

TARTU ÜLIKOOL  
Majandusteaduskond

Nikolay Kryzhanovskiy

**ERAISIKU KREDIIDIRISKI HINDAVA MUDELI  
KOOSTAMINE ETTEVÕTTE SNEL GRUPP OÜ NÄITEL**

Magistritöö sotsiaalteaduse magistri kraadi taotlemiseks majandusteaduses

Juhendaja: teadur Oliver Lukason

Tartu 2016

Soovitan suunata kaitsmisele.....

(juhendaja allkiri)

Kaitsmisele lubatud „“ .....2016.a.

.....õppetooli juhataja

.....

(õppetooli juhataja nimi ja allkiri)

Olen koostanud töö iseseisvalt. Kõik töö koostamisel kasutatud teiste autorite tööd, põhimõttelised seisukohad, kirjandusallikatest ja mujalt pärinevad andmed on viidatud.

.....

(töö autori allkiri)

## SISUKORD

<b>SISSEJUHATUS</b> .....	<b>4</b>
<b>1. ERAISIKUTE KREDIIRISKI OLEMUS JA MODELLEERIMISE TEOREETILISED ALUSED</b> .....	<b>8</b>
1.1 Eraisiku krediiriski olemus ja hindamine.....	8
1.2 Eraisiku krediiriski mõjutavad tegurid.....	21
1.3 Meetodid eraisiku krediiriski hindamiseks .....	31
<b>2. ERAISIKU KREDIIRISKI HINDAMISEKS SKOORINGMUDELI KOOSTAMINE ETTEVÖTTE SNEL GRUPP OÜ NÄITEL</b> .....	<b>40</b>
2.1 Ettevõtte lühituvustus, olemasolev krediidipoliitika ja eraisiku krediiriski hindamise süsteem .....	40
2.2 Eraisiku krediiriski modelleerimiseks kaasatud andmed ja muutujad .....	46
2.3 Skooringumodeli koostamine, tulemuste analüüs.....	53
<b>KOKKUVÕTE</b> .....	<b>69</b>
<b>KASUTATUD KIRJANDUS</b> .....	<b>74</b>
<b>LISAD</b> .....	<b>80</b>
<b>Lisa 1.</b> Väikelaenu laenuaotluse vorm (SNEL Grupp OÜ ettevõtte oma) .....	80
<b>Lisa 2.</b> Muutujate <i>sissetlk, kulud, reserv</i> ja <i>kohustus</i> kategooriad.....	81
<b>Lisa 3.</b> Lõpliku mudeli (L1) muutujate VIF ja TOL väärtused .....	81
<b>Lisa 4.</b> Andmete kirjeldav statistika ja informatsiooni väärtus ( <i>IV</i> ).....	82
<b>Lisa 5.</b> Lõpliku mudeli (L1) Pearsoni korrelatsiooni maatriks.....	83
<b>Lisa 6.</b> Lõpliku mudeli (L2) Pearsoni korrelatsiooni maatriks.....	84
<b>Lisa 7.</b> Lõpliku mudeli (L2) muutujate VIF ja TOL väärtused .....	85
<b>PEJOME</b> .....	<b>86</b>

## SISSEJUHATUS

Me elame ajal, mil finantsteenuste kasutamine on muutunud elu lahutamatuks osaks ning laenuvõtmine tavapäraseks tarbijakäitumiseks. Erinevate laenutoodete ja nende tarbijate hulk kasvab iga aastaga. See viitab asjaolule, et oma tulevikus saadava sissetuleku arvel inimesed üha rohkem eelistavad tarbida viivitamata. Kasvav nõudlus antud teenuste vastu avaldub suurenevas pakkumises ja selle tulemusena näeb tänapäeval kõikvõimalikke järelmaksu, liisingu, väike- ja tarbimislaenu reklaame igal pool nii tänavatel, meedias kui ka internetis. Vaadates ükskõik millist Eesti ajalehte, võib alati leida artikleid ja arvamusi selle kohta, kuivõrd häirivaks on muutunud kiirlaenude reklaam. Nimelt see asjaolu oli esmaseks ajendiks autorile oma magistritöö teema valikul.

Teiseks, Majandus- ja Kommunikatsiooniministeeriumi läbi viidud analüüsi (Kiirlaenuturg... 2014: 4-8) põhjal on kiirlaenu võtnud 100 000 kuni 190 000 inimest ning kiirlaenude või tarbijakrediidile spetsialiseerunud ettevõtete poolt välja antud laenude alusel on tekkinud maksehäireid 30.01.2014 seisuga 34 706 isikul. Seega võib öelda, et ligikaudu kolmandik väljastatavatest laenudest on probleemsed. Kasvab ka vastavaid finantsteenuseid pakkuvate ettevõtete arv: Finantsinspektsiooni järelevalvega katmata laenuuru osas tegutseb üle 100 ettevõtte ning nende arv pidevalt suureneb. Kasvu üheks põhjuseks on eriti viimasel ajal märgatav trend, et teistest Euroopa Liikmesriikidest tulevad ettevõtted oma filiaalidega Eestisse, kuna Eestis kehtivad laenuandmisele leebemad nõuded.

Laenuandja poolt puudulikult teostatud maksevõime analüüs väljendub tihti selles, et osad kliendid kaotavad kontrolli oma finantsolukorra üle, kuna saadud laenu teenindamine osutub probleemseks. Ka arutelu meedias viitab sellele, et üha rohkem muret tekitab maksejõuetu inimeste arvu kasv. Oma uurimuses Skiba ja Tobacman (2011: 21) jõudsid järelduseni, et kiirlaenude kasutamine suurendab tõenäosust muuta

maksejõuetuks. Samas Neil Bhutta uurimusest (2013: 20) selgus, et antud teenuse olemasolu ja kasutamise ning inimeste finantsilise heaolu vahel puudub tähelepanuväärne seos.

Kahtlemata ei saa nõrk või ebapiisav laenuaotleja maksevõime analüüs ja krediidiriski hindamine mõjutada positiivselt krediidiandja majandustulemust, eriti olukorras, kus vaadeldaval turul valitseb väga tihe konkurets. Lähimõttlemata krediidipoliitika võib põhjustada laenuportfelli kvaliteedi langust ning halvemal juhul ettevõtte ebaõnnestumist ja pankrotistumist. Sellepärast võimalikult ratsionaalsemad ja täpsemad otsused eraisiku krediidiriski hindamises ja juhtimises on äärmiselt tähtsad ettevõtete konkurentsivõime tõstmise ja jätkusuutlikkuse mõttes. Selleks, et parandada oma krediidiotsused, ettevõtted üha rohkem pööravad tähelepanu erinevatele statistilistele krediidiriski hindamismeetoditele, kuna traditsioonilised meetodid üha vähem vastavad tänapäeva oludele. Näiteks, Eesti suuremates kommertsbankades (Swedbank, SEB bank, Danske Bank ja teised) kasutatakse laenude analüüsimisel reiting- või skooringu-meetodit, mille eesmärgiks on hinnata makseviivituse või maksmata jätmise tõenäosust (*probability of default*). Hindamine toimub ajalooliste andmete põhjal, mis on võimalik saada nii krediidiandja andmebaasidest kui ka avalikest andmebaasidest.

Eraisiku krediidiriski hindamine ei ole Eestis väga levinud uurimisvaldkond: pigem analüüsitakse ja modelleeritakse äriühingute pankrotistumist ning ebaõnnestumist teatud majandusharu lõikes. Osades krediidiriski käsitlevates uuringutes piirduvad autorid krediidiriski hindamise ja krediidipoliitika kirjeldamisega konkreetse ettevõtte näitel ning enamik skoorimudelitest on saadud kommertsbankade andmete analüüsimisel. On leitud, et eraisikust laenuaotleja krediidiriski hindamismeetodid peaksid arvestama mikrokrediteerimisega tegelevate ettevõtete eripäradega ja väikelaene taotlejate karakteristikutega (JianHua, Tao 2010: 1112). Valminud uurimusest, kus eraisiku krediidiriski hindava skoorimudelit saadi Eestis mitte panga andmete analüüsimisel, autoril ei ole midagi teada.

Autori eesmärgiks on käesoleva magistritöö kirjutamisel eraisiku krediidiriski hindava mudeli koostamine mikrokrediteerimisega tegeleva ettevõtte näitel. Mudeli koostamise käigus selgitatakse, millised demograafilised, sotsiaalsed, varasemat maksekäitumist kirjeldavad ja muud tegurid eristavad laenu korrektelt tasunud ja tasumata jätnud

kliente. Valmiva skoorimudeli ülesandeks on anda laenuaotlejale hinnangu võetava kohustuse ebakorrekse teenindamise tõenäosusele. Kõnealune mudel on heaks vahendiks nii laenuotsuste tegemise kvaliteedi täiustamiseks kui ka tööprotsesside optimeerimiseks. Eelpool nimetatud eesmärgini jõudmiseks kasutatakse logit-analüüsi.

Töö eesmärgist lähtuvalt on püstitatud järgmised uurimisülesanded:

- määratleda eraisiku krediidiriski mõistet ning välja tuua selle hindamise võimalused;
- selgitada eraisiku krediidiriski mõjutavaid tegureid;
- analüüsida erinevate hindamismeetodite nõrku ja tugevaid külgi ning seostada varem saadud tulemustega;
- tutvustada ja analüüsida SNEL Grupp OÜ-s kasutatavaid eraisikute krediidiriski hindamise etappe ja –meetodit;
- SNEL Grupp OÜ andmebaasist saadavate andmete kirjeldamine ja töötlemine;
- logit-analüüsi kasutades skoorimudeli koostamine ning tulemuste analüüsimine.

Teoreetilise osa tagapõhja avamisel tuginetakse inglisekeelsele kirjandusele ja artiklitele. Viidatud ka ühe Tartu Ülikooli majandusteaduskonnas valminud magistritööle, mis käsitleb eraisiku krediidiriski hindamist Krediidipanga näitel. Empiirilise osa kirjutamiseks kasutatakse esmaseid andmeid SNEL Grupp OÜ andmebaasidest.

Käesoleva magistritöö sisuline osa koosneb kahest peatükist, kus töö esimeses peatükis tuuakse välja eraisiku krediidiriski teoreetiline käsitlus, selle hindamise etapid ja meetodid. Vaatluse alla tulevad ka eraisiku krediidiriski mõjutavad tegurid – autor üldistab praktikas aset leidnud ja teoorias pakutud erinevaid mõjureid. Teoreetilise osa viimases alapunktis tuuakse ülevaade skoorimudeli koostamise meetoditest ja varasematest tulemustest. Töö teises peatükis tutvustatakse ja analüüsitakse SNEL Grupp OÜ-s kasutatavat eraisikute krediidiriski hindamismeetodit. Viimaks kirjeldatakse modelleerimisprotsessi tarbeks kasutatud andmeid, koostatakse skoorimudel eraisikute krediidiriski hindamiseks ning selgitatakse välja seda mõjutavad tegurid ning mudeli rakendamise võimalusi ja võimalikke tulemusi.

Esiteks tänab autor oma juhendajat Oliver Lukason`it väärtuslike nõuannete ja tähelepanekute eest. Lisaks tänab autor Anton Adamenkov`it, kes võimaldas kasutada SNEL Grupp OÜ andmebaase vajalike andmete kättesaamiseks. Lõpuks autor soovib tänada Tatjana Kudrjajtseva`t töö keelelise korrektsuse kontrollimise eest.

**Märksõnad:** eraisiku krediidirisk, krediidiriski modelleerimine, skoorimudel, logistiline analüüs

# 1. ERAISIKUTE KREDIIDIRISKI OLEMUS JA MODELLEERIMISE TEOREETILISED ALUSED

## 1.1 Erasiku krediidiriski olemus ja hindamine

Selleks, et midagi hinnata ja erinevaid protsesse modelleerida, peab esmalt selgelt defineerima hinnatavat objekti või nähtust. Kuigi sõna „risk“ kasutatakse nii igapäevases suhtluses kui ka kirjanduses üsna tihti, ei ole selle termini sisu üheselt arusaadav. Ka erinevad autorid on defineerinud riski mitmeti. Näiteks, Perry (2003: 4) defineerib riski kui tõenäosust, et oht või sellest tulenev kahju realiseerub. Ghosh (2012: 21) arvab, et risk on potentsiaalne kahju, mis võib tekkida teatud sündmuste esinemise tõttu. Väga lühidalt ja täpselt on panganduse riski kirjeldanud Cade (1999: 12) – „risk on tulemuse määramatuse oht“. Iga otsusega kaasnev risk tuleneb selle otsuse tagajärgede määramatusest ehk ebasoodsa sündmuse esinemise võimalusest. On tähtis ka mõista, et riski juhtimine ei seisne üksnes riski vähendamises, vaid läbimõeldud ja planeeritud riski võtmises (Cade 1999: 15).

Panga tegevuse tulemusi mõjutavaid riske võib jagada selle tekkekoha järgi sise- ja välisriskiks. Olulisemad välisriskid ehk välisjõud, mis mõjutavad panga oodatavat kasumit on: tehnoloogia risk, regulatiivne risk, intressimäära risk, konkurents ja kapital. Üldisemalt tuuakse erialases kirjanduses kuni 5 fundamentaalset pangandusriski (Cade 1999: 18-22; Gestel, Baesens 2009: 23-40; Koch 1992: 112-113; Rose 1991: 140):

1. **Krediidirisk** (*credit risk*) on oht, et tehingu vastaspoole kohustuste mittekohasest täitmisest võib tekkida kahju.
2. **Likviidsusrisk** (*liquidity risk*) - ettevõtte võimetus hankida likviidseid rahalisi vahendeid finantskohustuste täitmiseks.
3. **Intressimäära risk** (*intrest rate risk*) – potentsiaalne panga intressitulu suuruse muutus, mis on tingitud turu intressimäärade muutumisest.



4. **Operatsioonirisk** (*operational risk*) – oht saada kahju, mille põhjustajateks võivad olla ettevõtte süsteem, töötajad, vigased sisemised protsessid. Operatsiooni risk on seotud ka kehtivate regulatsioonide ja seadusandlusega.
5. **Kapitalirisk** (*capital risk*) või maksevõimelisuse risk (*solvency risk*), on oht, et liiga suure riski tõttu võib pank muutuda maksejõuetuks ehk aktive turuväärtus on kohustustest väiksem.

Mõned autorid toovad veel sellised pangandusriskid nagu: tururisk, välisvaluutarisk, suveräänsusrisk, maarisk ja muud riskid. Osa ülaltoodud riskidest ei eksisteeri mikrokrediteerimisega tegeleva ettevõtte jaoks, kuna finantseerimisasutuste struktuur võrreldes pankade struktuuriga on tavaliselt lihtsam. Vaatamata sellele, et erinevad autorid pakuvad erinevaid pangandusriske ja nende definitsioone, tuuakse esimesele kohale alati krediidiriski.

Krediidirisk on üks vanimaid pankade tegevusega seonduvaid riske. Krediidiriski hindamise tähtsus seisneb selles, et pankade üheks põhi- ja tulutoovaks tegevuseks on krediteerimine: tagatiseta või tagatisel nii era- kui ka juriidilistele isikutele raha väljalaenamine. Krediidiriski peetakse võtmeriskiks, mis mõjutab panga tulemuslikkust (Sinkey 1992: 279; Cade 1997: 20-21). Tõepoolest, laenu-tegevus on väga oluline panga tegevusvaldkond, mis toob pankadele suuremat tulu. Allpool asuvas tabelis 1.1 leidub selle kinnitus.

**Tabel 1.1** Eesti pankade intressi- ja teenustasutulu aastatel 2011-2014 (mln EUR)

	31.12.2011	31.12.2012	31.12.2013	31.12.2014
Intressitulu kokku	606,9	537,2	440,9	444,3
Intressitulu laenudelt	575,8	496,7	414,5	414,3
Intressitulu laenudelt/kogu intressitulu	94,88%	92,46%	94,01%	93,25%
Teenus- ja vahendustasu tulu	177,4	179,9	190,1	193,9
Laenude intressitulu ja teenustasutulu suhe	3,25	2,76	2,18	2,14

Allikas: autori koostatud Eesti Panga statistika põhjal.

Eesti krediidasutuste koondaruandest selgub, et pankade tuludest moodustavad intressitulud laenudelt suurima osa – 92% kuni 94%. Suuruse järgi teine tuluallikas – teenustasutulu – oli vaadeldaval perioodil keskmiselt 2,5 korda väiksem, kuid viimastel aastatel võib märgata selle tuluallika kasvutrendi. Panga laenuportfelli kvaliteet, mis

tagab intressitulu saamise, panga tegevuse jätkusuutlikkuse ja edukuse tagamise seisukohast on väga tähtsal kohal.

Krediidirisk on otseselt seotud panga laenamistegevusega ja sellepärast kirjeldavad paljud autorid seda kui potentsiaalset riski, et laenusaja ei täida oma kohustust tagastada laenu kokkulepitud tingimustel, summas (põhisumma ja intressid) ning tähtajal (Casu *et al* 2006: 259; Koch 1992: 112; Gestel, Baesens 2009: 24). Mõned autorid pakuvad krediidiriski laiema definitsiooni ning kirjeldavad seda, kui tõenäosust, et panga varad, eriti laenud, võivad kaotada enda väärtust ja muutuda väärtusetuks (Rose 1991: 140). Antud töö kontekstis on krediidiriski definitsiooniks loetakse klientide kohustustuste tasumata jätmise riski ehk tõenäosust, et võetud laen jääb tagastamata (*probability of default*). Järgmisena toob autor eraisiku krediidiriski mõned aspektid, mis on antud töö kontekstis olulised: laenu liik, riski ulatus ja riski realiseerimise aeg.

Kirjandust, mis käsitleb eraisiku krediidiriski hindamisel mikrokrediteerimisega tegeleva ettevõtte seisukohast, on suhteliselt vähe. Enamus antud töös analüüsitud uurimusest on ikkagi universaalpankade klientide ja laenude näitel. Need autorid, kes analüüsisid just mikrokrediteerimisega tegeleva ettevõtte krediidiriski on kasutanud samad tehnikad, põhimõtted ja tegurid krediidiriski modelleerimiseks (Gool *et al.* 2012: 104-106). Siiski soovib antud töö autor lühidalt kirjeldada, mille poolest on pangalaen erineb mikrokrediteerimisega tegeleva ettevõtte laenust ning sellest tulenevalt ka antud teenuse tarbija.

Mikrokrediteerimisega<sup>1</sup> tegelevate finantseerimisasutuste laenamistegevuse põhitooteks on üldiselt tagatiseta väikelaen. Teenuse kättesaadavuse, lihtsuse ja kiiruse ning suhteliselt väike laenusumma (50 kuni 5000 EUR) ja lühikese perioodi (7 päevast kuni 3, harva 5, aastani) tõttu nimetatakse seda kiirlaenuks<sup>2</sup>. Üldiselt loetakse, et kiirlaenude kasutajad on suurema krediidiriskiga võrreldes pangalaenude kasutajatega. Risk väljendub mitmetes faktorites, mis eelkõige iseloomustavad kliendi usaldatavust ja maksevõimet.

---

<sup>1</sup> Antud töös kasutab autor sünonüümidena mõisted krediteerimine ja laenamine ning krediit ja laen.

<sup>2</sup> Inglise keelses kasutatakse väljendit „palgalaen“ (*payday loan*) või „mikrolaen“ (*microloan*).

Kiirraenu ohtlikkus peitub kõrgetes intressides, mis esialgu aga ei torka silma, kuna laenupakkumine ja tagasimaksegraafik esitatakse absoluutsummates. Siiski antud teenuse kohta tekitab rohkem muret puudulik või suhteliselt pealiskaudne eraisiku makse- ehk krediivõime (*creditworthiness* või *capacity*) analüüs, mille tulemusena kannatavad nii kliendid kui ka laenupakkujad. Koch (1992: 720) defineerib krediivõimet kui isiku finantsilist võimekust täita krediidilepingust tulenevaid kohustusi olemasolevate elamiskulude ja teiste finantskohustuste juures. Kliendi maksevõime määrab kindlaks, milline on maksimaalne laenukohustuste summa, mida ta suudab teenindada.

Puudulik krediivõime kontroll võib realiseeruda laenusaja maksejõuetuses, mis toob ettevõttele kahju tagastamata laenu näol. Laenuvõtja võib olla nii ajutiselt kui ka püsivalt maksejõuetu. Eesti Pankrotiseaduse § 1 sätestab, et isik on maksejõuetu siis, kui ta ei suuda rahuldada võlausaldaja nõudeid ja see suutmatus on võlgniku majanduslikust olukorrast tulenevalt alaline. Ettevõtte jaoks see tähendab laenuportfelli kvaliteedi langust mittetöötava<sup>3</sup> laenu (*non-performing loan*) tõttu. Sõltuvalt sellest, kas eraisiku laen oli tagatud kinnis- või vallasvaraga (nt auto) või laen oli väljastatud käendusel, ettevõttel on siiski olemas võimalus osaliselt oma laenu tagasi saada tagatise realiseerimise teel. Ajutise maksejõuetuse puhul võivad pangad pakkuda kliendile laenu restruktureerimist, mis üldiselt tähendab igakuise osamakse alandamist laenuperioodi pikendamise teel, või pikemat maksepuhkust, mille jooksul peatuvad nii laenu põhiosa kui ka intressi tagasimaksed. Antud töö kontekstist lähtuvalt analüüsitakse ja modelleeritakse makseviivituse tekkimise tõenäosus, mitte seda, kas ja mis ulatuses lõpuks saab ettevõtte oma laenu tagasi.

Krediidiriski modelleerimisel on oluline ka määratlenda, milline on „õige“ aeg, millal laenu võib pidada tasumata jäetuks ja laenuvõtjat kohustuse mitte täitnuks ehk maksejõuetuks. Paljud autorid jagavad seisukohta, et mittetöötavaks muutub laen siis, kui kohustuste täitmise kuupäevast on möödunud rohkem kui 90 päeva (Rose 1991: 140; Gestel, Baesens 2009: 25). Ka vastavalt Eesti Panga presidendi määrusele nr 9 „Krediidiasutuste laenude teenindamine ja ebatõenäoliselt laekuvate nõuete kuludesse kandmine“ punktide 8.4 ja 8.5 järgi peavad pangad lõpetamata intresside tekkepõhise

---

<sup>3</sup> Mittetöötav laen on laen, mis on kas täielikult või osaliselt hinnatud ebatõenäoliselt laekuvaks.

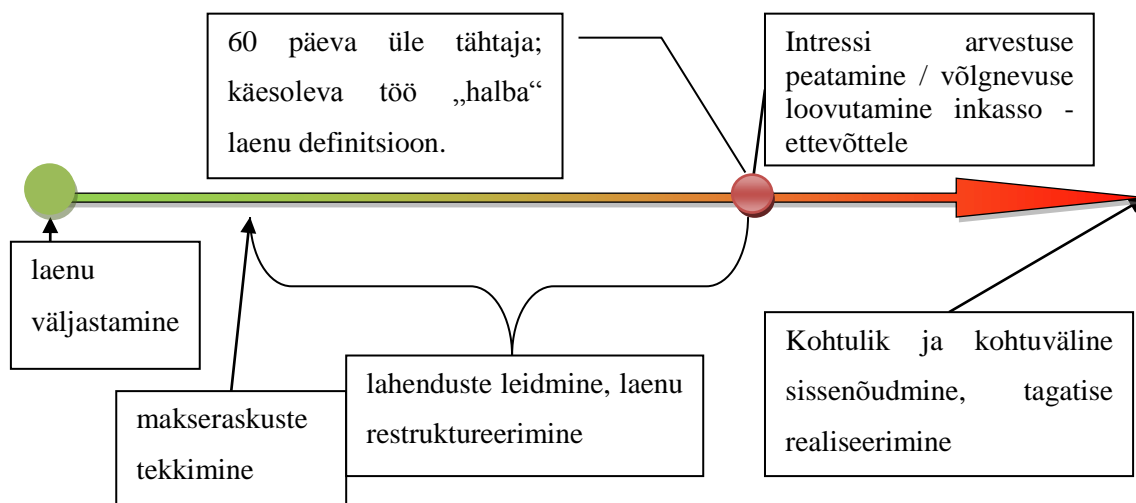
arvestamise nendel laenudel, mille maksetähtajast on möödunud 90 kalendripäeva. Tegelikult lõpetavad pangad intressiarvestuse juba 60-päevase viivituse korral. Mikrokrediteerimisega tegelevad ettevõtted võivad kasutada ka rangemad definitsioonid, näiteks 15 päeva üle tähtaja (Caire *et al.* 2006: 10). Praktikud, kes kasutavad krediidiriski modelleerimiseks skoorimudeleid, defineerivad „halva“ laenu kui laenu, mille puhul on tasumata 3 järjekordset osamakset ehk tavaliselt 60 päeva üle tähtaja (Thomas *et al.* 2002: 123). Allpool asuvas tabelis 1.2 on toodud ülevaade erinevatest definitsioonidest, mida uurijad on kasutanud oma töödes tasumata jäetud laenu jaoks.

**Tabel 1.2** Erinevad laenu tasumata jätmise definitsioonid

	<b>„Halva“ laenu definitsioon</b>	<b>Autor ja aasta</b>
1	viivituspäevade arv üle 2	Gool <i>et al.</i> 2012
2	viivituspäevade arv üle 60 / 3 tasumata osamakset	Baesens <i>et al.</i> 2003; Ong <i>et al.</i> 2005; West 2000
3	viivituspäevade arv üle 63	Kokk 2011
4	viivituspäevade arv üle 90	Kočenda, Vojtek 2009; Baesens <i>et al.</i> 2005
5	viivituspäevade arv üle 180	Greene 2008
6	laenu loovutamine inkasso-ettevõttele, päevade arv määramata	Jacobson, Roszbach 2003; Banasik <i>et al.</i> 2003

Allikas: autori koostatud.

Ülaltoodud tabelist 1.2 selgub, et „halva“ laenu või maksejõuetu kliendi definitsioonid on väga erinevad. Mõned uurijad kasutavad väga rangeid kriteeriume - viivituspäevade arv on üle 2, mõned aga vastupidised – viivitus üle 180 päeva. Äärmised definitsioonid ei tundu autorile optimaalsed olevat, kuid kõik sõltub siiski uurija eesmärkidest. Spetsialiseeritud ettevõttele võlgnevuse üleandmine sissenõudmise eesmärgiga on autori arvamusel piisavalt mõistlik hetk, mille arvates võib laenu tõepoolest pidada „halvaks“. Nagu eespool on mainitud, ei tähenda krediidiriski realiseerumine veel seda, et laenuandja ei saa oma laenu täies ulatuses tagasi. Sõltuvalt laenu tüübist võib tagatise realiseerimisest saadav summa osaliselt või täielikult katta laenu väljastamise, sissenõudmise ja muud kulud. Järgmisel joonisel 1.1 on visualiseeritud „halva“ laenu eluiga.



**Joonis 1.1** “Halva” laenu võimalik eluiga. (autori koostatud)

Nii pangad kui ka uurijad defineerivad oma töö eesmärkidest lähtuvalt krediidiriski realiseerimist väga erinevalt. Kõik sõltub sellest, milline punkt joonisel 1.1 panga või uurija jaoks omab suuremat tähtsust, kas lühiajaline viivitus või mitmekuuline hilinemine kuni võlgnevuse loovutamiseni ja tagatise, selle olemasolu korral, realiseerimiseni. Antud töö autori arvates on 60-päevane viivitus piisav ja mõistlik, et pidada eraisikut maksejõuetuks ja laenu „halvaks“ ehk tagastamata jäetuks ning kooskõlas näitena võetud ettevõtte huvidega (vt. alapunkti 2.2). Seega eraisiku krediidirisk realiseerub, kui võetud laenu tagasimaksmist ei toimu üle 60 päeva, edaspidi nimetatakse antud töös sellist laenu „halvaks“ ja vastava laenusaja kohustuse mittetäitnuks ja maksejõuetuks muutunuks. „Hea“ laenu puhul ei ületa makseviivitus tagasimakseperioodil 60 päeva, mis on korrektse ja maksevõimelise kliendi tunnuseks. Järgmisena tuuakse krediidiriski juhtimise võimalused ja hindamismeetodid.

Krediidiriski hindamine ja juhtimine on terve süsteem, mis algab sellest, et määratakse sihtturgu ja segmenteeritakse kliente. Üldjuhul pannakse need tähtsad punktid paika ettevõtte krediidipoliitikas. Teoorias on kirjeldatud mitmed krediidiriski juhtimismeetodid. Näiteks, võib riski jagada kaheks (Casu *et al* 2006: 279):

- 1) kvantitatiivne risk,
- 2) kvalitatiivne risk.

Kvantitatiivne osa kirjeldab pakutavaid müügitingimusi ehk krediidi andmise üldiseid kriteeriume: maksimaalne laenusumma, maksimaalne tagasimakse tähtaeg, intressimäär ja muud. Riski maandamiseks kasutatakse ka teisi kvantitatiivseid komponente, kuid viimasel ajal tihenend konkurentsi tõttu üha rohkem pööratakse tähelepanu just kvalitatiivse riski maandamisele. Kvalitatiivne osa keskendub aga rohkem laenuaotluse analüüsile ehk potentsiaalselt riskantsete klientide väljaselgitamisele. Riski kvalitatiivne tase kiirraenuettevõttes on kommertspankadest kõrgem, kuna laenuotsuste tegemine kulgeb tavaliselt kiiremini, mille tulemusena jääb maksevõime hindamise kvaliteet madalamaks. Riski kvalitatiivse komponendi maandamiseks kasutavad finantseerimisetevõtted pankadest kõrgemaid intressimäärasid, et potentsiaalse maksmata jäänud laenu tõttu kaotatud raha oleks võimalik katta „heade“ laenude arvelt.

Teistsugust riski liigitamist selle parema võimaliku juhtimise jaoks pakuvad Gestel ja Baesens (2009: 42-43):

1. **Valik** (*selection*). Hea krediidiriski juhtimine algab laenuaotlejate selekteerimisest. Kvalifitseeritud laenuametnikud<sup>4</sup> ning tugevad riski hindavad mudelid on hea valiku võtmefaktorid. Vastavalt üleval käsitletule on tegemist kvalitatiivse meetodiga.
2. **Kitsendused** (*limitations*) reglementeerivad müügitingimusi. Kitsenduste eesmärgiks on konkretiseerida, mis tingimusel ja kui suure laenusumma võib väljastada teatud krediidiriskiga kliendile. Tegemist on riski maandamise kvantitatiivse meetodiga Casu *et al* (2006: 279) käsitluse järgi.
3. **Diversifitseerimine** (*diversification*) on krediidiportfelli hajutamine, mille eesmärgiks on tagada, et panga portfell ei oleks liiga kontsentreeritud ühele kliendigrupile, laenuototele, geograafilise piirkonnale või tööstusharule.
4. **Laenude kvaliteedi parandamine** (*credit enhancement*). Kui panga hinnangul on tema laenuportfell mingi kliendigrupi suhtes liiga kontsentreeritud, võib pank osta kindlustust garantiide või krediididerivatiivide näol.

---

<sup>4</sup> Laenuametnik (edaspidi ka laenuhaldur) on laenuaotluse menetlemisega tegelev, krediidiriski hindav pangatöötaja, kelle kohustuseks võib olla ka laenuotsuste langetamine.

Ülaltoodust järeldeb, et krediidiriski võib juhtida ja maandada mitmeti. Osa meetmetest rakendatakse laenuportfelli tasandil, teised puudutavad müügitingimusi. Töö eesmärgist lähtuvalt peatub autor just esimesel meetodil, mis käsitleb laenuaotleja ja –taotluse hindamist.

Üleüldine krediidiriski hindamise printsiip on võrrelda klientide karakteristikute omadused nende klientide omadustega, kelle laenud on varasemal perioodil juba tagasi makstud. Kui karakteristikud on piisaval määral sarnased nende klientide karakteristikutega, kes on laenu korrektselt tagastanud, siis võetakse positiivne laenuotsus vastu ning väljastatakse laenu ja vastupidi: laenuaotlus lükatakse tagasi, kui laenuaotleja karakteristikud sarnanevad probleemse kliendi omaga. (Abdou, Pointon 2011: 60-61) Krediidiriski hindamismeetodeid on väga palju. Üldisemalt võib neid jagada kaheks: subjektiivne (*judgmental*) ja skoorimismeetod (*credit scoring*).

Subjektiivne meetod (ka kvalitatiivne meetod) on traditsiooniline meetod, mida kasutatakse eraisikute krediidiriski hindamiseks. Laenuametniku ülesandeks on kliendiga suhtlemine, laenuanalüüsi tegemine ja laenuandmise ettepaneku koostamine. Vastavalt sellele meetodile võetakse laenuanalüüsi käigus arvesse nii laenuaotleja omadusi ja karakteristikuid kui ka väliskeskonna mõjureid. (Kalapodas, Thomson 2006: 26) Laenuaotleja spetsiifiliste omaduste hulka kuuluvad kõik tegurid, mis võivad ohustada tema kohustuste täitmist panga ees. Subjektiivne meetod eeldab potentsiaalse laenuvõtja isiklike omaduste ja finantsseisu kaalutletud analüüsi. Laenuametnik tõlgendab subjektiivselt laenuvõtja kohta olevat teavet ning otsustab pärast informatsiooni põhjalikku läbitöötamist, kas klient on krediivõimeline või mitte.

Maksevõime analüüsi põhjalikkus sõltub taotletavast summast ja tagasimakse graafiku pikkusest. Mida lühem on laenuperiood, seda vähem aega kulub analüüsimisele, kuna puudub vajadus väga põhjalikult üksikasjalikult hinnata sissetuleku jätkusuutlikkust ja töökoha püsivust. Mida pikem on maksegraafik, seda rohkem tähelepanu pööratakse ka teistele olulistele laenuaotleja karakteristikutele nagu haridus, töökogemus ja amet (McNaughton 1992: 36).

Subjektiivsel meetodil on mitmed tugevad küljed. Esimesena võib pidada selle lihtsust. Subjektiivne meetod ei nõua keerulist matemaatikat ega arvutiprogramme, see eeldab

vaid andmekogumit ja analüüsimist ning isiklikku kontakti potentsiaalse laenuvõtjaga. Meetodi eeliseks on laenuvõtja ja panka tihedate omavaheliste suhete välja kujunemine. (Kalapodas, Thomson 2006: 27) Lisaks sellele on personaalne lähenemine kindlasti parem siis, kui analüüsitakse laenuaotlust, mis tugevasti erineb eelnevatest (Hand, Henley 1997: 531). Järgnevalt on toodud subjektiivse hindamismeetodi puudused.

Kõige suuremaks puuduseks võib kvalitatiivse meetodi puhul pidada selle subjektiivsust. Informatsiooni tõlgendamine sõltub laenuametniku oskustest, tujust, pädevusest ja muudest faktoritest. Kogu kättesaadava informatsiooni analüüsimine ja tõlgendamine on pikk ja raske protsess, mille tulemusena võidakse krediidiriski tegurid valikuliselt analüüsi protsessi kaasata. Veel üheks nõrkuseks on antud meetodi hind – krediidiriski hindamine nõuab palju aega ja inimtööjõudu. Ning viimaseks võib nimetada asjaolu, et laenuametnik ei saa aru, kas laen mitmekesistab või suurendab laenuportfelli kontsentratsiooni. (Kalapodas, Thomson 2006: 27-28) Lisaks ei suuda laenuametnik öelda, millised tegurid on tõepoolest olulised eristamas maksevõimelist ja maksevõimetu eraisikut. Kokkuvõtteks võib öelda, et subjektiivsel meetodil olemas nii plussid kui ka miinused, kuid nimelt selle kõrge hinna tõttu üritavad pangad viimasel ajal võtta skoorings-meetodi kasutusele.

Arvestades subjektiivse meetodi puudustega pööravad pangad üha rohkem tähelepanu statistilistel mudelitel põhinevale ehk objektiivsele meetodile. Antud meetodi nimetuseks on krediidi skoorings-meetod ehk lihtsalt skoorings-meetod, mille idee seisneb selles, et tegureid, mis eraldavad „häid“ laene „halbade“ ja seega ka maksevõimelisi kliente maksevõimetutest, on võimalik identifitseerida suure hulga inimete põhjal, kes on saanud laenu. Skoorings-meetod on tehnoloogia, mis aitab väljendada konkreetse laenuaotleja krediidiriski koguselisel (Avery *et al.* 2009: 516). Esimeseks, kes tegeles 1940-ndates laenuaotleja valiku probleemi lahendamisega oli Ameerika majandusteadlane David Durand. Laialdast kasutamist on antud meetod leidnud viimase kahe aastakümne jooksul. Esialgu kasutati skooringsmudelite väljatöötamiseks diskriminantanalüüsi. Nüüdseks kujunes kõige edukamaks statistiliseks meetodiks *logistic regressioon*. (Thomas *et al.* 2002: 3, 41) Erinevatest skoorings-meetodi tehnikatest räägitakse täpsemalt alapunktis 1.3.



Skoringmudeli loomine nõuab ettevõttelt eelneva kogemuse põhjalikku üldistamist ja süstematiseeritamist. Väga hea mudeli loomiseks peab ettevõtte krediteerimise kogemus olema vähemalt aastapikkune, lisaks sellele on vajalik hästi arenenud pangasisene infosüsteem.

Kuigi USA kõige suuremate finantsinstitutsioonide uurimuses leidsid A. Fatemi ja I. Fooladi (2006: 231), et laenusaaja kohustuse maksmata jätmise riski tuvastamine laenutaotlemise ajal on skoringmudeli kõige olulisem eesmärk, ei piirdu selle meetodi kasutusala üksnes laenutaotlejate krediidiriski hindamisega. Skoringmudelit võib luua selleks, et hinnata juba väljastatud laenu kvaliteeti, kasutatakse skoring-meetodit ka laenude sissenõudmise protsessides (Gestel, Baesens 2009: 96).

Iga skoringmudeli väljatöötamisel on mitu fundamentaalset sammu (Thomas *et al.* 2002: 121-149; Glennon *et al.* 2008: 7-27):

- 1) andmete kogumine,
- 2) sõltuva muutuja defineerimine,
- 3) selgitavate muutujate valik,
- 4) valimi ehitus,
- 5) mudeli valik,
- 6) mudeli loomine,
- 7) mudeli toimimise kontroll.

Andmete kogumine on üsna aeganõudev protsess. Seda lihtsustab arenenud pangainfosüsteem, kus laenu ja laenutaotleja andmed salvestatakse digitaalselt. Andmete rohkus sõltub taotlusvormi pikkusest: pikemad taotlusvormid hiljem lubavad saada palju rohkem andmeid kliendi kohta. Taotluse esitamise lihtsus ja kiirus on üks konkurentsieelistest, sellepärast on oluline arvestada ka sellega, et pikemad taotlusvormid võivad peletada kliente eemale. Andmeid saab hankida nii ettevõtte sisemisest infoallikatest kui ka avalikest infoallikatest. Ettevõttesisesed andmed ei ole enamasti oma privaatsuse ja tähtsuse tõttu kolmandatele isikutele kättesaadavad.

Sõltuva muutuja (eraisiku krediidiriski) defineerimisel lähtub ettevõtte skoringmudeli eesmärkidest, näiteks võib „halva“ laenu definitsioon märkimisväärselt erineda

tagatiseta ja tagatisega laenude puhul. Sõltuva muutuja erinevad definitsioonid aga ei mõjuta skoorimudeli ülesehitamise põhimõtteid.

Mudelites kasutatakse tüüpiliselt pidevaid (vanus, sissetulek jm) või kategoorilisi (amet, ülalpeetavate arv, elamu omanik või rentnik jm) karakteristikuid. Pidevad tunnused grupeeritakse tavaliselt intervallidesse, muutes need seeläbi kategoorilisteks. Kuigi selline lähenemine ei ole nõutav, lihtsustab see gruppidevahelise erinevuse interpreteerimist. (Hand 2001:144)

Valimi koostamisel on skoorimudeli ehitusel väga tähtis roll. Kõigepealt peab valim olema läbilõige klientide üldkogumist. Alles siis saab mudelit kasutada kogu populatsiooni hindamiseks. Teiseks, krediidiriski modelleerimisel nagu ka ettevõtete pankrotistumise modelleerimisel on väga tüüpiline olukord, kus „häid“ laene (mittepankrotistunud ettevõtteid) on portfellis kordades rohkem, kui „halbade“. Ei ole harv olukord, kus „heade“ ja „halbade“ laene suhe on 20:1, ja nagu Thomas *et al.* täheldasid (2002: 122) selline proportsioon võib viia selleni, et analüüs ei võimalda identifitseerida kahte grupi eristavaid tegureid korrektselt. Sellel põhjusel koostatakse valim, kus kummagi grupi laenu esinemise tõenäosus on 50 protsenti. See viib väga levinud probleemini mudeli valimi koostamisel. „Halbade“ vaatluste kunstlik suurendamine põhjustab valimi kallutatus (Zmijewski 1984: 59). Siinkohal võib märkida, et selline spetsialiseeritus tulenevalt mudeli eesmärgist ei pruugi olla ebasoovitav. „Halbade“ laenude esinemissageduse kunstlik tõstmine parandab mudeli maksejõuetu klientide klassifitseerimistäpsust. Puuduseks on „heade“ klientide identifitseerimise täpsuse vähenemine. (*Ibid.*: 74) Ettevõtte seisukohast on maksejõuetu kliendi identifitseerimine kindlasti tähtsam tänu suurematele kulutustele, mida ettevõtte kannab väljastades potentsiaalselt „halva“ laenu. Antud töö teises peatükis koostatakse kaks mudelit – esialgu kaalumata, seejärel mudel, kus mõlemad laenugrupid on esindatud võrdselt.

Skoorimudeli valik sõltub uurija oskustest ja vajadustest. Mudeli ehitamisel jagatakse valim osadeks: üks kasutatakse koostamiseks (algvalim) ja teine - mudeli testimiseks (kontrollvalim). Valimi proportsioonid võivad tugevalt erineda: alates 9:1 lõpetades 1:1. Alg- ja kontrollvalimi erineva suhe mõju pole aga modelleerimise tulemustele täheldatud (Abdou, Pointon 2011: 68, 73). Tänu väga mahukatele

üldkogumitele koostatakse tavaliselt juhuvalimeid ilma selle kogu valimiga sarnasuse kontrollita. Mudeli koostamiseks kasutatakse antud töös 75% ja testimiseks 25% valimi vaatlustest.

Kui skoorimudel koostatakse selleks, et eristada „heade“ ja „halbade“ laenuaotluste vahel, ei ole mudeli kasutamine laenuportfelli riski hindamiseks otstarbekas, kuna mitmed taotleja karakteristikud võivad ajas muutuda. (Kočenda, Vojtek 2009: 4) Seega valmivat mudelit võib rakendada ainult laenuaotluse esitanud kliendi krediidiriski hindamiseks.

Skoring-meetodil on mitmed puudused. Esiteks, mõned väga olulised andmed ei ole nii lihtsasti andmebaasidest kättesaadavad. Näiteks Tartu Ülikooli Majandusteaduskonnas kaitsnud tööd Helena Kokk`al (2011: 42) ei õnnestunud teatud põhjustel oma mudelisse kaasata sellised tegurid nagu krediidiajalugu, mis tegelikkuses on üks tähtsamatest faktoritest krediidiriski hindamisel, haridustase, maksehäirete olemasolu ja paljud teised. Mudeli koostamiseks oli võimalik kasutada vaid 5 muutujat. Käesoleva töö autoril õnnestus saada andmebaasi 30 erinevate muutujatega.

Teiseks puuduseks võib nimetada valimi kallutatus (*sample-selection bias*), mis tuleneb sellest, et mudelid koostatakse kasutades informatsiooni ja andmeid, mis on saadud laenuaotlustest, mis olid tegelikult rahuldatud. Selle probleemi teine nimetus on tagasilükkamise tagajärg (*reject inference*) (Gool *et al.* 2009: 9; Hand, Henley 1997: 525). Kriteeriumid, mille alusel laenuaotlus oli tagasi lükatud, arvesse aga ei võeta. Siin võib tuua ka mõned seadusandlusest tulenevad piirangud: nt Rootsis pangad tohivad säilitada tagasi lükatud taotluste informatsiooni vaid 3 kuud. (Jacobson, Roszbach 2003: 616). Seda riski on võimalik maandada konstrueerides mudelit kahe järjestikuse sõltuva muutujaga: esiteks on laenuandja otsus taotluse rahuldamiseks või tagasi lükkamiseks, teiseks, väljastatud laenu puhul – tagasimaksmise kvaliteet. (Greene 2008: 19-20) Veel üheks võimaluseks on Reichert *et al.* lähenemine (1983, viidatud Thomas *et al.* 2002: 143 vahendusel), kes jagasid sõltuvat muutujat kolmeks grupiks: „hea“ laen, „halb“ laen ja tagasi lükatud taotlus. Probleemiks on see, et üldjuhul skoorimudeli kasutamise eesmärgiks on jagada laenuaotlusi kaheks: nendeks, kelle tasumata jätmise tõenäosus võimaldab saada laenu ja nendeks, kelle mitte. Sellepärast mida teha tagasi lükatud klassifitseeritud taotlustega, jääb küsimuse alla. Kahjuks antud

töö autoril ei olnud võimalik kasutada tagasi lükatud taotluste informatsiooni skoorimudeli koostamisel. Peale selle eeldab töö autor, et laenu mitte saanud laenuaotlejad ning potentsiaalsed kliendid ei erine andmebaasis olevatest klientidest. Lisaks sellele jõudsid Banasik *et al.* oma uurimuses (2003: 831-832) järelduseni, et kogu laenuaotlejate baasil ehitatud skoorimudeli klassifitseerimise täpsus ei ole oluliselt kõrgem võrreldes mudeliga, mille koostamiseks on kasutatud vaid rahuldatud taotluste klientide karakteristikud.

Kolmandaks puuduseks, millele pööravad oma tähelepanu mõned autorid, on populatsiooni nihe (*population drift*) (Hand, Henley 1997: 525; Thomas *et al.* 2002: 110). Probleemi sisu seisneb selles, et uued kliendid, kelle hindamiseks kasutatakse välja töötatud skoorimudelit, võivad teatud aja jooksul hakata erinema nendest laenuaotlejatest, kelle alusel mudel oli koostatud ja testitud, mille tulemusena mudeli ennustamistäpsus hakkab langema. Erinevused tulenevad nii muutlikust makrokeskkonnast kui ka ettevõtte seestpoolt: uute toodete sihtgrupiks võivad olla teise profiiliga kliendid. Sellest tulenevalt peab skoorimudelit pidevalt täiustama ning kaasajastama. Mudeli uuendamine on asjakohane siis, kui (Thomas *et al.* 2002: 163):

- 1) kättesaadavaks muutunud uued ja parema kvaliteediga andmed,
- 2) ilmunud uued informatsiooni allikad,
- 3) muutunud ettevõtte eesmärgid, krediidipoliitika või turundusstrateegia.

Kuna eraisiku krediidiriski hindamise protsess koosneb mitmest etapist, ei saa skoorimudel täielikult asendada laenuametniku. Konkreetse laenuaotluse hindamine skoorimudeligas võib olla abivahendina juba olemasoleva informatsiooni hindamisel. Suurem töö, nagu näiteks informatsiooni kogumine, laenusoovide väljaselgitamine ja paremate tingimuste pakkumine, jääb ikka laenuametniku ülesandeks. JianHua ja Tao on täheldanud (2010: 11), et ka mitmed uurimused on kinnitanud, et skoorimudelit saab kasutada vaid täiendava kontrolli ja hindamise vahendina.

Vaatamata kitsendustele ja puudustele, on sellel meetodil tugevad eelised subjektiivse meetodi ees. Subjektiivse meetodiga võrreldes on skoorimudeli eeliseks ka see, et ta arvestab nii heade kui ka halbade laenusajate karakteristikuid. Mudel ehitatakse väga suure andmestiku baasil: eraisiku krediidiriski hindava skoorimudelis võib muutujaid

olla üle 100 ning kokku hinnatakse üle 100 000 laenujuhtumi (Hand, Henley 1997: 526). Need numbrid on vaieldamatu palju suuremad, kui laenuametnik suudab mäletada analüüsidest laenuaotlust. Lisaks ülaltoodule minimiseerib skoorimeetod laenuotsustusprotsessi kulusid ja vigu. (Abdou, Pointon 2011: 61-62) Automatiseeritud laenuaotluste hindamine võimaldab olulisel määral panga kulusid vähendada, sest 80% laenu taotlemise protsessist on seotud inimeste jõuga (Wendel, Harvey 2003: 6-7). Skoorimeetodil puuduvad eelarvamused laenuotsuste tegemisel ning vajaduse korral mudel võimaldab koguseliselt paremini väljendada erinevate laenuvõtjate klasside oodatud kahjumit (Caire et al. 2006: 1). Skoorimeetod aitab krediidiriski hinnata kiiresti: otsustamiseks lõppkokkuvõttes on vaja vähem informatsiooni, kuna modelleerimise protsessi käigus jäävad mudelisse vaid olulised karakteristikud, mis iseloomustavad laenuaotleja kohustuse korrektse täitmise tõenäosust. Skoorimeetodeid käsitletakse nagu kõige edukamaid meetodeid, mida kasutatakse äri- ja finantsvaldkonnas. Seal hulgas võib antud meetod olla heaks vahendiks laenuotsustusprotsesside täiustamiseks ja parandamiseks mikrokrediteerimises (Gool et al. 2009: 19-20).

Vahekokkuvõtteks võib öelda, et eraisiku krediidiriski hindamiseks on mitu võimalusi alustades müügitingimustest ja lõpetades väljastatud laenude jaoks garantiide ostmisega. Antud töö uurimuse objekti fookusest analüüsitakse krediidiriski tuvastamist laenuaotluse esitamise ajal. Laenuaotluste hindavate meetodite eesmärgiks on eristada „häid“ ja „halbu“ kliente ning minimiseerida laenu väljastamise tõenäosust viimastele. Panganduses on kasutusel kaks põhimeetodit: subjektiivsed ja statistilised, kolmandaks võib nimetada nende meetodite koostööd. On leitud, et statistilisel skoorimeetodil on palju eeliseid subjektiivse meetodi ees, kuid selle meetodi kasutamine eeldab palju aspektidega arvestamist vajavate skoorimeetodite ehitamist. Võimalikud tegurid, mida kasutatakse skoorimeetodi ehitamiseks maksejõuliste ja maksejõuetute klientide eristamiseks on vaadeldud järgmises alapunktis.

## **1.2 Eraisiku krediidiriski mõjutavad tegurid**

Antud alapunktis tuuakse põhilised tegurid (edaspidi ka mõjurid või karakteristikud), mida peetakse olulisteks laenuaotleja krediidiriski hindamisel ehk need tegurid, mida

tavaliselt kasutatakse maksejõuliste ja –jõuetute klientide eristamiseks. Esiteks vaadeldakse üldisemalt teorias pakutud laenuaotleja karakteristikud ja muud tegurid, seejärel analüüsib autor praktikute poolt eraisiku krediidiriski modelleerimiseks kasutatud tegurid. Karakteristikud grupeeritakse ning tuuakse nende oodatavad mõjusuunad ja tugevused.

Küsimus, milliseid näitajaid mudelis kasutada, on mudelite koostamisel väga tähtsal kohal. Erinevate võimalike tegurite arv on väga suur – kasutatakse ja koostatakse andmebaase sadade muutujatega. Üldine mõjurite valiku reegel puudub ning tegurite arv ja koosseis sõltub nii valitud analüüsimeetodist kui ka valdkonnast, riigist, uurijate eesmärkidest ja muudest asjaoludest. Traditsioonilised krediidiriski hindamise meetodid, nt ülalpool käsitletud subjektiivne meetod, põhinevad laenuaotleja erinevate omaduste ja karakteristikute analüüsimisel. Üheks levinumaks tegurite süsteemiks on nn 5 C-d (Koch 1992: 640-641):

1. Iseloom (*character*) – iseloom viitab taotleja usaldusväärsusele ja aususele.
2. Kapital (*capital*) – kliendi majanduslik olukord.
3. Maksevõime (*capacity*) – kliendi võime täita võetud finantskohustused vastavalt lepingutingimustele.
4. Majandustingimused (*conditions*) – üldine majanduslik olukord.
5. Tagatised (*collateral*) – ehk teisesed tagastamisallikad, ehk kindlustus laenu tasumata jätmise ja laenusaaaja maksejõuetuse puhul.

Autor nõustub Rose arvamusega (1991: 245-246), kes väidab, et laenuaotluse hindamise võtmefaktorid on laenuvõtja iseloom ja maksevõime. Laenuametniku eesmärgiks on välja selgitada kliendi moraalse vastutuse tase laenu täies mahus ja õigeaegse tagastamise eest. Peale selle peab sissetulekute tase olema võetava kohustuse suurusega vastavuses ning peab tagama seda, et laen koos intressiga osutub tasutuks vastavalt laenutingimustele. Kliendi kavatsustest pakub palju infot laenu eesmärk, millele pöörab tähelepanu ka McNaughton (1992: 34). Siinkohal on tõhusam pidada suulist vestlust kliendiga, kuna vestluse käigus võib paremini aru saada, millised on tegelikud laenu eesmärgid ning märgata, kas kliendi kavatsused on tõemeelsed või mitte. Sissetuleku hindamisel on tähtis nii selle suurus kui ka jätkusuutlikkus. (Gustafson *et al.* 2005: 206) Lisaks sissetuleku hindamisel arvestatakse selle

läbipaistvuse ja legaalsusega. Kindlasti tuleb prognoosida ka sissetuleku edaspidise muutumise võimalike stsenaariume. Prognoosimiseks võib kasutada ka teisi tegureid, nt kliendi vanust, haridust ja senist ametikäiku. Pangad eeldavad laenu väljastades, et eraisikust laenuvõtja maksab laenu tagasi oma sissetulekust, seega mida stabiilsem, jätkusuutlikum ja suurem see on, seda tõenäolisem on korrektne kohustuste täitmine.

Tuleb pöörata tähelepanu ka üldisele majandusolukorrale, kuna krediidiriski suurus ei lähtu üksnes laenuvõtjast. Kuigi majanduskriisid on harvad, kannavad nemad endas kõige suuremat ohtu (Rizzi 2003: 8). Mõned laenuvõtjad on eriti tundlikud majanduse kõikumise ehk äri tsüklite suhtes. (Rose 1991: 185-187) Selline lähenemine aga rohkem vajalik juriidiliste isikute krediidiriski analüüsimiseks, suuremate laenusummade ning järelikult suuremate riskide puhul. Tavaliselt jäävad majandustsüklitest tulenevad ohud laenu taotluse analüüsist välja. Olulisteks võib pidada ka teised majandusliku olukorra näitajad nagu tööhõive, inflatsioon, valuutakursid jm.

Tegurid, mida võib kasutada „hea“ ja „halba“ kliendi eristamiseks, on toonud nt Lawrence Galitz (1993: 27) oma uurimuses „Eraisiku krediidianalüüs“. Tema leidis, et kliendi stabiilsuse näitajateks võivad olla perekonnaseis, ülalpeetavate arv, ametikäik, varasemad või kehtivad finantskohustused, praeguses elukohas elatud aeg jt. Stabiilsematel klientidel on maksejõuetuks muutmise tõenäosus on väiksem.

Eraisiku krediidiriski hindamiseks kasutavad pangad peamiselt välisinformatsiooni, mida pakub neile laenu taotleja ise. Analüüs algab pakutud informatsiooni ülevaatest (laenu taotluses olev informatsioon, majandusaasta aruanded ja eraisiku pangakonto väljavõtted), seejärel kontrollitakse varasemat majandustulemust ja eraisiku puhul - maksekäitumist krediidibüroodest ja üldist tausta laenu taotleja kohta. (Rose 1991: 185-187). Laenu taotluse hindamist raskendab ebavõrdne informeeritus, mis seisneb selles, et harilikult tunneb laenuvõtja paremini oma häid ja halbu külgi ning teab paremini oma tegelikke kavatsusi. Ülaltoodud probleem on tuntud kui moraalariski (*moral hazard*) probleem ja ebasoodsa valiku (*adverse selection*) probleem. Selle probleemi vähendamiseks ettevõtte peab rohkem tähelepanu pöörama laenu taotleja motivatsiooni ja kavatsuste välja selgitamiseks. Lisaks püüab laenuandja omandada rohkem informatsiooni muudest allikatest. (Gustafson *et al.* 2005: 206) Muude allikate all tavaliselt mõistetakse erinevad krediidibürood, maksu- ja muud registrid, interneti

otsingumootorid, mida laenupakkujad kasutavad laenuaotleja usaldusväärse ja krediitkõlblikkuse kontrollimiseks.

Laenuaotleja krediidiriski hindamiseks võib kasutada mitmeid avalikult kättesaadavaid infoallikaid (*publicly available data sources*). Mõnede infoallikate teenused on tasuta, teised pakuvad informatsiooni tasu eest. Tabelis 1.3 on toodud Eestis kasutatavad infoallikad.

Maksu- ja Tolliameti andmebaas sisaldab informatsiooni maksuvõla suuruse, liigi ja tekkimise kuupäeva kohta. Tegemist on laenuaotleja maksevõimet iseloomustava näitajaga, mille olemasolu tihti välistab laenu väljastamist.

**Tabel 1.3.** Põhilised Eestis avalikult kättesaadavad infoallikad, mida võib kasutada eraisiku krediidiriski hindamiseks

	Allikad	Informatsioon	Tasuta/tasuline
1	Maksu- ja Tolliamet	Maksuvõla olemasolu, suurus ja tekkimise aeg.	tasuta
2	Krediidiinfo AS	Maksehäirete <sup>5</sup> olemasolu.	tasuline
3	Krediidiregister OÜ	Informatsioon eraisikute võlgnevuste kohta.	tasuline
4	Kinnistusraamat	Kinnisvara olemasolu, hüpoteegid.	mõned teenused tasulised
5	Ametlikud Teadaanded	Laenuaotleja tausta teabe, tema kohta avaldatud teadete loetelu.	tasuta
6	Äriregister	Eraisikute seosed ettevõtlusega. Töökoha kontroll.	mõned teenused tasulised
7	Statistikaamet	Makromajanduslik informatsioon.	tasuta
8	Register OÜ	Inforegister: ettevõtete ja juhatuse liikmete seire.	mõned teenused tasulised
9	Otsingumootorid internetis	Laenuaotleja tausta teave.	tasuta

Allikas: (Lukasov 2010: 139-141); autori koostatud

AS Krediidiinfo pakub erinevat liiki teavet, üks nendest on maksehäirete raport. Eraisiku maksehäirete raport kajastab eraisiku maksekombeid ehk teavet nii isiku lõpetatud kui lõpetamata maksehäirete kohta. Raport sisaldab järgnevat informatsiooni:

<sup>5</sup> Maksehäireregister on AS Krediidiinfo hallatav register, kuhu ettevõtted võivad sisestada teavet eraisiku või teise ettevõtte maksehäirete kohta. Maksehäireks loetakse krediidisaja poolt rahalise kohustuse täitmata jätmist, mis on tekkinud lepingu rikkumisest ja selle rikkumise algusest on möödas vähemalt 45, ning mille summa koos intresside ja viivistega on vähemalt 30 eurot.



maksehäirete algus- ja lõppkuupäevad, summade vahemik, maksehäirete päritolu (krediteerija tegevusala). Info maksehäirete kohta pärineb maksehäireregistri liikmetelt või teistelt lepingulistelt osapooltelt. (Eraisikute raportid 2015) Registrit kasutavad paljud eesti laenuandjad ning maksehäire olemasolu loetakse üldjuhul tõsiseks põhjuseks laenuaotluse mitte rahuldamiseks. Siiski ei pruugi võlgnevuse olemasolu välistada laenuandmist, kuid krediidirisk kehtiva maksehäirega kliendile laenuväljastamisel on tunduvalt suurem.

Sarnast teenust pakub Krediidiregister OÜ, mille eesmärk on „vahendada informatsiooni, mis aitab teha paremaid krediidiotsuseid ja samas ka distsiplineerida võlglast.“ Krediidiregistris on laenuusaldajate poolt avaldatud maksehäired, mille makseviivitus on ületanud 30 päeva ning võla jääk on suurem kui 30 eurot. Lisaks maksehäirete olemasolule pakub antud register ka võimalust näha laenuaotleja kohta laenuandjate poolt sooritatud päringute arv. (Krediidiregister 2015)

Kinnistusraamatu abil saab kontrollida kinnisvara olemasolu laenuaotlejal. Selle olemasolu võib olla distsiplineeritavaks faktoriks laenuvõtmisel ning peaks vähendama krediidiriski. Ametlike Teadaannete kaudu võivad edastada informatsiooni võlgnevuse olemasolu kohta erinevad asutused, samuti kasutavad seda portaali ka kohtutäiturid täitmisteadete avalikult kätte toimetamiseks. Selle infoallika probleem seisneb selles, et teave on raske koguseliselt väljendatav ning peab olema laenuametniku poolt kontrollitud ja tõlgendatud.

Laenuametnik võib kontrollida ka eraisiku seost ettevõtlusega nii Äri- kui ka Inforegistris. Läbi nende portaalide on võimalik teha kindlaks, kas taotluses deklareeritud kliendi töökoht-ettevõtte tõepoolest eksisteerib ja hetkel tegutseb või mitte. Statistikaamet pakub makroökonomilist informatsiooni ning selle peamiseks puuduseks on info ajaline viivitus. Laenuaotleja internetiotsing on väga kasulik vahend krediidiotsuste tegemisel. Kahjuks leitavad tulemused on väga raskesti (automaatselt) kvantitatiivselt väljendada. Mõned ajalehed ja foorumid võivad samuti pakkuda negatiivset informatsiooni taotleja kohta. Lisaks leiab internetist inkasso-ettevõtete avalikud andmebaasid, nt Julianus Inkasso AS, kust on võimalik saada informatsiooni taotleja varasemast maksekäitumisest.

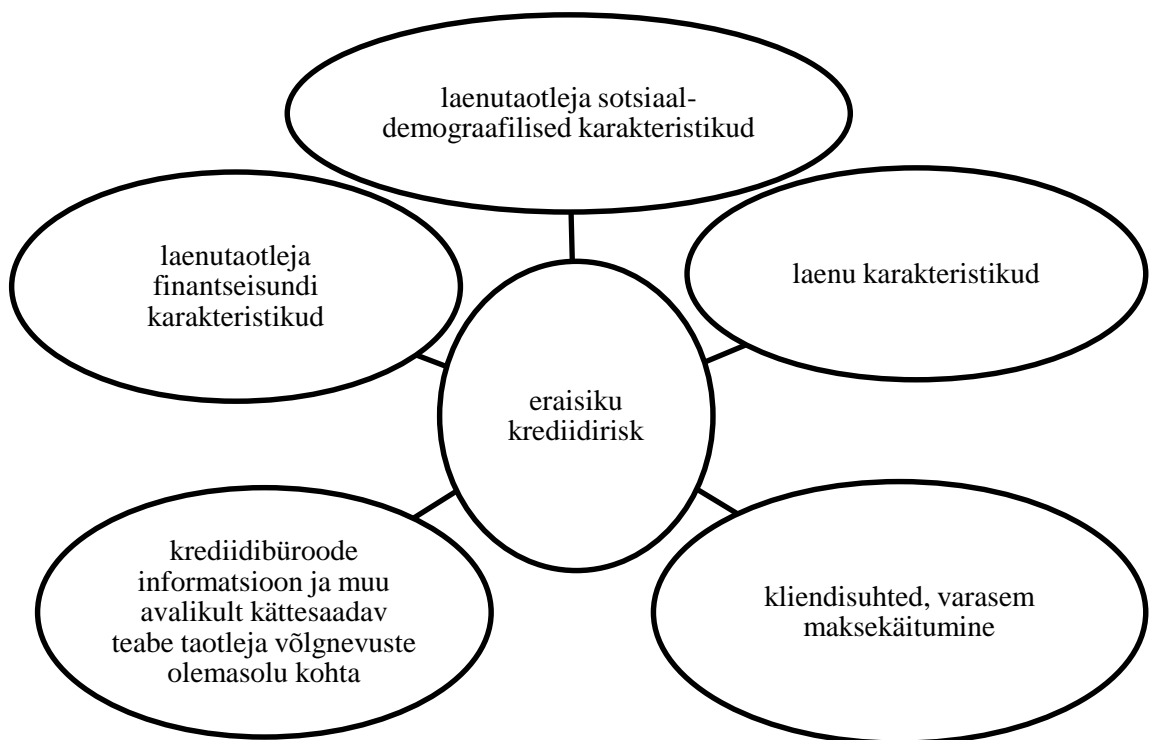
Kahtlemata, avalikult kättesaadav informatsioon omab mitu kitsendust: see võib olla mitte ajakohane, mitte laialdane ja üldse ebatäpne. Enamasti mida spetsiifilisem ja täpsem on teave, seda tõenäolisem, et see ei ole avalik. Avalik informatsioon võib varieeruda riigiti. Esiteks, teabe kogumine ja varustamine on reglementeeritud seadusandlusega erinevalt. Teiseks, erinevad piirangud võivad esile kerkida, sõltuvalt kokkulepetest ja lepingutest. Kolmandaks, krediidiotsuste tegemiseks kasutatav informatsioon on tavaliselt salastatud ja seda ei avalikustata. (Lukason 2010: 138) SNEL Grupp OÜ kasutab krediidiriski hindamiseks kõik tabelis 1.3 loetletud allikaid ning antud töö skoorimudeli koostamiseks, on võimalik kasutada allikat nr 2, 4, ning 5 ja 9, mis on koondatud ühe muutuja alla. Allpool asuvas tabelis 1.4 asub autori ülevaade erinevates uurimistöodes kasutatud karakteristikute kogustest ja põhilistest teguritest, mis näitasid suurema mõju kahte laenusaja gruppi eristamisel.

**Tabel 1.4.** Erasisiku krediidiriski mõjutavate tegurite ülevaade

	<b>Autor ja aasta</b>	<b>Valimi suurus</b>	<b>Tegureid kasutati</b>	<b>Oluliste tegurite arv</b>	<b>Suurema mõjuga tegurid</b>
1	Gool <i>et al.</i> 2012	4705	16	12	vanus, laenu periood, laenutaotlemise kuu, töökogemus, muude finantskohustuste suurus
2	Kokk 2011	2327	5	4	vanus, sissetulek, laenu teeninduse määr
3	Greene 2008	13444	55	23	töötatud aeg, maksehäirete olemasolu, sissetulek, 30+ päeva viivituste arv viimase aasta jooksul.
4	Angelis <i>et al.</i> 2008	350	11	11	sissetulek, vanus, kinnisvara olemasolu
5	Kočenda, Vojtek 2009	2280	22	10	omafinantseeringu olemasolu, laenu eesmärk, haridus, eelnev maksekäitumine, perekonnaseis, laenu suurus, tööstaaž
6	Baesens <i>et al.</i> 2005	10000	14	14	tööstaaž, laenu eesmärk
7	Jacobson, Roszbach 2003	6439	57	16	sissetulek, finantskohustuste suurus, käenduse olemasolu, päringute arv krediidibüroos
8	West 2000	845	19	19	varasem maksekäitumine, amet, kinnisvara olemasolu, märgitud aadressil elatud aeg.
9	Arslan, Karan 2010	25566	12	9	auto olemasolu, logaritmitud sissetulek, pere suurus

Allikas: autori koostatud.

Nagu eelmises alapunktis on mainitud, krediidiriski modelleerimiseks võib kasutatavate andmete hulk (valimi suurus, tegurite arv) olla päris suur. Tabelist 1.4 selgub, et eraisiku krediidiriski modelleerimiseks kasutatakse palju erinevaid tegureid. Nende arv sõltub nii laenuaotluse ankeedi põhjalikkusest kui ka andmete kättesaadavusest ja seaduslikest regulatsioonidest. Näiteks USA laenuandmete seast ei ole võimalik leida informatsiooni laenuaotleja soo, perekonnaseisu ja rahvuse kohta, kuna antud informatsiooni kogumine on seaduslikult piiratud (West 2000: 1141). Alljärgneval joonisel 1.2 püüab autor need tegurid kokkuvõtvalt grupeerida viide suuremasse rühma.



**Joonis 1.2.** Eraisiku krediidiriski mõjutavad tegurid. (autori koostatud)

Joonisel 1.2 on toodud põhilised mõjurite grupid, mida uurijad kasutavad krediidiriski modelleerimiseks skoorimismeetodiga. Esimese grupi moodustavad sotsiaal-demograafilised tegurid: vanus, sugu, perekonnaseis, haridus, tööstaaž, deklareeritud aadressil elatud aeg, maa või linna elanik ja muud.

Vanemad kliendid on vähem riskivõtlikud ning järelikult tõenäosus, et laen jääb tasumata, vanema kliendi puhul võrreldes noorema on väiksem. Seda on empiiriliselt kinnitanud ka mitmed uurimused (Gool *et al.* 2009: 116; Green 2008: 32). Sellele

vastandiks on Danel Tuusise uurimus (2010: 131), milles on jõutud järelduseni, et nooremad kliendid ei ole riskantsemad. Kočenda ja Vojtek uurimus (2009: 27) aga näitas, et vanus (nemad kasutasid vanuse asemel sünniaastat) ei ole üldse oluline tegur. Käesoleva töö autor arvab, et vanus peab siiski olema üks olulisematest teguritest, millel on negatiivne mõju eraisiku krediidiriskile ehk mida vanem on inimene, seda vähem tõenäosus, et tema laen jääb tasumata.

Tuusis (2010: 131) leidis ka seda, et mehed on suurema krediidiriskiga kui naised. Kokk' a uurimuse järgi (2011: 50) on meeste tõenäosus muutuda maksejõuetuks ligi 11 protsenti suurem. Kočenda ja Vojtek täheldasid (2009: 27), et soo informatsiooni väärtus on liiga madal, et seda kasutada krediidiriski modelleerimiseks. Samas näitas protsentuaalne jaotus, et naiste maksekäitumine on korrektsem (*Ibid.*: 40). Käesoleva töö autor eeldab, et naistel on väiksem maksejõuetuks muutumise tõenäosus kui meestel.

Perekonnaseis on vähe kasutatud muutuja, mille kohta eeldatakse, et abiellunud isikud on vähem riskantsed tänu suuremale vastutusele enda partneri ja arvatavasti ka pere ees. Seda kinnitanud ka mõned uurimused (Jacobson, Roszbach 2003: 624; Kočenda, Vojtek 2009: 27).

Vaatamata sellele et hariduse kohta uurijatel kas ei olnud või oli väga vähe informatsiooni, osutus antud tegur väga oluliseks ning kõrgem haridustase näitas tugevat positiivset seost laenu korrektse tasumisega (Arslan, Karan 2010: 35; Kočenda ja Vojtek 2009: 15). Analoogset seost oodatakse ka käesolevas töös.

Järgmine sotsiaal-demograafiline tegur, mida võib tihti kohata mitmetes uurimustes, on tööstaaž. Pikem tööstaaž on üldiselt tugevasti positiivselt seotud laenu korrektse tagastamisega. Seda karakteristikut võib pidada ka laenuaotleja finantsseisundi iseloomustavana.

Üheks huvitavamaks teguriks võib nimetada ka laenuaotleja elukoha asukohta. Käesoleva töö autoril on võimalik analüüsi kaasata muutujat, mis näitab, kas laenuaotleja elab linnas või väljaspool linna (edaspidi maal). Üldine idee seisneb selles, et linnaelanikel on rohkem võimalusi töö kaotuse puhul leida endale uus töökoht

ning seega vältida maksejõuetust. Samas kui sellist juhuriski ei peaks realiseeruma, eeldavad nt Gool *et al.* (2009: 113), et maaelanikud tänu suuremale sotsiaalsele kontrollile peaksid tagastama laene korrektsemalt. Ka Eestis läbiviidud uurimus on seda kaudselt kinnitanud (Tuusis 2010: 131). Arslan ja Karan (2010: 35) jõudsid siiski järelduseni, et linnaelanike maksekäitumine on korrektsem. Jacobsoni ja Roszbachi (2003: 624) oma analüüsi käigus ei leidnud kinnitust sellele, et antud muutuja võib olla kasulik maksejõuetu ja maksevõimelise kliendi eristamiseks.

Laste arv või peresuurus ei näidanud suurt mõju krediidiriskile välisautorite uurimustes. Autor eeldab, et ülalpeetavate arv mõjutab negatiivselt kliendi maksevõimet, järelikult tõstab tõenäosust, et laenuvõtja ei täida oma laenukohustust korrektselt.

Kõige olulisemad tegurid on need, mis iseloomustavad laenuaotleja finantsseisundit. Peaaegu iga uuriija kasutab mitu kõnealust tegurit, sh ka tabelis 1.4 (vt lk 26) esitatud autorid. Laenuaotleja maksevõimelisust otseselt iseloomustavad sissetulek, auto või kinnisvara olemasolu, kehtivate finantskohustuste suurus, laenuteeninduse määr (kehtivate finantskohustuste + võetava laenu igakuise osamakse ja sissetuleku suhe) ja muud. Üldisemalt on maksevõimelisemad ja väiksema krediidiriskiga on need kliendid, kelle finantsilised näitajad on kõrgemad ning olemasolevad kohustused võimalikult madalad.

Tegurid, mis iseloomustavad laenu, on laenu suurus, pikkus, intressimäär. Mida suuremat arvulist väärtust omavad need muutujad, seda suurem on tõenäosus, et laen jääb tasumata. Need oletused on leidnud kinnitust ka mitmetes töödes (Gool *et al.* 2009: 115; Kočenda, Vojtek 2009: 27; West 2000: 1150).

Käesoleva töö autor on huvitatud laenuaotlemise perioodi iseloomustava muutuja testimises. Gool *et al.* (2009: 117) leidsid, et talvekuudel väljastatud laenudel on suurem tõenäosus, et kohustus jääb tasumata. Seda võib põhjendada sellega, et talvekuudel on juhuriski (näiteks ajutine töökaotus jää peal kukkumisel saadud trauma tõttu) tekkimise tõenäosus on suurem. Antud töö raames ei ole kahjuks võimalik kontrollida laenu kasutamise eesmärki ja laenu liigi mõju krediidiriskile.

Kliendisuhete pikkust peetakse karakteristikus väga oluliseks. Paljud uurimused on näidanud positiivset seost suhete pikkuse ja korrektse laenu tagastamise vahel (näiteks Kočenda, Vojtek 2009: 16; Greene 2008: 32; West 2000: 1150). Teisalt tuleb testida mitte üksnes suhete pikkust, vaid ka varasemat maksekäitumist. Väiksemate hilinemiste olemasolu eelmis(t)e laenu(de) tasumisel peaks andma märku kliendi maksevõimekusest. Selliste karakteristikutena kasutatakse käesolevas töös näiteks tagastatud laenude arvu ja viivituste olemasolu viimase kolme laenu tasumisel.

Kui taustauuringu käigus selgub mingi tugevalt negatiivne asjaolu: näiteks tegemist on variisikukahtluse või terrorismikahtlusega isiku, narkomaani, hasartmängu- või alkoholisõltlasega, keeldutakse laenuandmisest tavaliselt koheselt. Kui krediidibüroode või näiteks Maksu- ja Tolliandmete alusel selgub maksehäirete olemasolu, lükatakse laenutaotlus tagasi. Väiksemate võlasummade korral võidakse laenutaotluse siiski rahuldada. Käesoleva magistritöö empiirilises osas kontrollitakse muuhulgas kehtivate või makstud maksehäirete arvu mõju eraisiku krediidiriskile.

Krediidiriski hindamisel kasutatakse palju erinevaid tegureid: ühed iseloomustavad laenutaotleja finantsseisundit, teised – tema sotsiaal-demograafilisi karakteristikuid, kolmandad kirjeldavad aga laenutoodet. Mõjurite valik võib uurimustes tugevasti varieeruda. Abdou ja Pointon tõdevad (2011: 68), et optimaalset karakteristikute koosseisu või nende arvu erinevate finantsasutuste, riikide ja keskkondade jaoks ei eksisteeri.

Modelleerimiseks kasutatavate tegurite komplekt sõltub kõigepealt andmete omanikust. Andmete kättesaadavus on väga tihti suureks probleemiks krediidiriski modelleerimisel, suurt mõju omab ka riigi regulatiivsed aspektid ja finantsasutuse infosüsteemi keerukus. Kindlasti omab rolli ka laenutaotluse pikkus ja põhjalikkus. Mõned tegurid, mis on osutunud olulisteks krediidiriski modelleerimisel (vt tabel 1.4, lk 26) välismaa autoritel, ei ole laenutaotluse piiratud pikkuse tõttu (Lisa 1) käesoleva töö autorile kättesaadavad. Teine oluline aspekt on kiirlaenude tarbijate usaldusväärsus. Autor on oma igapäevases töös täheldanud, et suhteliselt tihti laenutaotluses toodud informatsioon ei vasta tõele ehk laenutaotlejad püüavad esitada eksitavat informatsiooni laenu saamise eesmärgiga. Eriti teravalt võib antud probleemi tunda kehtivate finantskohustuste märkimisel. Taotluses deklareeritud numbrid ei ühti pangakonto väljavõtte analüüsi käigus

tuvastatud kohustustega. Analüüsimiseks kasutatakse mitmeid statistilisi tehnikaid. Erinevate skoorimismeetodite võrdlemisele on pühendatud teoreetilise osa viimane alapunkt.

### 1.3 Meetodid eraisiku krediidiriski hindamiseks

Erinevate skoorimudemelite kvaliteedi võrdlemiseks kasutatakse väga tihti korrektse kirjeldamistäpsuse määra, mis on võimalik leida klassifitseerimistabelist. Tüüpiline mudeli prognoosivõime iseloomustav tabel on esitatud allpool tabelis 1.5 ning omab 2x2 maatriksi kuju, mille lahtrites tuuakse iga grupi vastavad numbrid.

**Tabel 1.5.** Õigesti ja valesti klassifitseerimiste arv

		Ennustatud kuuluvus		Kokku
		hea laen (g)	halb laen (b)	
Tegelik kuuluvus	hea laen (G)	gG	bG	nG
	halb laen (B)	gB	bB	nB
Kokku		g	b	n

Allikas: Thomas *et al.* 2002: 109.

Tabelis 1.5 toodud arvud gG ja bB väljendavad õigesti klassifitseerimist: tegelikkuses tasumata jäänud laenu („halb“ laen) on mudeli poolt ennustatud „halvana“ ning korrektelt tasutud laen ennustatud kui „hea“. gB ja bG on seevastu valesti klassifitseeritud. Eelpooltoodud on võimalik esitada protsentuaalsel kujul ja selleks tuleb konkreetne arv jagada vastava rea arvude summaga. I tüüpi viga (gB) esineb siis, kui tegelikult tagastamata jäänud laen ennustatakse mudeli poolt kui korras olev laen. II tüüpi veaga (bG) on tegemist, kui tegelikkuses „hea“ laen mudeli arvates on „halb“. Teisel juhul võib vea kulud väljenduda laenuandjale laenult saamata jäänud tuluna, esimesel juhul aga on tegemist oluliselt ohtlikuma veaga, mille tulemusena võivad kreditorile nii laenu põhisumma kui ka intressid jääda tagastamata. Ehk maksevõimeliseks hinnatud klient või aktsepteeritud taotlus tähendab I vea juhul otseselt kulu. Sellepärast „halva“ laenu korrektne klassifitseerimine võiks autori arvates olla eelistatum „hea“ laenu korrektse klassifitseerimise eest. Tavaliselt võrreldakse siiski erinevaid mudeleid keskmise õigesti klassifitseerimise määra alusel, mis omab kuju  $\frac{gG+bB}{n}$ . Näiteks Tartu Ülikooli majandusteaduskonnas kaitsnud Helena Kokk (2011:

52) jõudis oma magistritöös mudelini, mis ennustas korrektselt 70,36% laenujuhtumitest. Antud meetod on mudeli kvaliteedi hindamiseks osutunud teiste meetodite seast läbi aegade kõige populaarsemaks. Abdou ja Pointon märkisid oma kirjanduse analüüsis (2011: 78), et vaadeldud kaheksast võrdlemismeetoditest kasutab ligi pool uurijatest just 2x2 klassifitseerimise tabelit.

Õigesti klassifitseerimise täpsusega on seotud veel korrektse murdepunkti (*cut-off point*, samuti *threshold*) valiku küsimus. Statistiliste skoorimismeetodite väljundiks on hinnatava objekti arvuline hinnang - skoor, mida võrreldakse tingliku murdepunkti väärtusega. Laenutaotleja krediidirisk sõltub skoori väärtusest: kui ta on murdepunktist väiksem, ennustatakse laen „halvana“. (Hand, Henley 1997: 529) Alapunktis 1.1 käsitletud valimi kallutatuse probleemi tõttu ei saa kasutada vaikimisi peetud 0,5 murdepunkti sellistes meetodites, mille mudelid annavad hinnangut vahemikus 0 kuni 1 (nt logit-analüüs). Kui skoori väärtus on 0,51, ennustab mudel, et antud laenutaotleja on maksevõimeline ning laenutaotlust võib rahuldada ning juhul, kui sõltuva muutuja väärtusele 1 vastab tasumata jäetud laen, siis vastupidi. Selline standardne ennustamise reegel ei tööta siis, kui „häid“ laene on valimis 10 korda rohkem kui „halbu“. Näiteks William Green kasutas murdepunktina „heade“ ja „halbade“ laenude proportsiooni valimis, mille tulemusena mudeli õigesti klassifitseerimistäpsus tunduvalt paranes (Greene 2008: 35-36). Sama lahendust kasutasid nt Banasik *et al.* (2003: 826). Teiseks võimaluseks on valimi kaalumise, mis oli samuti käsitletud 1.1 alapunktis. Antud töö empiirilises osas hinnatakse kaalumata mudeli puhul erinevate murdepunktide väärtuste mõju mudeli klassifitseerimistäpsusele.

Töötava mudeli murdepunkti väärtus sõltub panga strateegiast, riskikartlikkust ja hindadest (Gestel, Baesens 2009: 97). Seega murdepunkti väärtus määrab, millist riski pank on valmis võtta. Arenenud mudelites võidakse kasutada kaks murdepunkti. Näiteks, juhul kui taotleja skoor ületab ülemist murdepunkti, laenutaotlus rahuldatakse, samal ajal taotlus lükatakse tagasi, kui skoori väärtus on alumisest murdepunktist väiksem. Juhul kui skoor sattub kahe murdepunkti vahele, automaatset laenuotsust ei toimu ja laenuametnik peab tegema täiendava eksperthindamist (Abdou, Pointon 2011: 62). Käesoleva töö empiirilise osa viimases alapunktis analüüsib autor 2 tingimuslikku murdepunkti rakendamise võimalusi ettevõtte laenuotsuste tegemisel.



Teatud skoorimismeetodite jaoks on vajalik ka esialgne muutujate valik (näiteks logistilise regressiooni jaoks soovitatakse kasutada kuni 20 muutujat). Selleks kasutatakse informatsiooni väärtust (*information value*). Kategoorilise muutuja üldine informatsiooni väärtus leitakse järgmise valemiga (Kočenda, Vojtek 2009: 8):

$$(1) \quad IV_i = \ln \left( \left( \frac{B_i}{B} \right) * \left( \frac{G}{G_i} \right) \right) * \left( \frac{B_i}{B} - \frac{G_i}{G} \right),$$

kus  $IV_i$  - muutuja informatsiooni väärtus,  
 $B_i$  - „halbade“ laenude arv muutuja  $i$ -kategoorias,  
 $B$  - „halbade“ laenude üldarv,  
 $G_i$  - „heade“ laenude arv muutuja  $i$ -kategoorias,  
 $G$  - „heade“ laenude üldarv.

Informatsiooni väärtus näitab muutuja ennustustugevust: mida suurem on väärtus, seda tugevamalt aitab muutuja eristada kahte gruppi laene. Praktikas loetakse piisavaks muutujat, mille informatsiooni väärtus on suurem kui 0,1 ning tugevaks, kui suurem kui 0,3. Enne lõpliku mudeli saamist arvutab käesoleva töö autor muutujate informatsiooni väärtust, testides, kuivõrd on antud meetod rakendatav andmete eelselekteerimisel.

Skoorimismudelite ehitamiseks kasutatakse mitmeid statistilisi tehnikaid. Neid võib liigitada edasiarendatuteks statistilisteks meetoditeks ja traditsioonilisteks. Edasiarendatud meetodid nagu närvivõrgu meetod (*neural networks*) ja korduva ositamise meetod (*recursive partitioning*) pakuvad alternatiivi traditsioonilistele meetoditele. Traditsioonilised meetodid on näiteks logit- ja probit- regressiooni mudelid ning diskriminantanalüüs. Nendest on kõike laiemat kasutust leidnud logit meetod. (Abdou, Pointon 2011: 69) Järgnevalt tutvustab autor lühidalt iga meetodit ja toob ülevaade varem tehtud töödest ja saadud klassifitseerimise täpsustest.

Diskriminantanalüüs on lihtne parameetiline statistika meetod, mis võimaldab identifitseerida seoseid sõltuva ja sõltumatute muutujate vahel. Antud meetodi eesmärgiks on leida nn diskriminantfunktsioon ja klassifitseerida vaatlusi neid kirjeldavate karakteristikute alusel kahte või rohkemasse gruppi (Gurny, Gurny 2013: 166). Aastal 1936 oli R. A. Fisher esimene, kes tuli ideega eristada populatsiooni

erinevate gruppide vahel. Hiljem, 1941. aastal D. Durand pakkus, et Fisheri diskriminantanalüüsi võib kasutada „heade“ ja „halbade“ laenude eristamiseks. Seejärel hakati kõnealust meetodit laialt kasutama laenuotsuste tegemiseks. (Abdou, Pointon 2011: 69) Diskriminantanalüüsi abil saab hinnata, millised sõltumatud muutujad eristavad sõltuva muutuja erinevaid gruppe („halb“ ja „hea“ laen ehk maksevõimetu ja maksevõimeline klient). Diskriminantfunktsiooni üldkuju võib esitada järgnevalt (Altman 1968: 592):

$$(2) \quad Z = v_1X_1 + v_2X_2 + \dots + v_nX_n ,$$

kus  $Z$  - diskriminantfunktsiooni väärtus,

$v_1, v_2, \dots, v_n$  - diskriminantfunktsiooni kordajad,

$X_1, X_2, \dots, X_n$  - diskriminantfunktsiooni sõltumatud muutujad.

$Z$  - skoori väärtus võib olla  $-\infty$  kuni  $+\infty$ . Üldisemalt, mida madalam on tulemus, seda halvemas olukorras on uuritav objekt (antud töö kontekstist signaliseerib madalam skoor laenutaotleja suuremas riskist).

Diskriminantanalüüsil on mitu kitsendavat eeldust (Balcaen, Ooghe 2006: 67): kasutatavad muutujad peavad vastama mitmemõõtmelise normaaljaotuse tingimustele ning ei tohi olla tugevalt omavahel seotud, muutujate dispersiooni ja kovariatsiooni maatriksid nii „heade“ kui ka „halbade“ laenude gruppide lõikes peavad olema võrdsed, eelnevalt peavad olema leitud maksejõuetuks muutmise tõenäosus ja valesti klassifitseerimise kulud. Lisaks ei võimalda saadud tulemus hinnata kliendi maksejõuetuks muutumise tõenäosust (Angelis *et al.* 2008: 19). Vaatamata kitsendustele kasutatakse diskriminantanalüüsi krediidiriski modelleerimiseks päris edukalt ka tänapäeval (vt tabel 1.6 lk 38).

Logit- (*logistic*) ja probit- (*probabilistic*) analüüsi kasutuselevõtt võimaldas hinnata kliendi maksejõuetuks muutumise tõenäosust ning saada parema arusaamise finantsilise riski jaotamisest. Lisaks sellele, diskriminantanalüüsile omased eeldused praktiliselt puuduvad ning mudeli sõltumatuteks muutujateks võivad sisuliselt olla mistahes tüüpi muutujad. (Angelis *et al.* 2008: 19) Logiti ja probiti vahe seisneb selles, et esimese puhul eeldatakse sõltumatute muutujate logistilist jaotust, teise puhul – normaaljaotust.

(Gurny, Gurny 2013: 165). Probit-analüüsi kasutatakse krediidiskoorinus tunduvalt vähem, arvatavasti selle suurema keerukuse tõttu. Logistiline regressioon omab järgnevat üldkuju (Angelis *et al.* 2008: 20):

$$(3) \quad P = \frac{e^{\beta_0 + \beta_1 X_{1j} + \dots + \beta_k X_{kj}}}{1 + e^{\beta_0 + \beta_1 X_{1j} + \dots + \beta_k X_{kj}}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_{1j} + \dots + \beta_k X_{kj})}},$$

kus  $P$  - logit-võrrandi väärtus,  
 $e$  - naturaalloogaritmi alus,  
 $X_{kj}$  - sõltumatud muutujad,  
 $\beta_k$  - muutuja  $k$  regressiooni koefitsiendid,  
 $\beta_0$  - vabaliige.

Antud mudeli mittelineaarsuse tõttu on vaja koefitsientide hindamiseks kasutada suurima tõepära meetodit (*maximum likelihood*) (Gurny, Gurny 2013: 165). Logit-võrrandi tulemuseks on alati arv 0 ja 1 vahel, mis sisuliselt väljendab maksejõuetuks muutumise tõenäosust protsentuaalsel kujul. Saadud koefitsientide väärtusi võib eraldi tõlgendada kui muutujate olulisust maksmata jätmise tõenäosuse ennustamisel. Logit-analüüsi puhul on oluliseks eelduseks multikollineaarsuse, erindite ja puuduvate väärtuste puudumine. (Balcaen, Ooghe 2006: 69) Üks esimestest, kes võrdles diskriminanti ja logit-analüüsi krediidiskoorinus, oli Wiginton (1980: 765). Tema uurimus näitas, et logit-analüüsiga on võimalik saada mudeli kõrgema klassifitseerimise täpsusega.

Üheks populaarsemaks edasiarendatud statistiliseks meetodiks on korduva ositamise meetod, mis on tuntud kui ka otsustuspuu meetod (*decisional tree*). Esimesed, kes on praktiseerinud antud meetodit krediidiskoorinus, olid Marais *et al.* (1984: 105). Nemad jõudsid järelduseni, et otsustuspuu pakub probit-meetodiga võrreldes sama klassifitseerimise täpsust, tingimusel, et valimi maht ei ole suur (nende valim koosnes 686 vaatlusest).

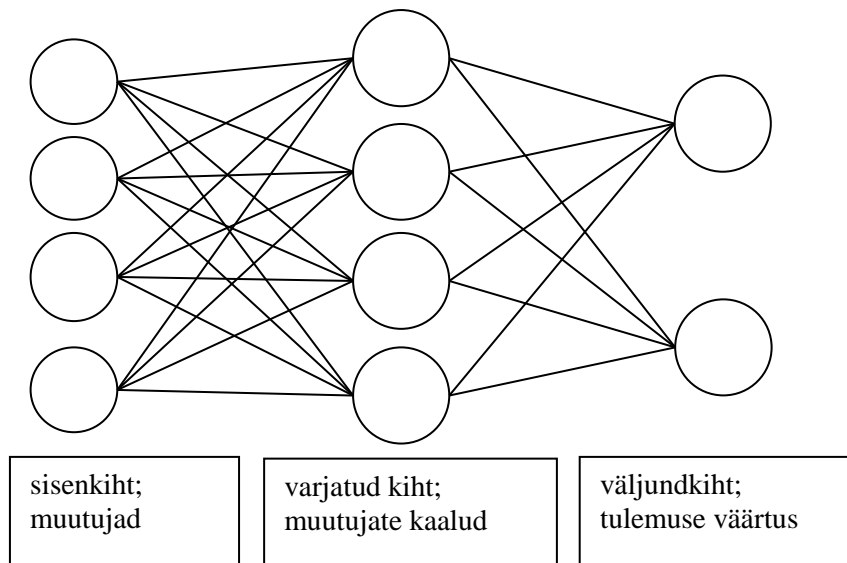
Otsustuspuu on oksade (tee juurest lehtedeni), lehtede (objektide klassid) ja sõlmede (otsustuspunktide ehk ositamise reeglite) kogum, mis klassifitseerib objekte vastavalt objektide karakteristikute väärtuste alusel. Puu ehitamiseks on vaja teada aprioorsed laenu korrektse ja mittekorrektse tagastamise tõenäosused ning valesti klassifitseerimise

kulud. (Balcaen, Ooghe 2004: 6-7) Otsustuspuu koostamiseks peab otsustama (Thomas *et al.* 2002: 54):

- 1) millise reegli järgi poolitatakse muutuja väärtust,
- 2) milline sõlm osutub lõpp-punktiks (*terminal node*),
- 3) kuidas lõpp-punkti jagada „heade“ ja „halbade“ laenude eristamiseks.

Korduva ositamise meetodi eelisteks on selle intuiitiivsus ja interpreteerimise lihtsus. Antud meetod ei sea rangeid eeldusi nagu diskriminantanalüüsi puhul, ei karda puuduvaid väärtusi nagu logit-analüüs. Kõige olulisemaks nõrkuseks ülalpool käsitletud meetoditega võrreldes on tundlikkus andmete muutumise vastu (Kočenda, Vojtek 2009: 18; Bolton 2009: 23). Lisaks rõhutatakse mõnikord aeganõudvat ja kulukat modelleerimisprotsessi. Otsustuspuude nõrga küljena võib tuua ka seda, et lõpliku mudeli koostamise käigus üht ja sama tegurit võidakse kasutada mitu korda (Kočenda, Vojtek 2009: 37). Mis tähendab seda, et pole võimalik öelda, millise muutuja panus kahe laenuvõtjate grupi eristamisel on kõige suurem (Balcaen, Ooghe 2004: 7). Viimaseks on asjaolu, et otsustuspuu sarnasel diskriminantanalüüsile ei võimalda hinnata tasumata jätmise tõenäosust.

Närvivõrgud olid välja arendatud inimese aju kommunikatsiooni ja informatsiooni töötlemise modelleerides. Antud meetod oli kirjeldatud 1960. aastatel, krediitdiskooringu hakati seda rakendama alates 1990. aastast. (Bolton 2009: 25) Närvivõrkude meetod on paindlik mittelineaarne ennustamise meetod, mille otsustusprotsess on sarnane inimeste ajus toimuvaga: olemas sisendid, väljundid ja vahepealne informatsiooni töötlemine. Klassifitseerimise jaoks nimetatakse kõige sagedamini kasutatavat närvivõrkude kuju mitmekihiliseks tajuriks (*multilayered perceptron*). Tihe võrk koosneb mitmetest omavahel seotud neuronitest, mis moodustavad sisend-, varjatud ja väljundkihti. Iga neuron töötleb (agregeerimisfunktsioon) enda sisendeid ning genereerib (ülekandefunktsioon) ühe või mitu väljundit, mida ta saadab järgmise kihi neuroonitele edasi. (Bolton 2009: 25) Tüüpilise närvivõrgu struktuuri näeb alljärgneval joonisel 1.3.



**Joonis 1.3.** Mitmekihiline närvivõrk. (Thomas *et al.* 2002: 72)

Väljundkihi neuronite väljundi transformeeritakse sigmoidfunktsiooniga (sama, mis 3. valem) nõnda, et tulemuseks on väärtus 0 ja 1 vahel, mis on tõenäosus, et laenuvõtja muutub maksejõuetuks. Sarnaselt logit-funktsiooniga saab tulemust võrrelda murdepunktiga, saades vastuse, kas laenuaotlus peab olema rahuldatud või tagasi lükatud. (Hand 2001: 147)

Närvivõrkude eelisteks traditsiooniliste meetodite eest on statistiliste eelduste puudumine: muutujad ei pea vastama normaaljaotusele ega teistele eeldustele. (Balcaen, Ooghe 2004: 10-11) Närvivõrkude võtmepuuduseks on selle tulemuse põhjendamise keerukus võrreldes kõikide ülalpool käsitletud meetoditega. Vaatamata sellele, et antud meetodiga on võimalik saada väga kõrgeid klassifitseerimistäpsusi, ei saa uurija vastata, miks ja kuidas on selle tulemuseni jõutud. Närvivõrke peetakse musta kasti tehnoloogiaks ilma loogikata ja reeglitel põhineva tulemuse selgitamiseta. (West 2000: 1148; Bolton 2009: 26) Puudusena võib tuua ka seda, et kõnealune meetod lähtub liiga palju konkreetsetest andmetest: algvalimi klassifitseerimise määr võib ulatuda kuni 90% ja isegi 100%-ni, kuid testvalimi tulemused on tunduvalt kehvemad (näiteks Abdou, Pointon 2009: 400 ja Khashman 2010: 6238). Antud probleem on tuntud nagu üleõppimise oht (*overfitting*). Ülevaade kasutatud meetoditest ja saadud klassifitseerimise täpsustest on toodud tabelis 1.6.

**Tabel 1.6.** Skoorimismeetodite ja saadud klassifitseerimise täpsuste ülevaade

	Meetod	Autor ja aasta	Valimi suurus	Õigesti klassifitseerimise määr (%)
1	Diskriminant-analüüs	Angelis <i>et al.</i> 2008	350	60,50
		Baesens <i>et al.</i> 2003	4875	79,30
		Abdou, Pointon 2009	1262	78,76
		West 2000	845	79,30
		<b>KESKMINE</b>	<b>1833</b>	<b>74,47</b>
2	Logit/ probit	Abdou, Pointon 2009	1262	81,29
		Angelis <i>et al.</i> 2008	350	71,87
		Baesens <i>et al.</i> 2003	4875	79,30
		Baesens <i>et al.</i> 2005	10000	78,24
		Banasik <i>et al.</i> 2003	4117	76,20
		Gool <i>et al.</i> 2012	4705	78,50
		Greene 2008	13444	87,10
		Kokk 2011	2327	70,36
		Ong <i>et al.</i> 2005	845	80,80
		West 2000	845	81,80
		<b>KESKMINE</b>	<b>4277</b>	<b>78,55</b>
		3	Otsustuspuud	Baesens <i>et al.</i> 2003
Kočenda, Vojtek 2009	2280			pole teada
Ong <i>et al.</i> 2005	845			78,20
West 2000	845			77,0
<b>KESKMINE</b>	<b>2211</b>			<b>77,40</b>
4	Närvivõrgud	Mirtalaei <i>et al.</i> 2012	800	pole teada
		Baesens <i>et al.</i> 2005	10000	78,58
		Baesens <i>et al.</i> 2003	4875	79,40
		Ong <i>et al.</i> 2005	845	81,70
		Abdou, Pointon 2009	1262	78 (algvalimil 89)
		West 2000	845	81,40
		Khashman 2010	1000	73,17 (algvalimil 99,50)
		<b>KESKMINE</b>	<b>2803</b>	<b>78,71</b>

Allikas: autori koostatud.

Tabelis 1.6 on toodud mudelite üldised õigesti klassifitseerimise määrad. Uurimustes, kus on kasutatud test-valimid, tuuakse nimelt test-valimil saadud mudelite täpsused. Kuna õigesti klassifitseerimise täpsus sõltub väga paljudest aspektidest nagu näiteks valimi suurus, andmete kättesaadavus ja päritolu, ei saa erinevate meetodite klassifitseerimise täpsused omavahel otseselt võrrelda. Üldisemalt võimaluse korral soovitatakse võrrelda sama andmete analüüsimisel saadud erinevate mudelite ennustustäpsused. Seega tabel 1.6 on pigem informatiivne ning selle alusel järeldusi

parima skooringu-meetodi kohta autor tegema ei hakka. Siiski on näha, et mõnevõrra parima klassifitseerimise täpsuse on saanud autorid, kes rakendasid närvivõrkude meetodit. Kõige kehvema tulemuse on näidanud diskriminantanalüüs - keskmine õigesti klassifitseerimise täpsus on 74,47%.

Võrreldes sama andmetega koostatud mudelid, saab järeldada, et nimelt logit- ja närvivõrkude meetod on kõige konkurentsivõimelisemad kahte gruppi korrektse ennustamiseks. Väga sarnased ennustustäpsused nende kahte meetodit rakendades on saanud West (2000: 1143), Baesens *et al.* (2005: 1097) ja Baesens *et al.* (2003: 633). Viimase uurimuse järgi ei jäänud klassifitseerimise täpsuse poolest ka diskriminantanalüüs nendele kahele meetodile alla.

Otsuspuude kasuks on antud meetodi stabiilsemad tulemused. Käesoleva töö autor ei leidnud ühtegi tööd, kus antud meetodiga saadud mudeli korrektse klassifitseerimise määr oleks kas liiga madal või 100%-le lähedane. Abdou ja Pointon jõudsid siiski oma kirjanduse ülevaates (2011: 79) järelduseni, et universaalset meetodit kreditskooringumudeli koostamiseks ei eksisteeri. See puudutab ka kasutatavate muutujate, *cut-off* punkti ja valimi mahu valikut.

Kuigi viimastel ajal on väga populaarsemaks muutunud närvivõrgud ja teised käesolevas töös mitte käsitletud uuemad meetodid, võib logistiline regressioon pakkuda nendele head alternatiivi. Arvestades käesoleva töö eesmärkidega, kergemini täidetavate eelduste ja tulemuste interpreteerimise lihtsusega, valib autor empiirilise osa analüüsi läbiviimiseks just logistilise regressiooni, mille abil selgitatakse, millised muutujad panustavad kahe kliendi grupi eristamisele ning leitakse maksevõimetuks muutumise tõenäosust.

## **2. ERAISIKU KREDIIDIRISKI HINDAMISEKS SKOORINGMUDELI KOOSTAMINE ETTEVÖTTE SNEL GRUPP OÜ NÄITEL**

### **2.1 Ettevõtte lühitutvustus, olemasolev krediidipoliitika ja eraisiku krediidiriski hindamise süsteem**

Käesoleva magistritöö mudelite koostamise aluseks on Eesti ettevõtte SNEL Grupp OÜ (edaspidi SG või ettevõtte) andmebaas. Ettevõtte on asutatud 2012. aastal ja tegutseb „BestCredit.ee - Parimad rahalahendused“ kaubamärgi all. SG pakub oma klientidele viit erinevat laenuteenust:

- 1) väikelaen (kiirlaen/tarbimisolaen),
- 2) reisilaen,
- 3) käenduslaen,
- 4) kinnisvaralaen,
- 5) laen mootorsõiduki tagatisel.

SNEL Grupp OÜ positsioneerib ennast kui sotsiaalselt vastutustundlikuks püüdlevat ettevõtet. Spetsiaalselt selleks otstarbeks välja töötatud ning ettevõttesiseselt rakendatud töökorraldus, sisereeglite ning teenindusstandardite süsteem tagavad seadusest tuleneva vastutustundliku laenamise põhimõtte järgimise ning oma ettevõtte krediidiriskide parema juhtimise.

Väikelaen on ettenägemata ja mitteplaneeritud kulutuste katteks mõeldud finantstoode. Laenusumma varieerub 100 kuni 3000 euronit ning periood – ühest kuust kuni kolme aastani, sõltuvalt laenusummast.



Reisilaen on sihtotstarbeline tagatiseta laen eraisikutele summas 300 kuni 3000 eurot, perioodiga kuni 18 kuud. Erinevalt väikelaenust tasutakse reisilaenu reisipakkujale kliendi valitud reisi eest.

Käendusega tagatud laenu väljastatakse kliendile, kellel on üks või kaks füüsilisest isikust käendajat. Oma olemuselt kuulub nn väikelaenude rühma. Maksimaalne laenuperiood on viis aastat ning taotleda saab 2000 kuni 5000 eurot.

Laenu mootorsõiduki tagatisel pakutakse kahel viisil: autopant ja autolaen. Autopandi korral hoitakse mootorsõiduk SG parklas ning poolte vahel on kokkulepitud käsipandi seadmises ning autolaenu puhul jääb mootorsõiduk laenusaja kasutusse, kuid Maanteeametis registreeritakse seda SG nimele. Minimaalne aastane intressimäär on vastavalt 24 ja 36 protsenti. Laenusumma suurus on kuni 80 protsenti mootorsõiduki turuväärtusest ning vähemalt 2000 eurot. Laenuperioodi lõpuks ei tohi mootorsõiduk olla vanem kui 10 aastat.

Kinnisvaraga tagatud laen on laenutoode, kus tagatisena aktsepteeritakse kinnisasju. Hüpoteegi seadmise leping sõlmitakse notari juures. Taotletav summa algab 2000 eurost ning moodustab kuni 75% pakutava tagatise turuväärtusest. Laenu saab maksimaalselt 10 aastaks<sup>6</sup>, intressiga alates 14% aastas.

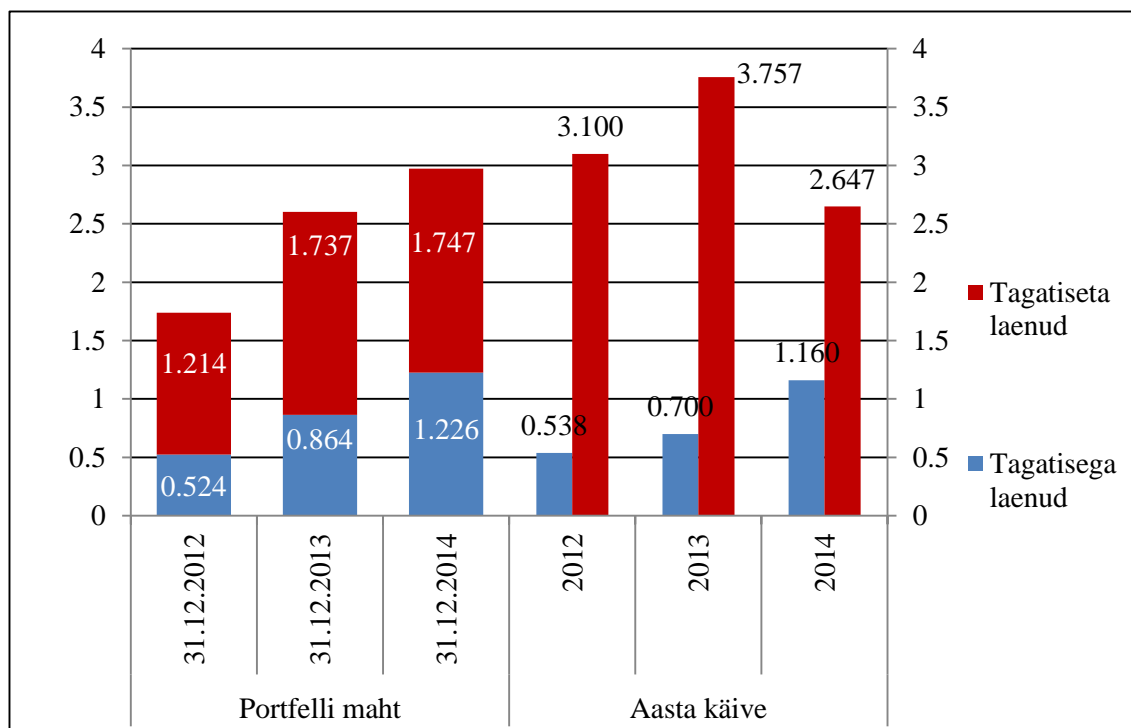
Alljärgneval joonisel 2.1 on toodud SNEL Grupp OÜ portfelli mahud ja aasta käibed miljonites eurodes erinevate laenutoodete lõikes aastatel 2012-2014. Kinnisvaraga ja mootorsõidukiga tagatud laenud ning käenduslaenud moodustavad tagatisega laenude portfelli, väikelaenud – tagatiseta (reisilaenu teenust pakutakse alates 2015. aastast).

Jooniselt 2.1 selgub, et üldine laenuportfelli maht on kolmanda tegutsemisaasta lõpus ligi 3 mln eurot, millest üle poole - 58,75% kuulub väikelaenudele. Võib märgata tagatisega laenude proportsiooni suurenemist koguportfelli mahust. Antud asjaolu on tingitud laenutoodete erinevast pikkusest: väikelaenud on pigem lühiajalised ja tagatisega laenud – pikemaajalised. Seda kinnitavad ka vastavate toodete aastakäibed. 2012. aasta jooksul oli tagatiseta laene väljastatud summas 3,10 mln eurot ning 2012.

---

<sup>6</sup> Kliendi soovil rakendatakse ka balloongraafikut, mille puhul laenu tagasimaksed arvutatakse välja kuni 15-aastase graafiku alusel. Nii jääb arvestatav osa laenu põhisummast laenu esialgseks lõpptähtajaks tagasi maksmata ja selle tasumise tingimustel lepatakse hiljem kokku.

aasta lõpus portfelli maht oli ligi 1,20 mln eurot. 2014. aasta lõpuks oli väljastatud kokku 9,504 mln eurot väikelaene ning portfelli suurus seisuga 31.12.2014 oli 1,747 mln eurot ehk 18,38% kolme aasta käibest.



**Joonis 2.1.** Tagatisega ja tagatiseta laenuportfelli maht ja vastavate toodete käibed aastatel 2012-2014 miljonites eurodes (autori koostatud).

Tagatislaenuid amortiseeruvad tunduvalt aeglasemalt: kolme aasta jooksul väljastatud summast 2,4 mln eurot 2014. aasta lõpuks on veel tagastamata laene summas 1,226 mln eurot, ehk 51,1%. Vaatamata sellele, et 2014. aasta kogu laenuportfellig moodustavad väikelaenuid alla 60%, antud laenukoote käive on kolme aasta jooksul tagatisega laenuid käibest olnud ligi neli korda suurem. Sama situatsiooni võib näha lepingute arvudes. Tabelist 2.1 selgub, et 2014. aasta lõpus on kehtivate väikelaenuid lepingute arv 5326 ning tagatisega laenuid - vaid 85.

2012.-2014. aastatel oli väljastatud keskmiselt 9726 väikelaenuid ning 46 tagatisega laenuid aastas. Kahjuks ei õnnestunud autoril teada saada tagasilükatud taotluste arvu. Kuid arvestades juba väljastatud laenuid arvu, võib teha järelduse, et ajaline kulu väikelaenuid taotluste hindamisel kokku on kordades suurem kui tagatisega laenuid puhul.

**Tabel 2.1.** Kehtivate ja sõlmitud lepingute arv aastatel 2012-2014, tükides

		<b>31.12.2012</b>	<b>31.12.2013</b>	<b>31.12.2014</b>
<b>Laenuid tagatisega</b>	kehtivad lepingud	35	68	85
	uued lepingud	37	56	46
<b>Laenuid tagatiseta</b>	kehtivad lepingud	4520	5619	5326
	uued lepingud	12461	11737	4980

Allikas: autori koostatud.

Seega arvestades portfelli mahu, aasta käibe eurodes ja lepingute arvuga, valib autor krediidiriski modelleerimiseks just tagatiseta laene ehk väikelaene. Järgnevalt autor tutvustab ja annab oma hinnangu SNEL Grupp OÜ-s kasutatavale krediidiriski hindamise meetodile, tuginedes ettevõtte üldreeglite ja teenindusstandarditele (SNEL Grupp OÜ...2014) ning omapoolse kaheaastasele kogemusele laenuhalduri ametikohal.

Võlaõigusseaduse § 403<sup>2</sup> kohaselt on SG kohustatud seoses tarbijakrediidiga järgima vastutustundliku laenamise põhimõtet. Vastutustundliku laenamise põhimõtte järgimiseks on SG enne tarbijakrediidilepingu sõlmimist kohustatud omandama teabe, mis võimaldab hinnata tarbija (edaspidi ka *klient* ja *laenusaja*) krediitvõimelisust. Vajaduse korral küsib SG tarbijalt teavet ja kasutab asjakohaseid andmekogusid. Samuti SG hindab tarbija krediitvõimelisust ja annab temale piisavaid selgitusi, et klient saaks hinnata pakutava tarbijakrediidilepingu vastavust tema vajadustele ja finantsolukorrale.

Krediidiriski paremaks juhtimiseks enne laenulepingu sõlmimist arvutab SG kliendi suhtes mõistliku laenukoormuse. SG peab mõistliku laenukoormuse arvutamiseks kogutud vajalike andmete ja dokumentide kohta laenutoimikut ettevõtte infosüsteemis, kust on pärit ka käesoleva töö analüüsiks vajalikud andmed. Eelkõige kliendilt endalt, aga ka SG poolt aktiivse otsinguga usaldusväärsetest allikatest saadud informatsiooni pinnalt ja SG igakordsel otsusel muudest allikatest järelepäritud informatsiooni alusel hindab ettevõtte, kas klient on võimeline tagastama laenu oma sissetulekute arvelt. SG võtab võimalusel mõistliku laenukoormuse arvutamisel arvesse:

- 1) erinevatest laenuoodetest tulenevaid erisusi;
- 2) laenuga seotud kohustuste suurust (eelkõige krediidi põhiosa ja intressi tagasimaksekohustust) ja sellega seoses võimalikku riski kliendi jaoks;

- 3) kliendi finantsolukorda laenuaotluse esitamise hetkel.

Krediidivõime hindamine toimub subjektiivse meetodiga, skooringtehnoogiaid hetkel ettevõtte veel ei kasuta. Krediidivõimelisuse hindamisel võtab laenuhaldur arvesse järgmiseid aspekte:

- 1) milline on laenu taotleja netosissetulek;
- 2) kas laenu taotlejal on ülalpeetavaid isikuid ning kui suur on nende arv;
- 3) milline on laenuaotleja krediidi ajalugu avalike allikate põhjal;
- 4) kas laenuaotleja on varem olnud lepingulistest suhetes SG-ga ning milline on sealjuures olnud tema maksekäitumine;
- 5) kas esineb muid asjaolusid, mis annavad aluse kahelda laenuaotleja suutlikkuses ja valmisolekus täita laenulepinguga endale võetavaid kohustusi nõuetekohaselt.

Juhul kui isikul, kes otsustab laenu väljastamist, on alust kahelda koostatud sissetulekute analüüsi õiguses, on ta kohustatud analüüsi tulemusi või vastavaid andmeid kontrollima. Isiku sissetulekute kontrollimiseks kasutatakse üldjuhul kliendi panga poolt paberandjal või digitaalselt kinnitatud kontoväljavõtteid. Erandina aktsepteeritakse väikelaenu puhul ka kinnitamata ja koopiana esitatud kontovaljavõtteid. Üldjuhul väiksemate summade (kuni 300 eurot) ja korduvklientide puhul kontoväljavõtet igakordse laenuaotlusega ei küsita. Vahepeal maksevõime analüüsil tuginetakse üksnes taotluses esitatud informatsioonile, mis ei pruugi vastata tõele.

Laenusaja väljastatava laenusumma suurus oleneb eelkõige tema enda netosissetuleku suurusest. Netosissetuleku leidmiseks lahutatakse kliendi igakuistest perioodilistest sissetulekutest tema perioodilised väljaminekud. Seejuures võetakse sissetulekutena arvesse pangakonto väljavõttelt nähtuvad (kinnitatud) sissetulekud, väljaminekutena, aga nii pangakonto väljavõttelt nähtavad kui ka laenuaotlusel näidatud (deklareeritud) väljaminekud.

Taotleja maksevõimeks loeb SG taotleja suutlikkust tagasi maksta ja teenindada võetud finantskohustusi ning elamiskulusid jt väljaminekuid. Maksevõime näitajaks on

arvestuslik reserv, mis leitakse taotleja igakuistest netosissetulekust elamiskulude jt väljaminekute ning taotletava laenumaksete mahalahutamisel. Maksevõime loetakse piisavaks kui reserv on suurem kui 0.  $\text{Reserv} = \text{netosissetulek} - \text{elamiskulud} - \text{muud väljaminekud} - \text{taotletava laenu kuumakse}$ . Olenemata taotleja maksevõimest, ei tohi SG standartide järgi taotletava ja olemasolevate laenude kuumaksed ületada 55% taotleja netosissetulekust.

Peale maksevõime kontrolli teostatakse ka kliendi tausta kontrolli, mis koosneb päringutest Maksu- ja Tolliametisse, AS Krediidiinfosse, OÜ Krediidiregistrisse, Äriregistrisse ja muudesse (täpsemalt avalikult kättesaadavatest allikatest võib lugeda käesoleva töö 1.3 alapunktis ning nende loetelu leida tabelis 1.3, lk 28). Lisaks sellele kontrollitakse kliendi poolt märgitud aadressi olemasolu.

Ülaltoodust järeltab käesoleva töö autor, et SNEL Grupp OÜ kasutab subjektiivset meetodit krediidiriski hindamiseks, rakendades võtteid ja tehnikaid, millest kirjutavad ka erinevad välismaised autorid (nt Kalapodas, Thomson 2006: 26, McNaughton 1992: 36). Välja töötatud meetodika on väga põhjalik ning võtab arvesse kõiki peamisi tegureid, mida kasutatakse riski hindamiseks ka statistiliste meetoditega (täpsem info leidub alapunktis 1.2, tabel 1.4, lk 26): varasem maksekäitumine, sissetulek, finantsolukord ja muu avalikult kättesaadav oluline info. Subjektiivne meetod on aeganõudev, ning arvestades taotluste arvuga - kallid meetod eraisiku krediidiriski hindamiseks. Samal ajal juhul, kui tegemist on teistest tugevasti erineva taotlusega, võib antud meetod osutada tänu oma personaalsele lähenemisele statistilistest meetoditest paremaks. Seda toovad näiteks ka Hand ja Henley oma töös (1997: 531). Peale selle võib laenuotsus sõltuda konkreetse töötaja oskustest, pädevusest ja informatsiooni tõlgendamisest.

Kokkuvõtvalt võib öelda, et finantseerimisasutuse SNEL Grupp OÜ põhitegevuseks on tagatiseta ja tagatisega laenude pakkumine. Toetudes ettevõtte 2012.-2014. aastate portfelli mahtudele, toodete käivetele ja lepingute arvule, võib teha järelduse, et peamiseks tooteks on tagatiseta laen ehk väikelaen. Sõlmitud lepingute arv ja taotluste läbivaatamiseks kulutatud aeg on kordades suurem, kui tagatisega laenude puhul, seega krediidiriski hindamise optimeerimine oleks rohkem vajalik just väikelaenude jaoks. Võttes arvesse asjaolu, et ettevõtte hetkel kasutab subjektiivset krediidiriski hindamise

süsteemi, koostab autor käesoleva magistritöö raames skoorimudeli, mis võimaldab muuta krediidiriski hindamise ja laenuotsustamise protsessi kuluefektiivsemaks. Järgmises alapunktis tuuakse andmete ja muutujate ülevaade ning arvutatakse kategooriliste tegurite informatsiooni väärtust.

## **2.2 Erasisiku krediidiriski modelleerimiseks kaasatud andmed ja muutujad**

Käesolevas alapunktis koostab autor ülevaadet analüüsi kaasatud andmetest, teostab pidevate muutujatega vajalikud kodeeringud, määrab valimi proportsiooni ja teostab kirjeldavat analüüsi. Alapunkti eesmärgiks on jõuda lõpliku andmete koosseisuni, mida kasutatakse skoorimudeli koostamisel. Analüüsi on kaasatud 100 kuni 3000 eurot väikelaenude tarbijate andmed. Modelleerimiseks on võetud nii tagastatud kui ka hetkel aktiivsed (klient maksab laenu graafiku järgi) laenud. Analüüsitakse perioodil 01.07.2012 – 01.07.2014 rahuldatud laenuaotluste andmed. Siinkohal on tähtis märkida, et osa väljastatud laenudest ei ole veel tagastatud, seega staatuse kontrollimine peab olema ajaliselt korrektselt rakendatud. Hetkel kontrollitakse veel tagastamata laenude puhul laenu staatust („hea“ või „halb“) 01.05.2015 kuupäeva seisuga, ehk viimaste laenude väljastamisest on möödunud 10 kuud. Autori arvates on see piisavalt pikk aeg selleks, et oleks võimalik järeldada, millisesse gruppi - „halba“ või „hea“ - kuulub laen. See on suures osas kooskõlas Thomas *et al.* (2002: 122) pakutuga, kus autorid tõid välja, et 9-12 kuud on piisav aeg korrektse tulemuse välja selgitamiseks. Analüüsi teostamisel kasutatakse statistilist tarkvaraprogrammi STATA ja andmetöötlusprogrammi Microsoft Excel.

Nagu oli juba varem mainitud, ei vasta mõned kliendi poolt taotluses esitatud maksevõime muutujad tegelikkusele, vaatamata sellele, et nad on kinnitanud esitatud andmete õigsust. Selliseid mittevastamisi on võimalik tuvastada näiteks klientide kontoväljavõtete analüüsimisel või kliendiga suhtlemise käigus. Kuna andmed on saadud muutmata taotlustest, tuleb arvestada sellega, et mõnedes taotlustes toodud info ei vasta inimese reaalsele olukorrale, mistõttu mõned kirjanduses leitud olulisemad muutujad (vt tabel 1.4, lk 26), nt finantsseisundit iseloomustavad karakteristikud võivad osutada statistiliselt ebaolulisteks kahe grupi eristamisel.

Modelleerimiseks on saadud üldkogum 18865 eraisikutele väljastatud laenudega. Pärast erindite eemaldamist jäi valimisse 18302 vaatlust. Nii suur erindite arv on tingitud SG infosüsteemi spetsiifikast: laekunud laenutaotlused salvestatakse süsteemis muutmata kujul. Laenuametnik ei saa muuta näiteks kliendi poolt kogemata sisestatud „600“ ülalpeetavat või „30 tuh. eurot igakuised kulutused“. Vaatlused olid kogu analüüsi perioodi jooksul jaotatud ühtlaselt. „Halb“ laen ehk maksejõuetus on tulenevalt teoreetilises osas käsitletust defineeritud kui makseviivitus üle 60 päeva. Antud definitsioon sobib ka ettevõttele selle spetsiifikat arvestades, kuna 61 viivituspäeval võlgnikule saadetakse laenulepingu ülesütlemise teatis. Erindite eemaldamise järgselt jäi koguvalimisse 3474 „halba“ laenu ehk 18,98% kogu vaatluste arvust ning 14828 „hea“ laenu ehk 81,02% üldvalimist.

SG andmebaasist on õnnestunud saada kokku 27 muutujat. Lisaks 3 muutujat on konstrueeritud autori poolt: laenu osamakse ja sissetuleku suhe (*LTI*), kõikide ankeedis märgitud olemasolevate igakuiste osamaksete ja sissetuleku suhe (*ALTI*), ning *reserv*, mida arvutatakse vastavalt SG üldreeglitele. Analüüsi on kaasatud kõik tegurid, mis on leidnud kasutust välismaa autorite uurimustes ja toodud tabelis 1.4, lk 26. Tegurite loetelu on toodud tabelis 2.2, kus muutujad on grupeeritud viite põhilistesse rühma, vastavalt käesoleva töö teoreetilises osas toodud põhimõtetele: lähtuvalt teguri päritolust, kättesaadavusest, avaldatavast mõjust ja objektist (vt joonis 1.2, lk 27).

Tabelis 2.2 esinevad nii pidevad kui ka kategoorilised ja nominaalsed muutujad. Esimese muutujate kategooria koosneb varasema maksekäitumise iseloomustavatest karakteristikutest. Muutuja *viivitus* on binaarne tunnus, mis näitab, kas viimase kolme laenu tasumisel on esinenud makseviivitusi üle 30 päeva või mitte. Kui klient on tagastanud ettevõttele laenu korrektselt, siis muutuja omab väärtust 0. *Kohtu\_k* ja *hasart* on 0, kui taotluse esitamisel klient märgib, et temal ei olnud ühtegi laenu välja nõutud kohtutäiturite või kohtu kaudu ning tema ei harrasta hasartmänge. Vastasel juhul muutujad omavad väärtust 1 ning eelduste kohaselt see tõstab krediidiriski.

Autori arvamusel, kui laenutaotleja märgib, et tema on varem kasutanud laenuteenuseid ehk kinnitab enda kogemust finantsteenuste tarbimises, siis tema maksejõuetuks muutumise tõenäosus peab olema väiksem. Sel juhul omab *kogemus* väärtust 1, vastasel juhul, kui kogemust pole, on 0.

Tabel 2.2. Eraisiku krediidiriski modelleerimisel kasutatud muutujad

Muutuja valdkond	Kodeering	Muutuja
<b>Varasem maksekäitumine, kliendisuhted</b>	<i>viivitus</i>	Varem hilinenud maksetega üle 30 päeva
	<i>kohtu_k</i>	Laene väljanõutud kohtutäiturite või kohtu kaudu
	<i>hasart</i>	Kas harrastatakse hasartmänge
	<i>kogemus</i>	Eelnev kogemus finantsteenuste kasutamises
	<i>bank</i>	Pank, kuhu klient soovib laenu saada
	<i>laen_nr</i>	Juba tagastatud laenude arv
<b>Finantsseisund</b>	<i>sissetlk</i>	Kuine netosissetulek
	<i>kulud</i>	Igakuised kulutused (v.a. finantskohustused)
	<i>kohustus</i>	Igakuiste finantskohustuste suurus
	<i>reserv</i>	<i>sissetlk</i> – <i>kulud</i> – <i>kohustus</i> – osamakse
	<i>kv</i>	Kinnisvara olemasolu
<b>Sotsiaal-demograafilised karakteristikud</b>	<i>vanus</i>	Kliendi vanus
	<i>eluase</i>	Isiklik korter/maja või mitte
	<i>sugu</i>	Kliendi sugu
	<i>lapsed</i>	Ülalpeetavate arv
	<i>haridus</i>	Kliendi haridus
	<i>staaz</i>	Töötatud aeg ankeedis märgitud töökohas
	<i>pereseis</i>	Kliendi perekonnaseis
	<i>area</i>	Maa või linna elanik
	<i>keel</i>	Ankeedis märgitud suhtluskeel
<b>Avalik informatsioon</b>	<i>mh_act</i>	Kehtivate maksehäirete arv Krediidinfo järgi
	<i>mh_clsd</i>	Tasutud maksehäirete arv Krediidinfo järgi
	<i>taust</i>	Ametlikud Teadaanded ja interneti otsingumootori tulemused
	<i>rr</i>	Rahvastikuregistri andmed
<b>Laenu karakteristikud</b>	<i>lnlaen_s</i>	Logaritmitud laenusuurus
	<i>lnosam</i>	Logaritmitud osamakse suurus
	<i>lnper</i>	Logaritmitud laenupikkus
	<i>talvekuu</i>	Talvel esitatud taotlus
	<i>LTI</i>	osamakse/igakuine neto sissetulek
	<i>ALTI</i>	(kohustus+osamakse)/ igakuine neto sissetulek

Allikas: autori koostatud.

Muutuja *bank* iseloomustab taotleja panka, kuhu kantakse laen. Autori ning sissenõudmisosakonna kolleegide tagasiside ja subjektiivse hinnangu järgi on vähem kasutatud pankade (nt Krediidipank, Citadele, LHV) puhul laenu tasumata jätmise tõenäosus suurem. Rohkem levinud pankade puhul (Swedbank, SEB, Nordea, Danske) muutuja *bank* väärtus on 0, vastasel juhul 1. Viimasena on kliendisuhete pikkust iseloomustav kategooriline muutuja *laen\_nr*, mille grupid on esitatud tabelis 2.3.



Allpool toodud tabelist on näha, et uute klientide käes olevate laenude kvaliteet on ligi kaks korda halvem, võrreldes nendega, kes vähemalt ühe laenu juba tagastanud (edaspidi püsiklient).

**Tabel 2.3.** Muutuja *laen\_nr* kategooriad

Kodeering	Laenude arv	Vaatlused	Sagedus (%)	Halbu laene (%)
0	0	5865	32,05	32,65
1	1-2	5711	31,20	17,96
2	3-4	2878	15,73	11,40
3	5-6	1587	8,67	6,62
4	7-9	1197	6,54	5,35
5	>10	1064	5,81	3,38
<b>Kokku</b>		<b>18302</b>	<b>100,00</b>	

Allikas: autori koostatud.

Üleval esitatud tabelist 2.3 näeme, et parem maksekäitumine on nendel laenuvõtjatel, kes on juba mitu laenu tagastanud, kuid selle seose tugevuse ja olulisuse kohta saab teha järelduse alles peale logistilise mudeli koostamist. Järgmine muutujate grupp koosneb finantsseisundit iseloomustavatest karakteristikutest. Eeldatakse, et mida suurem on kliendi igakuine netosissetulek ja reserv ning väiksem kulutuste ja finantskohustuste igakuine summa, seda väiksem on krediidirisk. Kuni 2014. aastani klient sai ise sisestada enda sissetuleku ja kulutuste suurust, hiljem süsteemi muudeti vahemikupõhiseks. Vastavate muutujate arväärtused pärast 2014. aastat olnud andmetes on esitatud vahemiku keskmise väärtusega. Pärast *LTI*, *ALTI* ja *reserv* muutujate konstrueerimist, muutujad *sissetlk*, *kulud*, *kohustus* ja *reserv* olid muudetud kategoorilisteks, kuna nende interpreteerimine pidevate muutujatena ei ole korrektne ega võimalik. Peale selle märkis Hand, et kategoriseeritud muutujate interpreteerimine on lihtsam (2001: 144). Lisaks sellele soovib autor kontrollida muutujate informatsiooni väärtust, nagu Kočenda ja Vojtek tegid enda uurimuses (2009: 27). Kodeerimisel on tähtis jälgida, et grupid oleksid maksimaalselt sarnased, et ükski kategooria ei domineeriks teiste üle. Kodeeringut näeb lisas 2. Viimasena on toodud binaarne muutuja kinnisvara olemasolu ( $kv = 0$  kui kinnisvara puudub, 1 – kui olemas), mis ühelt poolt näitab kliendi maksevõimet, teisalt osutub distsiplineeritavaks faktoriks selle võimaliku ilmajäämise tõttu.

Modelleerimiseks kasutatakse 9 sotsiaal-demograafilist muutujat, millest binaarsed on *area* (0 kui linna maaelanik, 1 = linnaelanik), *keel* (0 kui eesti keel, 1 = vene keel), *pereseis* (0 kui abielu või vabaabielu, 1 = mitte), *staaž* (0 kui töötab antud töökohas rohkem kui aasta, 1 = kui vähem, sh katseajal ja töötu), *sugu* (0 = naine, 1 = mees) ja *eluase* (0 kui elab isiklikus korteris/majas, 1 = kui mitte). Muutuja *keel* viitab kaudselt rahvusele, kuid paljud vene keelt emakeelena kõnelevad noored märgivad suhtluskeelena siiski eesti keelt. Tööstaaži, elukoha ja perekonnaseisu mõjusuunad on käsitletud käesoleva töö 1.2 alapunktis. Pikem tööstaaž on üldiselt tugevalt positiivselt seotud laenu korrektse tagastamisega. Sama seost on oodata ka linnaelanikel ning abielus olevatel klientidel. Meeste puhul oodatakse suuremat tõenäosust muutuda maksejõuetuks. Hariduse olulisust on täheldatud ka teoorias – mida haritum on laenutaotleja, seda väiksem on maksejõuetuks muutumise tõenäosus (Arslan, Karan 2010: 35; Kočenda, Vojtek 2009: 15). Muutuja on loogiliselt järjestatud nii, et *haridus* omab 0 väärtust kõrghariduse puhul, 1 = kutse- või keskhariiduse puhul ning 2 = põhi- või alghariduse puhul. Muutuja *lapsed* iseloomustab ülalpeetavate arvu, mida klient märgib ankeedis. Ülalpeetavateks loetakse kuni 18-aastased lapsed ja näiteks töötud vanemad, kelle ülalpidamiseks kulub osa kliendi sissetulekust. Eelduste kohaselt, mida suurem on ülalpeetavate arv, seda vähem jääb raha kohustuste teenindamiseks ning seda suurem on krediidirisk. Viimaseks teguriks on kliendi *vanus* laenutaotlemise hetkel. Tunnus ei ole pidev, kuna andmebaasist õnnestus saada vaid täisaastate arvu. Informatsiooni väärtuse arvutamise jaoks ning tõlgendamise lihtsustamiseks muutujat otsustati grupeerida. Vahemikud ja „halva“ laenu proportsioonid on toodud tabelis 2.4.

**Tabel 2.4.** Muutuja *vanus* kategooriad

Kodeering	Vanus	Vaatlused	Sagedus (%)	Halbu laene (%)
0	<22	1383	7,56	35,94
1	≥22<26	2803	15,32	23,12
2	≥26<32	3563	19,47	19,00
3	≥32<39	3501	19,13	15,22
4	≥39<50	3944	21,55	15,31
5	≥50	3108	16,98	16,57
<b>Kokku</b>		18302	100,00	

Allikas: autori koostatud.

Gruppide moodustamisel lähtuti ettevõtte huvidest ning jälgiti ka seda, et ühtegi vanusegruppi ei kuuluks liiga palju vaatlusi. Mõnevõrra üllatusena tuli noorematele klientidele väljastatud laenude kvaliteet (35,94% „halbu“ laene), mis on keskmisega võrreldes (18,98%) ligi kaks korda kehvem näitaja.

Avalikult kättesaadav informatsioon on esindatud nelja muutujaga. Muutuja *rr* (0 – kui rahvastikuregistri järgi isikul on sissekirjutus Eestis, ning aadress on märgitud korteri/talu täpsusega, 1 = kui välismaalane, aadress on poolikult märgitud, või informatsioon sissekirjutuse kohta puudub) on modelleerimise kaasatud eeldusega, et väga tihti petturitel või suurema krediidiriskiga isikutel on rahvastikuregistri andmed kas kustutatud või on pooleli. Eelduse suuna ja mõju kohta oma arvamust on autorile avaldanud sissenõudmisosakonna kolleegid. Kahtlase taustaga inimestelt oodatakse kehvemat kohustuste teenindamist (*taust* = 0, kui *Google* või Ametlike Teadaannete järgi leidub informatsioon, mis ei välista laenu väljastamist, kuid samas viitab laenuaotleja kehvema maksekäitumisele, nt tasumata trahvid; vastava mäрге jätab laenuametnik ettevõtte infosüsteemis. Vastasel juhul muutuja omab väärtust 1). *mh\_act* ja *mh\_clsd* on tunnused, mis näitavad kehtivate ja tasutud maksehäirete arvu laenuaotlemise hetkel Krediidinfo AS järgi. Muutujad on kodeeritud järgmiselt: *mh\_act* ja *mh\_clsd* = 0 kui kehtivaid või tasutud maksehäireid polnud, 1 = kui oli üks tasumata/tasutud ebaoluline maksehäire, 2 = kui neid oli kaks või rohkem. Kehtivate maksehäirete arv 1 kategoorias on 728 ja teises = 213; tasutud maksehäireid vastavalt 2540 ja 3287. Vastavalt SG üldreeglitele, kui laenuaotlejal on kehtivad maksehäired, üldjuhul laenu ta ei saa. Ebaolulise maksehäire puhul (kuni 320 eurot) tehakse täiendav kontroll ning taotluse rahuldamine pole välistatud. Tasutud maksehäirete arvu puhul eelselekteerimist ei toimu, kuid suurem tasutud võlgnevuste arv annab selgesõnalist signaali kliendi maksevõimest ja –käitumisest.

Viimaseks analüüsitakse 6 laenu iseloomustavat tegurit. *lnlaen\_s*, *lnosam*, *lnper* – standarthälvete vähendamise eesmärgiga logaritmitud laenu karakteristikud, mille suuremad väärtused tähendavad suuremat riski kõrgema maksekoormuse ja pikema perioodi tõttu. Eelduste kohaselt, mida pikem on taotletava laenu periood, seda suurem on tõenäosus, et laen võib jääda tasumata. Kui laenu oli taotletud talvekuudel (detsember, jaanuar, veebruar) omab *talvekuu* muutuja väärtust 1, vastasel juhul 0.

Lisaks alapunktis 1.2 toodud eeldusele võidakse autori arvamusel just talvekuudel võtta rohkem kiir-laene hetkeväljaminekute katmiseks, mis võib pikemas perspektiivis vähendada maksevõimet. *LTI* ja *ALTI* võib lugeda nii finantsseisundi, kui ka laenu karakteristikuks, kuna nende arvutamiseks kasutati mõlema grupi muutujad. Suuremad laenuteeninduse määrad tähendavad suuremat maksekoormust, mis peaks negatiivselt mõjutama krediidiriski. Tabelis 2.5 on toodud vaatluste jaotus ja maksedistsipliin maakonniti.

**Tabel 2.5.** Vaatluste jaotus ja maksedistsipliin maakonniti

	<b>Vaatlused</b>	<b>Sagedus (%)</b>	<b>Halvad laenud (%)</b>
<b>Põlvamaa</b>	237	1,29	28,69
<b>Järvamaa</b>	304	1,66	26,97
<b>Hiiumaa</b>	56	0,31	25,00
<b>Jõgevamaa</b>	303	1,66	24,42
<b>Lääne-Virumaa</b>	719	3,93	24,34
<b>Viljandimaa</b>	435	2,38	23,68
<b>Läänemaa</b>	196	1,07	22,96
<b>Saaremaa</b>	190	1,04	21,05
<b>Pärnumaa</b>	818	4,47	21,03
<b>Tartumaa</b>	1761	9,62	19,76
<b>Ida-Virumaa</b>	2843	15,53	19,52
<b>Raplamaa</b>	390	2,13	19,23
<b>Võrumaa</b>	219	1,20	17,35
<b>Harjumaa</b>	9412	51,43	17,21
<b>Valgamaa</b>	419	2,29	15,51
<b>Kokku / Keskmine</b>	<b>18302</b>	<b>100</b>	<b>18,98</b>

Allikas: autori koostatud.

Lisaks tabelis 2.2 loetletud muutujatele õnnestus autoril saada ka karakteristikut, mis iseloomustab laenuaotleja maakonda. Kuna antud muutujad ei ole võimalik loogiliselt järjestada krediidiriski modelleerimiseks, kasutab autor seda maksedistsipliini jaotamise analüüsimiseks. Maakonnad on järjestatud alustades kõige kehvema maksedistsipliiniga maakonnast. Krediidiriski modelleerimisel antud karakteristikut otseselt siiski ei kasutata.

Ülaltoodud tabelist 2.5 selgub, et kõige korrektsema maksekäitumisega on Valgamaa elanikud, kelle maksejõuetuks muutmise tõenäosus 15,51% on üle kolme protsendipunkti vähem kui keskmine. Peale Valgamaa tagastavad laenud keskmisest paremini Võru- ja Harjumaa elanikud. Kõige rohkem tasumata jäetud laene on Põlva-, Järva- ja Hiiumaa elanikel – vähemalt iga neljas väljastatud laen osutub probleemseks. Autoril pole võimalik kindlalt selgitada, millest on tingitud kahe naabermaakonna - Valgamaa ja Põlvamaa „halbade“ laenude osakaalu ligi kahekordne vahe. Võibolla on see tingitud suuremate tööandjate olemasolust ja suurema töökohtade arvust. Ühtlasi tabelist 2.5 on näha, et üle 51% laenuaotlejatest elab Harjumaal. Üle 75% kliendibaasist koosneb taotlejatest, kes elavad Ida-Viru, Tartu ja Harju maakonnas. Kõigest 56 laenu ehk 0,31% on väljastatud Hiiumaa elanikele. Ülejäänud maakonnad moodustavad 1,04% kuni 4,47% andmebaasist.

Kokkuvõtvalt võib öelda, et käesoleva analüüsi jaoks on õnnestunud saada väga mahuka valimi – 18302 vaatlust. Kõige lähedama valimi mahuga on olnud William Greene töö, kus modelleerimisel kasutati 13444 vaatlust (2008: 26). „Halbu“ laene on 18,98% ning „häid“ 81,02%. Modelleerimiseks kasutatakse kokku 30 muutujat. Mõned muutujad, nt vanus, laenude arv, sissetulek ja teised on kategoriseeritud, mis lihtsustab nende interpreteerimist tulemuste tõlgendamisel. Peale selle arvutatakse järgmises alapunktis kõikide kategooriliste muutujate informatsiooni väärtust (IV), välja selgitamas, millised muutujad kaasata analüüsi. Alapunkt 2.3 algab koostamise ja testvalimi moodustamisega ning esialgse mudeli kokku panemisega.

## **2.3 Skoorimudeli koostamine, tulemuste analüüs**

Mudelite koostamiseks ja õigesti klassifitseerimisvõime testimiseks ei kasutata sama valimit. Käesolevas magistritöös jagatakse üldvalim kaheks: 25 protsenti vaatlustest lisati klassifitseerimise testvalimisse ning ülejäänud 75 protsenti mudeli koostamise valimisse. Valimid koostatakse juhuslikul meetodil iga sõltuva muutuja grupist ajaliselt reastatud vaatluste alusel. Numbriliselt koosneb testvalim 868 „halbade“ ja 3707 „headest“, protsentuaalselt vastavalt 18,97% ja 81,03% ning koostamise valim 2606 „halbade“ ja 11121 „headest“ laenudest, protsentuaalselt vastavalt 18,98% ja 81,02%. Nõnda säilitakse mõlemal juhul üldvalimi heade ja halbade laenude proportsioonid.

Lisas 4 on esitatud andmete kirjeldav statistika, lisatud ka binaarsete ja grupeeritud muutujate informatsiooni väärtus (*IV*). Praktikas piisavaks loetakse muutujat, mille informatsiooni väärtus on suurem kui 0,1. Väiksema väärtusega muutujat modelleerimisse kaasata ei soovitata. Tugevaks loetakse informatsiooni kriteeriumit alates 0,3. (Kočenda, Vojtek 2009: 8) Tabelis 2.6 on toodud muutujad, mille informatsiooni väärtus ehk ennustusvõime on piisav.

**Tabel 2.6** Andmete kirjeldav statistika ja informatsiooni väärtus

Muutuja	Vaatluste arv	Keskmine/Sagedus	Standarthälve	Min	Max	<i>IV</i>
<i>kogemus</i>	18302	0,9070593	0,2903572	0	1	<b>0,194</b>
<i>kv</i>	18302	0,3933996	0,4885176	0	1	<b>0,183</b>
<i>haridus</i>	18302	0,9451972	0,5555347	0	2	<b>0,095</b>
<i>vanus</i>	18302	2,827451	1,533786	0	5	<b>0,113</b>
<i>laen_nr</i>	18302	1,438968	1,466552	0	5	<b>0,533</b>

Allikas: autori koostatud lisas 4 oleva tabeli alusel.

Tabelist 2.6 järeldub, et 30-st on vaid viiel muutujal informatsiooni väärtus piisav (olgu väärtust 0,095 loetakse ka piisavaks). Kõrgema *IV*-ga on muutuja *laen\_nr*, mis näitab tagastatud laenude arvu ehk iseloomustab kliendisuhete pikkust. Sama gruppi kuulub ka muutuja *kogemus*. Sotsiaal-demograafilisi muutujaid esindavad *haridus* ja *vanus*, mille informatsiooni väärtust võib pidada keskmiseks. Tabelist järeldub, et keskmine klient on 32 kuni 39 aastane, kutse- või keskharidusega, kes on juba tagastanud ühe või kahe laenu ning kellel on 39,33% tõenäosusega olemas kinnisvara. Kliendi maksevõime muutujatest omab olulist informatsiooni väärtust vaid *kv* ehk kinnisvara olemasolu. Ülejäänud muutujate niivõrd madal informatsiooni väärtus võib olla tingitud asjaolust, et „head“ ja „halvad“ laenud esindatud väga ebavõrdselt. Toodud tulemus on siiski informatiivse iseloomuga, sest skoorimudelite loomisel on arvesse esialgu võetud kõik muutujad. Pärast lõpliku mudeli valmimist võib teha järelduse, kuivõrd usaldusväärseks võib antud kriteeriumit pidada. Mudelite koostamise meetodist tulenevalt ei jää mudelisse ebaolulisi muutujaid.

Logit-meetodi kasutamine eeldab erindite, puuduvate väärtuste puudumist ja sõltumatute muutujate multikollineaarsuse puudumist. Kahe esimese eeldusega on

tegeletud eelmises alapunktis ning tulemuseks saadi valim, mis vastab nende logit-meetodi eeldustele.

Muutujate omavahelisi korrelatsioonikordajaid näitab Pearsoni korrelatsiooni maatriks. Suurte valimite puhul peetakse oluliseks korrelatsiooni, mille absoluutväärtus on suurem kui 0,7. Korrelatsiooni maatriksi kontrollimine on kasulik, kuid mitte piisav viis multikollineaarsuse kontrollimiseks. Paremaks meetodiks võib nimetada VIF'i (*variance inflation factor*) ehk dispersiooni inflatsioonifaktorit. Kui VIF'i väärtus on suurem kui 10, viitab see multikollineaarsuse olemasolule. Lihtsamaks võtteks multikollineaarsuse vähendamiseks loetakse tugevalt korreleeritud muutujate mudelist eemaldamist. (Midi *et al.* 2010: 257-261) VIF'i asemel võib kasutada tolerantsuse näitajat (TOL), mis on tegelikult VIF'i pöördväärtus. Teiseks multikollineaarsuse indikaatoriks on suur koefitsiendi hinnangu standartviga ning laiad 95% usaldusintervallid.

Logit-mudelit koostatakse kasutades *backward stepwise* tehnikat ehk esialgu mudelisse kaasatakse kõik muutujad ning edaspidi eemaldatakse ükshaaval ebaolulised tegurid. Olulisust kontrollitakse *p-value* järgi, mis ei tohi ületada 95% olulisusenivool väärtust 0,05. Eemaldamist alustatakse kõige suurema *p-value* muutujast.

Analüüsi läbiviimiseks koostas autor järgneva ökonomeetrilise mudeli:

$$(4) \quad Y_i = \beta_0 + \beta_1 X_{k1} + \beta_2 X_{k2} + \dots + \beta_n X_{kn} + \varepsilon_i$$

kus  $Y_i$  - logistilise regressiooni väärtus,  
 $\beta_1, \beta_2, \dots, \beta_n$  - mudeli parameetrid,  
 $X_{1k}, X_{2k}, \dots, X_{nk}$  - mudeli sõltumatud muutujad,  
 $\beta_0$  - vabaliige,  
 $\varepsilon_i$  - mudeli vealiige,  
 $n$  = vaatluste arv 13726.

Krediidiriski modelleerimist alustatakse mudelist, mille „heade“ ja „halbade“ laenude proportsioon jäi koguvalimiga võrreldes samaks (mudel L1). Korruga lisatud kõik tabelis 2.2 toodud muutujad ning peale selle hakati ükshaaval eemaldama vähem statistiliselt olulised muutujad. Saadud esialgne mudel oli kontrollitud multikollineaarsuse esinemise suhtes, mille tulemusena olid eemaldatud veel mõned

muutujad, nt *kv*, kuna see oli suhteliselt tugevalt seotud vanusega (korrelatsioon üle 0,4) ning *lnper*, mille VIF oli 13,07. Teiseks kontrolliti hinnangute mõjusuunad, kui hinnangu märk ei olnud loogiline (nt kehtivate maksehäirete suurem arv või kõrgem laenuteeninduse määr vastasid väiksemale tasumata jätmise tõenäosusele) – eemaldati muutuja mudelist. Statistiliselt olulisteks jäänud muutujad toodud tabelis 2.7.

**Tabel 2.7** Statistiliselt oluliste parameetritega logistiline regressioonimudel (L1) krediidiriski tegurite mõju hindamiseks kliendi maksejõuetuks muutumise tõenäosusele

Muutuja valdkond	Muutuja	Parameetri hinnang	Standartviga
Varasem maksekäitumine, kliendisuhted	<i>viivitus</i>	1,017726***	0,12895
	<i>kohtu_k</i>	0,234067**	0,10398
	<i>bank</i>	0,463256***	0,15220
	<i>kogemus</i>	-1,02775***	0,06812
	<i>laen_nr</i>	-0,5357***	0,02337
Finantsseisund	<i>sissetlk</i>	-0,15582***	0,02144
Sotsiaal-demograafilised karakteristikud	<i>vanus</i>	-0,05907***	0,01746
	<i>eluase</i>	0,162155***	0,05404
	<i>sugu</i>	0,324642***	0,05348
	<i>haridus</i>	0,316238***	0,04522
	<i>staaz</i>	0,103544*	0,05588
	<i>pereseis</i>	0,165548***	0,04983
Avalik informatsioon	<i>taust</i>	-0,20802*	0,11140
	<i>rr</i>	0,448046***	0,08520
Laenu karakteristikud	<i>lnlaen_s</i>	0,725039***	0,03693
	<i>vabaliige</i>	-4,12561***	0,25111

n=13727; Pseudo R<sup>2</sup> = 0,1817; \*\*\* - olulisuse nivool 0,01; \*\* - olulisuse nivool 0,05; \* - olulisuse nivool 0,1 statistiliselt oluline.

Allikas: autori koostatud.

Mudelisse jäid vaid statistiliselt olulised muutujad vähemalt olulisuse nivool 0,1, teised, sh multikollineaarsust põhjustavad muutujad, olid eemaldatud (vt lisa 3 ja lisa 5 testide tulemused). Selle tulemusena osutus 30-st muutujatest statistiliselt olulisteks 15, mis on teiste autoritega võrreldav suurus (vt tabel 1.4, lk 26).

Tabelis 2.7 esitatud tulemuste alusel võib väita, et krediidiriski aitavad eristada kõikides mõjurite gruppides asuvad muutujad, mis on autori poolt pakutud antud töö teoreetilises osas. Kõige rohkem on sotsiaal-demograafilisi (6) ja varasemat maksekäitumist iseloomustavaid (5) statistiliselt olulisi muutujaid. Kõige tagasihoidlikumalt esindatud muutujate grupiks on osutunud finantsseisundi ja laenutoodet iseloomustatav. Tulemus



on ühelt poolt üllatav, kuna nii autori arvamusel kui ka teorias toodu põhjal (Rose 1991; Angelis *et al.* 2008 Arslan; Karan 2010 Jacobson; Roszbach 2003 ja teised), peaksid eraisiku finantsnäitajad olema põhilisteks kahte grupi eristamisel. Vastavalt varasemale kirjandusele, mida suurem on inimese sissetulek, seda väiksem on tema maksejõuetuks muutumise tõenäosus.

Üheks põhjuseks, miks 5-st finantsnäitajatest on kõigest 1 statistiliselt oluline, võib tuua kasutatud andmete puudulikkust, mis tulenes ettevõtte eripärast (andmete salvestamise süsteemi muutmine). Teisalt, nagu on juba mainitud, muutuja *kv* oli eemaldatud tuvastatud multikollineaarsuse tõttu. Kolmandaks on asjaolu, et kliendid ei pruugi ausalt märkida enda finantsseisundi näitajad, seega laenuaotlejate reaalne seisundit võib tuvastada ainult pangakonto väljavõtte analüüsimisel.

Kõik tabelis 2.7 toodud muutujate mõjusuunad on loogilised ja vastavad autori ootustele ja kooskõlas teoreetilises osas käsitletuga. Inimese kogemus laenuteenuste kasutamisel, kliendisuhete pikkus ja viivituste puudumine vähendavad tõepoolest maksejõuetuks muutumise tõenäosust. Antud tulemus on leidnud kinnitust ka mitmete autorite töödes (Kočenda, Vojtek 2009: 16; Greene 2008: 32; West 2000: 1150). Samuti kui laenuvõtja märgib, et temalt on olnud laene nõutud kohtu- või kohtutäituri kaudu, tõstab see krediidiriski. Leidis kinnitust ka autori eeldus, et rohkem levinud pankade klientide tõenäosus muuta maksejõuetuks on väiksem.

Kliendi vanuse iseloomustav muutuja on osutunud vastandiks Kočenda ja Vojtek uurimusele (2009: 27) - statistiliselt oluliseks ja selle mõjusuund on kooskõlas Gool *et al.* (2009: 116) ja Green (2008: 32) poolt leituga ehk vanemate laenuaotlejate krediidirisk on väiksem. Antud tulemus on vastupidine Tuusise leitul (2010: 131).

Kuigi Kočenda ja Vojtek ei kasutanud soo muutujat enda töös, kuna selle informatsiooni väärtus oli liiga madal (2009: 27), osutus antud tegur käesolevas analüüsis oluliseks ning kooskõlas Koka (2011: 50) ja Tuusise (2010: 131) tulemustega - mehed on suurema krediidiriskiga kui naised.

Ootusepäraselt näitab kõrgem haridustase positiivset seost laenu korrektse tasumisega – sama seost täheldasid Arslan ja Karan enda analüüsis (2010: 35). Vastab käesoleva töö

autori eeldusele ka pikema tööstaaži mõju laenu korrektsele tagastamise tõenäosusele, mida kauem on laenuvõtja töötanud, seda väiksem on tõenäosus.

Elamine mitte enda korteris või majas tähendab suuremat krediidiriski. Antud tulemus vastab mitmete autorite töödele (Baensens *et al.* 2005; Khashman 2010; West 2000). Ülalpeetavate arv ei avalda statistiliselt olulist mõju krediidiriskile, mis ei vasta Greene uurimusele (2008: 31).

Laenu karakteristikutest on statistiliselt olulisteks osutunud laenusuurus. Sama tulemuseni on jõudnud näiteks ka järgmised autorid: Gool *et al.* 2009: 115; Kočenda, Vojtek 2009: 27; West 2000: 1150. Nendest erinevalt ei osutunud antud analüüsis olulisteks laenu pikkus ja osamakse suurus. Ei õnnestunud tuvastada ka laenutaotlemise perioodi mõju krediidiriskile, mis on olnud oluline Gool *et al.* töös (2009: 117). Autori poolt konstrueeritud muutujad, mis iseloomustavad laenuteeninduse määra, samamoodi ei aita kahe grupi eristamisel. Osaliselt võib seda põhjendada ettevõtte SNEL Grupp OÜ muutunud andmete salvestamise põhimõtetega, mille tõttu pidi autor nende muutujate konstrueerimisel kasutada vahemikkude keskmisi väärtusi. Teisalt korreleerusid kõnealused muutujad laenutaotleja sissetulekut iseloomustava muutujaga, kuna nii *LTI* kui ka *ALTI* on konstrueeritud selle muutuja baasil. Ei leidnud kinnitust autori eeldus, et talvekuudel esitatud taotlustel on suurem krediidirisk.

Avalikult kättesaadav informatsioon aitab kahe grupi eristamisel: *Google* või Ametlikes Teadaannetes leiduv informatsioon ning Rahvastikuregistris salvestatud aadress on kaks statistiliselt olulist näitajat neljast. Seevastu ei aita tasutud ja tasumata maksehäirete arv selgitada, kas laen jääb maksmata või mitte. Põhjuseks võib autor tuua valimi kallutatus ehk asjaolu, et analüüsitud andmed on saadud juba rahuldatud taotlustest. Suuremate kehtivate maksehäirete olemasolul lõpetati laenuotsustamise protsessi ning langetati negatiivse otsuse.

Vahetulemusena võib järeldada ka seda, et informatsiooni väärtus (*IV*) on suhteliselt nõrk meetod muutuja ennustustugevuse arvutamiseks. Neli muutujat viiest on osutunud statistiliselt oluliseks, kuid lisaks sellele jäid lõplikku mudelisse ka paljud muud tegurid, mille informatsiooni väärtus oli väiksem kui 0,1.

Logistilise regressioonimudeli korral iseloomustavad parameetrite hinnangud vaid eksogeensete muutujate mõju suunda, kuid mitte selle arvulist väärtust. Järgmisena leiab autor mõju kvantitatiivset väärtust kajastavad parameetrite marginaalsed efektid erinevates sõltumatute muutujate gruppides. Kategooriliste muutujate puhul referentsgruppideks on 0 grupp, binaarsete muutujate puhul on nullile vastav kodeering. Pidev muutuja jääb grupeerimata. Allpool asuvas tabelis 2.8 on toodud muutujate marginaalsed efektid.

**Tabel 2.8.** Marginaalsed efektid tegurite mõju kvantitatiivseks hindamiseks laenu tagastamata jätmise tõenäosusele erinevates eksogeensete muutujate gruppides

Muutuja valdkond	Muutuja	Parameetri marginaalne efekt	Standartviga
Varasem maksekäitumine, kliendisuhted	<i>viivitus(on olnud)</i>	0,147792***	0,016934
	<i>kohtu_k(on nõutud)</i>	0,034767**	0,013647
	<i>bank(harvemad pangad)</i>	0,063091***	0,019961
	<i>kogemus (kogenud)</i>	-0,12242***	0,008852
	<i>laen_nr (1-2)</i>	-0,11721***	0,009049
	<i>laen_nr (3-4)</i>	-0,17895***	0,009928
	<i>laen_nr (5-6)</i>	-0,21965***	0,010744
	<i>laen_nr (7-9)</i>	-0,22825***	0,011341
	<i>laen_nr (&gt;=10)</i>	-0,25251***	0,010562
Finantsseisund	<i>sissetlk (&gt;=350&lt;550)</i>	-0,00209	0,017034
	<i>sissetlk (&gt;=550&lt;750)</i>	-0,02307	0,017042
	<i>sissetlk (&gt;=750&lt;1000)</i>	-0,00561	0,017865
	<i>sissetlk (&gt;=1000&lt;1500)</i>	-0,07498***	0,018326
	<i>sissetlk (&gt;=1500)</i>	-0,08027***	0,019534
Sotsiaal-demograafilised karakteristikud	<i>vanus (≥22&lt;26)</i>	-0,05297***	0,013702
	<i>vanus (≥26&lt;32)</i>	-0,05988***	0,014116
	<i>vanus (≥32&lt;39)</i>	-0,0777***	0,014625
	<i>vanus (≥39&lt;50)</i>	-0,07581***	0,014712
	<i>vanus (≥50)</i>	-0,06199***	0,015264
	<i>eluase(üürikorter/vanematega)</i>	0,021073***	0,007107
	<i>sugu (mees)</i>	0,03975***	0,007028
	<i>haridus (kutse- või kesk-)</i>	0,050328***	0,008245
	<i>haridus (põhi- või alg-)</i>	0,08269***	0,011848
	<i>staaž (vähem kui aasta)</i>	0,0126*	0,007420
	<i>pereseis (ei ole abiellunud)</i>	0,017478***	0,006594
Avalik informatsioon	<i>taust (puhas)</i>	-0,02827*	0,014616
	<i>rr (aadress poolelik/puudub)</i>	0,058161***	0,011143
Laenu karakteristikud	<i>Inlaen_s</i>	0,096531***	0,00464

N=13727; \*\*\* - olulisuse nivool 0,01; \*\* - olulisuse nivool 0,05; \* - olulisuse nivool 0,1 statistiliselt oluline. Allikas: autori koostatud.

Tabelist 2.8 selgub, et kui laenuvõtjal on varem esinenud viivitused laenude tagastamisega, siis on tema maksejõuetuks muutumise tõenäosus umbes 14,78 protsendipunkti suurem. Kui laenuvõtja märgib taotluses, et temal on olnud kohtutäituri kaudu väljanõutud laenu, siis võib arvestada sellega, et võrreldes kliendiga, kellelt pole laene väljanõutud, on tema maksejõuetuks muutumise tõenäosus 3,48 protsendipunkti võrra suurem. 6,31 protsendipunkti võrra suurem tõenäosus, et laen jääb korrektselt tagastamata, on vähem populaarsete pankade klientidel. Suurt mõju näitab kogemuse näitaja – kogemusega klientidel võrreldes kogemusetu laenuvõtjatega, tõenäosus korrektselt tagastada laenu on 12,24 protsendipunkti võrra väiksem. Mida kauaegsem on kliendisuhe, seda väiksem tõenäosus, et iga järgneva võetud laenuga laenuvõtja muutub maksejõuetuks. Nt juhul, kui taotluse esitab klient, kes on varem juba 8 laenu tagastanud, siis tema maksejõuetuks muutumise tõenäosus, võrreldes uue kliendiga, 22,83 protsendipunkti võrra väiksem.

Kui laenuvõtja kuine netosissetulek jääb vahemikku 1000 kuni 1500 eurot, siis võrreldes kliendiga, kelle netopalk on alla 350 eurot, tema maksejõuetuse muutumise tõenäosus on 7,5 protsendipunkti võrra madalam ning kui sissetulek ületab 1500 eurot – 8,02 protsendipunkti võrra madalam. Väiksemate vahemike tõlgendamine ei ole korrektne, kuna nende puhul statistiline olulisus ei ole tõendatud. Kommentaariks võib lisada, et sissetuleku mõju laenu korrektse teenindamisele on suhteliselt tagasihoidlik võrreldes teiste muutujatega, mis kindlasti ei vasta autori ootustele.

Vanematel klientidel on krediidirisk tõepoolest väiksem võrreldes alla 22-aastaste klientidega, kuid siin kvantitatiivne väärtus ei suurene lineaarselt. Võrreldes nooremate klientidega, on 32-39-aastastel laenuvõtjatel 7,78 protsendipunkti võrra suurem tõenäosus laenu korrektselt tagastada ja nendel, kelle vanus ületab 50 aastat, on 6,2 protsendipunkti võrra suurem. Selline tulemus vastab siiski autori ootustele, kuna viimase vanuse kategooriasse kuuluvad ka 60+ vanuses laenuvõtjad, kelle sissetulek võrreldes keskealiste klientidega hakkab vähenema.

Kui laenuvõtjaks ei ole mitte oma korteris või majas elav isik, siis tõenäosus, et väljastatud laen tagastatakse korrektselt, on 2,11 protsendipunkti võrra väiksem. Tõenäosus, et meessoost laenusaja tagastab laenu korrektselt on 3,98 protsendipunkti väiksem kui naissoost laenusajal. Kõrgelt haritud kliendid tagastavad laene 8,27

protsendipunkti võrra korrektsemalt, kui isikud, kellel on vaid alg- või põhiharidus ning abiellunud taotlejad võrreldes vallalistega 1,75 protsendipunkti korrektsemalt. Olulisuse nivool 0,05 ei ole staaži muutuja statistiliselt oluline, kuid nivool 0,1 võib siiski öelda, et rohkem kui aasta ankeedis märgitud töökohas töötajatel on laenu korrektse tagastamise tõenäosus on 1,26 protsendipunkti võrra kõrgem, võrreldes alla aasta töötajatega.

Olulisuse nivool 0,1 võime väita, et otsingumootoritest ja Ametlikest Teadaannetest leiduv kahtlane informatsioon kliendi varasema maksekäitumise kohta tähendab 2,82 protsendipunkti võrra kõrgemat krediidiriski võrreldes kliendiga, kelle kohta kahtlane ja/või negatiivne informatsioon puudus. Rahvastikuregistri järgi kliendi elukoha kohta korrektselt täidetud informatsioon viitab 5,82 protsendipunkti võrra kõrgemale korrektselt tasumise tõenäosusele.

Kui logaritmitud laenusumma suureneb 1 ühiku võrra ehk 486 euro võrra, siis tõenäosus, et antud laenusaja tagastab oma krediiti korrektselt on 9,65 protsendipunkti võrra madalam, võrreldes keskmise suurusega laenu (282 eurot) laenusajaga. Järgnevalt hindab autor saadud logistilise regressioonimudeli prognoosivõimet ehk klassifitseerimise täpsust, testides, mil määral mudeliga prognoositud ja tegelikud väärtused (laenu staatus) kokku langevad. Tabeli 2.9 numbrid näitavad, et antud logistiline regressioonimudel ennustab kokku õigesti  $(10776 + 457) / 13727 = 81,83\%$  juhtudest, mis on lk 38 tabeli 1.6 keskmisest näitajast ligi 2 protsendipunkti kõrgem.

**Tabel 2.9** Õigesti ja valesti klassifitseerimiste arv (*cut-off* 0,5)

		Ennustatud kuuluvus		Kokku
		hea laen	halb laen	
Tegelik kuuluvus	hea laen	10776	345	11121
	halb laen	2149	457	2606
Kokku		12925	802	13727

Allikas: autori koostatud.

Tingliku murdepunkti varieerumisel ei õnnestunud õigesti kogu mudeli klassifitseerimise täpsust parandada. Kontrollvalimil testitud mudel ennustab korrektselt 80,81% juhtudest, mis on ka keskmisest kõrgem näitaja.

Kuna „heade“ ja „halbade“ laenude proportsioon on valimis 0,5-st kaugel, ei ennusta mudel 0,5 murdepunkti juures „halbu“ laene väga efektiivselt: 802 „halba“ laenu, kui tegelikult neid on 2606. Vastavalt Greene (2008: 31) ja Banasik *et al.* (2003: 826) töödes kasutatud meetodile, võrdsustame murdepunkti „heade“ ja „halbade“ laenude proportsiooniga valimis ning tulemuseks on saadud see, et „halbu“ laene tuvastab nüüd mudel korrektselt 70,22% juhtumites (1830/2606) (vt tabel 2.10). Testvalimil murdepunkti muutmise tulemusena saadi „halbade“ laenude korrektse klassifitseerimise täpsust 70,01%. Üldine klassifitseerimise täpsus langes 69,35%-ni.

**Tabel 2.10.** Õigesti ja valesti klassifitseerimiste arv (*cut-off* 0,1898)

		Ennustatud kuuluvus		Kokku
		hea laen	halb laen	
Tegelik kuuluvus	hea laen	7689	3432	11121
	halb laen	776	1830	2606
Kokku		8465	5262	13727

Allikas: autori koostatud.

Järgnevalt analüüsib autor mudeli (L2) sellise valimi põhjal, kus kummagi grupi laenu esinemise tõenäosus on 50 protsenti. Zmijewski tõi välja (1984: 74), et selline „halbade“ laene esinemissageduse kunstlik tõstmine võib parandada mudeli maksejõuetute klientide klassifitseerimise täpsust. Antud meetod on teine võimalus klassifitseerimistäpsuse parandamiseks võrdselt murdepunkti nihutamisega. Kõnealuse valimi saamiseks kasutab autor kõiki halbu laene ning juhumeetodiga valitud sama palju häid laene. Kontrollimiseks kasutatakse testvalim, kuhu kuuluvad kõik halvad laenud ning uued head laenud (valimid moodustatakse juhusliku meetodiga tagasipanekuta). Saadud valimi maht on 6948 vaatlust, kusjuures 3474 head laenu ja 3474 halba laenu. Statistiliselt olulisteks jäänud muutujad võib näha tabelis 2.11. Sarnaselt L1 mudelile on kontrollitud VIF väärtused ja muutujate multikollineaarsus (lisa 6 ja lisa 7).

Tabelist 2.11 näeme, et olulised muutujad on enamuses samad, mis L1 mudeli puhul, kuid esineb paar erinevust. Ei osutunud statistiliselt olulisteks muutujad *kohtu\_k* ja *eluase*, ning vastupidi jäi mudelisse muutuja *mh\_cls* ehk tasutud maksehäirete arv. Mida rohkem maksehäired on kliendil tasutud laenu taotlemise hetkeks AS Krediidiinfo

alusel, seda suurem tõenäosus, et laen jääb korrektseks tagastamata. Antud tulemus vastab Greene tulemusele (2008: 29).

**Tabel 2.11.** Statistiliselt oluliste parameetritega logistiline regressioonimudel (L2) krediidiriski tegurite mõju hindamiseks kliendi maksejõuetuks muutumise tõenäosusele

Muutuja valdkond	Muutuja	Parameetri hinnang	Standartviga
Varasem maksekäitumine, kliendisuhted	<i>viivitus</i>	1,056167***	0,158115
	<i>bank</i>	0,496606***	0,188532
	<i>kogemus</i>	-1,11335***	0,090174
	<i>laen_nr</i>	-0,51652***	0,024131
Finantsseisund	<i>sissetlk</i>	-0,19357***	0,024747
Sotsiaal-demograafilised karakteristikud	<i>vanus</i>	-0,07441***	0,018617
	<i>sugu</i>	0,333748***	0,060628
	<i>haridus</i>	0,329585***	0,052425
	<i>staaz</i>	0,110525*	0,063984
	<i>pereseis</i>	0,166047***	0,055656
Avalik informatsioon	<i>mh_clsd</i>	0,127263***	0,034385
	<i>rr</i>	0,221803***	0,099829
	<i>taust</i>	-0,39986**	0,134536
Laenu karakteristikud	<i>lnlaen_s</i>	0,798739***	0,046134
	<i>vabaliige</i>	-2,71608***	0,301956

N=6948; \*\*\* - olulisuse tase 0,01; \*\* - olulisuse tase 0,05; \* - olulisuse tase 0,1 statistiliselt oluline. Allikas: autori koostatud.

Teostades *backward stepwise* logit-analüüsi kontrollvalimil on saadud sama muutujatega mudel, marginaalsed efektid olid peaaegu identsed. Järgnevalt hindab autor saadud L2 mudeli prognoosivõimet. Arvestades sellega, et nüüd on tegemist valimiga, kus mõlemad laenugrupid on esitatud võrdselt, saab vaikimisi kasutada murdepunktina väärtust 0,5. L2 klassifitseerimise täpsuse parandamiseks analüüsib autor ka teisi naaberväärtusi.

Tabelis 2.12 on toodud erinevate murdepunktide juures saadud kogu mudeli klassifitseerimise täpsused ning eraldi „halbade“ laenude klassifitseerimise täpsused (sensitiivsus). Kõrgeim „halbade“ laenude klassifitseerimise täpsus saavutati murdepunkti 0,48 juures. Võrreldes L1 mudeli klassifitseerimise täpsusega võib nihutatud murdepunkti puhul (õigesti klassifitseeritud 69,35% ja sensitiivsus 70,22%) järeldada, et võrdsete laenugruppidega mudeli „halbade“ laenude klassifitseerimise täpsus on üle 3 protsendipunkti parem.

**Tabel 2.12.** Õigesti ja valesti klassifitseerimiste proportsioonid mudeli L2 puhul

	Murdepunkt						
	0,47	<b>0,48</b>	0,49	0,5	0,51	0,52	0,53
<b>Klassifitseerimine</b>	70,14%	<b>70,28%</b>	70,18%	69,95%	69,92%	69,88%	69,57%
<b>Sensitiivsus</b>	74,99%	<b>73,46%</b>	71,91%	70,26%	68,77%	67,27%	65,14%

Allikas: autori koostatud.

Ettevõtte vaatenurgast võib kasutamiseks valida L2 mudelit, mis on saadud kaalutud andmete analüüsimise käigus, kuna selle klassifitseerimise täpsus just halbade laenude osas on osutunud paremaks. Järgnevalt analüüsib autor 2 tingimuslikku laenuaotleja skoori murdepunkti rakendamise võimalusi ettevõtte laenuotsuste tegemisel. Analüüsimiseks kasutab autor saadud mudeli L2 ning koguvalimi (N=18302). Eelduste kohaselt laenuaotleja skoor võib jagada kaheks: juhul kui taotleja skoor ületab ülemist murdepunkti, laenuaotlus rahuldatakse, kui väärtus on alumisest murdepunktist madalam – langetatakse automaatne negatiivne otsus ning juhul, kui skoor sattub kahe murdepunkti vahele, automaatset laenuotsust ei toimu ning laenuhaldur peab tegema täiendavat hindamist, toetudes oma parimatele teadmistele ja oskustele, arvestades laenuaotlejate erisusi. Murdepunkti ehk kogutud skoori väärtus on logit-võrrandi (valem 3, lk. 35) 1-P väärtus.

Tabelis 2.13 on toodud võimalikud alumised murdepunktid ning valitud murdepunktist lähtuvalt ka erinevad koguvalimi karakteristikud, s.h. väljastamata „halvad“ ja „head“ laenud ning laenude rahaline väljendus.

**Tabel 2.13.** Alumiste murdepunktide mõju koguvalimi karakteristikutele

Murdepunkt	0,100	0,110	0,120	<b>0,126</b>	0,130	0,135	0,140
<b>Halvad laenud, tk (ennustus)</b>	189	244	308	<b>358</b>	382	437	475
<b>nendest tegelikult halvad</b>	113	147	180	<b>208</b>	220	246	267
<b>nendest tegelikult head</b>	76	97	128	150	162	191	208
<b>Oleks jäänud väljastamata halbu laene, tuh. eur</b>	107,10	128,56	152,48	<b>181,51</b>	191,70	209,18	220,68
<b>Oleks jäänud väljastamata häid laene, tuh. eur</b>	89,48	107,38	133,33	151,83	169,53	199,49	214,72
<b>Portfelli muutus, tuh. eur</b>	-17,62	-21,18	-19,15	<b>-29,68</b>	-22,17	-9,69	-5,96

N=18302; Allikas: autori koostatud.



Otsuse aluseks on väljastama jäetud „heade“ laenude kogusumma ja väljastatud „halbade“ laenude kogusumma vahe. Teisisõnu, tegemist on kokkuhoiuga, mida oleks võimalik saada juhul, kui antud murdepunktist väiksemate skooridega taotlused oleksid automaatselt tagasi lükatud. Nagu võib näha, maksimaalne sääst on saavutatud murdepunkti 0,126 juures. Juhul, kui taotlused, mille skoor on väiksem kui 0,126, oleksid tagasi lükatud, ettevõtte ei oleks väljastanud potentsiaalselt halbu laene summas 181,83 tuh. eurot. Tagasi lükatud taotluste hulka oleks sattunud tegelikkuses osutunud head laenud kogu summas 151,83 tuh. eurot ehk laenusumma, mille pealt ettevõtte poleks tulu teeninud. Seega optimaalseks variandiks osutub antud näitajate maksimaalne vahe, mis maksimaalselt optimeeriks portfelli. Murdepunkti valik sõltub ettevõtte eesmärkidest. Kui eesmärgiks oleks portfelli kvaliteedi maksimeerimine, siis alumise murdepunkti võib nihutada edasi, kuid tuleb arvestada sellega, et osa headest laenudest jääb väljastamata. Alumise murdepunkti valikut võib täpsustada kasumit iseloomustava võrrandi lisamisega mudelisse. Näiteks eeldusel, et tagastamata laen on sama kahjulik kui väljastamata laen, siis alumiseks murdepunktiks võib seada väärtust 0,254, mille puhul mudel ennustaks 1886 „halbu“ laene, millest 50% on realselt jäänud tagastamata.

Järgmisena illustreerib autor ülemise murdepunkti võimalikud valikud. Tabelis 2.14 näeb ülemise murdepunkti rakendamise puhul portfelli karakteristikud. Sarnaselt alumise murdepunktiga sõltub ülemise murdepunkti valik ettevõtte riskitaluvusest ja eesmärkidest.

**Tabel 2.14.** Ülemiste murdepunktide mõju koguvalimi karakteristikutele

Murdepunkt	0,90	0,85	0,80	0,75	0,70	0,65	0,60	0,55
Head laenud, tk (ennustus)	979	2035	3074	4232	5482	6836	8247	9741
sh tegelikult „halvad“	11	48	99	166	254	379	547	763
sh tegelikult „head“	968	1987	2975	4066	5228	6457	7700	8978
Eksimuse tõenäosus	1,12%	2,36%	3,22%	3,92%	4,63%	5,54%	<b>6,63%</b>	7,83%
Väljastatud heade laenude summa, tuh. eur	262,1	580,1	871,6	1191,5	1530,3	1870,9	<b>2221,5</b>	2588,1
Väljastatud halbade laenude summa, tuh. eur	4,3	20,4	40,7	65,5	98,0	137,9	<b>191,3</b>	260,3

N=18302; Allikas: autori koostatud.

Ülemise murdepunkti idee seisneb selles, et antud reegel võimaldab võtta automaatselt positiivne laenuotsus, kuna laenutaotleja krediidirisk on minimaalne (ettevõtte subjektiivne hinnang). Näiteks juhul, kui otsustatakse võtta automaatselt positiivne laenuotsus, kui skooringumudel arvutab laenutaotleja skooriks 0,60 ja kõrgem, siis krediidirisk antud juhul moodustab vaid 6,63% ning väljastatud tegelikult „heade“ laenude summa rohkem kui kümnekordselt ületab tegelikult „halbade“ laenude summat. Arvestades üldvalimi mahtu  $n=18302$ , antud murdepunkti rakendamine tähendaks laenuotsustamise protsessi üle 45% automatiseerimist. Tuleb nentida, et laenuametnikul jääb siiski kohustus kontrollida kliendi tausta, kuna isegi 0,999 skoori saanud taotluse puhul, kehtiv oluline maksehäire Krediidinfo AS järgi välistab laenu väljastamist. Kinnitades eeldust, et just võrdsete laenujuhtumitega valimil saadud skooringumudel peaks olema korrektsem „halbade“ laenude ennustamiseks, on testitud ka L1 mudel alumise ja ülemise murdepunktide osas. Alumise murdepunkti puhul maksimaalseks säästuks, mis õnnestus saada oli vaid 15,6 tuh. eurot. Ülemise murdepunkti puhul, kus ennustatud „heade“ laenude arv on samamoodi 8247 (nagu 0,6 murdepunkti juures L2 mudeli puhul) eksimuse tõenäosus ulatus 6,83%-ni, ehk siiski pisut kõrgema määrani. Seega võib ka selles töös kinnitada reeglit, et kaalumata (või antud juhul võrdsustamata) valimi puhul „halbade“ laenude korrektse ennustamise tõenäosus on madalam.

Pakutud L2 mudeli ülemise ja alumise murdepunktid võib ühendada ja esitada otsustusreeglina. Üldine otsustusreegel laenuotsuse tegemisel esitatud tabelis 2.15.

**Tabel 2.15.** Skooringumudel logit-mudeli L2 alusel

Skoori väärtus	Tõlgendus
<0,126	Automaatselt negatiivne laenuotsus
$\geq 0,126 < 0,6$	Vajalik laenuametniku täiendav analüüs
$\geq 0,6$	Automaatselt positiivne laenuotsus <sup>7</sup>

Allikas: autori koostatud.

Kollases tsoonis olevad laenud vajavad laenuametniku täiendavat analüüsi ja otsust, kuna kindlat vastust, kas anda laenu või mitte, pole võimalik anda. Raske öelda, kui kaua antud kujul saadud mudelit L2 saab ettevõtte kasutada. Kindlasti mudeli iga-

<sup>7</sup> kui otsungumootoritest või Maksehäireregistrist ei leidu informatsiooni, mis välistab laenu väljastamist.

aastane ülevaatus ja kohandamine on vajalik ning selle põhjuseks mitte maksejõuetust selgitavate muutujate muutumine, vaid pigem nende muutujate proportsioonide ehk mõju suuruse muutumine. Pakutud mudel pole siiski täielikult automaatne, vaid kujutab endast subjektiivse ja statistilise meetodi hübriidi. Saadud mudeli plussideks on kohene hinnang konkreetsele laenuaotlusele, laenuotsustamise protsessi kestuse vähendamine ning subjektiivsuse vähendamine. Miinuseks on perioodilise korrigeerimise ja täiustamise vajadus.

Selleks, et täielikult asendada olemasolevat krediidiriski hindamise süsteemi, peab skooringu süsteem omama kindla stabiilsuse, loetavuse ning klassifitseerimise täpsuse. Üleval esitatud tulemused näitavad, et mudel L2 omab head täpsust ning saadud skoorid on lihtne tõlgendada ja kasutada. Tuleb alati pidada meeles, et laenuaotlejad võivad skoori tulemusi moonutada, sisestades valeandmed. Sellepärast võttes skooringu mudeli kasutusse, tuleb SNEL Grupp OÜ-l teha vastavaid kohandusi enda infosüsteemis.

Käesoleva magistr töö eesmärgiks oli võimalikult hea kahe grupi eristusvõimega mudeli koostamine, ja seeläbi ka eraisiku krediidiriski selgitavate tegurite välja selgitamine. Antud eesmärgi saavutamiseks autor on kasutanud muutmata kujul valimit, kus korrektselt tagastamata laenude osakaal olnud 18,98%. Võib öelda, et käesoleva alapunkti alguses esitatud mudel L1 on selle eesmärgiga kindlalt hakkama saanud ning tänu mudelile, selgus, millised muutujad on osutunud statistiliselt olulisteks kahe laenugrupi eristamisel. Saadud mudel on näidanud küllalt kõrget klassifitseerimise täpsust - 81,83%, mis on antud töö teoreetilises osas käsitletud kirjandusega võrreldes keskmisest kõrgem tulemus. Skooringu meetod võimaldab saada objektiivset vastust, millised faktorid mõjutavad eraisiku krediidiriski. Kasutades *logit*-analüüsi, autoril on õnnestunud saada mudeli, mis koosneb 15 eksogeensetest muutujatest. Statistiliselt on olulisteks teguriteks osutunud laenuaotleja sotsiaal-demograafilised, finantsseisundi, laenu toote ja varasemat maksekäitumist kirjeldavad ja avalikult kättesaadavad karakteristikud, mis suuremal määral kinnitab varasema teaduskirjanduse seisukohti. Huvipakkuvaks võib nimetada vaid laenuaotleja finantsolukorda iseloomustavate näitajate vähest esindatust lõplikus mudelis. Varasemates töodes on laenuaotleja finantsseisundi koos varasemat maksekäitumist iseloomustavatel karakteristikutel on olnud siiski keskne roll. Üldisemalt võib kinnitada Gool *et al.* seisukohta, et mikro-

krediteerimisega tegeleva ettevõtte krediidiriski analüüsimisel ja rahuldava tulemuse saamisel, võib kasutada samu tehnikaid, põhimõtteid ja tegureid (2012: 104-106).

Antud töö on kinnitanud varasemate uuringute tulemusi: teatud muutuja statistiline olulisus või vastupidi ebaolulisus, või mõjusuund ei osutunud ettearvamatuks ja uudseks võrreldes teiste autorite saadud tulemustega. Huvipakkuvaks ülesandeks oleks hinnata puhtalt varasemat maksekäitumist iseloomustavate karakteristikute põhjal krediidiriski hindava mudeli ennustustäpsust. See ning mudeli konstrueerimine teisi meetodeid kasutades ja oodatava kasumi/laenu kulu mudelisse sisselülitamine võib jääda autori edaspidiseks uurimuseks.

Kokkuvõtteks on käesoleva magistritöö tulemuseks Eestis tegutseva mitte pangast laenupakkuja mahuka valimi alusel koostatud skoorimudel, mis aitab kahte laenugruppi eristavaid tegureid identifitseerida ning hinnata laenuaotleja võetava laenu korrektse tagastamise tõenäosust. Tulemuse saamiseks oli põhjalikult analüüsitud arvestatav teaduslike tööde maht, leitud ja grupeeritud kõige sagedamini kasutatavad muutujad ning valitud ja mitmekülgsest kirjeldatud analüüsi jaoks kasutatud statistiline meetod. Üldvalim koosneb 18302-st laenujuhtumist, SNEL Grupp OÜ andmebaasist on saadud 27 erinevat muutujat, lisaks 3 on autori konstrueeritud. Töö käigus koostati 2 erinevat mudelit, millest esimese mudeli põhjal koostati 15-st statistiliselt olulistest muutujatest koosneva loetelu – andes vastuse, millised muutujad aitavad eraisiku krediidiriski modelleerimisel Eestis. Teise mudeli väljundiks on autori poolt pakutud skoorimudel, mille kasutuselevõtt oleks säästnud sõltuvalt ettevõtte riskitaluvusest ligikaudu 50% ajakulust ning oleks saanud parandada laenuportfelli kvaliteeti, tagades kiiret ja objektiivset hinnangut laenu tagastamise tõenäosusele. Valminud L2 mudelit võivad muutmata kujul kasutada ka teised mikrokrediteerimisega tegelevad ettevõtted.

## KOKKUVÕTE

Laenuturul valitseva tihe konkurentsi ja riigipoolse turu regulatsiooni mahu suurenemise tõttu on laenupakkujad sunnitud suure hoolega oma laenuportfelli kvaliteedi jälgima, tööprotsesse optimeerima ning kulusid minimiseerima. Sellepärast võimalikult ratsionaalsemad ja täpsemad otsused eraisiku krediidiriski hindamises ja juhtimises on muutunud tänapäeval väga tähtsaks. Oma krediidiotsuste parandamiseks pööravad ettevõtted üha rohkem tähelepanu statistilistele krediidiriski hindamismeetoditele, kuna nende eelis subjektiivse ehk klassikalise meetodi ees on vaieldamatu. Käesoleva magistritöö eesmärgiks oli eraisiku krediidiriski hindava mudeli koostamine mikrokrediteerimisega tegeleva ettevõtte näitel. Modelleerimise käigus koostati statistiline mudel, mis annab arvilise hinnangu taotletava laenu korrektselt maksmata jätmise tõenäosusele üle 81%-lise ennustustäpsusega. Valminud mudel koosneb 15 statistiliselt olulistest teguritest, mis aitavad kahe laenugrupi eristamisel.

Võimalikult hea mudeli saamiseks on läbitud mitu uurimisetappi. Varasemate uurimuste põhjal on määratud krediidiriski mõiste ning analüüsitud selle hindamise võimaluste nõrgad ja tugevad küljed. Uurimisülesandest lähtuvalt loetakse krediidiriskiks viivitust laenu tasumisel üle 60 päeva. Autor on jõudnud järelduseni, et statistiline skoorimismeetod on siiski riski realiseerumise hindamisel subjektiivsest meetodist optimaalsem tänu oma objektiivsusele, laenuotsustusprotsessi pikkuse vähenemisele ja sellest tulenevalt kulude kokkuhoiule, vigade minimiseerimisele ning eelarvamuste puudumisele. Vaatamata eelistele, tuleb arvestada statistilise meetodi keerukusega ning jälgida mudeli koostamise eeldusi ja etappe.

Krediidiriski selgitamiseks ja hindamiseks kasutatakse palju erinevaid tegureid. Teaduslike artiklite läbiviidud analüüsi tulemusena grupeeris käesoleva töö autor neid viite põhikategooriasse: laenuaotleja sotsiaal-demograafilised, finantsseisundit iseloomustavad ja laenutoote karakteristikud, varasema maksekäitumise näitajad ning

muu erinev avalikult kättesaadav informatsioon. Tegurite koosseisu määrab eelkõige andmete kättesaadavus. Kuna tegemist on tundlike andmetega, vahepeal ei õnnestu uurijatel mudelitesse kaasata piisavalt palju muutujaid. Samas, mõnedes töödes kasutati üle 50 muutuja, kuid lõplikku mudelisse on üldjuhul jäänud 10 kuni 20 statistiliselt olulist muutujat. Käesoleva töö autoril õnnestus saada ettevõtte andmebaasist 27 muutujat, lisaks 3 laenusaja finantsseisundi iseloomustavat muutujat oli moodustatud autori poolt.

Valides erinevate hindamismeetodite vahel, tuleb kõigepealt arvestada meetodi keerukuse, asjakohasuse, efektiivsuse ja tulemuste interpreteerimise lihtsusega. Eraisiku krediidiriski hindamiseks kasutatakse tavaliselt nelja meetodit: diskriminantanalüüsi, *logit/probit* analüüsi, otsustuspuud ja viimasel ajal eriti levinuks muutunud närvivõrkude meetodit. Vastavalt teostatud võrdlusele ja analüüsile osutus valituks logistiline regressioon, mis näitas ühte kõrgemat klassifitseerimise täpsust 25 erineva skoorimudeli seast. Antud meetod võimaldab hinnata korrektselt maksmata jätmise tõenäosust ning parameetrite marginaalsed efektid näitavad muutuja arvulist panust tõenäosuse suurenemisele või vähenemisele.

Eraisiku krediidiriski modelleerimiseks kasutatakse mikrokrediteerimisega tegeleva ettevõtte SNEL Grupp OÜ andmebaasist saadavaid andmeid laenusajate kohta. Hetkel kasutab ettevõtte subjektiivset krediidiriski hindamise meetodit ehk maksevõime analüüsi teostavad laenuametnikud, kes menetlevad iga laenuaotleja eraldi, võttes arvesse tema karakteristikuid, maksekäitumist, finantsseisundit ja muud informatsiooni. 2012.-2014. aastate portfelli mahu, toodete käibe ja lepingute arvu järgi on otsustatud laenuandmise protsessi kuluefektiivsemaks muutmist modelleerida tagatiseta väikelaenude kasutajate näitel.

Autoril on õnnestunud saada ettevõtte andmebaasist väga mahuka valimi, mis koosnes pärast erindite ja puuduvate väärtuste eemaldamist 18302 laenujuhtumist. Analüüsi kaasati väljastatud laenude andmed. Osa 30 muutujatest oli kategoriseeritud tulemuste tõlgendamise lihtsustamiseks. Korrektselt tagastamata laene oli esialgses valimis 18,98%, mis on hästi tüüpiline proportsioon nii ettevõtete pankrotistumiste kui ka eraisiku krediidiriski modelleerimisel.

Arvestades valimi kallutatust kasutati saadud mudeli (L1) puhul tingliku murdepunktina „heade“ ja „halbade“ laenude proportsiooni valimis, parandades klassifitseerimise täpsust. Teisalt oli testitud ka kunstlikult võrdsustatud laenugruppidega mudel (L2), mille just halbade laenude ennustustäpsus osutus kõrgemaks.

Käesoleva magistritöö esimeseks väljundiks on L1 mudel, mille järgi saab väita, et kokku 15 erinevat tegurit mõjutavad eraisiku krediidiriski. Mudelisse on jäänud vaid statistiliselt olulised muutujad, mis panustavad mudeli kahe laenugrupi võimalikult täpsele eristamisele. Mudeli üldine klassifitseerimise täpsus on algvalimil olnud 81,83% ning testvalimil – 80,81% ehk neljale laenuaotlusele viiest annab mudel tõe vastavat hinnangut laenu korrektse või ebakorrektse tagastamisele. Antud tulemustega võib kindlasti rahule jääda, kuna tulemus on magistritöö teoreetilises osas käsitletud teiste autorite mudelite keskmisest klassifitseerimise täpsusest kõrgem. Lõpliku L1 mudelisse jäi nt kliendi netosissetulek, mille suurenemine vähendab ootuspäraselt krediidiriski. Selgus ka see, et laenusumma suurenemisel kasvab ka ebakorrektse tagastamise tõenäosus. Samas ei osutunud teised laenutoode karakteristikud nagu perioodi pikkus ja osamakse olulisteks. Ei leidnud kinnitust ka autori eeldus, et talvekuudel väljastatakse rohkem “halb” laene.

Ootuspäraselt aitab ka avalikult kättesaadav informatsioon kahe laenugrupi eristamisel. Poolikult sisestatud või puudulik aadress Rahvastikuregistris viitab suuremale krediidiriskile ning Ametlikes Teadaannetes ja otsingumootoritest leiduv negatiivne informatsioon signaaliseerib kõrgemast krediidiriskist.

Kliendisuhete pikkus, mis on väljendatud tagastatud laenude arvuna, kogemuse olemasolu finantsteenuste kasutamisel ning korrektselt varem tasutud laenud vähendavad tõenäosust, et taotletav laen jääb korrektselt tagastamata. Statistiliselt oluliseks on osutunud ka muutuja, mis indikeerib, kas laenuaotlejal on olnud laene tagastatud kohtutäituri või kohtu kaudu või mitte. Madalam tõenäosus tagastada laenu korrektselt on nendel taotlejatel, kes sellele ankeedi küsimusele vastanud jaatavalt. Need tulemused vastavad ka teiste autorite poolt läbiviidud uurimistele.

Kuue statistiliselt olulise muutujaga on esindatud laenuaotleja sotsiaal-demograafiliste karakteristikute grupp. Vanematel klientidel, kõrghariduse omanikel ning pikema

tööstaažiga klientide tõenäosus muuta maksejõuetuks on väiksem. Mehed ning vallalised kliendid on suurema krediidiriskiga kui naised ning abiellunud kliendid. Viimaseks statistiliselt oluliseks muutujaks on oma eluase olemasolu. Üürikorteri või oma tuttavate/vanemate juures elavatel klientidel on suurem tõenäosus jätta laen korrektselt tagastamata.

Rääkides tegurite arvulisest panusest, tuleb märkida, et suuremat mõju avaldavad, kooskõlas varasema kirjanduse ja antud töö autori eeldusega, varasemat maksekäitumist iseloomustavad karakteristikud: näiteks, eelnevalt 5 laenu korrektselt tagastanud laenutaotlejal tõenäosus tagastada laenu ebakorrektselt on ligi 36 protsendipunkti võrra väiksem. Saades laenutaotluse inimeselt, kes ei ole kogenud finantsteenuste kasutaja, tuleb olla eriti ettevaatlik ning vastutustundlik, pakkudes igakülgset abi teenuse valikul. Kogemusteta laenutaotleja krediidirisk on 12,24 protsendipunkti võrra kõrgem, võrreldes kogenud finantsteenuste kasutajatega. Sotsiaal-demograafilistest karakteristikutest suuremat panust laenugruppide eristamisel näitab haridus: kõrgelt haritud inimeste krediidirisk on 8,27 protsendipunkti võrra väiksem vaid alg- või põhihariduse omandanud isikutega võrreldes. 32-39 aastatel inimestel on noorematest kõrgem palk, kindlam töökoht ning paremad võimalused uuesti tööturule naaseda töö kaotuse puhul – seetõttu on nende krediidirisk 7,78 protsendipunkti võrra madalam. Naiste puhul ennustab mudel 3,98 protsendi punkti kõrgemat korrektselt tagastamise tõenäosust.

Testides, kas võrdsustatud laenude proportsioonidega valimi põhjal õnnestub saada parema mudeli või lõpptulemuseks jääb kõrgem „halbade“ laenude ennustustäpsus, oli koostatud L2 mudel. Konstrueeritud mudeli sensitiivsuseks („halbade“ laenude ennustustäpsuseks) saadi 73,46%. Erinevalt L1 mudelist, mille „halbade“ laenude klassifitseerimise täpsus oli vaid 70,22%, ei osutunud olulisteks isikliku maja või korteri iseloomustav muutuja ja ankeedi vastus küsimusele kohtutäituri kaudu tagastatud laenude kohta. See-eest tuli oluliseks tasutud maksehäirete arv Krediidinfo AS andmetel. Ülejäänud tegurid jäid samaks, mis kinnitab, et laenugruppide kunstlik võrdsustamine ei moonuta analüüsi tulemusi.

Saadud L2 mudeli tulemuste alusel võib autor ettevõttele pakkuda skooringsüsteemi, mille üldine otsustusreegel võiks sõltuvalt taotluse skoori väärtusest näha järgnevalt:



- $<0,126$  Automaatselt negatiivne laenuotsus
- $\geq 0,126 < 0,6$  Vajalik laenuametniku täiendav analüüs
- $\geq 0,6$  Automaatselt positiivne laenuotsus

Murdepunktide valik sõltub siiski ettevõtte enda riskitaluvusest ning eesmärkidest. Autori poolt pakutud murdepunktide puhul oleks kogu taotluste arvust automaatse vastuse saanud üle 45%, kus juures korrektselt tagastatuks osutuks ligi 93,7% laenudest. Alumise murdepunkti puhul mudel suudaks korrektselt tuvastada ligi 58% tegelikult „halbade“ laenudest, mis arvestades saadava kahjumi laenude ebakorrektsuse või hoopis mittetagastamisest, on väga hea näitaja.

Vaieldamatult statistilistel skoorimismeetoditel on selge ja kaalukas roll krediidi- ja finantseerimisasutuste eraisikust klientide krediidiriski hindamisel. Üha rohkem statistiline lähenemine asendab subjektiivset meetodit. Käesoleva töö tulemustele toetudes võib järeldada, et skoorimismeetodi kasulikkus ja vajalikkus on tõendatud mikrokrediteerimisega tegelevate ettevõtete jaoks. L2 mudeli kasutuselevõtt võimaldaks automatiseerida kuni 50% laenuotsuse protsessist, samal ajal parandades ka laenuportfelli kvaliteeti.

Antud töö panustab kasvavale kirjanduse mahule, mis käsitleb erinevate statistiliste meetodite rakendamist krediidiriski modelleerimisel. Käesolev magistr töö näitab, et krediidiriski suurust aitavad hinnata suuremal määral mitmed sotsiaal-demograafilised faktorid koos varasemat maksekäitumist iseloomustavate karakteristikutega. Valminud L2 mudelit võivad muutmata kujul kasutada ka teised Eestis mikrokrediteerimisega tegelevad ettevõtted. Peale mudeli presenteerimist SNEL Grupp OÜ-le kaalub ettevõtte selle kasutuselevõttu ning kalkuleerib mudeli juurutamise kulusid.

Käesoleva magistr töö on võimalik edasi arendada kaasates skoorimudelis oodatava kasumi ja kahjumi võrrandi laenu taotluse aktsepteerimisest, testides, kas selline edasiarendus muudab laenuotsuste reeglit, mille fookuses on puhtalt maksmata jätmise tõenäosus või mitte. Veel üheks arendamisvõimaluseks on tagasilükatud taotluste modelleerimisse kaasamine *reject inference* probleemi ületamiseks. Autorile pakub huvi ka teiste analüüsimeetodite testimine, vaatamata sellele, et nende klassifitseerimise täpsus on osutunud logistilise regressioonist madalamaks.

## KASUTATUD KIRJANDUS

1. **Abdou, H. A., Pointon, J.** Credit scoring and decision making in Egyptian public sector banks. – *International journal of managerial finance*, 2009, Vol. 5, Issue 4, pp. 391-406.
2. **Abdou, H. A., Pointon, J.** Credit Scoring, Statistical Techniques and Evaluation Criteria: A Review of the Literature. – *Intelligent Systems in Accounting, Finance & Management*, 2011, Vol. 18, pp. 59-88.
3. **Altman, E. I.** Financial Ratios, Discriminant Analysis And The Prediction Of Corporate Bankruptcy. – *Journal of Finance*, 1968, Vol. 23, No. 4, pp. 589–609.
4. **Angelis, V., Gaki, E., Ioannou, G., Koufodontis, I., Mavri, M.** A Two-Stage Dynamic Credit Scoring Model, Based on Customers' Profile and Time Horizon. – *Journal of Financial Services Marketing*, 2008, Vol. 13, No 1 pp. 17-27.
5. **Arslan, Ö., Karan, M.** Consumer Credit Risk Characteristics: Understanding Income and Expense Differentials. – *Emerging Markets Finance and Trade*, 2010, Vol. 46, No 2, pp. 20-37.
6. **Avery, R. B., Brevoort, K. P., Canner, G. B.** Credit Scoring and Its Effects on the Availability and Affordability of Credit. – *The Journal of Consumer Affairs*, 2009, Vol. 43, No 3, pp. 516-537.
7. **Baesens, B., Gestel, T., Stepanova, M., Van den Poel, D., Vanthienen, J.** Neural Network Survival Analysis for Personal Loan Data - *The Journal of the Operational Research Society*, 2005, Vol. 56, No. 9, pp. 1089 -1098
8. **Baesens, B., Gestel, T., Stepanova, M., Viaene, S., Suykens, J., Vanthienen, J.** Benchmarking State-of-the-Art Classification Algorithms for Credit Scoring. – *The Journal of the Operational Research Society*, 2003, Vol. 54, No. 6, pp. 627-635.

9. **Balcaen, S., Ooghe, H.** 35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems. – The British Accounting Review, 2006, No. 38, pp. 63-69.
10. **Balcaen, S., Ooghe, H.** Alternative methodologies in studies on business failure: do they produce better results than the classical statistical methods? Working paper, 2004, Ghent University, Belgium, 40 p.
11. **Banasik, J., Crook, J., Thomas, L.** Sample Selection Bias in Credit Scoring Models. - The Journal of the Operational Research Society, 2003, Vol. 54, Issue 8, pp. 822-832.
12. **Bhutta, N.** Payday Loans and Consumer Financial Health. Finance and Economics Discussion Series, Divisions of Research & Statistics and Monetary Affairs, Federal Reserve Board. Washington, D.C., 2013, 38 p. [<http://www.federalreserve.gov/pubs/feds/2013/201381/201381pap.pdf>] 14.02.2015
13. **Bolton., C.** Logistic regression and it's application in credit Scoring. University of Pretoria, 2009, 240p.
14. **Cade, E.** Managing Banking Risks. 1st ed., Elsevier: Woodhead Publishing, 1997, 256p.
15. **Cade, E.** Managing Banking Risks. New York : AMACOM, 1999, 237 p.
16. **Caire, D., Barton, S., Zubiria, A., Alexiev, Z., Dyer, J., Bundred, F., Brislin, N.** A Handbook for Developing Credit Scoring Systems in a Microfinance Context. United States Agency for International Development, 2006, 79 p.
17. **Casu, B., Giradone, C., Molyneux, P.** Introduction to banking. Financial Times Prentice Hall, 2006, 526 lk.
18. Eesti Panga finantssektori statistika. Krediidiasutuste koondbilanss ja – kasumiaruanne. Eesti Pank. [<http://statistika.eestipank.ee/?lng=et#listMenu/2092/treeMenu/FINANTSSEKTOR/147/645>] 20.02.2015
19. Erasisikute raportid. AS Krediidinfo. [<http://www.krediidinfo.ee/index.php?m=8>] 19.03.2015
20. **Fatemi, A., Fooladi, I.** Credit risk management: a survey of practices. – Managerial Finance, 2006, Vol. 32, No 3, pp. 227-233.

21. **Galitz, L., C.** Consumer Credit Analysis – Managerial Finance, 1993, Vol. 9, Issue 3, pp. 27 – 33.
22. **Gestel, T., Baesens, B.** Credit Risk Management: Basic Concepts. Oxford: Oxford University Press, 2009, 552 p.
23. **Ghosh, A.** Managing Risks in Commercial and Retail Banking. Singapore: John Wiley & Sons, 2012, 352p
24. **Glennon, D., Kiefer, N. M., Larson, C. E., Choi, H.** Development and Validation of Credit-Scoring Models. – Journal of Credit Risk, 2008 Vol. 4, No 3, pp. 41-102.
25. **Gool, J., Baesens, B., Sercu, P., Verbeke, W.** An Analysis of the Applicability of Credit Scoring for Microfinance. Proceedings of the Academic and Business Research Institute Conference, Orlando, 2009, 28 p.
26. **Gool, J., Verbeke, W., Sercu, P., Baesens, B.** Credit Scoring for Microfinance: Is It Worth It? – International Journal of Finance and Economics, 2012, Vol. 17(2), pp. 103-123.
27. **Greene, W. H.** A Statistical Model for Credit Scoring. – Advances in Credit Risk Modelling and Corporate Bankruptcy Prediction. S. Jones, D.A. Hensher (Ed.) New York : Cambridge University Press, 2008, pp. 14-43.
28. **Gurny, P., Gurny, M.** Comparison of credit scoring models on probability of default estimation for us banks. – Prague economic papers, 2013, No. 2, pp. 163-181.
29. **Gustafson, C. R., Pederson, G. D., Brent A. Gloy, B. A.** Credit risk assessment. – Agricultural Finance Review, 2005, Vol. 65, Issue 2 pp. 201 – 217.
30. **Hand, D. J.** Modelling consumer credit risk. – Journal of Management Mathematics, 2001, Vol. 12, pp. 139-155.
31. **Hand, D. J., Henley, W. E.** Statistical Classification Methods in Consumer Credit Scoring: a Review. – Journal of the Royal Statistical Society, 1997, Vol. 160, No 3, pp. 523-541
32. **Jacobson, T., Roszbach, K.** Bank Lending Policy, Credit Scoring and Value-at-Risk. – Journal of Banking & Finance, 2003, Vol. 27, Issue 4, pp. 615–633.

33. **JianHua, L., Tao, S.** Credit Risk Evaluation of Micro-loan companies on Soft Set. – International Conference on E-Business and E-Government, 2010, pp. 1110-1115.
34. **Kalapodas, E., Thomson, M. E.** Credit Risk Assessment: a Challenge for Financial Institutions. – Journal of Management Mathematics, 2006, Vol. 17, No 1, pp. 25-46.
35. Kiiralaenu turg – analüüs ja ettepanekud, Eesti Vabriigi Majandus- ja Kommunikatsiooniministeerium, veebruar 2014, 62lk [https://www.mkm.ee/sites/default/files/kiiralanuturg\_analyys\_ja\_ettepanekud.pdf] 12.02.2015.
36. **Kočenda, E., Vojtek, M.** Default Predictors and Credit Scoring Models for Retail Banking. 2009, CESifo Working Paper, No. 2862. 53 p.
37. **Koch, T. W.** Bank Management. 2th ed., Orlando: The Dryden Press, 1992, 970 p.
38. **Kokk, H.** Erasikute Krediidiriski hindamine AS Eesti Krediidipanga näitel. TÜ ettevõtte majanduse instituut, 2011, 78 lk. (magistritöö)
39. Krediidiasutuste laenude teenindamine ja ebatõenäoliselt laekuvate nõuete kuludesse kandmine. Eesti Panga Presidendi määrus. Vastu võetud 27.06.2000 nr 9. – Riigi Teataja, 2003, nr. 76, art. 1146. [https://www.riigiteataja.ee/akt/905900?leiaKehtiv] 12.03.2015.
40. Krediidiregistrist. Krediidiregister. [http://www.krediidiregister.ee/et/21/] 19.03.2015
41. **Lukason, O.** Using publicly available data for building credit scoring models: the case of Estonia. Sander, Priit (Toim.) – Financing of companies and private persons: theory, issues and Estonian evidences. Tartu: Tartu University Press, 2010, pp. 133 - 143.
42. **Marais, M. L., Patell, J. M., Wolfson, M. A.** The Experimental Design of Classification Models: An Application of Recursive Partitioning and Bootstrapping to Commercial Bank Loan Classifications. – Journal of Accounting Research, 1984, Vol. 22, pp. 87-114.
43. **McNaughton, D.** Banking Institutions in Developing Markets: Building strong management and responding to change. Vol.1, Wahington: The World Bank 1992, 184 p.

44. **Midi, H., Sarkar, S. K., Rana, S.** Collinearity diagnostics of binary logistic regression model. – Journal of Interdisciplinary Mathematics, 2010, Vol. 13, Issue 3 pp. 253-267.
45. **Mirtalaei, M. S., Saberi, M., Hussain, O. K., Ashjari, B., Hussain, F. K.** A trust-based bio-inspired approach for credit lending decisions. – Computing. 2012, Vol 94. pp. 541-577.
46. **Ong, C-S., Huang, J-J., Tzeng, G-H.** Building credit scoring models using genetic programming – Expert Systems with Applications, 2005, Vol. 29, Issue 1, pp. 41–47.
47. Pankrotiseadus. Vastu võetud Riigikogus 22. jaanuaril 2003. a. – Riigi Teataja I osa, 2003, nr. 17, art. 95. [<https://www.riigiteataja.ee/akt/257670?leiaKehtiv>] 22.02.2015.
48. **Perry, P.** Risk Assessments Questions and Answers: A Practical Approach. London : Thomas Telford, 2003, 270 p.
49. **Reichert, A. K., Cho, C-C., Wagner, G. M.** An Examination of the Conceptual Issues Involved in Developing Credit-Scoring Models – Journal of Business & Economic Statistics, 1983, Vol. 1, No. 2, pp. 101-114. Viidatud Thomas, L. C., Edelman, D. B., Crook J. N. Credit Scoring and Its Applications. 1st ed. Philadelphia: Society for Industrial and Applied Mathematics, 2002, 248p. vahendusel.
50. **Rizzi, J., V.** Behavioral Bias: The Hidden Risk in Risk Management. – Commercial Lending Review, 2003, Vol. 18, Issue 6, pp. 2-8.
51. **Rose, P. S.** Commercial Bank Management. Producing and Selling Financial Services. Homewood, Boston: Irwin, 1991, 677 p.
52. **Sinkey, J. F.** Commercial Bank Financial Management in the Financial Services Industry. 4th ed. New York: Macmillan, 1992, 899 p.
53. **Skiba, P. M., Tobacman, J.** Do Payday Loans Cause Bankruptcy? – Vanderbilt Law and Economics Research Paper, 2011 No. 11-13, 52 p.
54. SNEL Grupp OÜ ettevõttesisesed üldreeglid ja teenindusstandardid. SNEL Grupp OÜ, 2014. (käsikiri)

55. **Thomas, L. C., Edelman, D. B., Crook J. N.** Credit Scoring and Its Applications. 1st ed. Philadelphia: Society for Industrial and Applied Mathematics, 2002, 248p.
56. **Tuuis, D.** Risk-Groups in the Estonian Private Persons` Credit Market. Sander, Priit (Toim.) – Financing of companies and private persons: theory, issues and Estonian evidences. Tartu: Tartu University Press, 2010, pp. 117 - 132.
57. **Wendel, C., Harvey, M.** Credit Scoring: best practises and approaches. – Commercial Lending Review, 2003, Vol. 18, Issue 3, pp. 4-7.
58. **West, D.** Neural network credit scoring model. – Computers & Operations Research, 2000, Vol. 27, Issue 11–12, pp. 1131–1152.
59. **Wiginton, J. C.** A Note on the Comparison of Logit and Discriminant Models of Consumer Credit Behavior. – The Journal of Financial and Quantitative Analysis, 1980, Vol. 15, No. 3, pp. 757 – 770.
60. **Zmijewski, M. E.** Methodological Issues Related to the Estimation of Financial Distress Prediction Models. – Journal of Accounting Research, 1984, Vol. 22, pp. 59-82.

## LISAD

**Lisa 1.** Väikelaenu laenu taotluse vorm (SNEL Grupp OÜ ettevõtte oma)

**Laenusaaaja andmed** (Täidab laenu taotleja. Palume täita trükitähtedega)

Eesnimi:
Perekonnanimi:
Isikukood:
Arvelduskonto:
Dokumendi tüüp:
Dokumendi number:
Dokumendi kehtivusaeg:
Maakond:
Linn / Vald:
Küla:
Kodune aadress:
Postiindeks:
Telefoninumber:
E-mail:

**Taotleva laenu andmed** (Täidab laenu taotleja)

Taotletav laenusumma, EUR:
Laenu periood (kuudes):

**Ankeet** (Täidab laenu taotleja. Palume täita trükitähtedega)

Elukohta tüüp
Töökoht (firma nimi)
Amet
Töötatud aeg antud töökohas
Haridus
Kas Teil on ülalpeetavaid?
Laenu kasutamise eesmärk
Igakuine neto sissetulek, EUR
Igakuulised kulutused, EUR
Olete varem kasutanud laene, krediite? Kui jah siis milliseid:
Kas Teil on kehtivaid finantskohustusi? kui on siis milliseid ja mis summades (EUR, täisarv):
Kas Teid keegi kohustab või muul viisil sunnib võtma krediiti?
Kas on Teie laene või muid krediite väljanõutud kohtutäiturite või kohtu kaudu?



**Lisa 2.** Muutujate *sissetlk*, *kulud*, *reserv* ja *kohustus* kategooriad

Kodeering	<i>sissetlk</i>		<i>kulud</i>		<i>kohustus</i>		<i>reserv</i>	
	Kuine nettosissetlek (eur)	vaatluste arv	Igakuised kulutused, v.a. <i>kohustus</i> (eur)	vaatluste arv	Finantskohustuste igakuine koormus (eur)	vaatluste arv	Vaba raha reserv (eur)	vaatluste arv
0	<350	725	<150	3059	0	12024	<0	2733
1	≥350<550	4056	≥150<250	4460	>0<100	2831	>0<50	1378
2	≥550<750	5185	≥250<350	3928	≥100<200	1777	≥50<150	3764
3	≥750<1000	4140	≥350<550	4489	≥200<350	1178	≥150<300	5103
4	≥1000<1500	2847	≥550<750	1366	≥350<500	284	≥300<550	3682
5	≥1500	1349	≥750	1000	≥500	208	≥550	1642
Kokku		18302		18302				18302

Allikas: autori koostatud.

**Lisa 3.** Lõpliku mudeli (L1) muutujate VIF ja TOL väärtused

Muutuja	VIF	Tolerance
<i>status</i>	1,15	0,8686
<i>viivitus</i>	1,01	0,9926
<i>kohtu_k</i>	1,03	0,9695
<i>bank</i>	1,01	0,9903
<i>kogemus</i>	1,09	0,9195
<i>laen_nr</i>	1,15	0,8724
<i>sissetlk</i>	1,38	0,7223
<i>vanus</i>	1,37	0,7298
<i>eluase</i>	1,33	0,7535
<i>sugu</i>	1,25	0,7998
<i>haridus</i>	1,13	0,8841
<i>staaz</i>	1,15	0,8729
<i>pereseis</i>	1,11	0,8999
<i>taust</i>	1,01	0,9886
<i>rr</i>	1,03	0,9689
<i>lnlaen_s</i>	1,17	0,8517

Allikas: autori koostatud.

Lisa 4. Andmete kirjeldav statistika ja informatsiooni väärtus (IV)

Muutuja	Vaatluste arv	Keskmine/Sagedus	Standarthälve	Min	Max	IV
<i>status</i>	18302	0,1898153	0,3921656	0	1	
<i>viivitus</i>	18302	0,0246968	0,1552035	0	1	0,012
<i>kohtu_k</i>	18302	0,0440935	0,2053086	0	1	0,009
<i>hasart</i>	18302	0,0991149	0,2988243	0	1	0,021
<i>bank</i>	18302	0,0168288	0,128633	0	1	0,013
<i>kogemus</i>	18302	0,9070593	0,2903572	0	1	<b>0,194</b>
<i>kv</i>	18302	0,3933996	0,4885176	0	1	<b>0,183</b>
<i>eluase</i>	18302	0,4101191	0,4918685	0	1	0,049
<i>sugu</i>	18302	0,5430008	0,4981611	0	1	0,041
<i>lapsed</i>	18302	0,570047	0,8779923	0	6	0,018
<i>haridus</i>	18302	0,9451972	0,5555347	0	2	<b>0,095</b>
<i>staaz</i>	18302	0,241449	0,4279736	0	1	0,035
<i>pereseis</i>	18302	0,4578735	0,4982358	0	1	0,020
<i>area</i>	18302	0,780188	0,4141305	0	1	0,001
<i>keel</i>	18302	0,4164572	0,4929847	0	1	0,002
<i>mh_act</i>	18302	0,0630532	0,2869811	0	2	0,001
<i>mh_clsd</i>	18302	0,4979784	0,7805286	0	2	0,014
<i>taust</i>	18302	0,9575456	0,2016289	0	1	0,004
<i>rr</i>	18302	0,0675336	0,2509507	0	1	0,014
<i>talvekuu</i>	18302	0,2325975	0,4224993	0	1	0,001
<i>sissetlk</i>	18302	2,4576	1,297137	0	5	0,033
<i>kulud</i>	18302	1,980494	1,395545	0	5	0,010
<i>vanus</i>	18302	2,827451	1,533786	0	5	<b>0,113</b>
<i>reserv</i>	18302	2,576385	1,493821	0	5	0,058
<i>laen_nr</i>	18302	1,438968	1,466552	0	5	<b>0,533</b>
<i>kohustus</i>	18302	0,6608567	1,103663	0	5	0,035
<i>lnlaen_s</i>	18302	5,645115	0,6391811	4,60517	8,006368	
<i>lnosam</i>	18302	5,070759	0,687009	2,71866	6,933423	
<i>lnper</i>	18302	4,083489	1,077306	1,94591	6,984716	
<i>LTI</i>	18302	0,264839	0,1563837	0,0095	0,849476	
<i>ALTI</i>	18302	0,3205985	0,1805029	0,0095	0,95	

Allikas: autori koostatud.

Lisa 5. Lõpliku mudeli (L1) Pearsoni korrelatsiooni maatriks

	<i>status</i>	<i>viivitus</i>	<i>kohtu_k</i>	<i>bank</i>	<i>kogemus</i>	<i>laen_nr</i>	<i>sissetlk</i>	<i>vanus</i>	<i>eluase</i>	<i>sugu</i>	<i>haridus</i>	<i>staaz</i>	<i>pereseis</i>	<i>taust</i>	<i>rr</i>	<i>lnlaen_s</i>
<i>status</i>	1,000															
<i>viivitus</i>	0,051	1,000														
<i>kohtu_k</i>	0,037	0,026	1,000													
<i>bank</i>	0,052	-0,006	0,022	1,000												
<i>kogemus</i>	-0,196	0,037	0,059	-0,046	1,000											
<i>laen_nr</i>	-0,243	-0,004	-0,058	-0,058	0,162	1,000										
<i>sissetlk</i>	-0,055	0,022	0,048	0,017	0,111	0,110	1,000									
<i>vanus</i>	-0,112	-0,003	-0,057	0,002	0,064	0,195	0,061	1,000								
<i>eluase</i>	0,088	-0,007	0,110	0,012	-0,010	-0,111	-0,089	-0,411	1,000							
<i>sugu</i>	0,077	0,014	0,085	0,026	-0,044	-0,038	0,330	-0,190	0,150	1,000						
<i>haridus</i>	0,115	-0,007	0,068	-0,005	-0,106	-0,095	-0,223	-0,195	0,163	0,068	1,000					
<i>staaz</i>	0,077	-0,014	0,022	0,003	-0,057	-0,176	-0,140	-0,301	0,199	0,040	0,112	1,000				
<i>pereseis</i>	0,057	-0,009	0,050	0,001	-0,025	-0,042	-0,046	-0,155	0,271	0,161	0,026	0,082	1,000			
<i>taust</i>	-0,024	-0,023	-0,010	-0,044	0,025	0,023	-0,072	0,004	-0,014	-0,044	0,015	0,000	-0,011	1,000		
<i>rr</i>	0,058	-0,006	0,021	0,007	-0,036	-0,028	0,036	0,061	0,087	0,027	0,044	-0,009	0,047	-0,039	1,000	
<i>lnlaen_s</i>	0,106	-0,009	-0,007	0,021	0,073	0,112	0,307	0,111	-0,122	0,030	-0,098	-0,138	-0,095	0,006	-0,010	1,000

n=13727

Allikas: autori koostatud.

Lisa 6. Lõpliku mudeli (L2) Pearsoni korrelatsiooni maatriks

	<i>status</i>	<i>viivitus</i>	<i>bank</i>	<i>kogemus</i>	<i>laen_nr</i>	<i>sissetlk</i>	<i>vanus</i>	<i>sugu</i>	<i>haridus</i>	<i>staaz</i>	<i>pereseis</i>	<i>mh_clsd</i>	<i>rr</i>	<i>taust</i>	<i>lnlaen_s</i>
<i>status</i>	1,000														
<i>viivitus</i>	0,040	1,000													
<i>bank</i>	0,055	0,000	1,000												
<i>kogemus</i>	-0,201	0,060	-0,046	1,000											
<i>laen_nr</i>	-0,342	0,023	-0,066	0,225	1,000										
<i>sissetlk</i>	-0,067	0,008	0,033	0,104	0,120	1,000									
<i>vanus</i>	-0,131	0,002	0,001	0,033	0,182	0,076	1,000								
<i>sugu</i>	0,099	0,011	0,033	-0,076	-0,069	0,329	-0,147	1,000							
<i>haridus</i>	0,140	-0,009	0,003	-0,125	-0,139	-0,223	-0,221	0,064	1,000						
<i>staaz</i>	0,092	-0,023	0,015	-0,047	-0,171	-0,154	-0,330	0,025	0,134	1,000					
<i>pereseis</i>	0,065	-0,033	0,000	-0,041	-0,058	-0,027	-0,155	0,189	0,024	0,077	1,000				
<i>mh_clsd</i>	0,040	0,079	0,007	0,072	-0,055	0,094	-0,011	0,034	0,024	-0,018	-0,024	1,000			
<i>rr</i>	0,068	0,000	0,027	-0,065	-0,059	0,055	0,069	0,063	0,036	-0,016	0,050	0,008	1,000		
<i>taust</i>	-0,034	0,017	-0,046	0,032	0,021	-0,076	-0,003	-0,059	0,013	0,004	-0,019	-0,006	-0,057	1,000	
<i>lnlaen_s</i>	0,138	-0,016	0,006	0,107	0,107	0,280	0,105	0,015	-0,110	-0,140	-0,102	0,050	-0,031	0,009	1,000

n=6948

Allikas: autori koostatud.

**Lisa 7.** Lõpliku mudeli (L2) muutujate VIF ja TOL väärtused

<b>Muutuja</b>	<b>VIF</b>	<b>TOL</b>
<i>status</i>	1,25	0,8
<i>viivitus</i>	1,016984	0,9833
<i>bank</i>	1,010611	0,9895
<i>kogemus</i>	1,117693	0,8947
<i>laen_nr</i>	1,23839	0,8075
<i>sissetlk</i>	1,3693	0,7303
<i>vanus</i>	1,234568	0,81
<i>sugu</i>	1,246572	0,8022
<i>haridus</i>	1,142335	0,8754
<i>staaz</i>	1,165909	0,8577
<i>pereseis</i>	1,076426	0,929
<i>mh_clsd</i>	1,030078	0,9708
<i>rr</i>	1,03146	0,9695
<i>taust</i>	1,01461	0,9856
<i>lnlaen_s</i>	1,187648	0,842

Allikas: autori koostatud.

## РЕЗЮМЕ

### ПОСТРОЕНИЕ МОДЕЛИ, ОЦЕНИВАЮЩЕЙ КРЕДИТНЫЙ РИСК ЧАСТНОГО ЛИЦА, НА ПРИМЕРЕ ФИРМЫ SNEL GRUPP OÜ

Nikolay Kryzhanovskiy

В современном мире использование всевозможных финансовых услуг стало неотъемлемой частью жизни. В последнее время особенно часто со всех каналов информации звучит вызывающая нелестные отзывы реклама быстрых или смс-кредитов. Неизменно увеличивается и количество предлагающих данную услугу фирм в Эстонии, что отчасти обусловлено и более мягкими требованиями по отношению к их деятельности в сравнении с другими странами Европы. Из года в год растёт как ассортимент различных кредитных продуктов, так и количество пользователей данных услуг, предпочитающих потреблять «здесь и сейчас» за счёт своего будущего дохода. В проведенном в 2014 году в Эстонии исследовании выяснилось, что быстрыми кредитами пользовались от 100 до 190 тысяч человек, причем около трети из выданных кредитов оказались проблемными (Kiirlaenu...2014: 4-8).

Бесспорно, недостаточный анализ платежеспособности клиента и, как следствие, менее качественный кредитный портфель, не может позитивно влиять на экономические результаты фирмы, особенно в условиях, когда на рынке быстрых кредитов царит бескомпромиссная конкуренция. Именно поэтому максимально рациональная и точная оценка кредитного риска ходатая является крайне важным фактором для поднятия конкурентоспособности и жизнеспособности субъекта. Для того, чтобы повысить качество своих кредитных решений, предприятия все чаще обращают своё внимание и берут на вооружение различные статистические методы. К примеру, во всех крупнейших банках Эстонии для оценки платежеспособности клиента используются рейтинговый или скоринговый метод,

задачей которого является дать оценку вероятности корректного возвращения кредита, опираясь на различные данные клиента.

Оценивание кредитного риска частного лица не является распространённой областью исследования в Эстонии. Большинство работ ограничиваются описанием системы оценивания кредитного риска на конкретном предприятии. О скоринговых моделях, построенных на данных не банковских финансовых организаций автору ничего не известно. Целью данной магистерской работы является построение скоринговой модели, оценивающей кредитный риск частного лица, на примере занимающейся микрокредитованием фирмы SNEL Grupp OÜ. В ходе моделирования выясняется, какие демографические, социальные, описывающие раннее платёжное поведение и другие факторы помогают различить клиентов, которые исполняют свои кредитные обязательства корректно, от клиентов, которые со своими обязательствами не справляются. Задачей скоринговой модели является оценивание вероятности корректного возвращения кредита.

Исходя из цели данной работы, были поставлены следующие задачи:

- раскрыть понятие кредитного риска и привести возможности его оценивания;
- выяснить, какие факторы влияют на кредитный риск;
- проанализировать сильные и слабые стороны различных методов оценивания кредитного риска и связать их с ранее полученными результатами;
- представить и проанализировать используемый в SNEL Grupp OÜ метод и этапы оценивания кредитного риска;
- описание и обработка данных, полученных из базы данных SNEL Grupp OÜ;
- построение скоринговой модели с помощью *logit*-метода, анализ результатов.

Данная работа состоит из двух частей: теоретической и эмпирической. В первой части приводятся теоретические аспекты кредитного риска частного лица, этапы и методы его оценивания. Далее следует анализ и обобщение факторов, выявленных и использованных в моделировании кредитного риска частного лица другими исследователями. В заключительном подпункте первой части анализируются различные статистические методы оценивания кредитного риска, а также приводятся и сравниваются результаты, полученные другими авторами. Эмпирическая часть начинается с анализа метода, применяемого в SNEL grupp OÜ, после чего описываются и обрабатываются данные, используемые для моделирования. В третьем подпункте второй части автор составляет выстраивает модель, делая заключения, касательно статистически достоверных характеристик клиента, которые можно использовать для оценивания вероятности корректного возвращения кредита. Дополнительно автор приводит конкретный пример, каким образом скоринговая модель может быть использована в работе предоставившей данные фирмы.

Для получения максимально точной модели, пройдено несколько этапов. Во-первых, было дефинировано понятие кредитного риска частного лица и условие, при котором данный риск реализуется. Исходя из исследовательского задания, кредитным риском считается задержка в оплате кредита длиной более 60 дней. Также были сделаны выводы касательно двух основных методов оценивания кредитного риска частного лица – субъективного и статистического. Были приведены особенности и узкие места обоих методов, выделены их сильные стороны. Ожидаемо лучшим оказался статистический метод, который позволяет быстро и эффективно оценить вероятность корректного платёжного поведения клиента. В то же время при моделировании необходимо считаться с отклонением выборки, сдвигом популяции, а так же с доступностью данных.

В результате анализа научных статей и работ других авторов, были выделены основные факторы и характеристики, влияющие на кредитный риск частного лица. Для упрощения понимания и оценки результатов, эти факторы были разбиты автором на 5 больших групп: социально-демографические, характеризующие финансовое положение ходатая, характеризующие особенности



кредита, показатели платёжного поведения и информация, находящаяся в свободном доступе. Количество используемых переменных в исследованиях определяется, прежде всего, доступностью данных: зачастую авторам не удается заполучить достаточное для моделирования количество данных, ввиду чувствительности последних. В общем случае в готовых моделях оставалось от 10 до 20 переменных. Автору данной работы удалось получить выборку, в которой каждый объект характеризуется 27 разными переменными. В добавление к ним, 3 переменные, описывающие финансовое положение клиента, были образованы самим автором.

Выбирая конкретный статистический метод для построения модели, необходимо считаться с уровнем его сложности, эффективностью и уместностью, а также легкостью интерпретации результатов выбранного метода. Для оценивания кредитного риска частного лица чаще всего применяется четыре метода: *logit/probit* метод, дискриминантный анализ, дерево принятия решений и нейронные сети. Согласно результатам проведенного анализа, выбранным оказался *logit* метод, поскольку с помощью данного метода, можно не только дать оценку вероятности корректного возвращения взятых финансовых обязательств, но и дать ответ, какие конкретно переменные и насколько сильно влияют на эту вероятность. Кроме того, точность предсказания моделей, полученных используя данный метод оказалась лишь незначительно ниже, чем у лидера по данному показателю - нейронных сетей.

Как выяснилось, финансовое учреждение SNEL Grupp OÜ, занимающееся микрокредитованием с 2012 года, для оценивания кредитоспособности ходатаев использует в своей работе субъективный метод оценивания. Что примечательно, характеристики, на которые кредитный специалист обращает внимание, совпадают с теми характеристиками, которые используются в статистических методах.

Для составления модели были взяты данные клиентов, которым были выданы малые (быстрые) кредиты в период с 01.07.2012 по 01.07.2014. Принадлежность к одной из групп («хорошие» либо «плохие») ещё не возвращенных кредитов проверялось по состоянию на 01.05.2015. Автору удалось заполучить объемную

выборку с 18302 различными кредитами. Количество «плохих» кредитов (в оплате случались задержки длительностью более 60 дней) в данной выборке составляло 18,98%.

Результатом моделирования стала модель L1, в конечный состав которой вошли 15 статистически достоверных переменных. Точность классификации кредитов данной модели на первичной выборке составила 81,83%, на тестовой выборке – 80,81%. Таким образом, модель даёт верную оценку четырём из пяти ходатайств, что является достаточно высоким показателем и превосходит среднее значение скоринговых моделей, проанализированных в теоретической части данной работы, зарубежных исследований.

Говоря о конкретных характеристиках, следует, прежде всего, отметить, что в модели L1 представлены все 5 групп различных факторов, речь о которых шла чуть ранее. С увеличением нетто-дохода клиента кредитный риск уменьшается. Из характеристик кредитного продукта, статистически достоверной оказалась только сумма кредита, которая, увеличиваясь, повышает и вероятность некорректного возврата. Не влияют на кредитный риск ни период, ни величина ежемесячного платежа. Не нашло подтверждения и предположение автора, что выданные в зимние месяцы кредиты возвращаются менее корректно. Большая длина клиентских отношений, наличие опыта в использовании финансовых услуг и ранее корректно возвращенные кредиты уменьшают вероятность кредитного риска. То обстоятельство, что у клиента были кредиты, которые он возвращал через суд или судебных исполнителей, является тем фактором, который увеличивает кредитный риск частного лица.

Статистически достоверной общедоступной информацией, которая повышает вероятность некорректного платежного поведения, оказались наполовину заполненная графа «адрес» в Регистре Народонаселения и негативная информация о клиенте по данным поисковых моторов. Шестью статистически достоверными представителями может похвастаться группа социально-демографических характеристик. У более возрастных, имеющих высшее образование и больший стаж работы клиентов вероятность некорректного возвращения кредита будет меньше. Аналогичная ситуация и у холостых мужчин,

которые по сравнению с замужними женщинами имеют менее корректную платёжную дисциплину. Последней характеристикой клиента, увеличивающей его кредитный риск, является отсутствие собственного жилья. В целом, полученный результат соответствует тем выводам, которые делали другие авторы, изучавшие кредитный риск частного лица.

Маргинальные эффекты логистической регрессии позволяют ответить на вопрос, с какой силой та или иная характеристика влияет на результат. В данной работе наибольшее влияние оказывают переменные, характеризующие платёжное поведение клиента. Например, ходатай, за плечами которого 5 корректно возвращенных кредитов, будет иметь на 36 процентных пункта меньшую вероятность некорректного возвращения кредита, в сравнении с ходатаем, для кого желаемый кредит станет первым. Из социально-демографических факторов наибольший вес имеет образование: у клиентов с высшим образованием кредитный риск будет на 8,27 процентных пункта ниже, чем у клиентов с начальным или основным образованием. Так же немалую роль играет и возраст – 32-39-летние кредитополучатели в среднем на 7,77 процентных пункта корректнее возвращают свои кредиты в сравнении с 18-22-летними.

Тестируя выборку, в которой количество «хороших» и «плохих» кредитов было равным, была получена модель L2. В фокусе этой модели было максимально верное выявление потенциально «плохих» кредитов – так называемая чувствительность. Автору удалось достичь корректного предсказания 73,46% «плохих» кредитов, что в сравнении с моделью L1 более чем на три процентных пункта выше. Взяв за основу модель L2, была предложена скоринговая система, которую могла бы в своей работе использовать фирма SNEL Grupp OÜ. В зависимости от числового значения, присваемого каждому ходатайству, общее правило вынесения решения может выглядеть следующим образом:

- $<0,126$                       автоматически негативное решение по ходатайству
- $\geq 0,126 < 0,6$                 необходим дополнительный кредитный анализ
- $\geq 0,6$                          автоматически негативное решение по ходатайству

Модель оценивает ходатайство по шкале от 0 до 1. Выбор пороговых значений для модели напрямую зависит от уровня риска, с которым фирма готова считаться. В случае предложенной автором системы, автоматический ответ на ходатайства давался бы на около 45% ходатайств, причём действительно корректно возвращёнными из них оказались бы 93,7%. Таким образом, предложенная модель могла бы значительно сократить время, затрачиваемое на вынесение решений по ходатайствам на быстрые кредиты, что в свою очередь означает оптимизацию расходов фирмы.

Данная работа вносит вклад в растущий объём литературы, в фокусе которой находится применение различных методов для оценки и моделирования кредитного риска частного лица. В результате проведённого исследования выяснилось, что на кредитный риск частного лица – клиента быстрых кредитов в Эстонии в большей степени влияют социально-демографические и описывающие кредитное поведение характеристики. Поскольку использованные в исследовании данные являются универсальными, предложенная автором скоринговая модель L2 может в неизменном виде быть использована и другими участниками рынка быстрых кредитов.

Данную магистерскую работу можно улучшить несколькими способами. Во-первых, в модель можно добавить уравнения дохода и убытка, получаемых с выданных «хороших» и «плохих» кредитов, тестируя, каким образом изменится правила решения по ходатайствам. Во-вторых, при моделировании было бы интересно учитывать и отклонённые ходатайства, чтобы избежать перекоса выборки, который происходит вследствие того обстоятельства, что в анализе были задействованы данные только по выданным кредитам. И наконец, можно использовать и другие статистические методы, несмотря на то, что в среднем точность их классификации уступала *logit* методу.

## **Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks**

Mina, Nikolay Kryzhanovskiy,

(sünnikuupäev: 25.02.1990)

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) enda loodud teose „Eraisiku krediidiriski hindava mudeli koostamine ettevõtte SNEL Grupp OÜ näitel“, mille juhendaja on Oliver Lukason,

1.1. reprodutseerimiseks säilitamise ja üldsusele kättesaadavaks tegemise eesmärgil, sealhulgas digitaalarhiivi DSpace-is lisamise eesmärgil kuni autoriõiguse kehtivuse tähtaja lõppemiseni;

1.2. üldsusele kättesaadavaks tegemiseks Tartu Ülikooli veebikeskkonna kaudu, sealhulgas digitaalarhiivi DSpace'i kaudu kuni autoriõiguse kehtivuse tähtaja lõppemiseni.

2. olen teadlik, et punktis 1 nimetatud õigused jäävad alles ka autorile.

3. kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest tulenevaid õigusi.

Tartus, **12.01.2016**