių paskolų registru duomenis. Tikėtina, kad ir tie du bankai, kurie planavo kurti naujus statistinius modelius, pirks ir reguliariai naudos išorinių paskolų registru teikiamą informaciją. Lietuvos bankai, kurdami statistinius, mišrius ir ekspertinius modelius, naudojo beveik tokius pačius įvesties kintamuosius, kurie dažniausiai buvo naudoti ir įvairių autorių pateiktuose modeliuose. Tačiau šalyje veikiančys bankai į modelius neįtraukė turto ir pardavimo pajamų logaritminės transformacijos rodiklių, o jų paprastai įtrauktas grynojo pelno (nuostolių) ir pardavimo pajamų santykis nepateko tarp dažniausiai kitų autorių sukurtuose modeliuose naudotų rodiklių. Ekspertinių modelių įvesties kintamųjų spektras buvo įvairesnis negu statistinių, nes kuriant ekspertinius modelius nebūtina turėti sukaupus praeities duomenų.
- Kai bankas turėjo patrunuojantį banką užsienio šalyje, kai kada statistiniai modeliai buvo sukurti tik naudojant vietinius duomenis, o kai kada, kai bankas neturėjo pakankamai vietinių duomenų – sukurti bendri modeliai naudojant visos grupės duomenis. Skirtingoms šalims sukurtų tos pačios paskolų rūšies modelių tiek įvesties kintamieji ir jų skaičius, tiek jų reikšmių grupės ir koeficientai skyrėsi. Taigi, naudojant visos grupės duomenis sukurti modeliai nereprezentuoja Lietuvos bankų skolininkų. Galima būtų daryti išvadą, kad kai bankas neturi pakankamai duomenų, kad galėtų sukurti savą statistinį modelį, jam geriau pirkti išorės modelį, sukurtą naudojant Lietuvos duomenis, arba išorės modeliu nustatytus skolininkų reitingus, negu kurti modelį naudojant patrunuojančio banko grupės duomenis. Kita išeitis galėtų būti naudoti kelių Lietuvoje veikiančių bankų duomenis arba kurti mišrius modelius, pavyzdžiui, sukurti statistinį modelį naudojant tik tuos įvesties kintamuosius, apie kuriuos bankas turi pakankamai patikimos informacijos, ir taikant šį modelį gautą rezultatą naudoti kaip atskirą ekspertinio modelio, apimančio daugiau įvesties kintamųjų, apie kuriuos bankas pakankamai patikimos informacijos neturi, įvesties kintamąjį.

7. Kadangi įmonių statistiniai modeliai Lietuvos bankuose nebuvo paplitę, buvo sukurta logistinės regresijos modeliu pagrįsta Lietuvos įmonių reitingų sistema. Modelį sudaro 19 įvesties kintamųjų, apimančių įvairiapusę informaciją apie įmonę: finansinę padėtį, išorinę mokėjimų istoriją, gyvavimo laiką, dydį, apskritį, ekonominės veiklos rūšį, neigiamos informacijos apie įmonę įrašus išoriniame paskolų registre, skolų išieškojimo įmonių pretenzijas. Buvo sudaryta optimali reitingų skalė, susidedanti iš dešimties reitingų (devyni „gerų“ įmonių reitingai ir vienas reitingas tokioms įmonėms, kurios jau faktiškai tapo „blogos“), nustatyti „kieto“ ir „minkšto“ lūžio reitingai. Reitingų PD buvo apskaičiuotos taikant keturis metodus. Tačiau tolesnei analizei buvo pasirinktas tik vienas jų – metodas, kai reitingo PD yra apskaičiuojama kaip aritmetinis tuo reitingu vertinamų įmonių individualių PD vidurkis. Šios PD tiko taikant visus PD kalibravimo tikslumo vertinimo metodus.
8. Buvo atliktas reitingų sistemos išankstinis patikimumo vertinimas taikant populiariausius, daugelio bankų priežiūros institucijų rekomenduojamus metodus, buvo gauti palankūs rezultatai. Taip pat buvo sudaryta pakartotinio patikimumo vertinimo, jau pradėjus pasiūlytą reitingų sistemą taikyti banke, schema, pasiūlant toleruotinas patikimumo vertinimo rodiklių reikšmių ribas bei banko veiksmus, kai šios ribos bus pažeidžiamos.
9. Pasiūlyta Lietuvos įmonių reitingų sistema gali būti taikoma visų ekonominės veiklos rūšių įmonėms, įvairių rūšių paskolas (investicines, apyvartinių lėšų finansavimo paskolas ir t. t.) imančioms įmonėms vertinti, įvairiuose banko procesuose (teikiant paskolas, skaičiuojant kredito rizikos maržas ir kapitalo, reikalingo kredito rizikai padengti, poreikį, atliekant testavimą nepalankiausiomis sąlygomis ir daugelyje kitų). Disertacijoje yra pateikti praktiniai tokio taikymo pavyzdžiai. Ši reitingų sistema atitinka pagal Naująjį kapitalo susitarimą parengtų Europos Sąjungos ir Lietuvos teisės aktų reikalavimus, todėl gali būti taikoma tuose bankuose, kurie taiko arba planuoja taikyti IRB metodą. Tačiau prieš pradėdamas ją taikyti bankas turėtų įvertinti jos patikimumą pasitelkęs savus duomenis. Be to, ši reitingų sistema gali būti taikoma ne tik bankuose, bet ir kitose kreditus teikiančiose ar įmonių riziką vertinančiose įstaigose, pavyzdžiui, vartojimo kreditų ir smulkiųjų vartojimo kreditų įmonėse skolininkų darbdavių rizikai vertinti, laidavimo paslaugas teikiančiose draudimo įmonėse ir pan. Ją taip pat gali taikyti įmonės, norinčios įvertinti savo pačių kreditingumą. Lietuvos bankuose gali būti taikoma nebūtinai visa šioje disertacijoje pasiūlyta reitingų sistema, bet ir atskiros jos dalys: Lietuvos įmonių logistinės

regresijos modelis, kiekviename šio modelio kūrimo etape taikyti metodai, įvesties kintamieji ir t. t. Šioje disertacijoje pateikta analizė gali būti naudinga ir kuriant bei taikant eksperimentinius įmonių modelius ar fizinių asmenų modelius.

10. Lietuvos autoriai iki šiol neanalizavo atmestų paraiškų įtraukimo metodų. Todėl buvo atliktas atmestų paraiškų įtraukimo kuriant statistinius vertinimo balais modelius tyrimas. Naudojant Lietuvos įmonių duomenis buvo sukurti 34 logistinės regresijos modeliai įvairiais būdais įtraukiant atmestų paraiškų duomenis arba jų neįtraukiant visai ir buvo palyginta modelių diskriminacinė galia. Tyrimo rezultatai parodė, kad, kai paraiškų atmetimo lygis buvo 10,92 %, bet kurie įtraukiant atmestas paraiškas sukurti modeliai paraiškas skiria prasčiau nei tik priimtų paraiškų duomenimis pagrįstas modelis. Kai buvo atmesta pusė visų paraiškų, pagal du rodiklius net septynių modelių, sukurtų įtraukus atmestas paraiškas, diskriminacinė galia buvo didesnė nei tik priimtų paraiškų duomenimis pagrįsto modelio. Remiantis šio tyrimo rezultatais buvo sudaryta atmestų paraiškų įtraukimo metodo pasirinkimo schema, kurią galima taikyti bankuose.
11. Lietuvos bankams, kuriantiems ar planuojantiems kurti statistiniais modeliais pagrįstas reitingų sistemas, yra rekomenduojama:
 - kurti atskirus modelius įmonėms, kurių paskolos yra priskiriamos mažmeninių paskolų grupei. Įmonių paskolas priskiriant mažmeninių paskolų grupei derėtų naudoti ne tik visą paskolos sumą, bet ir papildomus kriterijus. Nustatydami šiuos papildomus kriterijus, bankai galėtų vadovautis pardavimo grynujų pajamų, turto ir darbuotojų skaičiaus rodikliais, kurie yra naudojami sprendžiant, ar įmonė gali pateikti sutrumpintas finansines ataskaitas. Skaičiavimų rezultatai parodė, kad IRB metodą taikančiuose bankuose kapitalo poreikis yra labai jautrus kriterijų, taikomų priskiriant paskolas mažmeninių paskolų grupei, pokyčiams, todėl bankams šiuos kriterijus derėtų rinktis labai atsakingai, daugiau dėmesio tam galėtų skirti ir Lietuvos bankas;
 - apibrėžiant „blogą“ skolininką naudoti įsipareigojimų neįvykdymo apibrėžimą ir vienerių metų trukmės stebėjimo laikotarpį, rinktis logistinę regresiją, nes ji turi daug pranašumų, palyginti su kitais statistiniais metodais, kurti ir skirtingais tikslais taikyti tiek laiko momento, tiek ekonominio ciklo modelius. Kad naujas modelis įgytų ekonominio ciklo modelio bruožų, reikėtų sukaupti bent 14 metų ekonominiam ciklui jautrių įvesties kintamųjų reikšmių dinamikos eilutes ir

- atimti periodiškai kintančias cikliškumo (ir sezoniškumo, jei duomenys ketvirtiniai) dedamąsias, paliekant tik tendą ir atsitiktinius nuokrypius;
- turint pakankamai duomenų kurti atskirus fizinių asmenų modelius skirtingoms paskolų rūšims paskolos lygiu, skiriant kuo daugiau paskolų rūšių, nes, kaip parodė mokslinių straipsnių analizė ir Lietuvos bankų apklausos rezultatai, skirtingoms fizinių asmenų paskolų rūšims būna būdinga skirtinga rizika, t. y. kurti atskirus būsto, vartojimo paskolų, kredito kortelių, išperkamosios nuomos ir t. t. modelius. Tai leistų įtraukti specifinius įvesties kintamuosius, statistiniai modeliai būtų tikslesni ir reprezentatyvesni. Tačiau iš pradžių derėtų atlikti savo vidinių duomenų analizę ir nustatyti, ar skirtingų paskolų rūšių skolininkų rizika skiriasi, ar ne. Įmonių modelį geriau kurti vieną, bendrą visoms paskolų rūšims. Bet kuriuo atveju bankui vertėtų patikrinti įvairias alternatyvas ir pasirinkti tą, kuriai esant išankstinio patikimumo vertinimo rezultatai yra patys geriausi. Be to, bankas turėtų įvertinti ir laiko, informacinių technologijų, darbuotojų darbo užmokesčio sąnaudas;
 - kurti atskirus paraiškų ir elgsenos modelius. Atskiras paraiškų modelis galėtų būti kuriamas ir esamiems banko skolininkams, besikreipiantiems dėl naujos paskolos. Nuo paraiškos vertinimo balo prie elgsenos vertinimo balo derėtų pereiti po truputį, t. y. svoris, suteikiamas paraiškos vertinimo balui, turėtų laikui bėgant mažėti, o svoris, suteikiamas elgsenos vertinimo balui – didėti;
 - įtraukti ne tik santykinius, bet ir absoliučius finansinius rodiklius, logaritmines jų transformacijas. Be to, derėtų kaupti informaciją apie ekspertinių modelių įvesties kintamųjų reikšmes praeityje, kad ją būtų galima panaudoti kuriant naujus statistinius modelius. Dažnai kredito rizikai įvertinti svarbiausi yra vidinės mokėjimų istorijos rodikliai, todėl bankams rekomenduojama naudoti šioje disertacijoje pasiūlytus mokėjimų istorijos rodiklius. Vidinės mokėjimų istorijos rodikliai galėtų būti modeliuojami atskirai, o tokio modeliavimo rezultatas galėtų būti naudojamas kaip atskiras pagrindinio modelio įvesties kintamasis. Atskirai modeliuoti vidinės mokėjimų istorijos rodiklius bankai galėtų kurdami ne tik statistinius, bet ir ekspertinius ar mišrius modelius;
 - pasirinkti tinkamą atmestų paraiškų įtraukimo metodą. Tam tikrais atvejais kuriamam statistiniam modeliui pakanka naudoti tik priimtų paraiškų duomenis. Neįtraukti atmestų paraiškų galima, kai bankas numato taikyti konservatyvesnę kreditavimo strategiją, t. y. gerokai padidinti paraiškų atmetimo lygį, arba taip

nepasitiki taikomu modeli, kad priimtų paraiškų riziką laiko mažai tesiskiriančia nuo atmestų paraiškų rizikos. Įtraukti atmestas paraiškas yra netikslinga ir tada, kai jų atmetimo lygis yra ne aukštesnis kaip 3 % ir atmestų paraiškų duomenų kokybė bloga. Kai atmestų paraiškų duomenų kokybė yra bloga, bet paraiškų atmetimo lygis yra aukštesnis nei 3 %, yra siūloma taikyti didinimą. Kai atmestų paraiškų duomenų kokybė yra gera, yra siūloma, atsižvelgiant į atmetimo lygį, arba visas paskolas priskirti prie „blogų“, arba taikyti vieną iš ekstrapoliacijos ar klasterizacijos metodų. Atmestų paraiškų duomenis derėtų įtraukti ne tik kuriant naują modelį, bet ir vertinant naujai kuriamo ar seniau sukurto modelio patikimumą;

- sudaryti optimalią reitingų skalę taikant šioje disertacijoje pateiktus principus (siekti, kad tuo pačiu reitingu vertinami skolininkai nebūtų pernelyg heterogeniški, bet, kad jų skaičius būtų pakankamas, kad būtų galima apskaičiuoti reitingo PD ir įvertinti jos patikimumą ir t. t.). Visi bankai, net ir netaikantys IRB metodo, turėtų nustatyti, kokie skolininkai yra laikomi nevykdančiais įsipareigojimų ir tokiems skolininkams skirti bent vieną atskirą reitingą, be to, visiems bankams derėtų skaičiuoti reitingų PD;
- kai reitinguose yra labai mažai arba visai nėra faktinių „blogų“ skolininkų, taikyti specialius LDP reitingų PD apskaičiavimo metodus. Šių metodų analizė parodė, kad Pluto, Tasche (2005) metodas be koreliacijos gali būti lengvai įdiegiamas bankuose. Tačiau jeigu skolininkų priskyrimas reitingams yra netikslus, šis metodas neužtikrina PD monotoniškumo. Ta pati problema išlieka ir taikant Kiefer (2006) pasiūlytą Bajeso metodą, be to, šis metodas yra sudėtingesnis. O štai Forrest (2005) metodas be koreliacijos užtikrina PD monotoniškumą, tačiau jį įdiegiant reikia programavimo įgūdžių, priešingu atveju žingsninė konservatyvių PD paieška užims daug laiko, ypač kai yra trys LDP reitingai iš eilės ar jų daugiau. Todėl kai banko darbuotojai (ar nepriklausomi išorės tyrėjai) neturi programavimo įgūdžių, geriau rinktis Pluto, Tasche (2005) metodą be koreliacijos ir, esant nemonotoniškoms PD, eksponentiškai glodinti jų reikšmes;
- pasirinkti toleruotinas tiek išankstinio, tiek pakartotinio patikimumo vertinimo metu gaunamų patikimumo vertinimo rodiklių reikšmių ribas, kurias pažeidus, reitingų sistema būtų koreguojama. Yra rekomenduojama taikyti visas reitingų sistemos patikimumo vertinimo sritis apimančius metodus, net tada, kai yra

- taikomi ekspertiniai, mišrūs ar individualių PD neleidžiantys apskaičiuoti statistiniai modeliai ir nėra taikomas IRB metodas. Sukaupiti modelio patikimumo vertinimo rezultatai, pavyzdžiui, informacija apie „blogus“ skolininkus, galėtų būti panaudota kuriant naujus statistinius modelius;
- vertinimo balais modelius taikyti ne tik teikiant paskolas, skaičiuojant kredito rizikos maržas ar paskolų vertės sumažėjimą, bet ir kituose vidaus procesuose, pavyzdžiui, vykdant paskolų išieškojimą, paskirstant kapitalą, atliekant testavimą nepalankiausiomis sąlygomis ir t. t. Tai yra ypač aktualu IRB metodą taikantiems arba planuojantiems jį taikyti bankams.
12. Lietuvos bankas ir Lietuvos bankų asociacija galėtų padėti bankams kurti statistinius modelius. Kuriant tokius modelius galima būtų pasinaudoti Lietuvos banko turima paskolų rizikos duomenų baze. Bankai, turintys savus vidaus modelius, išorės modelius galėtų taikyti lyginamajai analizei. Išorės modeliai būtų naudingi ir pačiam Lietuvos bankui: leistų palyginti skirtingų bankų skolininkų riziką, vertinti konkretaus banko ir viso bankų sektoriaus skolininkų rizikingumą. Be to, kai bankai patys pasirenka LDP reitingų PD apskaičiavimo metodą, skirtinguose bankuose PD, apskaičiuotos tos pačios paskolų rūšies reitingams, kai toks pats „gerų“ ir „blogų“ skolininkų skaičius, gali reikšmingai skirtis, t. y. bankai gali pasirinkti ne tik skirtingus metodus, bet ir skirtingus to paties metodo parametrus (pasiklivimo lygmenis, koreliaciją ir t. t.). Lietuvos bankas ar Lietuvos bankų asociacija galėtų nustatyti visiems bankams vienodą LDP reitingo apibrėžimą ir sukurti vieną bendrą LDP reitingų PD apskaičiavimo metodiką arba parengti palyginamąsias PD lenteles, kuriomis vadovaudamiesi bankai pakoreguotų savo pačių apskaičiuotas LDP reitingų PD.
13. Galimos tolesnės tyrimų kryptys būtų tokios:
- Informacinių technologijų specialistams reikėtų sukurti standartizuotus kompiuterinius paketus, kad būtų galima kurti naujos kartos statistinius vertinimo balais modelius.
 - Turint ilgesnio laikotarpio Lietuvos įmonių duomenis būtų galima kurti išlikimo analizės modelius.
 - Galima sukurti statistinius Lietuvos fizinių asmenų vertinimo balais modelius atskiroms paskolų rūšims.
 - Turint reikiamus duomenis būtų galima iširti kitus specialius reitingų PD apskaičiavimo metodus.

AUTORĖS PUBLIKACIJŲ DISERTACIJOS TEMA SĄRAŠAS

1. Dzidzevičiūtė L. 2010: Application and Behavioural Statistical Scoring Models. – *Economics and Management* 15, 1046–1056.
2. Dzidzevičiūtė L. 2010: Statistical Scoring Model of Lithuanian Companies. – *Ekonomika* 2010 89 (4), 96–115.
3. Dzidzevičiūtė L. 2010: Statistinių vertinimo balais modelių kūrimo ir taikymo ypatumai. – *Pinigų studijos* 1, 35–54.
4. Dzidzevičiūtė L. 2010: Statistinių vertinimo balais modelių taikymas Lietuvos bankuose. – *Pinigų studijos* 2, 69–85.
5. Dzidzevičiūtė L. 2012: Estimation of Default Probability for Low Default Portfolios. – *Ekonomika* 2012 91(1), 132–156.

LITERATŪRA

1. Aleknevičienė V. 2011: *Įmonės finansų valdymas*, VŠĮ „Spalvų kraitė“, 2011.
2. Altman E. I. 2000: Predicting Financial Distress of Companies: Revisiting the Z-score and ZETA^R Models, July.
3. Altman E. I., Sabato G. 2005: Global Effects of the New Basel Capital Accord's Implementation on SMEs.
4. Andersen H. 2008: Failure Prediction of Norwegian banks: a Logit Approach, Central Bank of Norway Working Paper.
5. Anderson R. 2007: *The Credit Scoring Toolkit. Theory and Practice for Retail Credit Risk Management and Decision Automation*, Oxford University Press.
6. Anderson B., Haller S., Siddiqi N. 2009: Reject Inference Techniques Implemented in Credit Scoring for SAS^R Enterprise MinerTM, SAS Institute, Cary, NC.
7. Anderson B., Haller S., Siddiqi N., Cox J., and Duling D. 2010: Improving Credit Risk Scorecards with Memory-Based Reasoning to Reject Inference with SAS^R Enterprise MinerTM, SAS Institute Inc.
8. Andreeva G., Ansell J., Crook J. N. 2004: Credit Scoring in the Context of the European Integration: Assessing the Performance of the Generic Models.
9. Andreeva G. 2006: European Generic Scoring Models Using Survival Analysis. – *Journal of the Operational Research Society* 57.(10), 1180–1187.
10. Anghelescu A., Tai B. 2005: Bankruptcy Prediction in the High-Tech Industry.
11. Aragon A. 2004: Discriminant Analysis of Default Risk.
12. Ash D., Meester S. 2002: Best Practices in Reject Inferencing, Conference on Credit Risk Modeling and Decisioning, Wharton FIC, University of Pennsylvania, May 29–30, 2002.
13. Auria L., Moro R. A. 2008: Support Vector Machines (SVM) as a Technique for Solvency Analysis, Discussion Paper, Berlin, August 2008.
14. Avery R. B., Brevoort K. P., Canner G. B. 2010: Does Credit Scoring Produce a Disparate Impact?, Finance and Economics Discussion Series.
15. Aziz M. A., Dar H. A. 2004: Predicting Corporate Financial Distress: Wither do We Stand?
16. Baesens B., Gestel T. V., Stepanova M., Vanthienen J. 2005: Neural Network Survival Analysis for Personal Loan Data. – *Journal of the Operational Research Society*, 59 (9), 1089–1098.
17. Banasik J., Crook J. 2003: Sample Selection Bias in Credit Scoring. – *Journal of the Operational Research Society*, 54, 822–832.
18. Banasik J., Crook J. 2004: Does Reject Inference Really Improve the Performance of Application Scoring Models? – *Journal of Banking and Finance*, 28, 857–74.
19. Banasik J., Crook J. 2005: Lean Models and Reject Inference.
20. Banasik J., Crook J. 2007: Reject Inference, Augmentation, and Sample Selection. – *European Journal of Operational Research* 183 (2007), 1582–1594.
21. Banasik J., Crook J. 2010: Reject Inference in Survival Analysis by Augmentation. – *Journal of the Operational Research Society* 61, 473–485.
22. Banca D'Italia 2006: Seminar “Quantitative Validation of Internal Ratings and IRB Parameters“, Rome, Italy, 18–20 December, 2006.
23. Bandyopadhyay A. 2007: Credit Risk Models for Managing Bank's Agricultural Loan Portfolio
24. Bank of Japan 2005: Advanced Credit Risk Management through Internal Rating Systems.
25. Banque de France 2008: *Seminar “Financial Derivatives“*, Paris, France, from 23 to 27 June 2008.
26. Basel Committee on Banking Supervision (BCBS) 2005a: Studies on the Validation of Internal Rating Systems, Working Paper No 14.
27. Basel Committee on Banking Supervision (BCBS) 2005b: Validation of Low-Default Portfolios in the Basel II Framework, Basel Committee Newsletter No 6 (September 2005).
28. Basel Committee on Banking Supervision (BCBS) 2006: *International Convergence of Capital Measurement and Capital Standards: A Revised Framework*.

29. Becchetti L., Sierra J. 2003: Bankruptcy Risk and Productive Efficiency in Manufacturing Firms, Centre for International Studies on Economic Growth Tor Vergata, Working Paper No 30, August 2003.
30. Bellotti T., Crook J. 2007: Credit Scoring with Macroeconomic Variables Using Survival Analysis. – *Journal of the Operational Research Society* 60, 1699–1707.
31. Berger A. N., Frame W. S., Miller N. H. 2002: Credit Scoring and the Availability, Price and Risk of Small Business Credit, FRB of Atlanta Working Paper No 2002–6, FEDS Working Paper No 2002–26.
32. Bernhardsen E. 2001: A Model of Bankruptcy Prediction, Working Paper
33. Biçer I., Sevis D., Bilgiç T. 2010: Bajesian Credit Scoring Model with Integration of Expert Knowledge and Customer Data, International Conference 24th Mini EURO Conference “Continuous Optimization and Information-Based Technologies in the Financial Sector” (MEC EurOPT 2010) June 23–26, 2010, Izmir, Turkey.
34. Bivainis J., Tamošiūnas A. 2003: Įmonių restruktūrizavimo programų valdymas. – *Verslas: teorija ir praktika* 4 (3), 117–128.
35. Blochwitz S., Hohl S., Tasche D., Wehn C. S. 2004: Validating Default Probabilities on Short Time Series. Deutsche Bundesbank, Working Paper.
36. Blochwitz S., Hohl S., Wehn C. S.: 2005: Reconsidering Ratings. – *Wilmott Magazine*, May 2005, 60 – 69.
37. Blochwitz S. 2008: The Supervisor’s Perspective on Rating Model Validation, Symposium on Rating Model Validation by Oesterreichische Nationalbank, Vienna, 15 May 2008.
38. Blöchlinger A., Leippold M. 2006: Economic Benefit of Powerful Credit Scoring. – *Journal of Banking & Finance* 30 (2006), 851–873.
39. Boegelein L. 2006: Credit Model Validation – *Evolving Practice and Challenges on the Way*.
40. Bofondi M., Lotti F. 2006: Innovation in the Retail Banking Industry: the Diffusion of Credit Scoring. – *Review of Industrial Organization* 28 (2006), 343–358.
41. Bonfim D. 2009: Credit Risk Drivers: Evaluating the Contribution of Firm Level Information and of Macroeconomic Dynamics. – *Journal of Banking and Finance* 33 (2), 281–299.
42. British Bankers Association, London Investment Banking Association, International Swaps and Derivatives Association (BBA, LIBA, ISDA) 2004: Introductory Paper on Low Default Portfolios.
43. British Bankers Association, London Investment Banking Association, International Swaps and Derivatives Association (BBA, LIBA, ISDA) 2005: Low default portfolios.
44. Bücker M., Krämer W. 2011: Reject Inference in Consumer Credit Scoring with Nonignorable Missing Data, Discussion Paper, SFB 823.
45. Bunn P., Redwood V. 2003: Company-Accounts-Based Modelling of Business Failure. – *Financial Stability Review*, December, 160–174.
46. Burgt M. 2007: Calibrating Low-Default Portfolios, Using the Cumulative Accuracy Profile.
47. Burez J., Van den Poel D. 2008: Handling Class Imbalance in Customer Churn Prediction.
48. Buzius G., Danėnas P., Garšva G. 2010: Credit Risk Evaluation Using SVM and Bajesian Classifiers, Informacinės technologijos: 15-osios tarpuniversitetinės magistrantų ir doktorantų konferencijos pranešimų „Informacinė visuomenė ir universitetinės studijos“ (IVUS 2010) medžiaga, 2010 m. gegužės 13 d. Kaunas, Lietuva.
49. Camoes F., Hill M. M. 2001: Prediction of Loan Defaults Using a Credit Card Scoring Model Incorporating Worthiness, UNIDE – ISCTE Working paper.
50. Caracota R. C., Dimitriu M., Dinu M. R. 2010: Building a Scoring Model for Small and Medium Enterprises. – *Theoretical and Applied Economics*, Volume XVII (2010), No. 9 (550), 117–128.
51. Carling K., Jacobson T., Linde J., Roszbach K. 2007: Corporate Credit Risk Modelling and the Macroeconomy. – *Journal of Banking and Finance* 31 (3), 845–868.
52. Castro C. E. 2008: Estimating a Financial Distress Rating System for Spanish Firms with a Simple Hazard Model.
53. Ciampi F., Gordini N. 2008: Using Economic-Financial Ratios for Small Enterprise Default Prediction Modeling: an Empirical Analysis. – *Oxford Business and Economics Conference Program*, 1–21.

54. Chava S., Jarrow R. A. 2004: Bankruptcy Prediction with Industry Effects. – *European Finance Review*, Volume 8, Issue 4, 537–569.
55. Chen G., Astebro T. 2003: Bound and Collapse Bajesoian Reject Inference When Data are Missing not at Random.
56. Chen G., Astebro T. 2006: A Maximum Likelihood Approach for Reject Inference in Credit Scoring, Rotman School of Management Working Paper No 07-05.
57. Christensen J. H. E., Hansen E., Lando D. 2004: Confidence Sets for Continuous-Time Rating Transitions Probabilities – *Journal of Banking & Finance* 28 (2004), 2575–2602.
58. Chorafas D. N. 2007: Stress Testing for Risk Control under Basel II, Butterworth-Heinemann.
59. Chung-Hua Shen, Yi-Kai Chen, Bor-Yi Huang 2010: The Prediction of Default With Outliers-Robust Logistic Regression. – *Handbook of Quantitative Finance and Risk Management*, 965–977.
60. Committee of European Banking Supervisors (CEBS) 2006: Guidelines on the Implementation, Validation and Assessment of Advanced Measurement (AMA) and Internal Ratings Based (IRB) Approaches.
61. Crone S. F., Finlay S. 2002: Big or Balanced? An Empirical Study of the Effects of Sample Size and Balancing on Model Performance.
62. Crone S. F., Finlay S. 2012: Instance Sampling in Credit Scoring: an Empirical Study of Sample Size and Balancing. – *International Journal of Forecasting*, Volume 28, Issue 1, January–March 2012, 224–238.
63. Čekanavičius V., Murauskas G. 2004: *Statistika ir jos taikymai. 2 dalis*. Vilnius: TEV.
64. Dakovic R., Czado C., Berg D. 2007: Bankruptcy Prediction in Norway: a Comparison Study.
65. Danėnas P., Garšva G. 2009: Atramos vektorių mašinos ir jų taikymas kredito rizikos vertinimo procese. – *International Journal of Scholarly Papers, Verslo ir ekonomikos transformacijos*, 8 tomas, 3(18), priedas B.
66. Deloitte Touche Tohmatsu 2002: Credit Scoring. A Southern Hemisphere Perspective. Global Financial Services Industries.
67. Deutsche Bundesbank (DB), Oesterreichische Nationalbank (ONB) 2007: Seminar on Capital Allocation in Banks, Vienna, Austria, 9 to 11 May 2007.
68. Dionne G., Laajimi S., Mejri S., Petrescu M. 2006: Estimation of the Default Risk of Publicly Traded Canadian Companies. – *Canadian Journal of Administrative Sciences* 25 (2), 134–152.
69. Doumpos M., Zopounidis C. 1999: A Multicriteria Discrimination Method for the Prediction of Financial Distress: The Case of Greece. – *Multinational Finance Journal* 3 (2), 71–101.
70. Dzidzevičiūtė L. 2010a: Application and Behavioural Statistical Scoring Models. – *Economics and Management* 15, 1046–1056.
71. Dzidzevičiūtė L. 2010b: Statistical Scoring Model of Lithuanian Companies. – *Ekonomika* 2010 89 (4), 96–115.
72. Dzidzevičiūtė L. 2010c: Statistinių vertinimo balais modelių kūrimo ir taikymo ypatumai. – *Pinigų studijos* 1, 35–54.
73. Dzidzevičiūtė L. 2010d: Statistinių vertinimo balais modelių taikymas Lietuvos bankuose. – *Pinigų studijos* 2, 69–85.
74. Dzidzevičiūtė L. 2012: Estimation of Default Probability for Low Default Portfolios. – *Ekonomika* 2012 91 (1), 132–156.
75. Emel A. B., Oral M., Reisman A., Yolalan R. 2003: A Scoring Approach for the Commercial Banking Sector. – *Socio-Economic Planning Sciences* 37 (2003), 103–123.
76. Engelmann B., Hayden E., Tasche D. 2003a: Measuring the Discriminative Power of Rating Systems, Deutsche Bundesbank, Discussion paper, Series 2: Banking and Financial Supervision, No 01/2003.
77. Engelmann B., Hayden E., Tasche D. 2003b: Testing Rating Accuracy. – *Risk*, Vol. 16, (January 2003), 82–6.
78. Erdogan B. E. 2008: Bankruptcy Prediction of Turkish Commercial Banks Using Financial Ratios. – *Applied Mathematical Sciences* 2 (60), 2008, 2973–2982.
79. Europos Parlamento ir Tarybos Direktyva 2006/48/EB dėl kredito įstaigų veiklos pradėjimo ir vykdymo. – *Europos Sąjungos oficialusis leidinys* L 177, 1–200.
80. Falkenstein E., Boral A., Carty L.V. 2000: RiskCalc™ For Private Companies: Moody's Default Model, Moody's Investors Service, Global Credit Research, May 2000.

81. Federal Reserve System (FRS) 2007: Report to the Congress on Credit Scoring and Its Effects on the Availability and Affordability of Credit, August.
82. Feelders A. J. 1996: Learning from Biased Data Using Mixture Models. – *KDD-96*.
83. Feelders A. J., Chang S., McLachlan G. J. 1998: Mining in the Presence of Selectivity Bias and its Application to Reject Inference. – *KDD-98*.
84. Feelders A. J. 2000: Credit Scoring and Reject Inference with Mixture Models. – *International Journal of Intelligent Systems in Accounting, Finance & Management* 2000, 9, 1–8.
85. Feelders A. J. 2001: An Overview of Model Based Reject Inference for Credit Scoring, Working paper, Institute for Information and Computing Sciences.
86. Feng L., Yao Y., Jin B. 2010: Research on Credit Scoring Model with SVM for Network Management. – *Journal of Computational Information Systems* 6:11 (2010), 3567–3574.
87. Fernandes J. E. 2005: Corporate Credit Risk Modelling: Quantitative Rating System and Probability of Default Estimation. Lisbon: Banco BPI.
88. Feruś A. 2008: The DEA Method in Managing the Credit Risk of Companies. – *Ekonomika* 2008 (84), 109–118.
89. Financial Services Authority (FSA) 2005: Expert Group article on Low Default Portfolios.
90. Financial Services Authority (FSA) 2006: Low Default Portfolios: a Proposal for Conservative Estimation of ;Low Default Probabilities.
91. Financial Stability Institute (FIS) & Bank for International Settlements, Committee of European Banking Supervisors (CEBS) 2006a: CEBS/FSI Seminar on Practical Application of the Standardised and Internal Ratings Based Approaches, London, United Kingdom, 4–6 July, 2006.
92. Financial Stability Institute (FIS) & Bank for International Settlements, Committee of European Banking Supervisors (CEBS) 2006b: Seminar on Securitisation, Basel, Switzerland, 19–21 April 2006.
93. Fogarty D. J. 2000: Multiple Imputation as a Missing Data Approach to Reject Inference on Consumer Credit Scoring.
94. Fons J. S., Viswanathan J. 2004: A User’ to Moody’s Default Predictor Model: an Accounting Ratio Approach, Moody’s Investors Service, Global Credit Research, December 2004.
95. Forrest A. 2005: Likelihood Approaches to Low Default Portfolios. Version 1.2 14/9/05.
96. Fortowsky E., LaCour-Little M. 2001: Credit Scoring and Disparate Impact.
97. Fritz S., Luxenburger M., Miede T. 2006: *The Basel Handbook (2nd edition)*, Implementation of an IRB Compliant Rating System, Deutsche Bank Group.
98. Gayler R. 2009: Credit Scoring and Data Mining, AusDM’09, Melbourne.
99. Garškaitė 2008: Įmonių bankroto prognozavimo modelių taikymas. – *Verslas: Teorija ir praktika* 9(4), 281–294.
100. Gerschick J. A. 2002: Credit Evaluation Grid for Microlenders: a Tool for Enhancing Scale and Efficiency.
101. Glennon D., Kiefer N. M., Larson C. E. 2008: Development and Validation of Credit-Scoring Models. – *Journal of Credit Risk* 4 (3), 41–101.
102. Golovan S., Karminski A., Kopylov A., Peresetski A. 2003: Modeli verovatnosti defolta rossijskih bankov: Predvaritelnoje razbijenije bankov na klasteri, Rossijskaja Ekonomitsheskaja Shkola, Working paper.
103. Greene W. H. 1992: A Statistical Model for Credit Scoring, Stern School of Business, Working Paper.
104. Grigaravičius S. 2003: Corporate Failure Diagnosis. – *Organizacijų vadyba: sisteminiai tyrimai* 28, 89–96.
105. Grunert J., Norden L., Weber M. 2005: The Role of Non-Financial Factors in Internal Credit Ratings. – *Journal of Banking & Finance* 29 (2005), 509–531.
106. Gusev P. 2005: Models of Credit Risk for Emerging Markets.
107. Hand D. J., Henley W. E. 1997: Statistical Classification Methods in Consumer Credit Scoring: a Review. – *Royal Statistical Society* (1997), 160, Part 3, 523–541.
108. Hand D. J. 2000: Reject Inference in Credit Operations: Theory and Methods.
109. Hand D. J., Vinciotti V. 2002: Scorecard Construction with Unbalanced Class Sizes. – *Journal of the Iranian Statistical Society* 2 (2), 189–205.

110. Hand D. J. 2009: Evaluating Scorecards, Conference on Risk Management in the Personal Financial Services Sector, London, United Kingdom, 22–23 January 2009.
111. Hayden E. 2003: Are Scoring Models Sensitive With Respect to Default Definitions? Evidence from the Austrian Market, University of Vienna, Working Paper.
112. Härdle W., Moro R. A., Schäffer D. 2005: Predicting Bankruptcy with Support Vector Machines, SFB 649 Discussion Paper 2005-009.
113. Härdle W., Moro R. A., Schäffer D. 2007: Estimating Probabilities of Default with Support Vector Machines, Discussion Paper, Series 2: Banking and Financial, No 18/2007.
114. Henley W. E., Hand D. J. 1996: A k-Nearest-Neighbour Classifier for Assessing Consumer Credit Risk. – *The Statistician*, Volume 45, Issue 1 (1996), 77–95.
115. Hillegeist S. A., Keating E. K. 2004: Assessing the Probability of Bankruptcy. – *Review of Accounting Studies* 9, 5–34.
116. Hornik K., Jankowitsch R., Lingo M., Pichler S., Winkler G. 2006: Benchmarking Credit Rating Systems
117. Hörkkö M. 2010: The Determinants of Default in Consumer Credit Market. Master's Thesis, Aalto University.
118. Hsieh Nan-Chen, Chu Kuo-Chung 2009: Enhancing Consumer Behavior Analysis by Data Mining Techniques. – *International Journal of Information and Management Sciences*, 20 (2009), 39–53.
119. Hu Yu-Chiang, Ansell J. 2007: Measuring Retail Company Performance Using Credit Scoring Techniques. – *European Journal of Operational Research*, 183 (2007), 3 (December), 1595–1606.
120. Jacobs M., Karagozoglu A. K., Laysih D. N. 2008: Understanding and Predicting the Resolution of Financial Distress, Risk Management Conference, Credit and Financial Risk Management: 40 Years after the Altman Z-Score Model, Florence, June 12–14, 2008.
121. Jacobson T., Roszbach K. 2003: Bank Lending Policy, Credit Scoring and Value-at-Risk. – *Journal of Banking & Finance* 27 (2003) 615–633.
122. Jacobson T., Lindé J., Roszbach K. 2006: Internal Rating Systems, Implied Credit Risk and the Consistency of Banks' Risk Classification Policies, Sveriges Riksbank Research Paper Series, June 2006.
123. Jafry Y., Schuermann T. 2004: Measurement, Estimation and Comparison of Credit Migration Matrices – *Journal of Banking & Finance* 28 (2004), 2603–2639.
124. Ji T. 2004: Consumer Credit Delinquency and Bankruptcy Forecasting Using Advanced Econometric Modeling.
125. John A., Banerjee P., Francis V. 2007: Modeling and Empirical Validation of Revised Altman's Credit Risk Model for Indian Banks, Working Paper Series.
126. Iscanoglu A. 2005: Credit Scoring Methods and Accuracy Ratio, Ankara.
127. Kamienas I., Valvonis V. 2004: Paskolų registro naudojimas kredito rizikai valdyti. – *Pinigu studijos* 1, 5–30.
128. Kennedy K. 2009: Low-Default Portfolio/One-Class Classification: A Literature Review.
129. Kiefer N. M. 2006: Default Estimation for Low-Default Portfolios.
130. Kiefer N. M. 2007: Bayesian Methods for Default Estimation in Low-Default Portfolios.
131. Kiefer N. M. 2008: Default Estimation, Correlated Defaults, and Expert Information.
132. Kiefer N. M., Larson C. E. 2005: Specification and Information Issues in Credit Scoring.
133. Kim Y., Sohn S. Y. 2007: Technology Scoring Model Considering Rejected Applicants and Effect of Reject Inference. – *Journal of the Operational Research Society* 58, 1341–1347.
134. Khandani A. E., Adlar J. Kim A. J., Lo A. W. 2010: Consumer Credit Risk Models via Machine-Learning Algorithms. – *Journal of Banking and Finance* 34, 2767–2787.
135. Kleinbaum D. G., Klein M. 2002: *Logistic regression. A Self-Learning Text*, Second Edition, Springer
136. Kleinbaum D. G., Klein M. 2005: *Survival analysis. A Self-Learning Text*, Second Edition, Springer
137. Klepac G. 2007: Integrating Seasonal Oscillations into Basel II Behavioural Scoring Models. – *Financial Theory and Practice* 31 (3), Rujan 2007, 281–291.
138. Kocenda E., Vojtek M. 2006: Credit Scoring Methods. – *Czech Journal of Economics and Finance* (56), 152–167.

139. Kocenda E., Vojtek M. 2009: Default Predictors and Credit Scoring Models for Retail Banking, CES Working Paper No 2862.
140. Kocenda E., Vojtek M. 2011: Default Predictors in Retail Credit Scoring: Evidence from Czech Banking Data, Working Paper.
141. Ko Li-Jen, Blocher E. J., Lin P. P. 2001: Prediction of Corporate Financial Distress: an Application of the Composite Rule Induction System. – *The International Journal of Digital Accounting Research* 1 (1), 69–85.
142. Komorád K. 2009: On Credit Scoring Estimation, VDM Verlag, 2009, 1–84.
143. Krapavickaitė D., Plikusas A. 2005: *Imčių teorijos pagrindai*, Vadovėlis universitetų studentams. Vilnius: Technika.
144. Kravets T., Kuznetsov G. 2011: Rating of Enterprises' Activities by the Modified Cluster Method. – *Ekonomika* 2011 90 (2), 101–113.
145. Lahsasna A., Aïnon R. N., Wah T. Y. 2010: Credit Scoring Models Using Soft Computing Methods: A Survey. – *The International Arab Journal of Information Technology* 7 (2), April 2010, 115–123.
146. Lando D., Skødeberg T. M. 2002: Analyzing Rating Transitions and Rating Drift with Continuous Observations – *Journal of Banking & Finance* 26 (2004), 423–444.
147. Leipus R., Valužis M. 2006: Kredito rizika kaip pasirinkimo sandoris. – *Pinigų studijos* 1, 36–59.
148. Leung K., Cheong F., Cheong C., O'Farrell S., Tislington R. 2008: Building a Scorecard in Practice, in Chung-Ming Ou (ed.), Proceedings of the 7th International Conference on Computational Intelligence in Economics and Finance (CIEF 2008), Taiwan, 5–7 December, 2008, 1–7.
149. Lieli R. P., White H. 2010: The Construction of Empirical Credit Scoring Rules Based on Maximization Principles. – *Journal of Econometrics* 157 (2010), 1 (July), 110–119.
150. Lietuvos bankas 2006a: Kapitalo pakankamumo skaičiavimo bendrosios nuostatos (2006 11 09, Nr. 138) (ir vėlesni šio nutarimo pakeitimai).
151. Lietuvos bankas 2006b: Patikimumo vertinimo ir jo tikrinimo nuostatos (2006 11 09, Nr. 140).
152. Lietuvos bankas 2008: Vidaus kontrolės ir rizikos vertinimo (valdymo) organizavimo nuostatos (2008 09 25, Nr. 149) (ir vėlesni šio nutarimo pakeitimai).
153. Lietuvos Respublikos Seimas (LRS) 2001: Lietuvos Respublikos Įmonių bankroto įstatymas (2001 03 20, Nr. IX-216) (ir vėlesni šio įstatymo pakeitimai).
154. Lietuvos Respublikos Seimas (LRS) 2008: Lietuvos Respublikos Įmonių finansinės atskaitomybės įstatymo pakeitimo įstatymas (2008-06-26, Nr. 1633) (ir vėlesni šio įstatymo pakeitimai).
155. Lingo M., Winkler G. 2008: Discriminatory Power: an Obsolete Validation Criterion? – *Journal of Risk Model Validation* 2 (1), 1–27.
156. Liu Y. 2001: New Issues in Credit Scoring Application.
157. Lykke M., Pedersen K. J., Vinther H. M. 2004: A Failure-Rate Model for the Danish Corporate Sector, Working Paper.
158. Longenecker J. G., Moore C. W., Petty J. W. 1997: Credit Scoring and the Small Business: a Review and the Need for Research.
159. Lopez R. F. 2010: Credit Risk Management for Low Default Portfolios. Forecasting Defaults through Cooperative Models and Bootstrapping Strategies.
160. Löffler G. 2004. An Anatomy of Rating Through the Cycle. – *Journal of Banking and Finance* 28(3), 695–720.
161. Lucas A. 2007: Basel Compliant Modelling with Little or No Data, Credit Scoring Conference, Credit Research Centre.
162. Luppi B., Marzo M., Scorcu A. E. Credit Risk and Basel II: Are Non-Profit Firms Financially Different? – *Applied Financial Economics Letters* 4 (3), 199–203.
163. Lykke M., Pedersen K. J., Vinther H. M. 2004: A Failure-Rate Model for the Danish Corporate Sector, Danmarks Nationalbank Working Paper No. 16.
164. Mackevičius J., Poškaitė D. 1999: Įmonių bankroto prognozavimo analizės metodų tyrimas, remiantis finansinių ataskaitų duomenimis. – *Ekonomika* 49, 59–63.
165. Mackevičius J. 2005: *Įmonių veiklos analizė. Informacijos rinkimas, sisteminimas ir vertinimas*, Vilnius, 2005.

166. Mackevičius J., Rakštelienė A. 2005: Altman modelių taikymas Lietuvos įmonių bankrotui prognozuoti. – *P pinigų studijos* 1, 24–42.
167. Mackevičius J., Silvanavičiūtė S. 2006: Įmonių bankroto prognozavimo modelių tinkamumo nustatymas. – *Verslas: teorija ir praktika* 8 (4), 193–202.
168. Mackevičius J., Sneidere R. 2010: Insolvency of Enterprise and Methods of Financial Analysis for Predicting it: – *Ekonomika* 89 (1), 1392–1258.
169. Malik M., Thomas L. 2006: Modelling Credit Risk of Portfolio of Consumer Loans. – *Journal of the Operational Research Society* 61 (3), 411–420.
170. Marius A. A., Bogdan C. 2011: Bank Performance in Central and Eastern Europe: The Role of Financial Liberalization, European Financial Management Association, 2011 Annual Meetings, Braga, Portugal, June 22–25.
171. Marquez J. 2008: An Introduction to Credit Scoring for Small and Medium Size Enterprises.
172. Mays E. 1998: Credit Risk Scoring: Design and Application, Glenlake Publishing Company Ltd
173. Mays E. 2004: *Credit Scoring for Risk Managers. The Handbook for Lenders*. Ohio: Thomson/South Western.
174. McNab H., Wynn A. 2003: Principles and Practice of Consumer Credit Risk Management, The Chartered Institute of Bankers.
175. Medema L., Koning R. H., Lensink R. 2009: A Practical Approach to Validating a PD Model. – *Journal of Banking and Finance* 33 (2009), 701–708.
176. Menardi G. 2009: Some Issues Emerging in Evaluating the Risk of Default for SMEs.
177. Merkevičius E., Garšva G., Girdzijauskas S. 2006: A Hybrid SOM-Altman Model for Bankruptcy Prediction. – *Lecture Notes in Computer Science*, Springer Berlin / Heidelberg; Volume 3994 / 2006, 364–371.
178. Mileris R. 2009: Statistinių kredito rizikos vertinimo modelių efektyvumo analizė. – *Economics and Management/Ekonomika ir vadyba* 14, 1156–1162.
179. Mileris R. 2010: Estimation of Loan Applicants Default Probability Applying Discriminant Analysis and Simple Bayesian Classifier. – *Economics and Management/Ekonomika ir vadyba* 15, 1078 – 1084.
180. Mileris R., Boguslauskas V. 2010: Data Reduction Influence on the Accuracy of Credit Risk Estimation Models. – *Inžinerinė Ekonomika-Engineering Economics*, 21 (1), 5–11.
181. Mileris R., Boguslauskas V. 2011: Credit Risk Estimation Model Development Process: Main Steps and Model Improvement. – *Inžinerinė Ekonomika-Engineering Economics*, 22 (2), 126–133.
182. Mircea R. 2007: Credit Risk for Non-financial Companies in the Context of Financial Stability. Bucharest, Academy of Economic Studies, Doctoral School of Finance and Banking.
183. Mok Jie-Men 2009: Reject Inference in Credit Scoring, BMI paper.
184. Montrichard D. 2007: Reject Inference Methodologies in Credit Risk Modeling, Credit Risk Analytics, Card Products, CIBC.
185. OCC 1997: Safety and Soundness and Compliance Issues on Credit Scoring Models, document OCC 97-24, dated May 20, 1997.
186. Oesterreichische Nationalbank (ONB) 2004: Rating Models and Validation. Guidelines on Credit Risk Management.
187. Pačebutaitė A. 2011: Key Determinants of Lithuania's Sovereign Credit Rating. – *Ekonomika* 2011, 90 (1), 73–84.
188. Paliulytė R. 2004: *Makroekonomika*, VVK, Vilnius, 2004.
189. Parnitzke T. 2005: Credit Scoring and the Sampe Selection Bias.
190. Philosophov L. V. 2004: Assessing Validity of the Basel II Model in Measuring Risk of Credit Portfolios
191. Philosophov L. V. 2005: Assessing the Time Horizon of Bankruptcy Using Financial Ratios and the Maturity Schedule of Long-Term Debt.
192. Pindyck R. S., Rubinfeld D. L. 1997: *Econometrics Models and Economic Forecasts*, fourth edition
193. Pintado J., Rodrigues L., De la Torre C. 2004: A New Approach to Estimate the Probability of Financial Insolvency

194. Plikynas D., Budrionis A. 2010: Kompiuterinio intelekto ir daugiaagenčių sistemų integralus taikymas socialiniams tyrimams: principai ir galimybės. – *Pinigų studijos* 1, 16–34.
195. Pluto K., Tasche D. 2005: Estimating Probabilities for Low Default Portfolios.
196. Pociuha J. 2005: Discriminant Methods for Bankruptcy Prediction – Theory and Applications. – *Ekonomika* 2005(72), 77–83.
197. Porath D. 2004: Estimating Probabilities of Default for German Savings Banks and Credit Cooperatives, Discussion Paper, Series 2: Banking and Financial Supervision, No 06/2004.
198. Porath D. 2006: Estimating Probabilities of Default for German Savings Banks and Credit Cooperatives. – *Schmalenbach Business Review* 58, July 2006, 214–233.
199. Pranckevičiūtė M. 2007: Apibendrintų Gini indeksų taikymas reitingavimo modeliams. – *Pinigų studijos* 2, 47–58.
200. Proškutė A. 2012: Bussiness Cycle Drivers in Lithuania. – *Pinigų studijos* 1, 5–29.
201. Psillaki M., Tsolas I. E., Margaritis D. 2009: Evaluation of Credit Risk Based on Firm Performance. – *European Journal of Operational Risk* 201 (3), 813–881.
202. Pukėnas K. 2005: *Sportinių tyrimų duomenų analizė SPSS programa*, Kaunas: Lietuvos kūno kultūros akademija.
203. Pukėnas K. 2009: *Kokybinių duomenų analizė SPSS programa*, Kaunas: Lietuvos kūno kultūros akademija.
204. Puri M., Rocholl J., Steffen S. 2011: Rules versus Discretion in Bank Lending Decisions, Working Paper.
205. Rommer A. D. 2005: Testing the Assumptions of Credit-scoring Models, Working Paper.
206. Sabato G. 2006: Managing Credit Risk for Retail Low-Default Portfolios.
207. Sabzevari H., Soleymani M., Noorbakhsh E. 2007: A Comparison Between Statistical and Data Mining Methods for Credit Scoring in Case of Limited Available Data, Credit Scoring Conference, Credit Research Centre.
208. SAS 2008: *Basic Credit Risk Modeling for Basel II Using SAS^R. Course Notes*.
209. SAS 2009: *Credit Risk Modeling Using SAS^R. Course Notes*.
210. Savickaitė D., Valvonis V. 2007: Įmonių reitingavimas: Lietuvos bankų patirtis. – *Pinigų studijos* 1, 86–108.
211. Siddiqi N. 2006: *Credit Risk Scorecards. Developing and Implementing Intelligent Credit Scoring*, John Wiley&Sons.
212. Schreiner M. 2004a: Scoring Drop-Out at a Microlender in Bolivia.
213. Schreiner M. 2004b: Scoring Arrears at a Microlender in Bolivia. – *Journal of Microfinance*, ESR Review 6 (2) (2004).
214. Schuermann T., Hanson S. 2004: Estimating Probabilities of Default.
215. Sezgin Ö. 2006: Statistical Methods in Credit Rating, a thesis submitted to the graduate school of Applied mathematics of the Middle East technical university.
216. Shen Chung-Hua, Chen Yi-Kai, Huang Bor-Yi 2010: The Prediction of Default With Outliers-Robust Logistic Regression. – *Quantitative Finance* (2010), 965–977.
217. Shumway T. G. 1999: Forecasting Bankruptcy More Accurately: A Simple Hazard Model.
218. Smith A., Elkan C. 2004: A Bajesian Network Framework for Reject Inference. – KDD'04, 2004, Seattle, Washington, USA
219. Stein M. R. 2002: Benchmarking Default Prediction Models: Pitfalls and Remedies in Model Validation. – *Journal of Risk Model Validation* 1 (1), 77–113.
220. Stein M. R. 2005: The Relationships between Default Prediction and Lending Profits: Integrating ROC Analysis and Loan Pricing. – *Journal of Banking & Finance* 29 (2005), 1213–1236.
221. Stepanova M., Thomas L. C. 2001: PHAB Scores: Proportional Hazards Analysis Behavioural Scores. – *Journal of the Operational Research Society* 52, 1007–1016.
222. Stepanova M., Thomas L. 2002: Survival Analysis Methods for Personal Loan Data. – *Operations Research* 50 (2), 277–289.
223. Stoškus S., Beržinskienė D., Virbickaitė R. 2007: Theoretical and Practical Decisions of Bankruptcy as One of Dynamic Alternatives in Company's Performance. – *Engineering Economics* 2 (52), 1392–2785.

224. Strangellini E. 1999: The Use of Graphical Models in Consumer Credit Scoring, Proceeding of the 52nd Session of the International Statistical Institute, Helsinki, Finland, 10–18, August 1999, 279–282.
225. Stundžienė A., Boguslauskas V. 2006: Valuation of Bankruptcy Risk for Lithuanian Companies. – *Engineering Economics* 4 (49), 29–36.
226. Sun Ming-Yi, Wang Szu-Fang 2007: Validation of Credit Rating Models – A Preliminary Look at Methodology and Literature Review.
227. Šušteršič M., Mramor D., Zupan J. 2007: Consumer Credit Scoring Models With Limited Data, EFA 2007 Ljubljana Meetings Paper.
228. Tasche D. 2006: Validation of Internal Rating Systems and PD Estimates.
229. Tasche D. 2009: Estimating Discriminatory Power and PD Curves when the Number of Defaults is Small.
230. Thomas L. C. 2000: A Survey of Credit and Behavioural Scoring: Forecasting Financial Risk of Lending to Customers. – *International Journal of Forecasting* 16, 149–172.
231. Thomas L. C. 2007: Survival Analysis and Consumer Credit Risk Modelling, University of Southampton.
232. Thomas L. C., Edelman D. B. Crook J. N. 2002: *Credit Scoring and its Applications*. Society for Industrial and Applied Mathematics. Philadelphia: Society for Industrial and Applied Mathematics.
233. Thomas L. C., Jung K. M., Thomas S. D., Wu Y. 2006: Modeling Consumer Acceptance Probabilities. – *Expert Systems with Applications* 30 (3), April 2006, 499–506.
234. Tong Lee-Ing, Yang Chien-Hui, Yu Hsiang-Pai 2005: Credit Rating Analysis Using General Regression Neural Network
235. Трифионов Ю. А. 2008: Количественные и качественные методы диагностики несостоятельности (банкротства) предприятий.
236. Tvaronavičienė M. 2001: Įmonių bankroto proceso ekonominio efektyvumo didinimo kryptys. – *Ekonomika* 54, 135–144.
237. Valvonis V. 2004: Kredito rizikos valdymas banke. – *Pinigų studijos* 4, 57–82.
238. Valvonis V. 2006: Šiuolaikinis kredito rizikos vertinimas banke: paskolos ir skolininko rizika. – *Pinigų studijos* 1, 58–74.
239. Verstraeten G. 2005: Issues in Predictive Modeling of Individual Customer Behavior: Applications in Targeted Marketing and Consumer Credit Scoring.
240. Verstraeten G., Van den Poel D. 2005: The Impact of Sample Bias on Consumer Credit Scoring Performance and Profitability. – *Journal of the Operational Research Society* 56, 981–992.
241. Waagepetersen R. 2010: A Statistical Modeling Approach to Build an Expert Credit Risk Rating System. – *Journal of Credit Risk*. 6. (2), 2010, 81–94.
242. Weldon G. A. 2011: Inferring Behavior On Rejected Credit Applicants – Three Approaches.
243. Wilde T., Jackson L. 2006: Low-Default Portfolios without Simulation.
244. Wozniowska G. 2008: Methods of Measuring the Efficiency of Commercial Banks: an Example of Polish Banks. – *Ekonomika* 2008 (84), 81–91.
245. Wu X. 2008: Credit Scoring Model Validation.

PAVYZDINIS EKSPERTINIS FIZINIŲ ASMENŲ VERTINIMO BALAIS MODELIS


A	B	C	D = A·C
Svoris	Rodiklio reikšmė	Balai	Pasvertas balas*
1. Amžius			
9 %	18–24	–200	22,50
	25–36	125	
	37–48	250	
	49–60	200	
	61–75	–125	
	> = 76	–250	
2. Išsilavinimas			
9 %	Aukštasis universitetinis	250	22,50
	Aukštasis neuniversitetinis	100	
	Aukštesnysis	50	
	Vidurinis	–20	
	Spec. pagrindinis	–20	
	Pagrindinis	–100	
3. Darbinė padėtis			
9 %	Vadovas (ė)	250	22,50
	Savarankiškai dirbantis (i)	200	
	Specialistas (ė)	150	
	Pensininkas (ė)	50	
	Nekvalifikuotas darbininkas (ė)	–50	
	Studentas (ė), namų šeimininkė (as), kita	–100	
4. Gyvenamoji padėtis			
8 %	Nuosavas būstas	250	20,00
	Nuomininkas (ė)	0	
	Gyvena pas tėvus ir kita	–50	
5. Šeiminė padėtis**			
8 %	Vedęs (ištekejusi), turi vaikų	250	20,00
	Vedęs (ištekejusi), neturi vaikų	200	
	Išsiskyręs (usi), turi vaikų	150	
	Našlys (ė), turi vaikų	100	
	Išsiskyręs (usi) arba našlys (našlė) ir neturi vaikų arba jų turi, bet jie gyvena ne su juo (ja), jiems išlaikyti nemoka alimentų	–50	
	Nevedęs (netekėjusi)	–50	
6. Grynosios šeimos pajamos per mėnesį vienam šeimos nariui***			
20 %	> = 5501	250	50,00
	4501–5500	200	
	3501–4500	150	
	2501–3500	50	
	1501–2500	0	
	< = 1500	–50	
7. Per dvejus paskutinius metus kredito įstaigoms, telekomunikacijų, komunalinių paslaugų ir kitoms įmonėms pradelstų įmokų skaičius****			
10 %	Nebuvo pradelsimų	250	25,00

	1 įmoka	0	
	2 įmokos	-50	
	3-4 įmokos	-125	
	5-7 įmokos	-250	
	> = 8 įmokos	-375	
8. Vidutinė visų pradelsimų per dvejus paskutinius metus trukmė****			
10 %	Nebuvo pradelsimų	250	25,00
	< = 15 dienų	0	
	16-30 dienų	-50	
	31-60 dienų	-125	
	61-90 dienų	-250	
	> = 90 dienų	-375	
9. Turi turto skolinančiame banke			
9 %	Taip	250	22,50
	Ne	0	
10. Naudojimas atnaujinamosiomis paskolomis			
8 %	Neturi tokių paskolų	0	20,00
	Panaudojimas <i>nedidėja</i> , panaudojimų vidurkis per paskutinį pusmetį <i>nėra daug didesnis</i> už panaudojimų per visą tokių paskolų turėjimo laiką vidurkį	250	
	Panaudojimas <i>nedidėja</i> , bet panaudojimų vidurkis <i>yra gerokai didesnis</i> už panaudojimų per visą tokių paskolų turėjimo laiką vidurkį	100	
	Panaudojimas <i>didėja</i> , bet panaudojimų vidurkis <i>nėra daug didesnis</i> už panaudojimų per visą tokių paskolų turėjimo laiką vidurkį	-50	
	Panaudojimas <i>didėja</i> , panaudojimų vidurkis <i>yra gerokai didesnis</i> už panaudojimų per visą tokių paskolų turėjimo laiką vidurkį	-250	
	Turi tokių paskolų, bet jomis nesinaudoja	-125	
		Iš viso	250,00
		Reitingas	1


Šaltinis: sudaryta autorės. * Čia nurodyti pačių geriausių skolininkų pasverti balai. Reitingas nustatytas pagal 4 pav. pateiktą reitingų skalę. Šis modelis labiau tinka vartojimo paskoloms ir kredito kortelėms.**Vaikai iki 24 metų. ***Iš šeimos pajamų atimami komunaliniai mokesčiai, finansinių įsipareigojimų mėnesinės įmokos ir kt. ****Tokią informaciją galima pirkti iš išorinių paskolų registru, pavyzdžiui, UAB „Creditinfo Lietuva“.

PATIKIMUMO VERTINIMO IMČIŲ PAVYZDŽIAI

2. Kūrimo imčiai nepriskiriamo laiko duomenys



1. Kūrimo imčiai nepriskiriamų skolininkų duomenys



- Skolininkas, kurio duomenys yra naudojami modeliui kurti




- Skolininkas, kurio duomenys yra naudojami modelio patikimumui vertinti




Laikas

4. Kitos rūšies paskolų ir kūrimo imčiai nepriskiriamo laiko duomenys



3. Kitos rūšies paskolų duomenys



MOKĖJIMŲ ISTORIJS RODIKLIAI

Žymuo	Ivesties kintamasis
X1*	Pagal pradelisimo pradžios datą įvertintas pradelisimų skaičiaus atitinkamo laikotarpio svertinis vidurkis
X2**	Pagal pradelisimo pradžios datą įvertinta atitinkamo laikotarpio svertinė pradelisimų trukmė
X3***	Pagal pradelisimo pradžios datą įvertintas atitinkamo laikotarpio pradelstos sumos ir mėnesio įmokos svertinis santykis
X4–X27****	Pradelisimo trukmė kiekvieną mėnesį
X28	Bendras atitinkamo laikotarpio pradelistų dienų skaičius
X29	Bendras atitinkamo laikotarpio pradelisimo atvejų skaičius
X30	Buvo bent vienas pradelisimas per atitinkamą laikotarpį
X31	Buvo bent X pradelisimų per atitinkamą laikotarpį
X32	Buvo bent vienas ilgesnis nei Y dienų pradelisimas per atitinkamą laikotarpį
X33	Buvo bent X ilgesnių nei Y dienų pradelisimų per atitinkamą laikotarpį
X34	Yra bent vienas pradelisimas atskaitos taške T_0
X35	Pradelisimų, ilgesnių nei Y dienų, skaičius atitinkamą laikotarpį
X36	Ilgiausio pradelisimo trukmė atitinkamą laikotarpį
X37	Laikas (mėn. ar d.) nuo paskutinio pradelisimo pradžios
X38	Laikas (mėn. ar d.) nuo paskutinio pradelisimo pabaigos, t. y. nuo tos dienos, kai paskutinis pradelisimas buvo apmokėtas
X39	Sukauptos neapmokėtos pradelstos sumos ir paskolos likučio santykis
X40	Bendros visų atitinkamo laikotarpio pradelisimų sumos ir paskolos likučio santykis
X41	Ar skolininkas bent kartą tapo „blogas“ nuo paskolos suteikimo pradžios iki atskaitos taško T_0 ?
X42	Kiek kartu skolininkas tapo „blogas“ nuo paskolos suteikimo pradžios iki atskaitos taško T_0 ?

Šaltinis: sudaryta autorės.

+ jeigu laikotarpis apima 24 mėn., tai paskutiniam pradelisimui suteikiamas svoris, lygus 24/24, o pirmam pradelisimui – svoris, lygus 1/24. Jeigu skolininkas pradelė vieną kartą per pirmąjį šio laikotarpio mėnesį ir vieną kartą per paskutinį mėnesį, rodiklio reikšmė būtų 1,04;

++ jeigu laikotarpis apima 24 mėn., tai paskutinio pradelisimo trukmei suteikiamas svoris, lygus 24/24, o pirmo pradelisimo trukmei – svoris, lygus 1/24. Jeigu abiem atvejais pradelisama po 30 dienų, rodiklio reikšmė būtų 31,25;

+++ jeigu laikotarpis apima 24 mėn., tai paskutinio pradelisimo santykiui suteikiamas svoris, lygus 24/24, o pirmojo pradelisimo santykiui – svoris, lygus 1/24. Jeigu abiem atvejais pradelisama po 50 % įmokos, rodiklio reikšmė būtų 52,08.

++++ gali būti testuojami 24 įvesties kintamieji taikant atitinkamo mėnesio pradelisimo trukmę: 1) pradelisimo trukmę pirmąjį 24 mėn. laikotarpio mėnesį, 2) pradelisimo trukmę antrąjį 24 mėn. laikotarpio mėnesį ir t. t. Pradelisimo trukmės rodikliai taikomi kaip atskiri įvesties kintamieji, jokių svorių nėra naudojama.

FORREST (2005) METODAI BE KORELIACIJOS

Apibūdinimas	Formulės	Komentariai
Vienas LDP reitingas, jame nėra faktinių „blogų“ skolininkų	$LR(PD) = \frac{L(PD)}{ML}$ $L(PD) = (1 - PD)^N$ $ML = (1 - ODF)^N$ <p>čia: $L(PD)$ – tikėtumas, t. y. tikimybė, kad bus gauti tokie patys duomenys, kokie buvo faktiškai stebimi; ML – didžiausias tikėtumas, t. y. didžiausia tikėtumo reikšmė iš visų modelio parametrų kombinacijų. Šiuo atveju yra tik vienas parametras – PD. Kadangi $ODF = 0$ (nes nėra faktinių „blogų“ skolininkų), tai $ML = 1$; N – reitingo skolininkų skaičius</p>	<p>Norint gauti konservatyvią PD, $LR(PD)$ lygtis yra sprendžiama žingsnis po žingsnio naudojant hipotetines PD ir perskačiuojant tol, kol $LR(PD)$ lygties reikšmė tampa lygi (100 % – pasiklovimo lygmuo). Pavyzdžiui, jeigu pasirinktume 95 % pasiklovimo lygmenį, turime gauti tokią PD, kad $LR(PD)$ lygties reikšmė būtų 0,05.</p> <p>PD gali būti apskaičiuota taikant „MS Excel“ funkciją =BETAINV(pasiklovimo lygmuo; 1; N)</p>
Vienas LDP reitingas, jame yra keli faktiniai „blogai“ skolininkai	$LR(PD) = \frac{L(PD)}{ML}$ $L(PD) = PD^D \cdot (1 - PD)^{N-D}$ $ML = ODF^D \cdot (1 - ODF)^{N-D}$ $MIN_PD < ODF < MAX_PD$ <p>čia: D – faktinių „blogų“ reitingo skolininkų skaičius</p>	<p>Yra paketiama $LR(PD)$ skalė, kad galima būtų gauti teigiamą dydį, išreikštą kaip $-2 \ln(LR(PD))$. Kadangi $-2 \ln(LR(PD))$ reikšmės yra pasiskirsčiusios pagal χ^2 skirstinį, konservatyvi PD yra didesnė iš dviejų PD, kurioms galioja ši sąlyga: $-2 \ln(LR(PD))$ reikšmė lygi atvirkštiniam χ^2 skirstinio vienpusės uodegos tikimybės dydžiui, kuris gali būti apskaičiuojamas taikant „MS Excel“ funkciją =CHIINV, naudojant (100% – pasiklovimo lygmuo) ir viena laisvės laipsnį (nes yra tik vienas LDP reitingas)</p>
Du LDP reitingai iš eilės, nėra faktinių „blogų“ skolininkų	$L(PD) = (1 - PD_A)^{NA+NB}$ (reitingui A); $L(PD) = (1 - PD_B)^{NB}$ (reitingui B);	<p>Maksimalių PD_A ir PD_B yra ieškoma žingsnis po žingsnio, kol $L(PD)$ lygties reikšmė tampa lygi (100 % – pasiklovimo lygmuo). Konservatyvių PD kombinacijos yra ant labiausiai koordinatų pradžios atžvilgiu nutolusios trikampio linijos (žr. 18 pav.)</p>
Du LDP reitingai iš eilės, yra keli faktiniai „blogai“ skolininkai	$LR(PD) = \frac{L(PD)}{ML}$ $L(PD) = PD_A^{DA} (1 - PD_A)^{NA-DA} \cdot PD_B^{DB} (1 - PD_B)^{NB-DB}$ $ML = ODF_A^{DA} (1 - ODF_A)^{NA-DA} \cdot ODF_B^{DB} (1 - ODF_B)^{NB-DB}$ <p>čia: DA, DB – atitinkamai faktinių „blogų“ A ir B reitingo skolininkų skaičius</p>	<p>Konservatyvių PD kombinacija turi atitikti tris sąlygas: a) $PD_A < PD_B$; b) $-2 \ln(LR(PD)) = CHIINV((100\% - pasiklovimo lygmuo); 2)$; c) PD kombinacija turi būti ant labiausiai koordinatų pradžios atžvilgiu nutolusios linijos (žr. 19 pav.).</p> <p>Laisvės laipsnių skaičius turi būti lygus LDP reitingų iš eilės skaičiui, šiuo atveju – 2</p>

Šaltinis: sudaryta autorės pagal Forrest (2005).

VERTINIMO BALAIS MODELIŲ TAIKYMO LIETUVOS BANKUOSE TYRIMO ANKETA

Gerb. Respondente,

Šios apklausos tikslas – išsiaiškinti mažmeninių paraiškų vertinimo balais modelių (ang. *application credit scoring*) taikymo Lietuvos bankuose specifiką. Aš garantuoju Jums banko anonimiškumą bei tai, jog gauti rezultatai bus panaudoti tik moksliniais tikslais.

1. Koks Jūsų banke yra taikomas visos paskolos sumos limitas paskolas priskiriant mažmeninių paskolų grupei? (pažymėkite intervalą, į kurį patenka taikomas limitas, ir nurodykite, ar šis limitas yra taikomas tik įmonių paskoloms, ar ir fizinių asmenų paskoloms)

Visa paskolos suma, litais

> 700 000
 (500 000–700 000]
 (300 000–500 000]
 (100 000–300 000]
 ≤ 100 000
 Netaikomas

2. Kokie Jūsų banke yra taikomi papildomi kriterijai, įmonių paskolas priskiriant mažmeninių paskolų grupei? (pažymėkite kriterijus ir intervalą, į kurį patenka atitinkamo taikomo kriterijaus limitas)

Įmonės pardavimo pajamos, litais

> 700 000
 (500 000–700 000]
 (300 000–500 000]
 (100 000–300 000]
 ≤ 100 000
 Netaikomas

Įmonės turtas, litais

> 700 000
 (500 000–700 000]
 (300 000–500 000]
 (100 000–300 000]
 ≤ 100 000
 Netaikomas

Darbuotojų skaičius

> 250
 (100–250]
 (50–100]
 (10–50]
 ≤ 10
 Netaikomas

Kiti kriterijai (jei galite, nurodykite kriterijus ir jų limitus):

.....

3. Ar Jūsų banke bent vienai mažmeninių paskolų rūšiai yra taikomi statistiniai paraiškų vertinimo balais modeliai?

Taip.....

Ne..... (žr. 10 klausimą)

4. Kiek statistinių paraiškų vertinimo balais modelių yra taikoma Jūsų banke ir kokioms mažmeninių paskolų rūšims? (išvardykite modelius, pažymėkite paskolų rūšis, kurioms yra taikomas konkretus modelis, ir, jei galite, nurodykite, ar tai yra naujų skolininkų, ar esamų skolininkų naujų paraiškų modelis)

	Įmonių paskolos			Fizinių asmenų paskolos				
	Investicinės paskolos	Apyvartinių lėšų finansavimas, kredito linija	Kitos rūšys (arba vienas modelis visoms įmonėms)	Būsto paskolos	Išperkamoji nuoma	Vartojimo paskolos	Kredito kortelės, kredito limitas	Kitos rūšys (arba vienas modelis visiems fiziniams asmenims)
1 modelis								
2 modelis								
3 modelis								
.....								
.....								
.....								

5. Kokie statistiniai metodai buvo taikyti? (pažymėti atsakymą tinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant į 4 klausimą)

	1 modelis	2 modelis	3 modelis
Diskriminantinė analizė						
Logistinė regresija						
Probito regresija						
Tobit regresija						
Sprendimų medžiai						
Artimiausio kaimyno metodas						
Išlikimo analizė						
Kitas metodas (jei galite, nurodykite)						

6. Jei Jūsų bankas turi patronuojantįjį banką, ar tokie patys statistiniai paraiškų vertinimo balais modeliai yra taikomi tiek grupės lygiu, tiek Jūsų banke? (pažymėti atsakymą tinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant į 4 klausimą)

	1 modelis	2 modelis	3 modelis
Yra taikomas tas pats modelis, sukurtas naudojant visos grupės duomenis						
Yra taikomas kitas modelis, sukurtas tik naudojant vietinius duomenis (jei galite, apibūdinkite skirtumus)						
Kita (jei galite, apibūdinkite situaciją)						

7. Ar kuriant modelius buvo naudotasi išorinių paskolų registrų duomenimis?

Taip (jei galite, nurodykite šaltinį (šaltinius) ir įvesties kintamąjį (kintamuosius)).....
 Ne.....

8. Ar Jūsų statistiniai paraiškų vertinimo balais modeliai yra taikomi skolininko lygiu ar paskolos lygiu? (pažymėti atsakymą tinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant į 4 klausimą)

	1 modelis	2 modelis	3 modelis
Skolininko lygiu						
Paskolos lygiu						

9. Kokie įvesties kintamieji yra naudojami Jūsų statistiniuose paraiškų vertinimo balais modeliuose? (pažymėti atsakymą tinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant į 4 klausimą)

Įvesties kintamasis	1 modelis	2 modelis	3 modelis
Įmonių modeliai				
makroekonominiai rodikliai				
ekonominės veiklos rūšies rodikliai				
įmonės padėtis rinkoje				
darbuotojų skaičius				
įmonės gyvavimo laikas				
sąskaitos balansas				
išorinė mokėjimų istorija				
vidinė mokėjimų istorija				
turto grąža, nuosavo kapitalo grąža				
apyvartinio kapitalo ir turto santykis				
trumpalaikio turto ir trumpalaikių įsipareigojimų santykis				
apyvartinio kapitalo ir įsipareigojimų santykis				
grynojo pelno (nuostolių) ir pardavimo pajamų santykis				
bendrojo pelno (nuostolių) ir pardavimo pajamų santykis				
veiklos pelno (nuostolių) ir veiklos sąnaudų santykis				
PPPM [†] / turtas				
nuosavo kapitalo ir turto santykis (arba įsipareigojimų ir turto santykis)				
trumpalaikių įsipareigojimų ir turto santykis				
grynojo pinigų srautų padidėjimo (sumažėjimo) ir įsipareigojimų santykis				
<i>kiti rodikliai (jeigu galite, įrašykite):</i>				
Fizinių asmenų modeliai				
makroekonominiai rodikliai				
duomenys apie naudojamąsi kitais skolinančiojo banko produktais				
turtas skolinančiajame banke				
kitų finansinių įsipareigojimų turėjimo faktas (arba jų skaičius)				
su panaudota / nepanaudota paskolos dalimi susiję rodikliai				
įsiskolinimo koeficientas				
einamųjų išlaidų ir pajamų santykis				
grynosios pajamos vienam šeimos nariui				
paskolos vertės likučio ir pajamų santykis				
išorinė mokėjimų istorija				
vidinė mokėjimų istorija				
šeiminė padėtis				
vaikų turėjimo faktas				
vaikų ir kitų išlaikytinių skaičius				
išsilavinimas				
amžius				
darbinės pareigos				
pastovumas (gyvenamosios ir darbo vietos kaita)				
gyvenamoji vieta (nuosavas būstas, nuoma ir kt.)				
<i>kiti rodikliai (jeigu galite, įrašykite):</i>				

[†] PPPM – pelnas (nuostoliai) prieš palūkanas ir mokesčius (angl. *Earnings Before Interest and Taxes (EBIT)*)

10. Ar tam tikroms mažmeninių paskolų rūšims Jūsų banke yra taikomi mišrūs paraiškų vertinimo balais modeliai? (pvz, gali būti taikomas statistinis finansinių rodiklių modelis, o kiti įvesties kintamieji, vertinant tos pačios rūšies paskolas, yra įtraukiami ekspertiniu būdu, taikant ekspertų šioms įvesties kintamiesiems nustatytus svorius)

Taip.....

Ne.....(Žr. 13 klausimą)

11. Kiek mišrių paraiškų vertinimo balais modelių yra taikoma Jūsų banke ir kokioms mažmeninių paskolų rūšims? (išvardykite modelius, pažymėkite paskolų rūšis, kurioms yra taikomas konkretus modelis, ir, jei galite, nurodykite, ar tai yra naujų skolininkų, ar esamų skolininkų naujų paraiškų modelis)

	Įmonių paskolos			Fizinių asmenų paskolos				
	Investicinės paskolos	Apyvartinių lėšų finansavimas, kredito linija	Kitos rūšys (arba vienas modelis visoms įmonėms)	Būsto paskolos	Išperkamoji nuoma	Vartojimo paskolos	Kredito kortelės, kredito limitas	Kitos rūšys (arba vienas modelis visiems fiziniams asmenims)
1 modelis								
2 modelis								
3 modelis								
.....								
.....								
.....								

12. Kurių įvesties kintamųjų svoriai Jūsų mišriuose paraiškų vertinimo balais modeliuose yra nustatomi ekspertiniu būdu? (pažymėti atsakymą tinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant į 11 klausimą)

Įvesties kintamasis	1 modelis	2 modelis	3 modelis
Įmonių modeliai				
makroekonominiai rodikliai				
ekonominės veiklos rūšies rodikliai				
įmonės padėtis rinkoje				
darbuotojų skaičius				
įmonės gyvavimo laikas				
sąskaitos balansas				
išorinė mokėjimų istorija				
vidinė mokėjimų istorija				
turto grąža, nuosavo kapitalo grąža				
apyvartinio kapitalo ir turto santykis				
trumpalaikio turto ir trumpalaikių įsipareigojimų santykis				
apyvartinio kapitalo ir įsipareigojimų santykis				
grynojo pelno (nuostolių) ir pardavimo pajamų santykis				
bendrojo pelno (nuostolių) ir pardavimo pajamų santykis				
veiklos pelno (nuostolių) ir veiklos sąnaudų santykis				
PPPM / turtas				
nuosavo kapitalo ir turto santykis (arba įsipareigojimų ir turto santykis)				
trumpalaikių įsipareigojimų ir turto santykis				
grynojo pinigų srautų padidėjimo (sumažėjimo) ir įsipareigojimų santykis				
<i>kiti rodikliai (jeigu galite, įrašykite):</i>				
Fizinių asmenų modeliai				
makroekonominiai rodikliai				
duomenys apie naudojimąsi kitais skolinančiojo banko produktais				
skolininko turtas skolinančiajame banke				
kitų finansinių įsipareigojimų turėjimo faktas (arba jų skaičius)				
su panaudota / nepanaudota paskolos dalimi susiję rodikliai				
įsiskolinimo koeficientas				
einamųjų išlaidų ir pajamų santykis				
grynosios pajamos vienam šeimos nariui				
paskolos vertės likučio ir pajamų santykis				
išorinė mokėjimų istorija				

vidinė mokėjimų istorija				
šeiminė padėtis				
vaikų turėjimo faktas				
vaikų ir kitų išlaikytinių skaičius				
išsilavinimas				
amžius				
darbinės pareigos				
pastovumas (gyvenamosios ir darbo vietos kaita)				
gyvenamoji vieta (nuosavas būstas, nuoma ir kt.)				
<i>kiti rodikliai (jeigu galite, parašykite):</i>				

13. Jeigu Jūsų banke nėra taikomi statistiniai mažmeninių paraiškų vertinimo balais modeliai, tai nurodykite priežastis, kodėl netaikomi?

Pernelyg trumpas duomenų kaupimo laikotarpis.....
 Nepakankama skolininkų (paskolų) imtis.....
 Buvo pradėta teikti daug naujų paskolų rūšių, apie kurias banke nebuvo sukaupta duomenų.....
 Informacijos apie pagrindinius įmonių ir (arba) fizinių asmenų rodiklius nepakankamumas.....
 Vidinės informacijos apie skolininkų mokėjimų istoriją nepakankamumas.....
 Nepatikimi įmonių ir (arba) fizinių asmenų praeities duomenys.....
 Nepakankamas individualaus vertinimo vaidmuo teikiant paskolas.....
 Kitos priežastys (jeigu galite, nurodykite).....

14. Ar tam tikroms mažmeninių paskolų rūšims Jūsų banke yra taikomi ekspertiniai paraiškų vertinimo balais modeliai?

Taip.....
 Ne..... (žr. 18 klausimą)

15. Kiek ekspertinių paraiškų vertinimo balais modelių yra taikoma Jūsų banke ir kokioms mažmeninių paskolų rūšims? (išvardykite modelius, pažymėkite paskolų rūšis, kurioms yra taikomas konkretus modelis, ir, jei galite, nurodykite, ar tai yra naujų skolininkų, ar esamų skolininkų naujų paraiškų modelis)

	Įmonių paskolos			Fizinių asmenų paskolos				
	Investicinės paskolos	Apyvartinių lėšų finansavimas, kredito linija	Kitos rūšys (arba vienas modelis visoms įmonėms)	Būsto paskolos	Išperkamoji nuoma	Vartojimo paskolos	Kredito kortelės, kredito limitas	Kitos rūšys (arba vienas modelis visiems fiziniams asmenims)
1 modelis								
2 modelis								
3 modelis								
.....								
.....								
.....								

16. Ar Jūsų ekspertiniai paraiškų vertinimo balais modeliai yra taikomi skolininko ar paskolos lygiu? (pažymėti atsakymą tinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant 15 klausimą)

	1 modelis	2 modelis	3 modelis
Skolininko lygiu						
Paskolos lygiu						

17. Kokie įvesties kintamieji yra naudojami Jūsų ekspertiniuose paraiškų vertinimo balais modeliuose? (pažymėti atsakymą tinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant 15 klausimą)

Įvesties kintamasis	1 modelis	2 modelis	3 modelis
Įmonių modeliai				
makroekonominiai rodikliai				
ekonominės veiklos rūšies rodikliai				
įmonės padėtis rinkoje				
darbuotojų skaičius				
gyvavimo laikas				
sąskaitos balansas				

išorinė mokėjimų istorija				
vidinė mokėjimų istorija				
turto grąža, nuosavo kapitalo grąža				
apyvartinio kapitalo ir turto santykis				
trumpalaikio turto ir trumpalaikių įsipareigojimų santykis				
apyvartinio kapitalo ir įsipareigojimų santykis				
grynojo pelno (nuostolių) ir pardavimo pajamų santykis				
bendrojo pelno (nuostolių) ir pardavimo pajamų santykis				
veiklos pelno (nuostolių) ir veiklos sąnaudų santykis				
PPPM / turtas				
nuosavo kapitalo ir turto santykis (arba įsipareigojimų ir turto santykis)				
trumpalaikių įsipareigojimų ir turto santykis				
grynojo pinigų srautų padidėjimo (sumažėjimo) ir įsipareigojimų santykis				
<i>kiti rodikliai (jeigu galite, įrašykite):</i>				
Fizinių asmenų modeliai				
makroekonominiai rodikliai				
duomenys apie naudojimąsi kitais skolinančiojo banko produktais				
turtas skolinančiajame banke				
kitų finansinių įsipareigojimų turėjimo faktas (arba jų skaičius)				
su panaudota / nepanaudota paskolos dalimi susiję rodikliai				
įsiskolinimo koeficientas				
einamųjų išlaidų ir pajamų santykis				
grynosios pajamos vienam šeimos nariui				
paskolos vertės likučio ir pajamų santykis				
išorinė mokėjimų istorija				
vidinė mokėjimų istorija				
šeiminė padėtis				
vaikų turėjimo faktas				
vaikų ir kitų išlaikytinių skaičius				
išsilavinimas				
amžius				
darbinės pareigos				
pastovumas (gyvenamosios ir darbo vietos kaita)				
gyvenamoji vieta (nuosavas būstas, nuoma ir kt.)				
<i>kiti rodikliai (jeigu galite, įrašykite):</i>				

18. Kokie Jūsų banke yra taikomi kiekybiniai statistinių, mišrių ir ekspertinių mažmeninių paraiškų vertinimo balais modelių patikimumo vertinimo metodai? (pažymėti atsakymą atitinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant į 4, 11 ir 15 klausimus)

	1 statistinis modelis	1 mišrus modelis	1 ekspertinis modelis
Diskriminacinės galios vertinimo metodai						
Kaupiamojo tikslumo (CAP) kreivė						
Gavėjų veiklos charakteristikų (ROC) kreivė						
Briero balų metodas						
I ir II rūšies klaidų tikimybių vidurkis						
Entropija pagrįsti metodai (pvz, informacijos vertė)						
Kiti metodai (jei galite, įrašykite)						
PD kalibravimo tikslumo nustatymo metodai						
Hosmerio ir Lemešou kriterijus						
Binominiai kriterijai						
Normalieji kriterijai						
Eismo šviesos metodas						
Koreliacijų modeliavimas						
Patikimumo diagramos						
Kiti metodai (jei galite, įrašykite)						
Skolininkų (paskolų) struktūros ir stabilumo vertinimas						
Reitingų pasikeitimo matricos						

Stabilumo indeksas						
Rizikos ir rinkos ciklų atitikimo analizė						
Diskriminacinės galios stabilumo vertinimas						
PD kalibravimo tikslumo pokyčių vertinimas						
Skolininkų (paskolų) koncentracijos pagal reitingus analizė, koncentracijos laiko atžvilgiu analizė						
Skolininkų (paskolų) skirstinio pagal reitingus monotoniškumo analizė						
Kiti metodai (jei galite, įrašykite)						
Įvesties kintamųjų analizė (jei galite, apibūdinkite)						
Kiti kiekybiniai metodai (jei galite, nurodykite)						
.....						

19. Kokie Jūsų banke yra numatomi pokyčiai mažmeninių paraiškų vertinimo balais modelių srityje? (jeigu galite, apibūdinkite detaliau)

Yra planuojama taikyti naujus statistinius mažmeninių paraiškų vertinimo balais modelius (jeigu galite, nurodykite statistinį metodą ir paskolų rūšį, kuriai modelis bus taikomas)

Yra planuojama taikyti naujus mišrius mažmeninių paraiškų vertinimo balais modelius (jeigu galite, nurodykite statistinį metodą ir paskolų rūšį, kuriai modelis bus taikomas)

Yra planuojama taikyti naujus ekspertinius mažmeninių paraiškų vertinimo balais modelius (jeigu galite, nurodykite statistinį metodą ir paskolų rūšį, kuriai modelis bus taikomas)

Yra planuojama tikslinti dabar taikomus mažmeninių paraiškų vertinimo balais modelius

- įtraukiant vietinius duomenis (jeigu galite, nurodykite kokius)
- įtraukiant išorinių paskolų registrų duomenis (jeigu galite, nurodykite duomenis ir šaltinį)
- įtraukiant visos grupės duomenis (jeigu galite, nurodykite kokius)

Yra planuojami kiti pokyčiai (jeigu galite, apibūdinkite detaliau)

Nėra planuojama jokių pokyčių (jeigu galite, nurodykite kodėl)

20. Kokiuose Jūsų banko procesuose yra taikomi atitinkami statistiniai, mišrūs ir (ar) ekspertiniai mažmeninių paraiškų vertinimo balais modeliai? (pažymėkite atsakymą atitinkamame langelyje pagal kiekvieną modelį, apibūdintą atsakant į 4, 11 ir 15 klausimus)

	1 statistinis modelis	1 mišrus modelis	1 ekspertinis modelis
Kainodaros procesai						
Vertės sumažėjimo skaičiavimas						
Paskolų teikimas						
Kapitalo poreikio skaičiavimas						
Strategijos numatymas						
Kapitalo paskirstymas						
Pelningumo ir efektyvumo vertinimas						
Ataskaitų pateikimas						
Kiti procesai (jeigu galite, įrašykite)						

Dėkoju Jums už Jūsų sugaištą laiką.

LIETUVOS BANKŲ VERTINIMO BALAIS MODELIŲ ĮVESTIES KINTAMIEJI

1 lentelė. Statistinių modelių įvesties kintamieji

Įvesties kintamasis	1 bankas	2 bankas	3 bankas	4 bankas
Įmonių modeliai				
makroekonominiai rodikliai	–	–	–	–
ekonominės veiklos rūšies rodikliai	–	–	–	–
įmonės padėtis rinkoje	–	–	–	–
darbuotojų skaičius	2 modeliai	–	–	–
gyvavimo laikas	2 modeliai	–	–	–
sąskaitos balansas	2 modeliai	–	–	–
išorinė mokėjimų istorija	2 modeliai	–	–	–
vidinė mokėjimų istorija	1 modelis	–	–	–
turto grąža, nuosavo kapitalo grąža	1 modelis	–	–	–
apyvartinio kapitalo ir turto santykis	–	1 modelis	–	–
trumpalaikio turto ir trumpalaikių įsipareigojimų santykis	–	1 modelis	–	–
apyvartinio kapitalo ir įsipareigojimų santykis	–	–	–	–
grynojo pelno (nuostolių) ir pardavimo pajamų santykis	–	1 modelis	–	–
bendrojo pelno (nuostolių) ir pardavimo pajamų santykis	–	–	–	–
veiklos pelno (nuostolių) ir veiklos sąnaudų santykis	–	1 modelis	–	–
PPPM ⁺ / turtas	–	–	–	–
nuosavo kapitalo ir turto santykis (arba įsipareigojimų ir turto santykis)	1 modelis	1 modelis	–	–
trumpalaikių įsipareigojimų ir turto santykis	–	1 modelis	–	–
grynojo pinigų srautų padidėjimo (sumažėjimo) ir įsipareigojimų santykis	–	–	–	–
<i>kiti rodikliai:</i>				
12 mėn. pervedimų ir įmokų skaičiaus vidurkis / 12 mėn. išmokų ir išėmimų iš sąskaitos skaičiaus vidurkis	2 modeliai	–	–	–
Fizinių asmenų modeliai				
makroekonominiai rodikliai	–	–	–	–
duomenys apie naudojimąsi kitais skolinančiojo banko produktais	4 modeliai	–	–	1 modelis
turtas skolinančiajame banke	4 modeliai	–	–	1 modelis
kitų finansinių įsipareigojimų turėjimo faktas (arba jų skaičius)	1 modelis	1 modelis	–	1 modelis
su panaudota / nepanaudota paskolos dalimi susiję rodikliai	1 modelis	–	–	–
įsiskolinimo koeficientas	–	1 modelis	–	–
einamųjų išlaidų ir pajamų santykis	–	1 modelis	–	1 modelis
grynosios pajamos vienam šeimos nariui	–	1 modelis	1 modelis	1 modelis
paskolos likučio ir pajamų santykis	1 modelis	1 modelis	–	1 modelis
išorinė mokėjimų istorija	4 modeliai	–	–	1 modelis
vidinė mokėjimų istorija	4 modeliai	–	–	1 modelis
šeiminė padėtis	–	1 modelis	–	1 modelis
vaikų turėjimo faktas	–	1 modelis	–	1 modelis
vaikų ir kitų išlaikytinių skaičius	–	1 modelis	–	1 modelis
išsilavinimas	–	1 modelis	1 modelis	1 modelis
amžius	4 modeliai	1 modelis	–	1 modelis
darbinės pareigos	–	1 modelis	–	1 modelis
pastovumas (gyvenamosios ir darbo vietos kaita)	–	1 modelis	1 modelis	–
gyvenamoji vieta (nuosavas būstas, nuoma ir kt.)	–	1 modelis	–	1 modelis
<i>kiti rodikliai:</i>				
darbo trukmė priešpaskutinėje darbovietėje	–	–	1 modelis	–
pradinis įnašas	2 modeliai	–	–	–
mėnesio paskolos įmokos ir pajamų, pervedamų į sąskaitą skolinančiajame banke, santykis	1 modelis	–	–	–
paskolos / užstato vertės santykis	1 modelis	–	–	–
laiduotojas	–	–	1 modelis	–

Šaltinis: sudaryta autorės; ⁺ PPPM – pelnas (nuostoliai) prieš palūkanas ir mokesčius (angl. *Earnings Before Interest and Taxes (EBIT)*).

2 lentelė. Mišrių modelių įvesties kintamieji, kurių svariai nustatomi ekspertiniu būdu⁺

Įvesties kintamasis	1 bankas	2 bankas
Įmonių modeliai		
makroekonominiai rodikliai	–	–
ekonominės veiklos rūšies rodikliai	1 modelis	–
įmonės padėtis rinkoje	1 modelis	–
darbuotojų skaičius	–	–
gyvavimo laikas	–	–
sąskaitos balansas	–	–
išorinė mokėjimų istorija	–	–
vidinė mokėjimų istorija	–	–
turto graža, nuosavo kapitalo graža	–	–
apyvartinio kapitalo ir turto santykis	–	–
trumpalaikio turto ir trumpalaikių įsipareigojimų santykis	–	–
apyvartinio kapitalo ir įsipareigojimų santykis	–	–
grynojo pelno (nuostolių) ir pardavimo pajamų santykis	–	–
bendrojo pelno (nuostolių) ir pardavimo pajamų santykis	–	–
veiklos pelno (nuostolių) ir veiklos sąnaudų santykis	–	–
PPPM / turtas	–	–
nuosavo kapitalo ir turto santykis (arba įsipareigojimų ir turto santykis)	–	–
trumpalaikių įsipareigojimų ir turto santykis	–	–
grynojo pinigų srautų padidėjimo (sumažėjimo) ir įsipareigojimų santykis	–	–
<i>kiti rodikliai:</i>		
verslo plano vertinimas	1 modelis	–
vadovų vertinimas	1 modelis	–
Fizinių asmenų modeliai		
makroekonominiai rodikliai	–	–
duomenys apie naudojamąsi kitais skolinančiojo banko produktais	1 modelis	–
turtas skolinančiajame banke	–	–
kitų finansinių įsipareigojimų turėjimo faktas (arba jų skaičius)	1 modelis	–
su panaudota / nepanaudota paskolos dalimi susiję rodikliai	–	–
įsiskolinimo koeficientas	–	–
einamųjų išlaidų ir pajamų santykis	–	–
grynosios pajamos vienam šeimos nariui	–	–
paskolos likučio ir pajamų santykis	–	–
išorinė mokėjimų istorija	1 modelis	1 modelis
vidinė mokėjimų istorija	1 modelis	–
šeiminė padėtis	–	–
vaikų turėjimo faktas	–	–
vaikų ir kitų išlaikytinių skaičius	–	–
išsilavinimas	–	–
amžius	–	–
darbinės pareigos	–	–
pastovumas (gyvenamosios ir darbo vietos kaita)	–	–
gyvenamoji vieta (nuosavas būstas, nuoma ir kt.)	–	–
<i>kiti rodikliai</i>	–	–

Šaltinis: sudaryta autorės.

3 lentelė. Ekspertinių modelių įvesties kintamieji

Įvesties kintamasis	1 bankas	2 bankas	3 bankas	4 bankas	5 bankas	6 bankas
Įmonių modeliai						
makroekonominiai rodikliai	1 modelis	1 modelis	–	–	1 modelis	N. D.
ekonominės veiklos rūšies rodikliai	1 modelis	–	–	1 modelis	1 modelis	N. D.
įmonės padėtis rinkoje	1 modelis	1 modelis	1 modelis	1 modelis	1 modelis	N. D.
darbuotojų skaičius	1 modelis	–	–	–	–	N. D.
gyvavimo laikas	1 modelis	1 modelis	1 modelis	1 modelis	1 modelis	N. D.
sąskaitos balansas	1 modelis	–	1 modelis	–	1 modelis	N. D.
išorinė mokėjimų istorija	1 modelis	1 modelis	1 modelis	1 modelis	1 modelis	N. D.
vidinė mokėjimų istorija	1 modelis	1 modelis	1 modelis	1 modelis	1 modelis	N. D.
turto graža, nuosavo kapitalo graža	1 modelis	1 modelis	1 modelis	–	1 modelis	N. D.
apyvartinio kapitalo ir turto santykis	–	1 modelis	1 modelis	–	1 modelis	N. D.
trumpalaikio turto ir trumpalaikių įsipareigojimų santykis	1 modelis	1 modelis	1 modelis	1 modelis	1 modelis	N. D.
apyvartinio kapitalo ir įsipareigojimų santykis	–	–	1 modelis	–	1 modelis	N. D.
grynojo pelno (nuostolių) ir pardavimo pajamų santykis	1 modelis	1 modelis	1 modelis	–	–	N. D.
bendrojo pelno (nuostolių) ir pardavimo pajamų santykis	–	1 modelis	1 modelis	–	–	N. D.
veiklos pelno (nuostolių) ir veiklos sąnaudų santykis	–	–	–	–	–	N. D.
PPPM / turtas	1 modelis	–	1 modelis	–	–	N. D.
nuosavo kapitalo ir turto santykis (arba įsipareigojimų ir turto santykis)	1 modelis	–	–	1 modelis	1 modelis	N. D.
trumpalaikių įsipareigojimų ir turto santykis	1 modelis	–	–	–	1 modelis	N. D.
grynojo pinigų srautų padidėjimo (sumažėjimo) ir įsipareigojimų santykis	–	–	1 modelis	–	–	N. D.
kiti rodikliai:						
PPPMNA ⁺ marža	–	–	–	1 modelis	–	N. D.
grynoji finansinė skola / PPPMNA	–	–	–	1 modelis	–	N. D.
gautinų sumų apyvartumas	–	1 modelis	–	–	–	N. D.
atsargų apyvartumas	–	1 modelis	–	–	–	N. D.
einamosios paskolos dalies ir palūkanų padengimo koeficientas	–	1 modelis	–	1 modelis	–	N. D.
pardavimo pajamų pokytis (nuo metų pradžios)	–	1 modelis	–	–	–	N. D.
pardavimo pajamų pokytis (palyginti su praėjusiais metais)	–	1 modelis	–	1 modelis	–	N. D.
Fizinių asmenų modeliai						
makroekonominiai rodikliai	–	–	–	–	–	–
duomenys apie naudojimąsi kitais skolinančiojo banko produktais	2 modeliai	–	1 modelis	2 modeliai	1 modelis	–
turtas skolinančiajame banke	–	–	1 modelis	–	1 modelis	–
kitų finansinių įsipareigojimų turėjimo faktas (arba jų skaičius)	2 modeliai	–	–	–	1 modelis	–
su panaudota / nepanaudota paskolos dalimi susiję rodikliai					1 modelis	–

įsiskolinimo koeficientas	2 modeliai	1 modelis	1 modelis	–	1 modelis	–
einamųjų išlaidų ir pajamų santykis	–	–	1 modelis	–	1 modelis	–
grynosios pajamos vienam šeimos nariui	2 modeliai	1 modelis	1 modelis	2 modeliai	1 modelis	1 modelis
paskolos likučio ir pajamų santykis	–	–	–	–	1 modelis	1 modelis
išorinė mokėjimų istorija	–	1 modelis	1 modelis	2 modeliai	1 modelis	1 modelis
vidinė mokėjimų istorija	2 modeliai	1 modelis	1 modelis	2 modeliai	1 modelis	1 modelis
šeiminė padėtis	2 modeliai	1 modelis	1 modelis	2 modeliai	1 modelis	1 modelis
vaikų turėjimo faktas	2 modeliai	1 modelis	1 modelis	–	1 modelis	–
vaikų ir kitų išlaikytinių skaičius	2 modeliai	–	1 modelis	2 modeliai	1 modelis	1 modelis
išsilavinimas	2 modeliai	1 modelis	1 modelis	2 modeliai	1 modelis	1 modelis
amžius	2 modeliai	1 modelis	1 modelis	2 modeliai	1 modelis	1 modelis
darbinės pareigos	2 modeliai	1 modelis	1 modelis	2 modeliai	1 modelis	1 modelis
pastovumas (gyvenamosios ir darbo vietos kaita)	–	–	–	2 modeliai	–	–
gyvenamoji vieta (nuosavas būstas, nuoma ir kt.)	2 modeliai	–	1 modelis	2 modeliai	1 modelis	1 modelis
kiti rodikliai:						
darbo trukmė (dabartinėje darbovietėje)	–	1 modelis	–	2 modeliai	–	1 modelis
gaunamų pajamų tipas	–	–	–	–	–	1 modelis
mėnesio įmokos ir grynujų mėnesio pajamų santykis	–	–	–	2 modeliai	–	–
vindikacijos išvada	–	–	–	–	–	1 modelis

Šaltinis: sudaryta autorės; ⁺ PPPMNA – pelnas (nuostoliai) prieš palūkanas, mokesčius, nusidėvėjimą ir amortizaciją (angl. *Earnings Before Interest, Taxes, Depreciation and Amortization (EBITDA)*); N. D. – bankas nepateikė informacijos apie įmonių modelio įvesties kintamuosius.

INDIVIDUALI ĮVESTIES KINTAMŲJŲ DISKRIMINACINĖ GALIA

Nr.	Įvesties kintamasis	IV	Diskriminacinė galia *	Pasirinktas 2-ame cikle (Taip/Ne)	Yra galutiniame modelyje (Taip/Ne)
X26	Turtas iš viso / Nuosavas kapitalas	0,528	Didelė	Taip	Taip
X16	Nuosavas kapitalas / Mokėtinis sumos ir įsipareigojimai	0,514	Didelė	Taip	Ne
X17	Pelnas (nuostoliai) prieš apmokestinimą / Mokėtinis sumos ir įsipareigojimai	0,505	Didelė	Taip	Ne
X35	Grynasis pelnas (nuostoliai) / Mokėtinis sumos ir įsipareigojimai	0,492	Didelė	Taip	Ne
X12	Pelnas (nuostoliai) prieš apmokestinimą / Turtas iš viso	0,443	Didelė	Taip	Ne
X11	Grynasis pelnas (nuostoliai) / Turtas iš viso	0,429	Didelė	Taip	Taip
X18	Trumpalaikis turtas / Mokėtinis sumos ir įsipareigojimai	0,428	Didelė	Taip	Taip
X32	Pelnas (nuostoliai) prieš apmokestinimą / Per vienerius metus mokėtinis sumos ir trumpalaikiai įsipareigojimai	0,426	Didelė	Taip	Ne
X36	Įprastinės veiklos pelnas (nuostoliai) / Mokėtinis sumos ir įsipareigojimai	0,426	Didelė	Taip	Ne
X31	Grynasis pelnas (nuostoliai) / Per vienerius metus mokėtinis sumos ir trumpalaikiai įsipareigojimai	0,417	Didelė	Taip	Ne
X19	Mokėtinis sumos ir įsipareigojimai / Turtas iš viso	0,416	Didelė	Taip	Ne
X47	Vidutinė pradelimų per paskutinius metus trukmė (dienomis)	0,409	Didelė	Taip	Taip
X44	Pagal pradelimo pradžios datą įvertintų svertinių pradelimų per paskutinius metus trukmių suma	0,384	Didelė	Taip	Ne
X37	Bendrasis pelnas (nuostoliai) / Mokėtinis sumos ir įsipareigojimai	0,370	Didelė	Taip	Ne
X46	Visų per paskutinius metus pradelstų įmokų skaičius	0,355	Didelė	Taip	Taip
X25	Pinigai ir pinigų ekvivalentai / Per vienerius metus mokėtinis sumos ir trumpalaikiai įsipareigojimai	0,344	Didelė	Taip	Taip
X10	Pelnas (nuostoliai) prieš apmokestinimą / Pardavimo pajamos	0,339	Didelė	Taip	Taip
X28	Įprastinės veiklos pelnas (nuostoliai) / Turtas iš viso	0,338	Didelė	Taip	Ne
X20	Ln (grynasis pelnas)	0,335	Didelė	Taip	Taip
X23	Grynasis apyvartinis kapitalas / Mokėtinis sumos ir įsipareigojimai	0,330	Didelė	Taip	Ne
X41	Ln (pelnas prieš apmokestinimą)	0,327	Didelė	Taip	Ne
X45	Pagal pradelimo pradžios datą įvertintų pradelimų per paskutinius metus suma	0,322	Didelė	Taip	Ne
X9	Grynasis pelnas (nuostoliai) / Pardavimo pajamos	0,316	Didelė	Taip	Ne
X48	Pagal pradelimo pradžios datą įvertintia vidutinė svertinė pradelimų per paskutinius metus trukmė	0,316	Didelė	Taip	Ne
X14	Nepaskirstytasis pelnas (nuostoliai) / Turtas iš viso	0,315	Didelė	Taip	Ne
X33	Įprastinės veiklos pelnas (nuostoliai) / Per vienerius metus mokėtinis sumos ir trumpalaikiai įsipareigojimai	0,300	Didelė	Taip	Ne
X34	Bendrasis pelnas (nuostoliai) / Per vienerius metus mokėtinis sumos ir trumpalaikiai įsipareigojimai	0,296	Vidutinė	Taip	Ne
X49	Pinigai ir pinigų ekvivalentai / Turtas iš viso	0,259	Vidutinė	Ne	-
X22	Ln (nepaskirstytasis pelnas)	0,227	Vidutinė	Taip	Ne
X15	Nepaskirstytasis pelnas (nuostoliai) / Pardavimo pajamos	0,209	Vidutinė	Taip	Ne
X50	Ln (pinigai ir pinigų ekvivalentai)	0,209	Vidutinė	Ne	-
X39	(Trumpalaikis turtas – Atsargos, išankstiniai apmokėjimai ir nebaigtos vykdyti sutartys) / Per vienerius metus mokėtinis sumos ir trumpalaikiai įsipareigojimai	0,206	Vidutinė	Taip	Ne
X27	Įprastinės veiklos pelnas (nuostoliai) / Pardavimo pajamos	0,203	Vidutinė	Taip	Ne
X29	Bendrasis pelnas (nuostoliai) / Turtas iš viso	0,202	Vidutinė	Taip	Taip
X40	Ln (įprastinės veiklos pelnas)	0,195	Vidutinė	Taip	Ne
X21	Ln (nuosavas kapitalas)	0,185	Vidutinė	Taip	Ne
X13	Grynasis apyvartinis kapitalas / Turtas iš viso	0,180	Vidutinė	Taip	Ne

X3	Ekonominės veiklos rūšis								
X24	Trumpalaikis turtas / Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai					0,178	Vidutinė	Taip	Taip
						0,170	Vidutinė	Taip	Ne
X4	Gyvavimo laikas					0,154	Vidutinė	Taip	Taip
X6	Yra / nėra įrašų iš skolų išieškojimo įmonių apie pretenzijas vertinamai įmonei per paskutinius metus					0,146	Vidutinė	Taip	Taip
X39	Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai / Turtas iš viso					0,130	Vidutinė	Taip	Taip
X30	Pardavimo pajamos / Turtas iš viso					0,115	Vidutinė	Taip	Ne
X42	Ln (po vienerių metų mokėtinos sumos ir įgalataikiai įsipareigojimai)					0,102	Vidutinė	Taip	Taip
X5	Yra / nėra neigiamos informacijos apie vertinamą įmonę įrašų išoriniame paskolų registre per paskutinius metus					0,101	Vidutinė	Taip	Taip
X2	Apskritis					0,100	Vidutinė	Taip	Taip
X1	Metinė apyvarta (tūkst. litų)					0,096	Maža	Taip	Taip
X7	Darbuotojų skaičius					0,091	Maža	Taip	Taip
X43	Pardavimo pajamos / Trumpalaikis turtas					0,089	Maža	Taip	Taip
X51	Bendrasis pelnas (nuostoliai) / Pardavimo pajamos					0,085	Maža	Ne	-
X8	Yra / nėra įrašų išoriniame paskolų registre apie vertinamos įmonės vadovų nepatikimumą					0,074	Maža	Taip	Ne
X52	Ln (mokėtinos sumos ir įsipareigojimai)					0,071	Maža	Ne	-
X53	Ln (per vienerius metus gautinos sumos)					0,058	Maža	Ne	-
X54	Tėsinė forma					0,011	Neprediktyvus	Ne	-
X55	Įmonė per savo gyvavimo laiką bent kartą keitė pavadinimą					0,010	Neprediktyvus	Ne	-
X56	Įmonė nuo 2000 metų bent kartą keitė pavadinimą					0,009	Neprediktyvus	Ne	-
X57	Įmonė per savo gyvavimo laiką bent kartą keitė adresą					0,002	Neprediktyvus	Ne	-

Šaltinis: autorės skaičiavimai. *Įvesties kintamieji buvo išrikiuoti jų individualios diskriminacinės galios mažėjimo tvarka.

ĮVESTIES KINTAMIEJŲ LOGISTINĖS REGRESIJOS MODELyje

Žymėjimas regresijos lygtyje ^a	Įvesties kintamojo reikšmės	WOE ^b	Koeficientas	Įtraukimas į regresijos lygtį	Komentariai
X ₁	(0–10]	0,7423	-0,677	12 žingsnis	
	(10–100]	0,6225			
	(100–200]	-0,3791			
	(200–1000]	-0,2636			
	(1000–2 000]	-0,1054			
	(2000–7 000]	-0,0756			
	(7000–10 000]	-0,0633			
(10 000–20 000]	0,4853				
(20 000–100 000]	0,6751				
> 100 000 + trūkstamos reikšmės	2,1215				
Apskritis					
X ₂	Alytaus	-0,0576	-0,958	5 žingsnis	
	Kauno	-0,0320			
	Klaipėdos	0,1220			
	Marijampolės	-0,7097			
	Panevėžio + trūkstamos reikšmės	-0,7456			
	Siaulių	-0,1143			
	Tauragės	0,1617			
Telsių	-0,0036				
Utenos	-0,4101				
Vilniaus	0,2633				
Ekonominės veiklos rūšis					
X ₃	Žemės ūkis, miškininkystė ir žuvininkystė (sekcija A)	0,0755	-0,821	3 žingsnis	
	Apdirbamoji pramonė, kalnakasyba, angliakasyba ir kita pramonė (sekcijos B, C, D, E)	-0,3917			
	Statyba (sekcija F)	-0,4294			
	Didmeninė ir mažmeninė prekyba, transportas ir sandėliavimas, apgyvendinimo ir maitinimo paslaugos (sekcijos G, H, I)	0,2072			
Informacija ir ryšiai (sekcija J)	0,4560				

Metinė apyvarta rodo įmonės dydį. Stambesnės įmonės yra strategiškai svarbesnės, gali pasiekti masto ekonomiją ir pan., todėl jų išpareigojimų nevykdymo rizika yra ne tokia didelė kaip smulkių įmonių. Tačiau labai smulkios įmonės yra lankstesnės, iškilus sunkumams gali lengviau pakeisti veiklos sritį ir pan. Skaičiavimų rezultatai parodė, jog didžiausia išpareigojimų nevykdymo rizika pasižymėjo tos įmonės, kurių metinė apyvarta buvo nuo 100 iki 200 tūkst. litų

Skiriasi įvairių regionų ekonominio ir socialinio išsivystymo lygis, juose yra plėtojamos skirtingos ekonominės veiklos rūšys. Be to, Lietuvoje darbo paklausos struktūra teritoriniu atžvilgiu dažnai neatitinka darbo pasiūlos struktūros, kai kuriuose regionuose tai pasireiškia stipriau, todėl įmonėms gali būti sunku susirasti pageidaujamos kvalifikacijos ir kompetencijos darbuotojų. Skaičiavimų rezultatai parodė, jog didžiausia išpareigojimų nevykdymo rizika pasižymėjo Panevėžio ir Marijampolės apskrityse veikusios įmonės, o mažiausia – Vilniaus apskrityje veikusios įmonės

Skirtingų ekonominių veiklos rūšių įmonės pasižymi skirtinga išpareigojimų nevykdymo rizika, nes skiriasi veiklos pobūdis (gamyba, prekyba ir pan.), rinka, konkurencija, veiklos cikliškumas ir (ar) sezoniškumas, darbo sąlygos, Vyriausybės dėmesys, teisinė aplinka ir įstatymų reikalavimai, plėtros tolydumas ir stabilumas ir t. t. Įmonės ekonominės veiklos rūšis buvo nustatyta pagal Lietuvos statistikos departamento patvirtintą Ekonominės veiklos rūšių klasifikatorių (EVRK 2 red.)

	Nekilnojamojo turto operacijos (sekcija L)	0,0533			
	Profesinė, mokslinė ir techninė veikla, administravimas ir paslaugos (sekcijos M, N)	1,1056			
	Viešasis administravimas ir gynyba, švietimas, sveikatos apsaugos paslaugos ir socialinis darbas (sekcijos O, P, Q)	1,2143			
	Finansų ir draudimo veikla ir kitos paslaugos (sekcijos R, S, T, U ir K)	0,7455			
Gyvyvimo laikas (metais)					
X₄	< = 1	0,3561			Ilgiau gyvuojančios imonės turi daugiau paitiries (pvz., yra išboulunusios savo taikomas technologijas, jau turi savo nuolatinių klientų, išmokusios kovoti su konkurentais ir pan.), todėl jų išpareigojimų nevykdymo rizika yra ne tokia didelė kaip trumpiau gyvuojančių imonių. Tačiau labai trumpai gyvuojančios imonės gali būti dar tik pradėjusios vykdyti atitinkamus projektus, naudojasi pradinėmis lėšomis veiklai finansuoti ir pan. Skaičiavimų rezultatai parodė, jog didžiausia išpareigojimų nevykdymo rizika pasizymėjo 3–4 metus gyvavusios imonės
	(1–2]	-0,3124			
	(2–3]	-0,4151			
	(3–4]	-0,6345			
	(4–5]	-0,4952		9 žingsnis	
	(5–6]	-0,2218		-0,831	
	(6–7]	-0,0585			
	(7–9]	0,2315			
	(9–10]	0,2647			
	> 10	0,4076			
Yra / nėra neigiamos informacijos apie vertinamą imonę įrašų išoriniame paskolų registre per paskutinius metus					
X₅	Taip	-2,4501		14 žingsnis	Buvo įtraukti visi UAB „Creditinfo Lietuva“ duomenų bazėje užregistruoti neigiami faktai apie vertinamą imonę (neigama informacija spaudoje, teismo procesai su kreditoriais, vekselių protestai prieš imonę, areštai, vadovų nepatikimumas ir kt.)
	Ne	0,0414		-0,423	
Yra / nėra įrašų iš skolų išieškojimo imonių apie pretenzijas vertinama imonei per paskutinius metus					
X₆	Taip	-2,4520		6 žingsnis	Buvo naudoti tik UAB „Creditinfo Lietuva“ duomenų bazėje užregistruoti įrašai
	Ne	0,0602		-0,755	
Darbuotojų skaičius					
X₇	< = 2	0,5735			Darbuotojų skaičius rodo imonės dydį ir veiklos pobūdį. Stambesnės imonės yra strategiškai svarbesnės, gali pasiekti masto ekonomiją ir pan., todėl jų išpareigojimų nevykdymo rizika ne tokia didelė kaip smulkių imonių. Tačiau labai mažos imonės yra lankstesnės, iškilus sunkumų gali lengviau pakeisti veiklos sritį ir pan. Skaičiavimų rezultatai parodė, jog didžiausia išpareigojimų nevykdymo rizika pasizymėjo nuo 30 iki 39 darbuotojų turėjusios imonės
	[3–29]	-0,0567			
	[30–39]	-0,5763		7 žingsnis	
	[40–69]	-0,0435		-0,911	
	[70–99]	0,2521			
	[100–149]	0,3587			
> = 150 + trūkstamos reikšmės	0,8388				
Pelnas (nuostoliai) prieš apmokestinimą / Pardavimo pajamos					
X₈	< -15,70 %	-0,8263			Kuo didesnė rodiklio reikšmė, tuo mažesnė išpareigojimų nevykdymo rizika
	-15,69 %–1,24 %	-0,5411			
	1,25 %–2,82 %	0,5197		20 žingsnis	
	> 2,82 %	0,5493		-0,135	
	Trūkstamos reikšmės	0,7843			

Grynasis pelnas (nuostoliai) / Turtas iš viso					
X₉	< -16,70 %	-0,8984	-0,145	17 žingsnis	Kuo didesnė rodiklio reikšmė, tuo mažesnė įsipareigojimų netvykdymo rizika
	- 16,69 %-1,43 %	-0,4812			
	1,44 %-3,34 %	-0,1337			
	3,35 %-9,96 %	0,4645			
	9,97 %-15,52 %	0,8167			
	> 15,52 %	1,0536			
	Trūkstamos reikšmės	-0,6035			
Trumpalaikis turtas / Mokėtinos sumos ir įsipareigojimai					
X₁₀	< = 0,2554	-0,7301	-0,164	18 žingsnis	Kuo didesnė rodiklio reikšmė, tuo mažesnė įsipareigojimų netvykdymo rizika.
	0,2555-0,4460	-0,5630			
	0,4461-0,9471	-0,2989			
	0,9472-1,0741	-0,1627			
	1,0742-1,2633	0,2489			
	1,2634-1,6287	0,9182			
	1,6288-2,6630	1,1514			
> 2,6630	1,5442				
Trūkstamos reikšmės	0,1358				
Ln (grynasis pelnas)					
X₁₁	< = 8,8968	-0,3980	-0,403	4 žingsnis	Kuo didesnė rodiklio reikšmė, tuo mažesnė įsipareigojimų netvykdymo rizika.
	8,8969-9,8999	-0,3597			
	9,9000-10,5798	-0,0986			
	10,5799-11,6622	0,2004			
	11,6623-12,2063	0,7272			
	12,2064-12,7400	0,8123			
	> 12,7400	0,8983			
Trūkstamos reikšmės arba nuostolinga veikla	-0,5742				
Pinigai ir pinigų ekvivalentai / Per vienierius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai					
X₁₂	< = 0,0055	-1,0490	-0,460	8 žingsnis	Kai šio rodiklio reikšmė yra maža, dėl pinigų srautų kintamumo įmonė gali pradėti nevykdyti savo įsipareigojimų kreditoriams. Tuo patiu teoriniuose literatūroje teigiama, kad šis rodiklis neturėtų būti didesnis kaip 0,6-0,8, t. y. įmonės neturėtų laikyti pernelyg daug neinvestuotų pinigų (žr. Aleksnevičienė 2011). Tačiau modeliausiai naudoti Lietuvos imonių duomenų analizė rodo, kad kuo šio rodiklio reikšmė didesnė, tuo mažesnė įsipareigojimų netvykdymo rizika. Matyti, kad Lietuvos įmonės nelinkusios agresyviai valdyti pinigų, t. y. nesistengia laikyti minimumo neinvestuotų pinigų.
	0,0056-0,0190	-0,5456			
	0,0191-0,0374	-0,4332			
	0,0375-0,1122	0,1621			
	0,1123-0,1807	0,2429			
	0,1808-1,108	0,5672			
	> 1,108	0,8585			
Trūkstamos reikšmės	-0,5417				

Turtas iš viso / Nuosavas kapitalas				
X₁₃	<= 1,2847 + trūkstamos reikšmės	1,7303	2 žingsnis -0,257	Rodiklio reikšmė parodo, kokia turto dalis tenka 1 litui nuosavų lėšų. Jei ši reikšmė teigiama, tai kuo ji didesnė, tuo didesnė įsipareigojimų nevykdymo rizika. Neigiamos reikšmės rodo labai didelę įsipareigojimų nevykdymo riziką.
	1,2848–1,9445	0,8725		
	1,9446–2,9413	0,5192		
	2,9414–3,8115	0,4375		
	3,8116–7,6253	-0,2744		
	7,6254–15,3320	-0,4712		
> 15,3320 + neigiamos reikšmės	-0,8341			
Bendrasis pelnas (nuostoliai) / Turtas iš viso				
X₁₄	<= 5,028 %	-0,7371	13 žingsnis -0,336	Kuo didesnė rodiklio reikšmė, tuo mažesnė įsipareigojimų nevykdymo rizika.
	5,029 %-22,142 %	-0,5062		
	22,143 %-30,901 %	-0,0100		
	> 30,901 %	0,3168		
	Trūkstamos reikšmės	0,9766		
Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai / Turtas iš viso				
X₁₅	<= 11,2460 %	0,7322	21 žingsnis -0,155	Rodiklio reikšmė rodo, kokia įmonės turto dalis finansuojama trumpalaikėmis skolomis. Todėl kuo didesnė rodiklio reikšmė, tuo didesnė įsipareigojimų nevykdymo rizika.
	11,2461 %-20,4192 %	0,3893		
	20,4193 %-28,4675 %	0,1006		
	28,4676 %-63,8380 %	0,0566		
	63,8381 %-76,5530 %	-0,0404		
	76,5531 %-93,2751 %	-0,2669		
	> 93,2751 %	-0,7336		
	Trūkstamos reikšmės	-0,1932		
Ln (po vienerių metų mokėtinos sumos ir ilgalaikiai įsipareigojimai)				
X₁₆	<= 10,3983	0,6535	11 žingsnis -0,774	Kuo didesnė rodiklio reikšmė, tuo didesnė įsipareigojimų nevykdymo rizika.
	10,3984–11,1692	0,2362		
	11,1693–11,7500	-0,1410		
	11,7501–13,3798	-0,2158		
	13,3799–13,9489	-0,2784		
	13,9490–14,6272	-0,3210		
>= 14,6273	-0,3432			
	Trūkstamos reikšmės	0,3342		
Pardavimo pajamos / Trumpalaikis turtas				
X₁₇	<= 0,8229	-0,5463	16 žingsnis -0,668	Rodiklio reikšmė rodo trumpalaikio turto panaudojimo efektyvumą uždirbant pajamų iš pardavimo, t. y. kiek pajamų tenka vienam trumpalaikio turto litui. Kuo didesnė rodiklio reikšmė, tuo mažesnė įsipareigojimų nevykdymo rizika.
	0,8230–1,3839	-0,4201		
	1,3840–2,2739	-0,1449		
	>= 2,2740 + trūkstamos reikšmės	0,2381		

Visų per paskutinius metus pradestų įmokų skaičius			
X₁₈	Per paskutinius metus nebuvo pradestų įmokų	0,3285	Buvo įtrauktos pradeltos įmokos kredito įstaigoms, išperkamosios nuomos, telekomunikacijų, komunalinių paslaugų įmoneis ir kitoms UAB „Creditinfo Lietuva“ duomenų bazei duomenis teikiančioms įmoneis. Kuo daugiau per paskutinius vienerius metus nuo vertinimo datos buvo pradestų įmokų, tuo didesnė įsipareigojimų neįvykdymo rizika.
	1 pradelta įmoka	-0,5268	
	2 pradeltos įmokos	-0,8548	
	3-4 pradeltos įmokos	-1,0295	
	5-8 pradeltos įmokos	-1,4815	
	9-14 pradestų įmokų	-1,6886	
> = 15 pradestų įmokų	-1,7467	-0,330	
Vidutinė pradestimų per paskutinius metus trukmė (dienomis)			
X₁₉	Per paskutinius metus nebuvo pradestų įmokų	0,3285	Buvo įtrauktos pradeltos įmokos kredito įstaigoms, išperkamosios nuomos, telekomunikacijų, komunalinių paslaugų įmoneis ir kitoms UAB „Creditinfo Lietuva“ duomenų bazei duomenis teikiančioms įmoneis. Kuo ilgesnė vidutinė pradelsimo trukmė, tuo didesnė įsipareigojimų neįvykdymo rizika.
	< = 6,14	0,2679	
	6,15-8,50	-0,3468	
	8,51-12,06	-0,4916	
	12,07-14,78	-0,5005	
	14,79-17,87	-1,3155	
> 7,87	-1,5708	-0,561	
I žingsnis			

Sąlytos: autorės skaičiavimai. ^a Įvesties kintamieji buvo pažymėti pagal trečiame cikle nustatytą eilę. Finansinių rodiklių pavadinimai buvo pateikti remiantis pagal Verslo apskaitos standartus sudaromomis finansinėmis ataskaitomis. ^b Skaičiuojant įmonės individualią PD, įvesties kintamojo reikšmių grupės WOE reikia dauginti iš to įvesties kintamojo koeficiento. Kuo mažesnis WOE, tuo didesnė tos įmonių grupės įsipareigojimų neįvykdymo rizika. Prie gautų sandaugų reikia pridėti ir laisvąjį narį, -1,352⁴.

MULTIKOLINEARUMO ANALIZĖ

Modelis	Nestandardizuoti koeficientai		Standartizuoti koeficientai	t	Sig.	Kolinearumo statistika	
	B	Std. paklaida	Beta			Tolerancija	VIF
(Laisvasis narys)	0,272	0,002		110,870	0,000		
X1	-0,055	0,006	-0,059	-8,474	0,000	0,677	1,478
X2	-0,136	0,008	-0,100	-17,097	0,000	0,963	1,038
X3	-0,087	0,005	-0,098	-16,652	0,000	0,941	1,063
X4	-0,118	0,006	-0,113	-18,327	0,000	0,865	1,156
X5	-0,091	0,009	-0,061	-10,232	0,000	0,914	1,094
X6	-0,127	0,007	-0,103	-17,207	0,000	0,907	1,103
X7	-0,097	0,008	-0,076	-11,722	0,000	0,785	1,274
X8	-0,027	0,007	-0,038	-3,833	0,000	0,338	2,958
X9	-0,016	0,007	-0,027	-2,285	0,022	0,321	3,115
X10	0,001	0,005	0,002	0,221	0,825	0,374	2,673
X11	-0,051	0,007	-0,077	-7,333	0,000	0,296	3,375
X12	-0,064	0,005	-0,091	-13,615	0,000	0,733	1,363
X13	-0,035	0,005	-0,069	-6,662	0,000	0,309	3,238
X14	-0,049	0,006	-0,054	-8,236	0,000	0,759	1,317
X15	-0,009	0,010	-0,008	-0,974	0,330	0,455	2,197
X16	-0,088	0,010	-0,071	-9,099	0,000	0,532	1,879
X17	-0,088	0,009	-0,063	-10,029	0,000	0,828	1,208
X18	-0,047	0,008	-0,063	-5,801	0,000	0,277	3,614
X19	-0,106	0,008	-0,150	-13,885	0,000	0,280	3,574

Šaltinis: autorės skaičiavimai SPSS programa.

NAGRINĖTOS REITINGŲ SKALĖS

Reitingas	Reitingų skalė Nr. 1						Reitingo imonės, palyginti su visomis imonėmis	Trūkumai
	Apatinė PD riba	Viršutinė PD riba	„Blogos“ imonės	Visos imonės	Reitingo ODF	„Blogos“ imonės, palyginti su visomis „blogomis“ imonėmis		
1	0,01 %	1,00 %	13	568	2,29 %	0,28 %	2,49 %	
2	1,01 %	4,00 %	95	3 922	2,42 %	2,02 %	17,20 %	
3	4,01 %	8,00 %	203	4 083	4,97 %	4,31 %	17,91 %	
4	8,01 %	15,00 %	533	4 278	12,46 %	11,33 %	18,76 %	
5	15,01 %	25,00 %	579	3 219	17,99 %	12,30 %	14,12 %	
6	25,01 %	99,99 %	3 283	6 729	48,79 %	69,76 %	29,51 %	
Iš viso			4 706	22 799		100,00 %	HHI = 0,2045	
Pemelyg daug blogiausių reitingu vertinamų įmonių. Be to, įmonių skirstinys nėra unimodinis								
Reitingas	Reitingų skalė Nr. 2						Reitingo imonės, palyginti su visomis imonėmis	Trūkumai
	Apatinė PD riba	Viršutinė PD riba	„Blogos“ imonės	Visos imonės	Reitingo ODF	„Blogos“ imonės, palyginti su visomis „blogomis“ imonėmis		
1	0,01 %	1,00 %	13	568	2,29 %	0,28 %	2,49 %	
2	1,01 %	4,00 %	95	3 922	2,42 %	2,02 %	17,20 %	
3	4,01 %	8,00 %	203	4 083	4,97 %	4,31 %	17,91 %	
4	8,01 %	15,00 %	533	4 278	12,46 %	11,33 %	18,76 %	
5	15,01 %	40,00 %	1 511	6 135	24,63 %	32,11 %	26,91 %	
6	40,01 %	99,99 %	2 351	3 813	61,66 %	49,96 %	16,72 %	
Iš viso			4 706	22 799		100,00 %	HHI = 0,1979	
Pemelyg daug priešpaskutinių reitingu vertinamų įmonių								
Reitingas	Reitingų skalė Nr. 3						Reitingo imonės, palyginti su visomis imonėmis	Trūkumai
	Apatinė PD riba	Viršutinė PD riba	„Blogos“ imonės	Visos imonės	Reitingo ODF	„Blogos“ imonės, palyginti su visomis „blogomis“ imonėmis		
1	0,01 %	1,00 %	13	568	2,29 %	0,28 %	2,49 %	
2	1,01 %	4,00 %	95	3 922	2,42 %	2,02 %	17,20 %	
3	4,01 %	8,00 %	203	4 083	4,97 %	4,31 %	17,91 %	
4	8,01 %	20,00 %	815	6 094	13,37 %	17,32 %	26,73 %	
5	20,01 %	50,00 %	1 888	5 606	33,68 %	40,12 %	24,59 %	
6	50,01 %	99,99 %	1 692	2 526	66,98 %	35,95 %	11,08 %	
Iš viso			4 706	22 799		100,00 %	HHI = 0,2065	
Pemelyg ketvirtu reitingu vertinamų įmonių. „Blogų“ reitingo įmonių dalis, palyginti su visomis „blogomis“ imonėmis, ne visada tuo didesnė, kuo blogesnis reitingas („blogų“ penkto reitingo įmonių dalis didesnė nei šešto reitingo).								
Reitingas	Reitingų skalė Nr. 4						Reitingo imonės, palyginti su visomis imonėmis	Trūkumai
	Apatinė PD riba	Viršutinė PD riba	„Blogos“ imonės	Visos imonės	Reitingo ODF	„Blogos“ imonės, palyginti su visomis „blogomis“ imonėmis		
1	0,01 %	1,00 %	13	568	2,29 %	0,28 %	2,4 %	
Įmonių skirstinys nėra unimodinis								

Reitingas	Apatinė PD riba	Virsutinė PD riba	„Blogos“ įmonės	Visos įmonės	Reitingo ODF	„Blogos“ įmonės, palyginti su visomis „blogomis“ įmonėmis	Reitingo įmonės, palyginti su visomis įmonėmis	Trūkumai
2	1,01 %	4,00 %	95	3 922	2,42 %	2,02 %	17,20 %	„Blogi“ reitingo įmonių dalis, palyginti su visomis „blogomis“ įmonėmis, ne visada tuo didesni, kuo blogesnis reitingas („blogi“ šešto reitingo įmonių dalis didesnė nei septinto reitingo)
3	4,01 %	8,00 %	203	4 083	4,97 %	4,31 %	17,91 %	
4	8,01 %	13,00 %	384	3 295	8,16 %	8,16 %	14,45 %	
5	13,01 %	20,00 %	431	2 799	15,40 %	9,16 %	12,28 %	
6	20,01 %	50,00 %	1 888	5 606	33,68 %	40,12 %	24,59 %	
7	50,01 %	99,99 %	1 692	2 526	66,98 %	35,95 %	11,08 %	
IS viso			4 706	22 799		100,00 %	HHI = 0,1710	
Reitingų skalė Nr.5								
Reitingas	Apatinė PD riba	Virsutinė PD riba	„Blogos“ įmonės	Visos įmonės	Reitingo ODF	„Blogos“ įmonės, palyginti su visomis „blogomis“ įmonėmis	Reitingo įmonės, palyginti su visomis įmonėmis	Trūkumai
1	0,01 %	0,85 %	12	419	2,86 %	0,25 %	1,84 %	Reitingo ODF nuo pirmo iki trečio reitingo ne didėja, kaip turėtų būti, bet mažėja. Be to, įmonių skirstinys nėra unimodinis
2	0,86 %	2,00 %	40	1 417	2,82 %	0,85 %	6,22 %	
3	2,01 %	4,00 %	56	2 654	2,11 %	1,19 %	11,64 %	
4	4,01 %	8,00 %	203	4 083	4,97 %	4,31 %	17,91 %	
5	8,01 %	15,00 %	533	4 278	12,46 %	11,33 %	18,76 %	
6	15,01 %	25,00 %	579	3 219	17,99 %	12,30 %	14,12 %	
7	25,01 %	50,00 %	1 591	4 203	37,85 %	33,81 %	18,44 %	
8	50,01 %	99,99 %	1 692	2 526	66,98 %	35,95 %	11,08 %	
IS viso			4 706	22 799		100,00 %	HHI = 0,1512	
Reitingų skalė Nr. 6								
Reitingas	Apatinė PD riba	Virsutinė PD riba	„Blogos“ įmonės	Visos įmonės	Reitingo ODF	„Blogos“ įmonės, palyginti su visomis „blogomis“ įmonėmis	Reitingo įmonės, palyginti su visomis įmonėmis	Trūkumai
1	0,01 %	0,85 %	12	419	2,86 %	0,25 %	1,84 %	Reitingo ODF ir „blogi“ reitingo įmonių dalis, palyginti su visomis „blogomis“ įmonėmis, ne visada tuo didesni, kuo blogesnis reitingas
2	0,86 %	1,90 %	27	1 270	2,13 %	0,57 %	5,57 %	
3	1,91 %	3,60 %	69	2 336	2,95 %	1,47 %	10,25 %	
4	3,61 %	6,00 %	65	2 742	2,37 %	1,38 %	12,03 %	
5	6,01 %	10,00 %	321	3 316	9,68 %	6,82 %	14,54 %	
6	10,01 %	18,00 %	533	3 916	13,61 %	11,33 %	17,18 %	
7	18,01 %	32,00 %	786	3 598	21,85 %	16,70 %	15,78 %	
8	32,01 %	50,00 %	1 201	2 676	44,88 %	25,52 %	11,74 %	
9	50,01 %	99,99 %	1 692	2 526	66,98 %	35,95 %	11,08 %	
IS viso			4 706	22 799		100,00 %	HHI = 0,1300	
Reitingų skalė Nr. 7								
Reitingas	Apatinė PD riba	Virsutinė PD riba	„Blogos“ įmonės	Visos įmonės	Reitingo ODF	„Blogos“ įmonės, palyginti su visomis „blogomis“ įmonėmis	Reitingo įmonės, palyginti su visomis įmonėmis	Trūkumai
1	0,01 %	0,85 %	12	419	2,86 %	0,25 %	1,84 %	Reitingo ODF ne visada tuo didesni, kuo blogesnis reitingas. Be to, įmonių skirstinys nėra unimodinis
2	0,86 %	1,90 %	27	1 270	2,13 %	0,57 %	5,57 %	
3	1,91 %	3,40 %	67	2 061	3,25 %	1,42 %	9,04 %	
4	3,41 %	6,50 %	80	3 516	2,28 %	1,70 %	15,42 %	
5	6,51 %	10,00 %	308	2 817	10,93 %	6,54 %	12,36 %	

6	10,01 %	18,00 %	533	3 916	13,61 %	11,33 %	17,18 %
7	18,01 %	32,00 %	786	3 598	21,85 %	16,70 %	15,78 %
8	32,01 %	50,00 %	1 201	2 676	44,88 %	25,52 %	11,74 %
9	50,01 %	99,99 %	1 692	2 526	66,98 %	35,95 %	11,08 %
Iš viso			4 706	22 799		100,00 %	HHI = 0,1311
Reitingų skalė Nr. 8							
Reitingas	Apatinė PD riba	Viršutinė PD riba	„Blogos“ imonės	Visos imonės	Reitingo ODF	„Blogos“ imonės, palyginti su visomis imonėmis	Reitingo imonės, palyginti su visomis imonėmis
1	0,01 %	1,00 %	13	568	2,29 %	0,28 %	2,49 %
2	1,01 %	2,10 %	39	1 393	2,80 %	0,83 %	6,11 %
3	2,11 %	3,40 %	54	1 789	3,02 %	1,15 %	7,85 %
4	3,41 %	6,40 %	80	3 418	2,34 %	1,70 %	14,99 %
5	6,41 %	10,00 %	308	2 915	10,57 %	6,54 %	12,79 %
6	10,01 %	15,00 %	350	2 768	12,64 %	7,44 %	12,14 %
7	15,01 %	23,00 %	505	2 749	18,37 %	10,73 %	12,06 %
8	23,01 %	36,00 %	721	2 718	26,53 %	15,32 %	11,92 %
9	36,01 %	60,00 %	1 316	2 702	48,70 %	27,96 %	11,85 %
10	60,01 %	99,99 %	1 320	1 779	74,20 %	28,05 %	7,80 %
Iš viso			4 706	22 799		100,00 %	HHI = 0,1130
Reitingų skalė Nr. 9							
Reitingas	Apatinė PD riba	Viršutinė PD riba	„Blogos“ imonės	Visos imonės	Reitingo ODF	„Blogos“ imonės, palyginti su visomis imonėmis	Reitingo imonės, palyginti su visomis imonėmis
1	0,01 %	1,00 %	13	568	2,29 %	0,28 %	2,49 %
2	1,01 %	2,20 %	40	1 543	2,59 %	0,85 %	6,77 %
3	2,21 %	3,70 %	55	2 023	2,72 %	1,17 %	8,87 %
4	3,71 %	8,00 %	203	4 439	4,57 %	4,31 %	19,47 %
5	8,01 %	16,00 %	573	4 675	12,26 %	12,18 %	20,51 %
6	16,01 %	28,00 %	697	3 529	19,75 %	14,81 %	15,48 %
7	28,01 %	40,50 %	811	2 288	35,45 %	17,23 %	10,04 %
8	40,51 %	60,00 %	1 085	2 075	52,29 %	23,06 %	9,10 %
9	61,01 %	99,99 %	1 229	1 659	74,08 %	26,12 %	7,28 %
Iš viso			4 706	22 799		100,00 %	HHI = 0,1406
Trūkumai							
<p>Tai yra tinkamiausia reitingų sistema, turinti didžiausią χ^2 reikšmę iš visų reitingų skalų, susidedančių iš devynių reitingų (6 189,53; reitingų skalės Nr. 6 χ^2 reikšmė yra lygi 5 987,66, o reitingų skalės Nr. 7 – 6 006,10)</p>							

Šaltinis: autorės skatėjavimai.

LYGINAMAJAI ANALIZEI TAIKYTI MODELIAI

Rodiklis*	Lis (1973) diskriminantinės analizės modelis	Tafler (1977) diskriminantinės analizės modelis	Shumway (1999) logistinės regresijos modelis su Zmijewskio kintamaisiais (1)**	Shumway (1999) logistinės regresijos modelis su Zmijewskio kintamaisiais (2)**	Shumway (1999) diskretaus laiko logistinės regresijos modelis	Stoškus ir kt. (2007) diskriminantinės analizės modelis, 1 lygtis	Stoškus ir kt. (2007) diskriminantinės analizės modelis, 2 lygtis
Trumpalaikis turas / Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai			-0,166	-1,119	-0,158	5,88	2,90
(Trumpalaikis turas – Asargos) / Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai						-5,80	-2,92
Apyvartinis kapitalas / Turas iš viso	0,063						
Bendrasis pelnas (nuostoliai) / Turas iš viso	0,092						
Pardavimo pajamos / Turas iš viso		0,16					
Nepaskirstytasis pelnas (nuostoliai) / Turas iš viso	0,057						
Grynasis pelnas (nuostoliai) / Turas iš viso			-5,222	-4,701	-6,307	4,77	2,82
Grynasis pelnas (nuostoliai) / Pardavimo pajamos							
Pelnas (nuostoliai) prieš apmokėtinimą / Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai		0,53					
Nuosavas kapitalas / Mokėtinos sumos ir įsipareigojimai	0,001		4,579	3,106	4,068	9,51	6,43
Mokėtinos sumos ir įsipareigojimai / Turas iš viso							
Per vienerius metus mokėtinos sumos ir trumpalaikiai įsipareigojimai / Turas iš viso		0,18					
Trumpalaikis turas / Mokėtinos sumos ir įsipareigojimai		0,13					
Įnelyvavimo laikas							
Latavimas narys			-5,112	-4,201	0,307	-6,42	-2,94
Komentari	Jei $Z < 0,037$, tai bankroto rizika – didelė	Jei $Z > 0,3$, imones ilgalaikės perspektyvos – geros, o jei $Z < 0,2$, bankroto rizika – didelė	Jei tikimybė $> 50\%$, bankroto rizika – didelė	Jei tikimybė $> 50\%$, bankroto rizika – didelė	Jei tikimybė $> 50\%$, bankroto rizika – didelė	Nebankrutuojančių įmonių lygtis (Z_0)	Bankrutuojančių įmonių lygtis (Z_1)

Šaltinis: Mackevičius (2005); Stoškus ir kt. (2007); Garškaitė (2008); Трифонов (2008). *Rodiklių pavadinimai buvo pateikti atsižvelgiant į pagal Verslo apskaitos standartus sudaromas finansines ataskaitas. **Shumway 1999 metais sukūrė du logistinės regresijos modelius naudodamas tokius pačius įvesties kintamuosius, kokius kitas autorius – Zmijewski – naudojo 1984 metais kurdamas savo modelį.

LYGINAMOSIOS ANALIZĖS REZULTATAI

Rei- tingas	Lis (1973) diskriminantinės analizės modelis			Taffler (1977) diskriminantinės analizės modelis			Shumway (1999) logistinės regresijos modelis su Zmijewskio kintamaisiais (1)			Shumway (1999) logistinės regresijos modelis su Zmijewski kintamaisiais (2)			Shumway (1999) diskretus laiko logistinės regresijos modelis			Stoškaus ir kt. (2007) diskriminatinės analizės modelis*		
	Įmonių skaičius	Įmonių dalis	Kaupiamoji įmonių dalis	Įmonių skaičius	Įmonių dalis	Kaupiamoji įmonių dalis	Įmonių skaičius	Įmonių dalis	Kaupiamoji įmonių dalis	Įmonių skaičius	Įmonių dalis	Kaupiamoji įmonių dalis	Įmonių skaičius	Įmonių dalis	Kaupiamoji įmonių dalis	Įmonių skaičius	Įmonių dalis	Kaupiamoji įmonių dalis
1	145	4,61 %	100,00 %	46	4,20 %	100,00 %	32	3,05 %	100,00 %	23	2,75 %	100,00 %	16	3,02 %	100,00 %	341	7,58%	100,00%
2	293	9,32 %	95,39 %	104	9,51 %	95,80 %	69	6,57 %	96,95 %	59	7,07 %	97,25 %	42	7,92 %	96,98 %	736	16,37%	92,42%
3	211	6,71 %	86,06 %	59	5,39 %	86,29 %	50	4,76 %	90,38 %	38	4,55 %	90,18 %	22	4,15 %	89,06 %	478	10,63%	76,05%
4	550	17,50 %	79,35 %	205	18,74 %	80,90 %	154	14,67 %	85,62 %	125	14,97 %	85,63 %	85	16,04 %	84,91 %	1 037	23,06%	65,42%
5	457	14,54 %	61,85 %	126	11,52 %	62,16 %	150	14,29 %	70,95 %	123	14,73 %	70,66 %	92	17,36 %	68,87 %	634	14,10%	42,36%
6	355	11,29 %	47,31 %	156	14,26 %	50,64 %	128	12,19 %	56,67 %	90	10,78 %	55,93 %	49	9,25 %	51,51 %	498	11,07%	28,26%
7	144	4,58 %	36,02 %	35	3,20 %	36,38 %	50	4,76 %	44,48 %	29	3,47 %	45,15 %	25	4,72 %	42,26 %	169	3,76%	17,19%
8	562	17,88 %	31,43 %	187	17,09 %	33,18 %	225	21,43 %	39,71 %	188	22,51 %	41,68 %	94	17,74 %	37,55 %	411	9,14%	13,43%
9	426	13,55 %	13,55 %	176	16,09 %	16,09 %	192	18,29 %	18,29 %	160	19,16 %	19,16 %	105	19,81 %	19,81 %	193	4,29%	4,29%
IS viso	3 143	100,00 %		1 094	100,00 %		1 050	100,00 %		835	100,00 %		530	100,00 %		4 497	100,00%	
AR		41,81 %			45,72 %			46,30 %			46,75 %			45,33 %			0,86%	
AUC		70,91 %			72,86 %			73,15 %			73,38 %			72,66 %			50,43%	
IV		0,556			0,795			0,718			0,698			0,692			0,347	

Šaltinis: autorės skaičiavimai. *Pagal Stoškaus ir kt. (2007) modelį, imonė yra priskiriama prie nebankrutuojančių arba bankrutuojančių imonių, atsižvelgiant į tai, kurios lygties tai pačiai imonei reikšmė yra didesnė. Jeigu didesnė yra Z_0 lygties reikšmė, tada imonė priskiriama prie nebankrutuojančių imonių grupės, o jeigu didesnė yra Z_1 lygties reikšmė – tada prie bankrutuojančių.

REITINGŲ PD(1), PD(2) IR PD(3) KALIBRAVIMO TIKSLUMO VERTINIMAS

Taikant H ir L kriterijų, kad PD būtų laikomos tikslomis (t. y. kad H_0 hipotezė nebūtų atmetama), statistikos p reikšmė turi būti ne mažesnė už pasirinktą reikšmingumo lygmenį. Lyginant tarpusavyje keliais skirtingais metodais apskaičiuotas PD, patikimesniu laikomas toks metodas, kurio χ^2 reikšmė mažesnė (o statistikos p reikšmė – didesnė) (žr. 1–3 lent.).

1 lentelė. H ir L kriterijus (PD(1))

A	B	C	D	E	F	G	H	I
Reitingas	Faktinis „blogų“ įmonių skaičius	Tikėtinas „blogų“ įmonių skaičius	Faktinis „gerų“ įmonių skaičius	Tikėtinas „gerų“ įmonių skaičius	= (B – C) ²	= (D – E) ²	= F/C	= G/E
1	2	2,16	367	366,84	0,02	0,02	0,01	0,00
2	10	10,61	696	695,39	0,37	0,37	0,04	0,00
3	11	10,77	350	350,23	0,05	0,05	0,00	0,00
4	49	48,70	840	840,30	0,09	0,09	0,00	0,00
5	52	53,35	412	410,65	1,82	1,82	0,03	0,00
6	68	67,69	258	258,31	0,10	0,10	0,00	0,00
7	17	17,30	33	32,70	0,09	0,09	0,01	0,00
8	272	257,61	210	224,39	207,02	207,02	0,80	0,92
9	279	286,69	97	89,31	59,13	59,13	0,21	0,66
	760	754,88	3 263	3 268,12	χ^2 reikšmė			2,70
Statistikos p reikšmė								0,975

Šaltinis: autorės skaičiavimai. *Statistikos p reikšmė, turinti devynis laisvės laipsnius, apskaičiuota taikant „MS Excel“ funkciją =CHIDIST().

Pasirinkus reikšmingumo lygmenį 0,05, tikslios buvo tik PD(1) ir PD(2), nes tada statistikos p reikšmė buvo didesnė nei 0,05. Tačiau galima sakyti, kad PD(1) buvo tikslesnės už PD(2), nes naudojant PD(1) χ^2 reikšmė buvo mažesnė (o statistikos p reikšmė – didesnė) nei naudojant PD(2), be to, naudojant PD(2) statistikos p reikšmė tik šiek tiek viršijo reikšmingumo lygmenį.

2 lentelė. H ir L kriterijus (PD(2))

A	B	C	D	E	F	G	H	I
Reitingas	Faktinis „blogų“ įmonių skaičius	Tikėtinas „blogų“ įmonių skaičius	Faktinis „gerų“ įmonių skaičius	Tikėtinas „gerų“ įmonių skaičius	$= (B - C)^2$	$= (D - E)^2$	$= F/C$	$= G/E$
1	2	1,86	367	367,14	0,02	0,02	0,01	0,00
2	10	11,33	696	694,67	1,77	1,77	0,16	0,00
3	11	10,67	350	350,33	0,11	0,11	0,01	0,00
4	49	52,05	840	836,95	9,31	9,31	0,18	0,01
5	52	55,7	412	408,3	13,71	13,71	0,25	0,03
6	68	71,74	258	254,26	13,96	13,96	0,19	0,05
7	17	17,13	33	32,87	0,02	0,02	0,00	0,00
8	272	244,64	210	237,36	748,62	748,62	3,06	3,15
9	279	302,68	97	73,32	560,74	560,74	1,85	7,65
	760	767,80	3 263	3 255,20	χ^2 reikšmė			16,61
Statistikos p reikšmė								0,055

Šaltinis: autorės skaičiavimai.

Vertinant PD(3) kalibravimo tikslumą, H_0 hipotezė, kai reikšmingumo lygmuo 0,05, buvo atmesta (nes statistikos p reikšmė buvo mažesnė už 0,05).

3 lentelė. H ir L kriterijus (PD(3))

A	B	C	D	E	F	G	H	I
Reitingas	Faktinis „blogų“ įmonių skaičius	Tikėtinas „blogų“ įmonių skaičius	Faktinis „gerų“ įmonių skaičius	Tikėtinas „gerų“ įmonių skaičius	$= (B - C)^2$	$= (D - E)^2$	$= F/C$	$= G/E$
1	2	0,37	367	368,63	2,66	2,66	7,21	0,01
2	10	10,52	696	695,48	0,27	0,27	0,03	0,00
3	11	10,32	350	350,68	0,46	0,46	0,04	0,00
4	49	48,43	840	840,57	0,32	0,32	0,01	0,00
5	52	52,53	412	411,47	0,28	0,28	0,01	0,00
6	68	69,02	258	256,98	1,05	1,05	0,02	0,00
7	17	16,84	33	33,16	0,03	0,03	0,00	0,00
8	272	239,6	210	242,4	1 049,54	1 049,54	4,38	4,33
9	279	293,67	97	82,33	215,35	215,35	0,73	2,62
	760	741,30	3 263	3 281,70	χ^2 reikšmė			19,38
Statistikos p reikšmė								0,022

Šaltinis: autorės skaičiavimai.

Binominio (Voldo) kriterijaus taikymo rezultatai parodė, jog, vertinant PD(1) kalibravimo tikslumą, H_0 hipotezė nebuvo atmesta, nes visų reitingų PD(1) pateko į nustatytą intervalą – PD(2) ir PD(3) aštuntam reitingui buvo per mažos, o PD(2) devintam reitingui – per didelė (žr. 4 lent.).

4 lentelė. Binominis (Voldo) kriterijus

A	B	C	D	E	F	G	H
Reitingas	ODF ₂₀₀₈	Paklaida (95 % pasiklivimo lygmuo)	Apatinė intervalo riba = B – C	Viršutinė intervalo riba = B + C	PD(1)	PD(2)	PD(3)
1	0,54 %	0,75 %	-0,21 %	1,29 %	0,58 %	0,51 %	0,10 %
2	1,42 %	0,87 %	0,54 %	2,29 %	1,50 %	1,61 %	1,49 %
3	3,05 %	1,77 %	1,27 %	4,82 %	2,98 %	2,96 %	2,86 %
4	5,51 %	1,50 %	4,01 %	7,01 %	5,48 %	5,86 %	5,45 %
5	11,21 %	2,87 %	8,34 %	14,08 %	11,50 %	12,01 %	11,32 %
6	20,86 %	4,41 %	16,45 %	25,27 %	20,76 %	22,01 %	21,17 %
7	34,00 %	13,13 %	20,87 %	47,13 %	34,61 %	34,26 %	33,68 %
8	56,43 %	4,43 %	52,00 %	60,86 %	53,45 %	50,76 %	49,71 %
9	74,20 %	4,42 %	69,78 %	78,62 %	76,25 %	80,50 %	78,10 %

Šaltinis: autorės skaičiavimai.

Taikant binominį (vienpusį) kriterijų, kad reitingo PD būtų laikoma tiksli, apskaičiuotas pasiklivimo lygmuo turi būti ne didesnis už pasirinktą pasiklivimo lygmenį. Matyti, kad pasirinkus 95 % pasiklivimo lygmenį, tik PD(1) visuomet buvo tikslios. PD(2) ir PD(3) buvo per mažos aštuntam reitingui, o PD(3) buvo per maža ir pirmam reitingui (nes apskaičiuotas pasiklivimo lygmuo buvo didesnis nei 95 %) (žr. 5 lent.).

5 lentelė. Binominis (vienpusis) kriterijus

Reitingas	Apskaičiuotas pasiklivimo lygmuo*		
	PD(1)	PD(2)	PD(3)
1	63,87 %	70,87 %	99,37 %
2	50,91 %	41,56 %	51,79 %
3	60,86 %	61,73 %	66,05 %
4	55,45 %	36,23 %	57,00 %
5	45,75 %	32,77 %	50,61 %
6	54,99 %	33,56 %	47,74 %
7	52,92 %	55,00 %	58,43 %
8	91,29 %	99,45 %	99,87 %
9	19,08 %	0,17 %	4,07 %

Šaltinis: autorės skaičiavimai. *Skaičiuojant buvo naudota „MS Excel“ funkcija ($= 1 - \text{betadist}(PD_i; D_i + 1; N_i - D_i)$), čia: N_i – i reitingo įmonių skaičius; D_i – „blogų“ i reitingo įmonių skaičius.

Binominio (vienpusio) kriterijaus su normaliaja aproksimacija (be koreliacijos) taikymo rezultatai buvo tokie patys kaip ir kriterijaus, aprašyto pirmiau: visų reitingų PD(1) buvo tikslios (nes visuose reitinguose ODF₂₀₀₈ buvo mažesnis už kritinę PD(1) reikšmę), PD(2) ir PD(3) buvo per mažos aštuntam reitingui, o PD(3) buvo per maža ir pirmam reitingui. Tačiau įtraukus koreliaciją visos trys PD visuose reitinguose buvo tikslios. Įtraukus koreliaciją kritinės PD reikšmės padidėjo, todėl visuose reitinguose ODF₂₀₀₈ buvo mažesnis tiek už kritinę PD(1) reikšmę, tiek už kritines PD(2) ir PD(3) reikšmes (žr. 6 lent.).

6 lentelė. Binominis (vienpusis) kriterijus su normaliaja aproksimacija

Reitingas	ODF ₂₀₀₈	Be koreliacijos			Naudojant 3 % koreliaciją		
		Kritinė PD(1) reikšmė	Kritinė PD(2) reikšmė	Kritinė PD(3) reikšmė	Kritinė PD(1) reikšmė	Kritinė PD(2) reikšmė	Kritinė PD(3) reikšmė
1	0,54 %	1,23 %	1,12 %	0,37 %	2,84 %	2,63 %	1,04 %
2	1,42 %	2,25 %	2,39 %	2,24 %	5,04 %	5,28 %	5,02 %
3	3,05 %	4,45 %	4,43 %	4,30 %	8,04 %	8,00 %	7,82 %
4	5,51 %	6,74 %	7,16 %	6,70 %	12,08 %	12,67 %	12,03 %
5	11,21 %	13,94 %	14,49 %	13,74 %	20,90 %	21,59 %	20,66 %
6	20,86 %	24,45 %	25,78 %	24,89 %	32,87 %	34,39 %	33,37 %
7	34,00 %	45,68 %	45,30 %	44,67 %	52,00 %	51,61 %	50,96 %
8	56,43 %	57,19 %	54,51 %	53,46 %	68,13 %	65,47 %	64,42 %
9	74,20 %	79,86 %	83,86 %	81,61 %	88,88 %	92,26 %	90,38 %

Šaltinis: autorės skaičiavimai.

Taikant normalųjį (dvipusį) kriterijų, kad reitingo PD būtų laikoma tikslia, skirtumo tarp ODF ir PD modulis turi būti nedidesnis už atitinkamą kritinę reikšmę. Vėlgi, tik PD(1) visuose reitinguose buvo tikslios (žr. 7 lent.).

7 lentelė. Normalusis (dvipusis) kriterijus

Reitingas	ODF ₂₀₀₈ – PD(1)	ODF ₂₀₀₈ – PD(2)	ODF ₂₀₀₈ – PD(3)	Kritinė skirtumo tarp ODF ₂₀₀₈ ir PD(1) reikšmė	Kritinė skirtumo tarp ODF ₂₀₀₈ ir PD(2) reikšmė	Kritinė skirtumo tarp ODF ₂₀₀₈ ir PD(3) reikšmė
1	-0,04 %	0,03 %	0,44 %	0,77 %	0,73 %	0,32 %
2	-0,08 %	-0,19 %	-0,07 %	0,90 %	0,93 %	0,89 %
3	0,07 %	0,09 %	0,19 %	1,75 %	1,75 %	1,72 %
4	0,03 %	-0,35 %	0,06 %	1,50 %	1,54 %	1,49 %
5	-0,29 %	-0,80 %	-0,11 %	2,90 %	2,96 %	2,88 %
6	0,10 %	-1,15 %	-0,31 %	4,40 %	4,50 %	4,43 %
7	-0,61 %	-0,26 %	0,32 %	13,19 %	13,15 %	13,10 %
8	2,98 %	5,67 %	6,72 %	4,45 %	4,46 %	4,46 %
9	-2,05 %	-6,30 %	-3,90 %	4,30 %	4,00 %	4,18 %

Šaltinis: autorės skaičiavimai.

Taikant ilgo laikotarpio normalųjį kriterijų, kad reitingo PD būtų laikoma tikslia, atitinkama apskaičiuota reikšmė turi būti mažesnė už atvirkštinės standartinio normaliojo dydžio pasiskirstymo funkcijos reikšmę. Pasirinkus 95 % pasiklovimo lygmenį, atvirkštinės standartinio normaliojo dydžio pasiskirstymo funkcijos reikšmė buvo lygi 1,64. Kaip matyti iš 8 lentelės, tokiu atveju tiek visų reitingų PD(1), tiek PD(2) ir PD(3) buvo tikslios. Taikant šį kriterijų buvo naudoti trejų metų (t. y. 2006–2008 metų) duomenys. O kiti kriterijai buvo taikyti naudojant tik 2008 metų duomenis. 2006–2007 metais faktinių „blogų“ įmonių buvo kur kas mažiau nei 2008 metais, maži buvo ir 2006–2007 metų ODF (žr. 32 lent.). Todėl šio kriterijaus taikymo rezultatai buvo tokie geri.

8 lentelė. Ilgo laikotarpio normalusis kriterijus

Reitingas	Reikšmė, lyginama su 1,64		
	PD(1)	PD(2)	PD(3)
1	-2,23	-1,80	-1,80
2	-2,36	-3,26	-3,26
3	-0,92	-0,89	-0,89
4	-1,52	-2,53	-2,53
5	-0,69	-0,93	-0,93
6	-1,46	-2,05	-2,05
7	-2,10	-1,98	-1,98
8	-0,48	-0,26	-0,26
9	-0,99	-1,42	-1,42

Šaltinis: autorės skaičiavimai.

Papildomai buvo apskaičiuoti ir Briero balai. Briero balų metodas neleidžia nustatyti, ar PD yra tikslios, ar ne, jis leidžia tik palyginti skirtingų PD apskaičiavimo metodų patikimumą tarpusavyje. Kuo mažesnis Briero balas, tuo patikimesnis PD apskaičiavimo metodas. Mažiausias Briero balas buvo naudojant PD(1), o didžiausias – naudojant PD(2), bet pastarasis balas nedaug skyrėsi nuo tų balų, kurie buvo gauti naudojant PD(1) ir PD(3) (žr. 9 lent.). Tai tik patvirtino, kad PD(1), PD(2) ir PD(3) reikšmės buvo labai panašios tarpusavyje.

9 lentelė. Briero balų metodas

Reitingas	Briero balas naudojant PD(1)	Briero balas naudojant PD(2)	Briero balas naudojant PD(3)
1	1,9892	1,9892	1,9964
2	9,8589	9,8610	9,8587
3	10,6650	10,6651	10,6661
4	46,2993	46,3100	46,2996
5	46,1764	46,2023	46,1730
6	53,8163	53,8591	53,8191
7	11,2219	11,2203	11,2205
8	118,9347	120,0566	120,6839
9	72,1338	73,4674	72,5473
Iš viso	0,0922	0,0929	0,0928

Šaltinis: autorės skaičiavimai.

LDP REITINGŪ PD₂₀₀₆ IR PD₂₀₀₇ APSKAĪCIĀVIMAS1. lentelē. PD₂₀₀₆ apkaļciāvimas taikant CAP kreivēs ir ROC kreivēs metodus

Reitings	Izonēs	*Blogs** imonzēs	ODF ₂₀₀₆	x _R	CAP kreivēs PD ₂₀₀₆	F _N (s)	R _{a,b} '(F _N (s))	R _{a,b} (F _N (s))	ROC kreivēs PD ₂₀₀₆
1 LDP	99	0	0,00 %	98,59 %	0,28 %	100,00 %	0,0051	100,00 %	0,06 %
2 LDP	292	3	1,03 %	93,04 %	0,37 %	96,85 %	0,0153	99,98 %	0,18 %
3 LDP	344	0	0,00 %	84,01 %	0,61 %	87,64 %	0,0668	99,61 %	0,80 %
4	732	31	4,23 %	68,72 %	1,41 %	76,69 %	0,1501	98,44 %	1,78 %
5	726	44	6,06 %	48,01 %	4,33 %	54,36 %	0,4268	92,33 %	4,91 %
6	568	78	13,73 %	29,63 %	11,77 %	32,64 %	0,9672	77,94 %	10,48 %
7	333	90	27,03 %	16,83 %	23,61 %	17,04 %	1,8218	57,10 %	18,06 %
8	275	64	23,27 %	8,20 %	37,75 %	9,30 %	2,7285	39,89 %	24,82 %
9	151	70	46,36 %	2,14 %	52,46 %	2,58 %	4,7902	16,11 %	36,70 %
Iš viso	3 520	380	AR	63,21 %			1,2990		
	ODF	10,80 %	k	5,44			b		

Šaltinis: autorēs skaitciāvimai.

2. lentelē. PD₂₀₀₇ apkaļciāvimas taikant CAP kreivēs ir ROC kreivēs metodus

Reitings	Izonēs	*Blogs** imonzēs	ODF ₂₀₀₇	x _R	CAP kreivēs PD ₂₀₀₇	F _N (s)	R _{a,b} '(F _N (s))	R _{a,b} (F _N (s))	ROC kreivēs PD ₂₀₀₇
1 LDP	222	0	0,00 %	96,12 %	0,09 %	100,00 %	0,0001	100,00 %	0,002 %
2 LDP	554	7	1,26 %	82,56 %	0,26 %	90,42 %	0,0023	99,99 %	0,05 %
3 LDP	259	8	3,09 %	68,35 %	0,78 %	66,82 %	0,0315	99,68 %	0,73 %
4	660	33	5,00 %	52,29 %	2,66 %	56,00 %	0,0691	99,16 %	1,59 %
5	278	36	12,95 %	35,90 %	9,33 %	28,95 %	0,4188	93,94 %	8,93 %
6	254	47	18,50 %	26,60 %	18,99 %	18,51 %	0,9281	87,34 %	17,86 %
7 LDP	38	9	23,68 %	21,50 %	28,06 %	9,58 %	2,2611	74,33 %	34,63 %
8	412	259	62,86 %	13,63 %	51,20 %	8,33 %	2,6541	71,27 %	38,34 %
9	184	144	78,26 %	3,22 %	113,56 %	1,73 %	10,6226	37,81 %	71,33 %
Iš viso	2 861	543	AR	73,85 %			2,2119		
	ODF	18,98 %	k	7,65			b		

Šaltinis: autorēs skaitciāvimai.

REITINGŪ PD (PLUTO, TASCHE (2005) METODAS BE KORELIACIJŪ)

Reitin- gais	50 % pasikliovimo lygmuo, be korekcijū		75 % pasikliovimo lygmuo, be korekcijū		90 % pasikliovimo lygmuo, be korekcijū		95 % pasikliovimo lygmuo, be korekcijū		99 % pasikliovimo lygmuo, be korekcijū		99,9 % pasikliovimo lygmuo, be korekcijū		99,99 % pasikliovimo lygmuo, be korekcijū								
	PD _{2006%}	PD _{2007%}	PD(4),%	PD _{2006%}	PD _{2007%}	PD(4),%	PD _{2006%}	PD _{2007%}	PD(4),%	PD _{2006%}	PD _{2007%}	PD(4),%	PD _{2006%}	PD _{2007%}	PD(4),%	PD _{2006%}	PD _{2007%}	PD(4),%	PD _{2006%}	PD _{2007%}	
1 LDP	0,50	1,51	1,01	0,69	1,78	1,24	0,91	2,05	1,48	1,05	2,22	1,64	1,36	2,57	1,96	1,77	3,00	2,38	2,15	3,38	2,76
2 LDP	0,58	1,93	1,25	0,80	2,27	1,54	1,05	2,61	1,83	1,21	2,83	2,02	2,42	3,27	2,42	2,04	3,80	2,92	2,48	4,29	3,38
3 LDP	0,20	3,34	1,77	0,40	4,15	2,28	0,67	4,97	2,82	0,87	5,50	3,19	1,33	6,60	3,96	1,99	7,96	4,98	2,64	9,19	5,92
4	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62
5	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51
6	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12
7 LDP	27,03	25,22	26,13	27,03	30,12	28,58	27,03	34,80	30,91	27,03	37,69	32,36	27,03	43,24	35,14	27,03	49,54	38,29	27,03	54,70	40,86
8	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07
9	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31
50 % pasikliovimo lygmuo, naudojant korekcijas																					
90 % pasikliovimo lygmuo, naudojant korekcijas																					
95 % pasikliovimo lygmuo, naudojant korekcijas																					
99 % pasikliovimo lygmuo, naudojant korekcijas																					
99,9 % pasikliovimo lygmuo, naudojant korekcijas																					
99,99 % pasikliovimo lygmuo, naudojant korekcijas																					
1 LDP	0,52	1,13	0,82	0,47	1,11	0,79	0,44	1,09	0,76	0,42	1,08	0,75	0,39	1,08	0,73	0,36	1,07	0,72	0,35	1,07	0,71
2 LDP	0,60	1,43	1,02	0,55	1,41	0,98	0,50	1,39	0,95	0,48	1,38	0,93	0,45	1,37	0,91	0,42	1,36	0,89	0,40	1,36	0,88
3 LDP	0,21	2,49	1,35	0,27	2,57	1,42	0,32	2,64	1,48	0,34	2,69	1,51	0,38	2,76	1,57	0,41	2,84	1,63	0,43	2,91	1,67
4	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62	4,23	5,00	4,62
5	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51	6,06	12,95	9,51
6	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12	13,73	18,50	16,12
7 LDP	27,03	18,76	22,89	27,03	18,67	22,85	27,03	18,52	22,77	27,03	18,40	22,71	27,03	18,11	22,57	27,03	17,70	22,37	27,03	17,31	22,17
8	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07	23,27	62,86	43,07
9	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31	46,36	78,26	62,31
K	1,04	0,74		0,68	0,62		0,48	0,53		0,40	0,49		0,29	0,42		0,21	0,36		0,16	0,32	

Šaltinis: autorės skaičiavimai.

REITINGŲ PD(4) KALIBRAVIMO TIKSLUMO VERTINIMAS

Binominio (Voldo) kriterijaus taikymo rezultatai parodė, kad, tik taikant tris LDP reitingų PD apskaičiavimo metodus, LDP reitingų PD(4) visada pakliuvo į nustatytą intervalą. O taikant kitus du metodus – Burgt (2007) CAP kreivės ir Tasche (2009) ROC kreivės metodus – 2 ir 3 reitingų PD(4) buvo mažesnė net už apatinę intervalo ribą (žr. 1 lent.). Visos septinto reitingo PD(4) pakliuvo į nustatytą intervalą, tačiau taikant Pluto, Tasche (2005) metodą be koreliacijos PD(4) buvo mažoka (netoli apatinės intervalo ribos).

H ir L kriterijaus taikymo rezultatai patvirtino binominio (Voldo) kriterijaus taikymo rezultatus, kad mažiausiai patikimi buvo Burgt (2007) CAP kreivės ir Tasche (2009) ROC kreivės metodai. Šių metodų χ^2 reikšmė buvo reikšmingai didesnė už kitų metodų χ^2 reikšmę. Pagal šį rodiklį patikimiausias buvo Forrest (2005) metodas be koreliacijos (nes χ^2 reikšmė – mažiausia).

Tačiau, taikant bet kurį LDP reitingų PD apskaičiavimo metodą, H_0 hipotezė buvo atmesta, nes statistikos p reikšmės visada buvo mažesnės už reikšmingumo lygmenį 0,05. Papildomai buvo įvertintas PD(4) kalibravimo tikslumas pirmam reitingui naudojant minimalią Lietuvos banko nustatytą PD – 0,03 %, o kitiems reitingams – įprastu būdu apskaičiuotas PD(4), netaikant LDP reitingų PD apskaičiavimo metodų. Tačiau ir šiuo atveju H_0 hipotezė buvo atmesta.

1 lentelė. Binominis (Voldo) ir H ir L kriterijai

A	B	C	D	E	F	G	H	I	J	K
Reitingas	ODF ₂₀₀₈	Paklaida (95 % pasikartojimo lygmuo)	Apatinė riba = B – C	Viršutinė riba = B + C	Burgi (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas	Pluto, Tasche (2005) metodas	Kiefer (2006) Bajeso metodas	Minimali PD
Binominis kriterijus										
1 LDP	0,54 %	0,75 %	-0,21 %	1,29 %	0,19 %	0,03 %	1,17 %	0,71 %	1,06 %	0,03 %
2 LDP	1,42 %	0,87 %	0,54 %	2,29 %	0,32 %	0,12 %	1,33 %	0,88 %	1,29 %	1,15 %
3 LDP	3,05 %	1,77 %	1,27 %	4,82 %	0,70 %	0,77 %	2,26 %	1,67 %	1,68 %	1,55 %
4	5,51 %	1,50 %	4,01 %	7,01 %	4,62 %	4,62 %	4,62 %	4,62 %	4,62 %	4,62 %
5	11,21 %	2,87 %	8,34 %	14,08 %	9,51 %	9,51 %	9,51 %	9,51 %	9,51 %	9,51 %
6	20,86 %	4,41 %	16,45 %	25,27 %	16,12 %	16,12 %	16,12 %	16,12 %	16,12 %	16,12 %
7 LDP	34,00 %	13,13 %	20,87 %	47,13 %	27,54 %	30,83 %	32,83 %	22,17 %	25,80 %	25,36 %
8	56,43 %	4,43 %	52,00 %	60,86 %	43,07 %	43,07 %	43,07 %	43,07 %	43,07 %	43,07 %
9	74,20 %	4,42 %	69,78 %	78,62 %	62,31 %	62,31 %	62,31 %	62,31 %	62,31 %	62,31 %
H ir L kriterijus										
χ^2 reikšmė					125,56	221,24	68,7	77,05	73,25	106,39
Statistikos p reikšmė					0,00	0,00	0,00	0,00	0,00	0,00

Šaltinis: autorės skaičiavimai.

Įprastų, ne LDP, reitingų (ketvirto-šešto ir aštunto-devinto) binominio (Voldo) kriterijaus taikymo rezultatai parodė, jog šešto bei aštunto ir devinto reitingų PD(4) nebuvo tikslios, nes jos nepateko į nustatytą intervalą ir visada buvo mažesnės už apatinę intervalo ribą.

2 lentelė. Binominis (vienpusis) kriterijus

Reitingas	Apskaičiuotas pasiklitavimo lygmuo							Minimali PD
	Burgt (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas	Pluto, Tasche (2005) metodas	Kiefer (2006) Bajeso metodas			
1 LDP	96,59%	99,98%	19,35%	51,29%	24,98%		99,98%	
2 LDP	100,00%	100,00%	65,94%	94,87%	69,39%		80,50%	
3 LDP	100,00%	100,00%	87,88%	98,02%	97,94%		98,82%	
4	90,82%	90,82%	90,82%	90,82%	90,82%		90,82%	
5	90,51%	90,51%	90,51%	90,51%	90,51%		90,51%	
6	99,01%	99,01%	99,01%	99,01%	99,01%		99,01%	
7 LDP	87,97%	74,20%	63,37%	98,19%	92,81%		93,77%	
8	100,00%	100,00%	100,00%	100,00%	100,00%		100,00%	
9	100,00%	100,00%	100,00%	100,00%	100,00%		100,00%	

Šaltinis: autorės skaičiavimai.

Binominio (vienpusio) kriterijaus ir binominio (vienpusio) kriterijaus naudojant normaliąją aproksimaciją (be koreliacijos) taikymo rezultatai buvo beveik vienodi, skyrėsi tik pirmo LDP reitingo PD(4) kalibravimo tikslumo vertinimo rezultatas taikant Burgt (2007) CAP kreivės metodą: pirmuoju atveju pirmo reitingo PD(4) buvo per mažą, o antruoju – tikslu (žr. 2 ir 3 lent.). Tik taikant vieną metodą – Forrest (2005) metodą be koreliacijos – visų LDP reitingų PD(4) buvo tikslios.

3 lentelė. Binominis (vienpusis) kriterijus naudojant normaliąją aproksimaciją (be koreliacijos)

Reitingas	ODF ₂₀₀₈	Kritinė PD(4) reikšmė, be koreliacijos							Minimali PD
		Burgt (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas	Pluto, Tasche (2005) metodas	Kiefer (2006) Bajeso metodas			
1 LDP	0,54 %	0,56 %	0,18 %	2,09 %	1,43 %	1,94 %	1,94 %	0,18 %	
2 LDP	1,42 %	0,67 %	0,33 %	2,04 %	1,46 %	1,46 %	1,99 %	1,81 %	
3 LDP	3,05 %	1,42 %	1,53 %	3,55 %	2,78 %	2,78 %	2,79 %	2,62 %	
4	5,51 %	5,78 %	5,78 %	5,78 %	5,78 %	5,78 %	5,78 %	5,78 %	
5	11,21 %	11,75 %	11,75 %	11,75 %	11,75 %	11,75 %	11,75 %	11,75 %	
6	20,86 %	19,47 %	19,47 %	19,47 %	19,47 %	19,47 %	19,47 %	19,47 %	
7 LDP	34,00 %	37,93 %	41,57 %	43,75 %	31,83 %	35,98 %	35,98 %	35,48 %	
8	56,43 %	46,78 %	46,78 %	46,78 %	46,78 %	46,78 %	46,78 %	46,78 %	
9	74,20 %	66,42 %	66,42 %	66,42 %	66,42 %	66,42 %	66,42 %	66,42 %	

Šaltinis: autorės skaičiavimai.

Kai taikant binominį (vienpusį) kriterijų su normaliąja aproksimacija buvo atsižvelgta į tapsmo „blogomis“ įmonės atvejų koreliaciją, kritinės PD(4) reikšmės tapo gerokai didesnės (žr. 4 lent.), todėl kriterijaus taikymo rezultatai buvo kur kas geresni nei ankstesnių kriterijų: tik taikant vieną iš LDP reitingų PD apskaičiavimo metodų – Tasche (2009) ROC kreivės metodą – antro LDP reitingo PD(4) buvo per maža (nes ODF buvo didesnis už kritinę reikšmę).

4 lentelė. Binominis (vienpusis) kriterijus naudojant normaliąją aproksimaciją (su koreliacija)

Reitingas	ODF ₂₀₀₈	Kritinė PD(4) reikšmė, 3 % koreliacija							Minimali PD
		Burgt (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas	Pluto, Tasche (2005) metodas	Kiefer (2006) Bajeso metodas			
1 LDP	0,54 %	1,48 %	0,54 %	4,36 %	3,20 %	4,10 %			0,54 %
2 LDP	1,42 %	1,97 %	1,13 %	4,67 %	3,60 %	4,58 %			4,26 %
3 LDP	3,05 %	3,18 %	3,37 %	6,68 %	5,48 %	5,50 %			5,22 %
4	5,51 %	10,71 %	10,71 %	10,71 %	10,71 %	10,71 %			10,71 %
5	11,21 %	18,15 %	18,15 %	18,15 %	18,15 %	18,15 %			18,15 %
6	20,86 %	27,10 %	27,10 %	27,10 %	27,10 %	27,10 %			27,10 %
7 LDP	34,00 %	43,87 %	47,71 %	50,00 %	37,36 %	41,80 %			41,27 %
8	56,43 %	57,64 %	57,64 %	57,64 %	57,64 %	57,64 %			57,64 %
9	74,20 %	76,70 %	76,70 %	76,70 %	76,70 %	76,70 %			76,70 %

Šaltinis: autorės skaičiavimai.

Taikant normalųjį (dvipusį) kriterijų rezultatai buvo tokie patys kaip ir taikant binominį (vienpusį) kriterijų su normaliaja aproksimacija (be koreliacijos) (žr. 5 lent.). Tik taikant Forrest (2005) metodą be koreliacijos visų LDP reitingų PD(4) buvo tikslios (nė viename iš LDP reitingų nebuvo atmesta H_0 hipotezė, nes skirtumo tarp ODF ir PD(4) modulis buvo ne didesnis už atitinkamą kritinę reikšmę).

5 lentelė. Normalusis (dvipusis) kriterijus

Reitingas	Kritinė skirtumo tarp ODF ₂₀₀₈ ir PD(4) reikšmė*								Minimali PD		
	Burgt (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas	Pluto, Tasche (2005) metodas	Kiefer (2006) Bajeso metodas	Burgt (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas		Pluto, Tasche (2005) metodas	Kiefer (2006) Bajeso metodas
1 LDP	0,44 %	0,18 %	1,10 %	0,86 %	1,04 %	0,44 %	0,18 %	1,10 %	0,86 %	1,04 %	0,18 %
2 LDP	0,42 %	0,26 %	0,85 %	0,69 %	0,83 %	0,42 %	0,26 %	0,85 %	0,69 %	0,83 %	0,27 %
3 LDP	0,86 %	0,90 %	1,53 %	1,32 %	1,33 %	0,86 %	0,90 %	1,53 %	1,32 %	1,33 %	1,27 %
4	1,38 %	1,38 %	1,38 %	1,38 %	1,38 %	1,38 %	1,38 %	1,38 %	1,38 %	1,38 %	1,38 %
5	2,67 %	2,67 %	2,67 %	2,67 %	2,67 %	2,67 %	2,67 %	2,67 %	2,67 %	2,67 %	2,67 %
6	3,99 %	3,99 %	3,99 %	3,99 %	3,99 %	3,99 %	3,99 %	3,99 %	3,99 %	3,99 %	3,99 %
7 LDP	12,38 %	12,80 %	13,02 %	11,51 %	12,13 %	12,38 %	12,80 %	13,02 %	11,51 %	12,13 %	12,06 %
8	4,42 %	4,42 %	4,42 %	4,42 %	4,42 %	4,42 %	4,42 %	4,42 %	4,42 %	4,42 %	4,42 %
9	4,90 %	4,90 %	4,90 %	4,90 %	4,90 %	4,90 %	4,90 %	4,90 %	4,90 %	4,90 %	4,90 %

Šaltinis: autorės skaičiavimai.

Taikant ilgo laikotarpio normalųjį kriterijų, tik kelios PD(4) buvo per mažos (nes atitinkamos reikšmės buvo didesnės už atvirkštinės standartinio normaliojo dydžio pasiskirstymo funkcijos reikšmę, kai pasikliovimo lygmuo 95 % (1,64)) (žr. 6 lent.).

6 lentelė. Ilgo laikotarpio normalusis kriterijus

Reitingas	Reikšmė, lyginama su 1,64								Minimali PD		
	Burgt (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas	Pluto, Tasche (2005) metodas	Kiefer (2006) Bajeso metodas	Burgt (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas		Pluto, Tasche (2005) metodas	Kiefer (2006) Bajeso metodas
1 LDP	-0,02	0,82	-5,48	-2,93	-4,84	-0,02	0,82	-5,48	-2,93	-4,84	0,83
2 LDP	8,10	9,87	-0,83	3,14	-0,43	8,10	9,87	-0,83	3,14	-0,43	0,80
3 LDP	1,32	1,25	-0,21	0,37	0,36	1,32	1,25	-0,21	0,37	0,36	0,49
4	0,80	0,80	0,80	0,80	0,80	0,80	0,80	0,80	0,80	0,80	0,80
5	0,27	0,27	0,27	0,27	0,27	0,27	0,27	0,27	0,27	0,27	0,27
6	0,75	0,75	0,75	0,75	0,75	0,75	0,75	0,75	0,75	0,75	0,75
7 LDP	0,23	-0,85	-1,51	2,00	0,80	0,23	-0,85	-1,51	2,00	0,80	0,95
8	0,36	0,36	0,36	0,36	0,36	0,36	0,36	0,36	0,36	0,36	0,36
9	0,40	0,40	0,40	0,40	0,40	0,40	0,40	0,40	0,40	0,40	0,40

Šaltinis: autorės skaičiavimai.

Mažiausias Briero balas buvo taikant Forrest (2005) metodą be koreliacijos, didžiausias – taikant Pluto, Tasche (2005) metodą be koreliacijos, tačiau visi balai buvo labai panašūs tarpusavyje (žr. 7 lent.).

7 lentelė. Briero balų metodas (PD(4))

Reitingas	Briero balas naudojant PD(4)							
	Burgi (2007) CAP kreivės metodas	Tasche (2009) ROC kreivės metodas	Forrest (2005) metodas be koreliacijos	Pluto, Tasche (2005) metodas be koreliacijos	Kiefer (2006) Bajeso metodas	Minimali PD		
1	1,9937	1,9988	2,0037	1,9902	1,9991	1,9988		
2	9,9432	9,977	9,8589	9,8787	9,8595	9,8634		
3	10,8637	10,852	10,6872	10,7333	10,7323	10,7457		
4	46,3699	46,3699	46,3699	46,3699	46,3699	46,3699		
5	46,306	46,306	46,306	46,306	46,306	46,306		
6	54,5481	54,5481	54,5481	54,5481	54,5481	54,5481		
7	11,4287	11,2702	11,2268	11,9197	11,5562	11,5932		
8	127,1114	127,1114	127,1114	127,1114	127,1114	127,1114		
9	77,2936	77,2936	77,2936	77,2936	77,2936	77,2936		
Iš viso	0,09591	0,09588	0,0958	0,09599	0,09589	0,09591		

Šaltinis: autorės skaičiavimai.

EKSPONENTINIO PD GLODINIMO REZULTATAI*

Reitingas	Pluto, Tasche (2005) metodas be koreliacijų				Kiefer (2006) Bajeso metodas			
	Glodintos PD ₂₀₀₆ (ar ODF ₂₀₀₆)	Glodintos PD ₂₀₀₇ (ar ODF ₂₀₀₇)	Glodintos PD(4)	Perskaiciuotos PD(4)	Glodintos PD ₂₀₀₆ (ar ODF ₂₀₀₆)	Glodintos PD ₂₀₀₇ (ar ODF ₂₀₀₇)	Glodintos PD(4)	Perskaiciuotos PD(4)
1 LDP	0,28 %	0,97 %	0,64 %	0,63 %	0,41 %	1,22 %	0,84 %	0,81 %
2 LDP	0,56 %	1,70 %	1,17 %	1,13 %	0,77 %	2,07 %	1,47 %	1,42 %
3 LDP	1,11 %	2,98 %	2,13 %	2,05 %	1,43 %	3,53 %	2,57 %	2,48 %
4	2,21 %	5,21 %	3,88 %	3,71 %	2,66 %	6,00 %	4,49 %	4,33 %
5	4,40 %	9,11 %	7,07 %	6,76 %	4,97 %	10,21 %	7,85 %	7,59 %
6	8,74 %	15,93 %	12,88 %	12,34 %	9,27 %	17,36 %	13,72 %	13,32 %
7 LDP	17,37 %	27,87 %	23,46 %	22,62 %	17,28 %	29,54 %	23,99 %	23,41 %
8	34,51 %	48,74 %	42,74 %	41,63 %	32,24 %	50,25 %	41,96 %	41,25 %
9	68,58 %	85,26 %	77,86 %	76,92 %	60,12 %	85,49 %	73,37 %	72,81 %

Šaltinis: autorės skaičiavimai. *Glodintos PD(4) buvo apskaičiuotos glodinant su pradinėmis PD₂₀₀₆ ir PD₂₀₀₇ (ar, kai yra ne LDP reitingai – su pradinėmis ODF₂₀₀₆ ir ODF₂₀₀₇) apskaičiuotas PD(4). Perskaiciuotos PD(4) buvo apskaičiuotos kaip aritmetinis glodintų PD₂₀₀₆ ir PD₂₀₀₇ vidurkis.

PORTFELIO NPV ANALIZĖ*

1 lentelė. Portfelio NPV analizė naudojant kairimo imtį

Reitingas	TP	TN	FP	FN	ODF _i	ONDF _i	ODF _a	ONDF _a	c(FP), littais	b(TN), littais	c(FN), Lt.	b(TP), Lt.	NPV, mln. Lt.	Pajamos, mln. Lt.	Sąnaudos, mln. Lt.
1	4 706	0	18 093	0	0,00 %	100,00 %	20,64 %	79,36 %	5 560	5 560	45 000	45 000	-34,73	42,03	76,76
2	4 693	555	17 538	13	2,29 %	97,71 %	21,11 %	78,89 %	5 560	5 560	45 000	45 000	-28,21	45,77	73,98
3	4 653	2 058	16 035	53	2,51 %	97,49 %	22,49 %	77,51 %	5 560	5 560	45 000	45 000	-10,49	56,01	66,50
4	4 598	4 026	14 067	108	2,61 %	97,39 %	24,63 %	75,37 %	5 560	5 560	45 000	45 000	13,17	69,97	56,80
5	4 395	8 262	9 831	311	3,63 %	96,37 %	30,89 %	69,11 %	5 560	5 560	45 000	45 000	64,51	101,32	36,81
6	3 822	12 364	5 729	884	6,67 %	93,33 %	40,02 %	59,98 %	5 560	5 560	45 000	45 000	106,94	127,87	20,92
7	3 125	15 196	2 897	1 581	9,42 %	90,58 %	51,89 %	48,11 %	5 560	5 560	45 000	45 000	129,86	143,75	13,90
8	2 314	16 673	1 420	2 392	12,55 %	87,45 %	61,97 %	38,03 %	5 560	5 560	45 000	45 000	124,13	140,00	15,87
9	1 229	17 663	430	3 477	16,45 %	83,55 %	74,08 %	25,92 %	5 560	5 560	45 000	45 000	92,95	118,29	25,34

Šaltinis: autorės skaičiavimai. *Skaičiuojant buvo darytos tokios prielaidos: kiekviena įmonė kiekvienais metais pateikė tik po vieną paraišką paskolai gauti; LGD =45 %; nerizikinga palūkanų norma yra lygi 4 %; paskolos palūkanų norma yra lygi 5,56 %; paskolos suma yra lygi 100 000 litų; paskolos trukmė yra lygi vieneriems metams; kiekvieną paskolą grąžinti ir visas paskolos palūkanas sumokėti reikia tik vieną kartą metų pabaigoje.

2 lentelė. Portfelio NPV analizė naudojant patikimumo vertinimo imtį

Reitingas	TP	TN	FP	FN	ODF _i	ONDF _i	ODF _a	ONDF _a	c(FP), littais	b(TN), littais	c(FN), littais	b(TP), littais	NPV, littais	Pajamos, mln. litų	Sąnaudos, mln. litų
1	1 683	0	8 721	0	0,00 %	100,00 %	16,18 %	83,82 %	5 560	5 560	45 000	45 000	-27,30	11,78	39,08
2	1 681	688	8 033	2	0,29 %	99,71 %	17,30 %	82,70 %	5 560	5 560	45 000	45 000	-19,26	16,25	35,51
3	1 661	2 220	6 501	22	0,98 %	99,02 %	20,35 %	79,65 %	5 560	5 560	45 000	45 000	-1,31	26,38	27,69
4	1 642	3 165	5 556	41	1,28 %	98,72 %	22,81 %	77,19 %	5 560	5 560	45 000	45 000	9,96	32,91	22,95
5	1 529	5 333	3 388	154	2,81 %	97,19 %	31,10 %	68,90 %	5 560	5 560	45 000	45 000	35,62	48,28	12,67
6	1 397	6 669	2 052	286	4,11 %	95,89 %	40,50 %	59,50 %	5 560	5 560	45 000	45 000	51,64	58,67	7,04
7	1 204	7 624	1 097	479	5,91 %	94,09 %	52,33 %	47,67 %	5 560	5 560	45 000	45 000	61,59	65,61	4,02
8	1 088	7 929	792	595	6,98 %	93,02 %	57,87 %	42,13 %	5 560	5 560	45 000	45 000	63,09	66,68	3,58
9	493	8 503	218	1 190	12,28 %	87,72 %	69,34 %	30,66 %	5 560	5 560	45 000	45 000	47,99	54,67	6,68

Šaltinis: autorės skaičiavimai.

REITINGŲ SISTEMOS TAIKYMO LIETUVOS BANKUOSE GALIMYBĖS

	Lietuvos įmonių reitingų skalė	Reitingų skalės sudarymo principai	Lietuvos įmonių logistinės regresijos modelis	Įvesties kintamieji	Atstų paraiškų įtraukimo metodai	Kiti atskiruose modelio kūrimo etapuose taikyti metodai	Reitingų PD	LDP reitingų PD	Reitingų PD apskaičiavimo metodai	LDP reitingų apskaičiavimo metodai	Pakartotinio patikimumo vertinimo schema
Įmonių modeliai	Sava statistinį įmonių modelį kuriančiame banke	X	X	X	X	X	X	X	X	X	X
	Sava statistinį įmonių modelį taikančiame banke	X	X	X	-	-	X	X	X	X	X
	Sava ekspertinį įmonių modelį kuriančiame banke	X	X	X	-	-	X	X	X	X	X
	Sava ekspertinį įmonių modelį taikančiame banke	X	X	X	-	-	X	X	X	X	X
Fizinų asmenų modeliai	Sava statistinį fizinų asmenų modelį kuriančiame banke	-	X	-	X	X	-	-	X	X	X
	Sava statistinį fizinų asmenų modelį taikančiame banke	-	X	-	-	-	-	-	X	X	X
	Sava ekspertinį fizinų asmenų modelį kuriančiame banke	-	X	-	-	-	-	-	X	X	X
	Sava ekspertinį fizinų asmenų modelį taikančiame banke	-	X	-	-	-	-	-	X	X	X

Šaltinis: sudaryta autorės.

