

TARTU ÜLIKOOL

Majandusteaduskond

Ettevõtetmajanduse instituut

Rauno Raudsepp

**KREDIIDIRISKI PROGNOOSIMISE MUDELI  
KOOSTAMINE TARTU TERMINAL AS NÄITEL**

Bakalaureusetöö

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

SISSEJUHATUS .....	4
1. ETTEVÕTTE KREDIIDIRISKI MODELLEERIMINE.....	6
1.1. Ettevõtete krediidiriski olemus.....	6
1.2. Krediidiriski prognoosimise meetodid .....	12
1.3. Krediidiriski prognoosimise muutujad ja klassifitseerimistäpsused .....	19
2. KREDIIDIRISKI PROGNOOSIMISE MUDELI KOOSTAMINE.....	25
2.1. Ettevõtte tutvustus ja senine krediteerimise poliitika.....	25
2.2. Töös kasutatavad andmed ja muutujad.....	30
2.3. Krediidiriski modelleerimine ja tulemuste analüüs .....	35
KOKKUVÕTE.....	41
VIIDATUD ALLIKAD .....	44
LISAD .....	50
Lisa 1. Lühendid finantsnäitajate ja suhtarvude kohta .....	50
Lisa 2. AS Tartu Terminali kaubakrediidi taotlus .....	51
Lisa 3. AS Tartu Terminali müügileping .....	52
Lisa 4. AS Tartu Terminali käendusleping .....	55
SUMMARY .....	57

## SISSEJUHATUS

Ettevõtete tähtsaimaid eesmärke on ettevõtte väärtuse maksimeerimine, mis ühtlasi tagab selle jätkusuutliku tegutsemise. Kõigil ettevõtetel ei õnnestu kasumlik tegutsemine, mis halvemal juhul võib viia nende pankrotini. Tihtipeale algab see kohustuste õigeaegselt mittetäitmisest ning võib viia välja püsiva maksehäireni. Ettevõtte, kellel on probleeme kohustuste täitmisega, võib kujutada partneritele tõsist krediidiriski. Riskide vähendamiseks tuleb leida võimalus eristada edukaid, oma kohustusi korrektselt täitvaid ning ebaedukaid ettevõtteid. Selleks on mitmeid võimalusi, näiteks ekspertide poolt antavad hinnangud ettevõttele, finantssuhtarvude analüüs ning ettevõtete majandusnäitajatel põhinevad mudelid. Eesmärk on leida vastus küsimusele, millisele ettevõttele võimaldada krediiti ja millisele mitte.

Antud teema on aktuaalne ka AS Tartu Terminalis, kuna ettevõtte on viimastel aastatel laienenud rohkem jaemüügiturule teenindusjaamade rajamise kaudu, siis on ka jaemüügiklientide ja ettevõtte kontseptsioonist lähtuvalt tanklate hulgimüügiklientide hulk oluliselt suurenenud. Seeläbi senine ettevõttesisene krediidipoliitika hakkab ennast ammendama ning on vaja leida uusi meetodeid, kuidas suurenenud krediidiklientide arvuga toime tulla. Üheks võimalikuks meetodiks on krediidiriski prognoosimise mudeli välja töötamine, mis sobiks hästi AS Tartu Terminali vajadustega ning oleks ettevõtte spetsiifiline, omades praktilist kasutuskogemust oleks võimalikult täpne ettevõtte vajadusi silmas pidades.

Seega on antud töö eesmärgiks seatud krediidiriski prognoosimise mudeli väljatöötamine AS Tartu Terminali näitel. Eesmärgi saavutamiseks on vaja leida parim võimalik viis, kuidas hinnata klientide krediidivõimelisust ning seeläbi muuta efektiivsemaks ja samas ka lihtsustada senist krediidipoliitikat AS Tartu Terminalis.

Töö eesmärgist lähtuvalt on püstitatud järgmised uurimisülesanded:

1. Ülevaate andmine krediidiriski olemusest.
2. Krediidiriski prognoosimise meetodite kirjeldus.
3. Krediidiriski prognoosimiseks kasutatavate muutujate leidmine.
4. Analüüsida varasemates teadustöodes kasutatud krediidiriski prognoosimise mudeleid.
5. Anda ülevaade AS Tartu Terminalist ja senisest krediidiriski poliitikast.
6. Kirjeldada kasutatavaid muutujaid ja nende kohta esitada kirjeldav statistika.
7. AS Tartu Terminali krediidiriski modelleerimine logistilist regressioon analüüsi kasutades.
8. Erinevate mudelite võrdlev analüüs ning kõrvutamine varasema teaduskirjandusega.

Töö teoreetilises osas vaadeldakse erinevaid krediidiriski prognoosimise meetodeid, analüüsitakse ja võrreldakse neid ning leitakse antud töö jaoks sobivaim. Samuti vaadeldakse erinevaid varasemaid kasutatud muutujaid ning hinnatakse nende kasutuskogemust. Paremaks ülevaateks vaadeldakse olulisemaid varasemaid uuringuid leides nendes kasutatud muutujad ning tuuakse välja antud uuringute klassifitseerimistäpsused.

Käesoleva bakalaureusetöö empiirilises osas tutvustatakse AS Tartu Terminali. Vaadeldakse ettevõtte näitajaid ning tuuakse välja positsioon Eesti kütuseturul. Kuna antud töö uurib krediidiriski prognoosimise mudeli koostamist AS Tartu Terminali näitel, siis on oluline ka välja tuua senine krediidipoliitika ettevõttes. Samamoodi tuuakse välja empiirilise osa teises peatükis modelleerimise jaoks kasutatud andmed ja muutujad, nende saamine ja kirjeldus. Viimases peatükis kirjeldatakse modelleerimisel saadud tulemusi ning tõlgendatakse neid ja samuti analüüsitakse saadud tulemusi AS Tartu Terminali seisukohast.

Käesoleva töö koostamisel ja teoreetilise tagapõhja kujundamisel on tuginetud tunnustatud ja enimsiteeritud inglisekeelsetele artiklitele ja uuringutele. Samuti on kasutatud erinevaid andmeid nii Taust.ee-st kui ka Äriregistri andmebaasist. Autor tänab oma juhendajat Oliver Lukasoni hindamatu abi eest töö valmimisel.

**Märksõnad:** krediidirisk, krediidiriski modelleerimine, logistiline regressioonanalüüs, varasem maksekäitumine, krediidimüük.

# 1. ETTEVÖTTE KREDIIRISKI MODELLEERIMINE

## 1.1. Ettevõtete krediidiriski olemus

Ettevõtte eesmärk on teenida võimalikult suurt kasumit, teenides sellega omaniku ja aktsionäride huve. Et antud eesmärki täita peab ettevõtte olema elujõuline, arenev ja konkurentsivõimeline. Ettevõtte edukuse määrab suure konkurentsiga keskkonnas ära tema maksejõulisus, võime luua põhitegevusest likviidset käibevara, ligipääs kapitaliturgudele ja finantsiline võimekus tulla toime ootamatute likviidsete käibevahendite puudujääkidega (Kumar, Ravi 2007: 1). Alati ei suuda kõik ettevõtted edukad olla ning erinevatel põhjustel (kogemuse puudus, kehv juhtimine, vähene kapital) võib ette tulla ka ebaõnnestumisi. Ettevõtte ebaõnnestumise (*business failure*) põhjuseid jaotatakse neljaks: inimkäitumisest, sisemistest ja välistest teguritest, ettevõtte struktuurist ja finantsilistest teguritest tulenevad ebaõnnestumised (Pretorius 2008: 412-414). Ettevõtte ebaõnnestumine mõjutab kogu organisatsiooni eksisteerimist, sh. töötajaid ja nende igapäevaseid tegevusi, ja samuti võib see olla kulukas koostööpartneritele, ühiskonnale ja riigile (Warner 1977).

Ettevõtte, mille majanduslik olukord on erinevatel põhjustel halb, võib kalduda ebaõnnestumisele, mis võib põhjustada riski laenavatele või siis krediidimüüki (*credit sales*) pakkuvatele ettevõtetele. Krediidimüüki võib defineerida kui müüki, kus kauba üleandmine toimub kohe ja tasumine hiljem. Sellise tehinguga võib kaasneda krediidirisk (*credit risk*). Cade (1999: 12) defineerib riski, kui tulemuse määramatust. Seega risk võib olla samas nii oht, kui ka võimalus. Antud töö kontekstis vaadeldakse riski kui ohtu, kus üks tehingu pool (krediidisaaja) ei täida kokkulepitud kohustusi korrektselt. Eelnev seletus defineerib ka mõistet krediidirisk. Krediidirisk realiseerub, kui kokkulepitud kuupäevaks ei täideta võetud kohustusi, mis võib viidata ajutisele maksejõuetusele.

Olukorda, kus võlgnik ei suuda täita võetud rahalisi kohustusi nimetatakse maksejõuetuseks (*insolvency*). Maksejõuetus jaguneb kaheks: ajutine ja püsiv. Ajutine maksejõuetus on lühiajaline mööduv olukord, kus ettevõtte ei täida korrektselt võetud kohustusi. Oluline on välja tuua, et lühiajalise lepingutingimuste rikkumise puhul ei pruugi olla ajutise maksejõuetusega, aga mida perioodilisemalt seda tehakse, seda enam ei ole tegemist juhuslikkusega. Püsiv maksejõuetus, aga on olukord, kus ettevõtte ei ole suutnud pikaajaliselt täita võetud kohustusi. Seega on püsiva maksejõuetuse puhul krediidirisk alati realiseerunud.

Krediidiriski prognoosimine on oluline seotud isikute, omanike, aktsionäride, juhatajate, töötajate, võlausaldajate, tarnijate, klientide, ühiskonna ja riigi seisukohast. Krediidiriski prognoosimise mudelid on tähtsad kahel erineval põhjusel. Esiteks saavad mudelid otsustajatele probleemidest varakult märku anda, tekitades võimaluse hoiduda suuremast kahjust. Teiseks saavad need mudelid olla kasulikud finantsinstitutsioonidele hindamiseks ja teistele ettevõtetele informatiivseks abiks, leidmaks, kas antud ettevõttesse tasub investeerida või siis koostööd teha. Mudelid annavad parema informatsioonibaasi otsustamiseks krediidimüügi teostamise üle. Oluline on arvestada võimalikke kulusid ja ebaõnnestumise riske. (Dimitras *et al* 1996: 487-488)

Teaduskirjanduses kasutatakse antud teemal enamasti kolme erinevat mõistet: ettevõtte ebaõnnestumine (*failure prediction*), pankroti prognoosimine (*bankruptcy prediction*) ja krediidiriski prognoosimine (*credit scoring*). Kõiki neid mõisteid kasutatakse ettevõtte elujõulisuse hindamisel vastavalt uurimiseks püstitatud ülesandele ja uurimissuunast lähtuvalt. Järgnevalt leitakse, mille poolest erinevad pankroti prognoosimine ja krediidiriski prognoosimine ettevõtte ebaõnnestumisest ning leitakse, miks antud töö jaoks sobivaim käsitusviis on krediidiriski hindamine.

Ebaõnnestumise definitsioone on erinevaid, aga peamiselt loetakse ebaõnnestumiseks situatsiooni, kus ettevõtte ei suuda tasuda võlausaldajatele ja tarnijatele ehk on maksejõuetu või koguni seaduse järgi pankrotis (Dimitras *et al* 1996: 487-488). Seega on katkenud kõik ettevõtte peamised tegevused. Antud mõistet on erinevates uurimustes defineeritud, kui ebaõnnestuva ja mitte ebaõnnestuva ettevõtte eristamist (Ooghe, Verbaere 1985; Ooghe, Joos 1990; Ooghe *et al* 1995; Altman, Eisenbeis 1978).

Eesti Vabariigi pankrotiseaduse §1 järgi on pankroti mõistet defineeritud järgmiselt:

1. Pankrot on võlgniku kohtumäärusega väljakuulutatud maksejõuetus.
2. Võlgnik on maksejõuetu, kui ta ei suuda rahuldada võlausaldaja nõudeid ja see suutmatuse ei ole võlgniku majanduslikust olukorrast tulenevalt ajutine.
3. Juriidilisest isikust võlgnik on maksejõuetu ka siis, kui võlgniku vara ei kata tema kohustusi ja selline seisund ei ole võlgniku majanduslikust olukorrast tulenevalt ajutine.

Seega pankroti prognoosimisel on tegemist ettevõttega, kes on püsivalt maksejõuetu. Kohtu poolt on välja kuulutatud pankrot ja ettevõtte ei ole enam tegev. Maksejõuetus jaotatakse kaheks eri liigiks: rahavooline ja bilansiline maksejõuetus. Rahavoolise maksejõuetuse (*cash flow insolvency*) puhul ei suuda võlgnik rahuldada võlausaldaja nõudeid ja see olukord ei ole ajutine. Bilansilise maksejõuetuse (*balance sheet insolvency*) puhul ületavad võlgniku kohustused tema vara ja see olukord ei ole ajutine. (Fletcher 1999)

Ajutise maksejõuetuse puhul on tegemist hetkeliste likviidsusprobleemidega. See tähendab, et õigete struktuursete juhtimisotsustega on võimalik ettevõtet ebaõnnestumisest päästa. Teatud olukordades kasutatakse ettevõtte päästmiseks saneerimisprotsessi, kus proovitakse taastada, koostöös võlausaldajatega, ettevõtte kasumlikkust ja jätkusuutlikust. Eduka saneerimise puhul välditakse ettevõtte pankrotistumist ja likvideerimist. Kui läheb teisiti ja ettevõtte muutub püsivalt maksejõuetuks, saavad võlausaldajad tihti kahju, kuna ettevõtte varad on nõuetest väiksemad. Maailmapanga aruande *Doing Business 2015* (2014: 170-226) aruande alusel saavad Eestis võlausaldajad pankrotti läinud ettevõttest 39,3% nõudest kätte. Selle alusel jäävad võlausaldajad keskmiselt 60,7% oma investeeringust ilma. Sellele lisandub asjaajamiskulud (advokaadid, riigilõivud jne.), mille alla võib liigitada ka ajakulu. Pankrotimudelid ei arvesta asjaoluga, et de facto püsivast maksejõuetusest pankrotini (ehk de jure maksejõuetuseni) võib olla pikem aeg. Selline ajaline viide võib mõningal juhul kesta aastaid. (Theodossiou 1993: 441–449; Ooghe *et al* 1995: 245–274)

Pankrot on seisund/staatust, kus enamikel juhtudel ettevõtte ei tegutse enam. Alati ei pruugi ettevõtte minna pankrotti. Mõnikord toimub enne pankroti välja kuulutamist raugemine, see toimub seetõttu, et ettevõttel pole varasid, mida võlausaldajate vahel jaotada, mistõttu teostatakse likvideerimine. Samuti on võimalikud ka juhud, kus ettevõtte pankrotistumise põhjus võib olla kuritegelik. Sellisel juhul ei ole ettevõtte eesmärk tegeleda tavapärase ettevõtlusega, vaid petuskeemide läbiviimisega (Lukason 2010: 11). Krediidinfo 2014 aasta andmete põhjal lõppes Eestis 64,5 % pankrotimenetlustest raugemisega. 2013 ja 2012 aastal oli vastav näitaja 67% ja 70,5% (Pankrotid Eestis... 2016: 5).

Eelnevast järeldub, et krediteeriva ettevõtte eesmärk peaks olema vältida olukordi, kus partnerettevõtte läheb pankrotti, kuna sellega kaasneb nii finantsiline kui ka ajaline kahju. Antud probleemi võimaldab vältida krediidiriski hindamine. Võrreldes ebaõnnestumisega tegeleb krediidiriski prognoosimine ennetamisega, et ei satuks finantsraskustes ettevõtte klientide hulka ja üritab vältida olukorda, kus partnerettevõtte ebaõnnestub. Samuti tegeletakse ettevõtte finantssuhtarvude põhjal jälgimise ja prognoosimisega ning püütakse vältida püsivat maksevõimetuse olukorda (Abdou, Pointon 2011: 59-61; Hand, Henley 1997: 523-526). Mõlema, ettevõtte ebaõnnestumise ja krediidiriski hindamise puhul kasutatakse samu meetodeid. Samuti saab pankrotistumise tõenäosust kasutada ka krediidiotsuste tegemisel. Lisaks on ühine ettevõtete klassifitseerimine „headeks“ ja „halbadeks“ (Dimitras *et al* 1996: 488) ehk krediidiriski prognoosimise kontekstis „krediidivääriliseks“ ja „mitte krediidivääriliseks“, mis tähendab klientide jagamist kahte gruppi: kohustusi korrektselt täitvad ettevõtted ja ettevõtted, kes ei täida kohustusi korrektselt. Antud grupid moodustavad tervikliku valimi, mille põhjal modelleeritakse krediidiriski.

Krediidiriski prognoosimist kasutatakse tõenäosuse, et klient jätab tagasi maksmata, määramisel (Hand, Henley 1997: 524). Hand ja Jacka (1998: 106) töid välja, et modelleerimisel krediidiväärilisust nimetatakse *credit scoringuks*. Krediidiriskiks nimetatakse erinevate mudelite ja nende leidmise tehnikaid, mis aitavad laenuandjail otsustada, kes ja kui palju saavad krediiti ja millise strateegia kasutamisel muutuvad laenajad laenuandjale kasulikuks. (Thomas *et al* 2002: 1)

Krediidiriski prognoosimise peamine idee on võrrelda ettevõtete omadusi ja tunnuseid klientidega eelmistest perioodidest, kelle laenud on juba tagasi makstud. Kui kliendi

tunnused on sarnased nendele, kellele on antud krediiti ja kes ei ole tingimusi korrektselt täitnud, siis klient krediiti ei saa. Kui kliendi tunnused on sarnased neile, kes on korrektselt makseid tasunud, siis antakse talle krediiti. (Crook 1996) Seega kasutavad analüütikud ajaloolist kogemust võlgnikega, et tuletada kvantitatiivne mudel, eraldamaks aktsepteeritavaid ja mitteaktsepteeritavaid krediidisoove. Krediidiriski prognoosimise süsteem on isetoimiv protsess, kus iga järgnev krediidisoov mõjutab kõiki krediidiotsuseid. Selles süsteemis saadakse iga muutuja väärtuse eest mingi hulga pluss ja miinus punkte. Need saadakse krediidi taotlejatelt kogutud statistilistest numbritest, mida võib mõjutada andmete kogumise aeg või allikate arv. See tähendab, et krediidiriski hindamine annab vastuse krediidiväärilisuse kohta ruttu ja lisaks säilitab ta kliendi info, mis aitab parandada info kvaliteeti. (Sullivan 1981; Bailey 2004)

**Tabel 1.1.** Krediidiriski prognoosimise mudeli kasutamise eelised ja puudused

<b>Eelised</b>	<b>Puudused</b>
Vajab vähe informatsiooni	Kasutab ka karakteristikuid, millel võib puududa seos tagasimaksega
Suudab analüüsida mitteaktsepteeritavaid krediidi soove	Majanduslikud tegurid võivad puududa
Arvestab nii heade kui halbade klientide omadusi	Võib esineda klassifikatsiooni vigu
Suudab kasutada väga suurt andmete hulka	Mudel ei ole lõplik
Näitab korrelatsiooni muutujate ja krediidi tagasimaksete vahel	Mudolid ei ole standardsed
Samade andmete puhul on teiste isikute modelleerimisel tulemus sama	

Allikas: (Abdou, Pointon 2011: 61-63); autori koostatud.

Tabelis 1.1. on välja toodud krediidiriski prognoosimise eelised ja puudused. Eelisena võib välja tuua, et kuna krediidiriski hindamise mudelis kasutatavad muutujad on tugevalt korrelatsioonis tagasimaksega, siis ei ole otsuse tegemiseks vaja palju informatsiooni. Samuti proovib krediidiriski hindamine korrigeerida eelarvamust, et kogu tagasimakse ajalooline info pärineb ainult vastuvõetud laenutaotlustest, tehes seda läbi eelduse, kuidas tagasilükatud avaldused oleksid toiminud, kui nad oleksid aktsepteeritud. Krediidiriski prognoosimise mudelid arvestavad nii heade, kui ka halbade maksjate karakteristikuid.

Samuti on nad võimelised töötlemata väga suurt andmete hulka ja on võimelised näitama kasutatud muutujate ja tagasimakse vahelist korrelatsiooni. Lisaks tuleb krediidiriski hindamise eelistena välja tuua ka asjaolu, et kasutades samu andmeid teise modelleerija poolt, saadakse samasugune tulemus. (Chandler, Coffman 1979; Crook 1996)

Puuduste poole pealt märgitakse ära, et mudelid võivad kasutada kliendi omadusi, mis ei ole seotud tagasimaksete tõenäosusega. Samuti võib tekkida olukord, kus majanduslikke tegureid ei ole arvestatud. Krediidiriski prognoosimise mudelite üks suurimaid miinuseid on valesti klassifitseerimise probleem. Näiteks võib tekkida olukord, kus kliendi omadused võivad juhuse tõttu sarnaneda rohkem halva tagasimaksja, kui hea krediitdivõtja omale. Mudel ei ole kunagi lõplik, kuna kasutatud muutujaid saab alati kasutada edasi, kui lisada sinna uusi muutujaid. Lisaks on krediidiriski hindamise mudelid iga turu jaoks erinevad ehk puudub ühtne standard. (Al Amari 2002: 69; Chandler, Coffman 1979; Crook 1996)

Ajalooliselt on enimkasutatud krediidiriski hindamise meetoditest diskriminantanalüüs ja lineaarregressioon. Arvutitehnoloogia arenguga on teiste meetodite, nagu logistiline regressioonanalüüs, probit analüüs, mitteparameetrilise silumise meetod, matemaatiline programmeerimine, Markovi ahela mudelid, rekursiivne ositamine, ekspert meetodid, geneetilised algoritmid, närvivõrkude meetod ja tingimuslike iseseisvate mudelite osatähtsus ajas suurenenud (Hand, Henley 1997: 531-532). Kõigi nende mudelite puhul jääb küsimus, mida Al Amari (2002: 41) arutles järgmiselt: milline on kliendi hindamiseks optimaalne meetod? Milliseid muutujaid tuleks kasutada? Milline informatsioon aitaks parandada ja lihtsustada otsuse tegemise protsessi? Milline on parim näitaja hindamiseks laenu kvaliteeti? Millises määras saab klienti klassifitseerida heaks ja halvaks?

Eelnevast arutlusest krediidiriski olemuse ja selle nüansside kohta järeldab autor, et krediidiriski prognoosimisel võib olla arvestatav ühisosa püsiva ja ajutise maksejõuetuse prognoosimisega. Teades selle peamisi tugevusi ja nõrkusi arutletakse järgnevas alapeatükis erinevate meetodite üle ja võrreldakse neid omavahel. Samuti proovitakse leida Al Amari (2002) arutletud küsimustele vastuseid.

## 1.2. Krediidiriski prognoosimise meetodid

Alates 1930 aastatest on tegeletud ettevõtte ebaõnnestumise prognoosimisega. Esimesena avaldas artikli *Bureau of Business Research* teemal „Ebaõnnestunud ettevõtete suhtarvud“. Kui aastatel 1930 kuni 1965 oli väga üksikuid teisi uurimusi, siis alates 1966. aastast on uurimuste maht märgatavalt kasvanud. Olulise märgina on Beaveri 1966. aastal koostatud ettevõtete ebaõnnestumise mudeli koostamine koos finantssuhtarvudega. Tema panus oli ühe muutujaga diskriminantanalüüsi mudel. Tamari kasutas riskiindeksi mudelit, et hinnata ebaõnnestumist. Altman tutvustas 1968. aastal mitme muutujaga diskriminantanalüüsi (*multiple discriminant analysis*) ja esitles oma *Z-score* mudelit, mille eesmärk oli prognoosida ettevõtte ebaõnnestumist. Altman muutis oma *Z-score* mudeli uuemaks ja paremaks *Zeta* analüüsi mudeliks. (Bellovary *et al* 2007: 2)

Paralleelselt ettevõtete ebaõnnestumisega tegeleti ka pankroti prognoosimise uurimisega. Kuna mõlemad uurimis valdkonnad on suhteliselt sarnased ja paralleelselt arenenud, siis kirjanduses ei ole ajalooline käsitlus väga konkreetselt eristatud, esineb juhtumeid, kus ettevõtte ebaõnnestumist ja pankroti prognoosimist on kasutatud sünonüümidena. Krediidiriski hindamine on aga hilisem uurimis valdkond, mis sai alguse umbes 50 aastat tagasi ja mille arengusse andis olulise panuse panganduse areng (Abdou, Pointon 2011: 59-61). Tõuke krediidiriski hindamise uurimiseks andis laenuvõtjate suurenenud hulk panganduses, mis tekitas vajaduse uurida, kuidas hinnata suurearvulises kliendihulgas võimalikult odavalt ja täpselt klientide maksekäitumist. Tänu globaliseerumisele on antud uurimissuund viimase 20-30 aastaga omandanud veelgi suurema tähtsuse, mida on toetanud ka krediidimüügi areng. Need arengud on lihtsustanud rohkearvulisi laenuandmise otsuseid, mille tulemusena on finantsasutused säästnud palju raha ja aega (Lee *et al* 2002: 245-254; Ong *et al* 2005: 41-47). Thomas *et al* (2002) arvab, et ilma krediidiriski hindamiseta ei oleks tänane „tarbijalaenu ühiskond“ nii suuremahulist arengut saavutanud.

Varaseima teadliku krediidiriski hindamise eristades „head“ ja „halba“ laenuaotlejat tegi tõenäoliselt Durand (1941), kes kasutas selleks diskriminantanalüüsi. Kuni 1980. aastateni oli domineerivaks uurimismeetodiks mitme muutujaga diskriminantanalüüs, mille osatähtsust uuringutes vähendasid hiljem vähemnõudlikumad statistilised tehnikad

nagu logit analüüs, probit analüüs ja lineaarne tõenäosusmudel. Kuni praeguseni on logit analüüs olnud väga populaarne mudel ettevõtete ebaõnnestumiste prognoosimisel. (Balcaen, Ooghe 2006: 64)

Krediidiriski hindamiseks kasutatakse mitmeid erinevaid statistilisi meetodeid. Igal meetodil on oma eeldus ja erinev panus. Põhieeldus, millega jagatakse krediteeritavad kahte gruppi, on neil ühine: „hea“ ja „halb“. Sõltuv muutuja ehk laenuvõtjad on binaarne ning omab järgnevat väärtusi (Dimitras *et al* 1996: 490):

$$(1) \quad y_i = \begin{cases} 0 & \text{kui krediteeritav ettevõtte } i \text{ on halb} \\ 1 & \text{kui krediteeritav ettevõtte } i \text{ on hea} \end{cases}$$

Vastavalt riski tasemele on tehtud erinevaid ettepanekuid jaotada ettevõtted ka kolme gruppi (Zopounidis, 1987: 45-67). Sisuliselt on siis lisaks „heale“ ja „halvale“ ka „teadmata“ grupp. Näiteks, heaks loetakse ettevõtet, kui laenajal ei ole vaatluse all oleval perioodil ühtegi maksuvõlga, halb krediit on see, kui laenajal on sel perioodil kolm või rohkem maksehäiret ning need laenajad, kel on olnud üks või kaks maksehäiret, paigutatakse kolmandasse gruppi (Hand, Henley 1997: 525-526). Üldine tõekspidamine on siiski, et tuleks kasutada jaotust kahte gruppi. Antud jaotust kasutatakse diskriminantanalüüsis ja selle alternatiivides, logit/probit analüüsis ja lineaarses tõenäosusmudelis (Dimitras *et al* 1996: 490).

Oluline asjaolu, liigitamisel krediteeritavaid „heaks“ või „halvaks“, on murdepunkt (*cut-off point*). See on punkt, millest allapoole jääv diskriminantfunktsiooni väärtus liigitab laenusaja „halvaks“ ja ülespoole jääv tulemus „heaks“ (Al Amari 2002). Murdepunkt ei pea olema täpselt keskel. Erinevates teadustöodes on selle parima asukoha üle diskuteeritud, aga tõenäoliselt ei ole sellel üht optimaalset kohta. See on keskonnast, riigist ja finantsasutusest, samuti ka krediidiotsuste tegijate riski võtmise julgusest. Näiteks mõnel juhul võib pank anda laenu oodatust rohkematele klientidele, sellisel juhul on murdepunkt madalamal kui tavaliselt. (Abdou, Pointon 2011: 66-68)

Krediidiriski hindamisel teeb mudeli heaks klassifitseerimistäpsus. Mida vähem on klassifitseerimisvigu, seda täpsem on mudel. On võimalik teha kahte moodi vigu. Neid nimetatakse tüüp I ja tüüp II. Tüüp I vea puhul liigitatakse halb ettevõtte heaks ja tüüp II puhul on vastupidi (Bellovary *et al.* 2007: 9). Üldiselt on tüüp I vead krediidiandjale

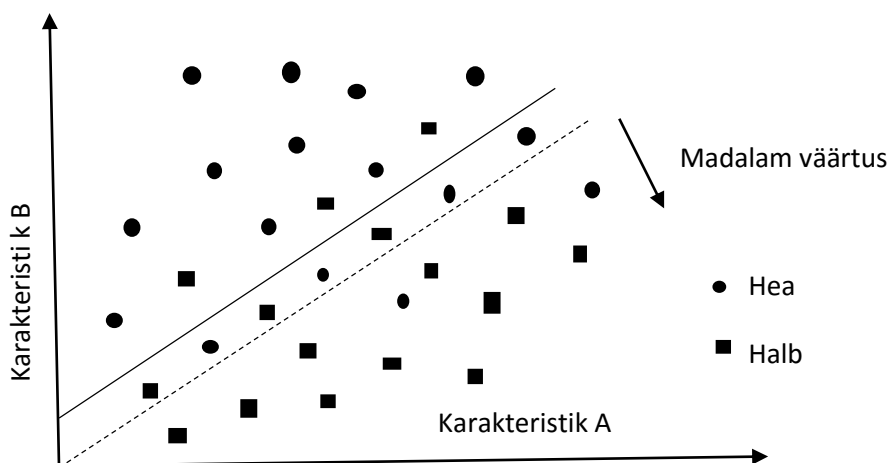
halvemad, kui tüüp II omad, kuna tüüp II vea puhul jääb hea laenuaotleja lihtsalt laenust ilma, aga tüüp I vea puhul on heade ettevõtete seas ettevõtte, kellel tekivad makseraskused. Sellisel juhul kannab laenuandja tulevikus kahju.

Dimitras *et al* (1996: 490-491) leiavad, et krediidiriski hindamise mudeli koostamine koosneb kolmest osast:

- 1) Valimi valik ja andmete kogumine (muutujad ja valimi suurus);
- 2) Meetodi ja kindlate muutujate valik;
- 3) Mudeli hinnang (statistiline olulisus ja tulemuste täpsus).

Meetodi valik on kõige tähtsam osa, kuna see oleneb analüüsitava test andmetest ja uurimiseesmärgist. Andmete valik sõltub nende kättesaadavusest ja usaldusväärsusest (Dimitras *et al* 1996: 490-491).

Järgnevalt toob autor välja enimkasutatud krediidiriski hindamise meetodid, võrdleb neid ning toob välja nende eeliseid ja puudusi. Esimene laialdast kasutust leidnud statistiline meetod, mis jaotas valimi kahte gruppi, oli diskriminantanalüüs. Paljud uurijad leiavad, et antud meetod on endiselt enimkasutatud tehnika, eraldamaks kliente heaks krediteeringuks või halvaks (Abdou, Pointon 2011: 69). Joonis 1.1. illustreerib kahe murdepunktiga diskriminantanalüüsi, kus on välja toodud heade ja halbade väärtuste asetsemine.



**Joonis 1.1.** Diskriminantanalüüsis „hea“ ja „halva“ eristamine. (Rosenberg, Gleit 1994: 592)

Diskriminantanalüüs on mitme muutujaga analüütiline meetod. Meetodi eesmärk on saavutada lineaarne kombinatsioon, mis maksimeerib erinevust kahe grupi vahel (Dimitras *et al.* 1996: 498). Diskriminantanalüüsi funktsioon on järgmine (Lachenbruch 1975: 1-11):

$$(2) \quad D_i = d_0 + d_1X_{i1} + d_2X_{i2} + \dots + d_nX_{in}$$

kus,  $D_i$  on diskriminantfunktsiooni väärtus ettevõtte  $i$  kohta

$X_i$  on sõltumatud muutujad

$d_i$  on funktsiooni kordajad

$D_i$  on vahemikus  $-\infty$  kuni  $+\infty$

Enamikes uuringutes näitab madal diskriminantfunktsiooni väärtus halba ettevõtte olukorda (Balcaen, Ooghe 2006: 66). Lisaks on tähtis välja tuua, et muutuja, mis võib tunduda eraldi vaadates ebaoluline, võib muutujate kogumis muutuda oluliseks informatsiooniks diskriminantanalüüsi mudelis (Altman 1968: 593-598). Olenemata järgnevatest probleemidest peetakse diskriminantanalüüsi ikkagi kõige sagedamini kasutatud tehnikaks krediidiriski hindamise juures (Greene 1998: 302; Abdou *et al* 2008).

Eisenbeis (1977) toob välja 7 statistilist probleemi diskriminantanalüüsi juures:

- 1) muutujate normaaljaotuse eelduse rikkumine;
- 2) kasutamine lineaar-, mitte ruutvõrrandit, kui grupi dispersioonid ei ole võrdsed;
- 3) ebasobiv tõlgendus iseseisva muutuja kohta;
- 4) mõõtmete vähendamine;
- 5) grupi definitsioon;
- 6) esmaste tõenäosuste sobimatu valik ja/või valesti klassifitseerimise kulu;
- 7) klassifikatsiooni vigade määrade valesti hindamise probleemid, mudeli edukuse määramisel.

Alternatiiviks diskriminantanalüüsile on pakutud lineaarset tõenäosusmudelit. Mudel on tavalise vähimruutude meetodi erijuht dihhotoomse väärtustega 0 ja 1 sõltuva muutujaga. Meetod eeldab fiktiivset muutujat  $y$  võrrandis, mis tähendab ettevõtte „ $i$ “ kohta kindlas grupis ja on ettevõtte „ $n$ “ omaduse lineaarne kombinatsioon (Dimitras *et al* 1996: 503).

Mudel hindamaks ettevõtte krediivõimelisust on toodud järgnevalt (Dimitras *et al* 1996: 503):

$$(3) \quad P_i = a_0 + a_1x_{i1} + a_2x_{i2} + a_3x_{i3} + \dots + a_nx_{in}$$

kus,  $P_i$  on ettevõtte ebaõnnestumise tõenäosus

$a_0, a_1, \dots, a_n$  on vähimruutude meetodil arvatud mudeli hinnangud

$x_{i1}, x_{i2}, \dots, x_{in}$  on ettevõtte põhised sõltumatud muutujad

Lineaarse tõenäosusmudeli puhul toovad Dimitras *et al* (1996: 503) välja esineda võivad statistilised probleemid:

- 1) juhuslikud vead ei ole normaal- vaid binoomjaotusega
- 2) juhuslikud vead on heteroskedastiivsed
- 3) leitud tõenäosused ei pruugi olla 0 ja 1 vahel

Põhilised eeldused diskriminantanalüüsil ja lineaarsel tõenäosusmudelil on erinevad, kuid meetodite tulemused on siiski identsed, mille tõttu ei olegi antud meetod saavutanud väga suurt populaarsust (Altman *et al* 1981).

Logistiline regressioonanalüüs, nagu ka diskriminantanalüüs, on üks kõige laialdasemalt kasutatust leidnud statistiline tehnika ebaõnnestumise modelleerimisel. Logistilist regressioonanalüüsi mudelit eristab lineaarsest tõenäosusmudelist asjaolu, et tõenäosuse väärtus ( $P_i$ ) on alati 0 ja 1 vahel, mis peegeldub mõlemas, nii mudeli parameetrite valikul kui ka eeldustel (Hosmer, Lemenshow 1989). Kui see erinevus välja jätta, siis mõlemad mudelid lähtuvad samadest üldistest printsiipidest. Logistilise regressioonanalüüsi mudelile saab juurde lisada rohkem sõltumatuid muutujaid kui üks. Rohkem kui ühe sõltumatu muutujaga mudelite puhul kasutatakse enamjaolt suurima tõepära meetodit (Freund, William 1998).

Mudel avaldub kujul (Hosmer, Lemeshow 1989: 25; Gujarati 2003: 595-615):

$$(4) \quad P_1(X_i) = \frac{1}{1+e^{-(b_0+b_1X_{i1}+b_2X_{i2}+\dots+b_nX_{in})}}$$

kus,  $P_1(X_i)$  on krediidiriski tekkimise tõenäosus

$X_{ij}$  on sõltumatu muutuja

$b_j$  on koefitsent  
 $b_0$  on vabaliige

Logistiline regressioonanalüüs kombineerib mitmeid ettevõtte omadusi ja tunnuseid mitme muutujaga tõenäosuse mudelisse, mis näitab ettevõtte krediidiriski tõenäosust või haavatavust raskustele (Ohlson 1980; Keasey, Watson 1987). Kui suurem krediidirisk on kodeeritud 0, siis madal logit väärtus näitab kehva ettevõtte olukorda. Kui logit väärtus on suurem murdepunktist, siis klassifitseeritakse ettevõtte olukord heaks. Oluline on veel välja tuua logistilise regressioonanalüüsi puhul kaks peamist eeldust: esiteks, meetod eeldab, et sõltuv muutuja on dihhotoomne, olles diskreetne, mitte kattuv ja eristatav; teiseks tuleb arvestada optimaalse murdepunkti leidmisel tüüp I ja tüüp II vigadega (Balcaen, Ooghe 2006: 69). Lisaks tuleb veel rõhutada, et logistilise regressioonanalüüsi mudelid on väga tundlikud multikollineaarsusele (Doupou, Zopoudinis 1999). Multikollineaarsuse probleem on suur, kuna enamuse mudelites kasutatakse finantsilisi muutujaid, mis on kõrgelt korreleeruvad, kuna baseeruvad ühesugusel numeratsioonil (Tucker 1996).

Eelnenud meetodid klassifitseeritakse klassikalisteks statistilisteks meetoditeks. Järgnevalt tuuakse välja kaks tuntuimat edasiarendatud ja keerulisemat statistilist meetodit. Üks uutest tehnikatest on ekspertsüsteem, see on automaatne algoritm, mis kujutab endast inimekspertide teadmisi, tõlgendusi ja nende mõtlemisviise lahendamaks kompleksseid probleeme (Rosenberg, Gleit 1994: 601). Joonisel 1.2. (lk. 18) on toodud töötlemise süsteem, mille pakkusid välja Messier ja Hansen (1988). Ekspert süsteem koosneb kolmest peamisest komponendist: teadmiste baasfaktidest ja reeglitest; mootorist, mis kombineerib faktid ja reeglid leidmaks lõplikke järeldusi; järeldustest, mis lubab kasutajatel mõista põhjuseid otsuste taga või uuendada informatsiooni jooksvalt (Nelson, Illingworth 1990). Hand ja Henley (1997) täheldasid, et üks ekspertsüsteemi privileege on võime seletada tulemusija seetõttu saab seletada põhjuseid, kui keeldutakse krediiti andmast. Süsteemil on ka mõned miinused. Esiteks on suure valimi puhul suur koormus ja teiseks võib tekkida konflikt, kui kahel ettevõttel on sarnased omadused, aga kuuluvad eri klassidesse (Messier, Hansen 1988).

**KUI** käibevara/lühiajalised kohustused  $< 1,533$  **ja**

**KUI** tulu/põhivara kokku  $< 0,092$  **ja**

**KUI** jaotamata kasum/põhivara kokku  $< 0,064$  **ja**

**KUI** jaotamata kasum/põhivara kokku  $< -0,942$

**SIIS** ettevõtte ei ebaõnnestu

**MUIDU** ettevõtte ebaõnnestub

**MUIDU** ettevõtte ei ebaõnnestu

**MUIDU** ettevõtte ei ebaõnnestu

**MUIDU** ettevõtte ei ebaõnnestu

**Joonis 1.2.** Messieri ja Hanseni (1988) väljapakutud ekspert süsteemi töötlemise süsteem.

Teine oluline edasiarendatud tehnika on närvivõrkude meetod. Meetod töötleb informatsiooni inimaju sarnaselt. Gately (1996:147) defineeris närvivõrkude meetodit järgmiselt: kunstlik intelligentne probleemi lahendav arvutiprogramm, mis õpib läbi treenimise protsessi. Mudel koosneb sisemisest, varjatud, välimisest kihist ja nende omavahel seotud neuronitest. Neuronid ühel kihil on paigutatud tugevuse järgi ja suunatud järgmisele kihile. Need tugevused lubavad võrgustikul õppida ja talletada ühendusi (Gallant 1988). Närvivõrkude meetodi arendamisel krediidianalüütiku jaoks on vaja treeningetappi, kus antakse reaalne informatsioon laenude ebaõnnestumise ja edukuse kohta koos krediiditaotluse informatsiooniga. Seda informatsiooni kasutatakse parima tugevuste valiku saamiseks. (Rosenberg, Gleit 1994: 602)

Närvivõrkude meetodi eelis diskriminantanalüüsi ees on see, et diskriminantanalüüs eeldab muutujate normaaljaotust, ilma selleta võib mudel olla vigane (Wilson, Sharda 1991). Närvivõrkude meetod on ikka kasutatav, kui otsuste reeglid ei ole selgelt kättesaadavad ja informatsioon on osaliselt korrektne (Jensen 1992). Bishop (1995) ja Masters (1995) töid välja mõned probleemid. Üheks on mustri tundmine ja otsesidemevõrgu arhitektuuri kasutamine. Närvivõrkude meetod esitavad andmeid uuesti paremini, kui logistiline regressioonanalüüs. Diskriminantanalüüs on parema klassifitseerimise võimega, kui logistiline regressioonanalüüs, aga kehvema ennustusvõimega. Üldiselt on närvivõrkude meetodid kõige kõrgeima keskmise õigesti

klassifitseerimise määraga (*ACC rate – average correctly classified*). Oluline on siin välja tuua, et ACC määra erinevused kirjeldatud meetodite puhul on väga väikesed. (Zekic-Susac *et al* 2004; Liang 2003; Haykin 1994; Crook *et al* 2007; Abdou *et al* 2008)

Kõigil meetoditel on oma plussid ja miinused. Parima meetodi leidmine võib sõltuda rohkematest asjaoludest, kui meetodi lihtsus ja kasutusmugavus. Hand ja Henley (1997: 535-537) arutlesid, et parim meetodi valik sõltub probleemi detailidest. Näiteks andmete struktuurist, kasutatud muutujatest, muutujate klassidesse jagamise võimaluse ulatusest ja klassifitseerimise eesmärgist. Samuti toovad nad välja, et väga oluline mudelite puhul on klassifitseerimistäpsus, samuti klassifitseerimise kiirus ja mudelite lihtsus ja arusaadavus.

Eelnevas peatükis toodi välja kolm põhilist klassikalist statistilist meetodit ja kaks uuemat statistilist meetodit. Arutleti nende plusside ja miinuste üle ning võrreldi neid omavahel. Kogutud info põhjal võib järeldada, et parima meetodi leidmiseks on vaja lisainformatsiooni. Järgnevas peatükis arutletakse muutujate üle ja leitakse erinevate varasemate mudelite tulemusi ning nende täpsusi, et leida antud töö raames parim meetod.

### **1.3. Krediidiriski prognoosimise muutujad ja klassifitseerimistäpsused**

Enamus krediidiriski prognoosimise klassikalised statistilised mudelid põhinevad empiirilistel muutujate valikutel. Nad alustavad esialgse ulatusliku muutujate paketiga, mis põhineb omavolilisel otsusel, mida on mõjutanud muutujate populaarsus ja nende prognoosimisvõime varasemates uuringutes (Balcaen, Ooghe 2006: 79). Karels ja Prakash (1987) toovad välja, et teoreetiliselt on muutujate valik piiratud, mis on omakorda pärssinud paremat muutujate valiku arendust. Põhjus miks muutujate valik põhineb peamiselt statistilisel ja empiirilisel kaalutlusel on see, et puudub teooria näitamaks, millise muutujal on parim prognoosimise võime (Scott 1981). Üldine arusaam on, et hea krediidiriski hindamise mudel koosneb hoolikalt valitud muutujatest kogu finantsanalüüsi spektrumi ulatuses ja need on valitud intuiitiivselt (Dambolena, Khoury

1980). Karels ja Prakash (1987) täheldavad, et krediidiriski hindamiseks vajalike muutujate valiku osa on vaja arendada.

Kuigi empiirikal põhinev muutujate valik on kõige populaarsem, siis on sellel ka puudusi (Keasey, Watson 1991). Esiteks on oht, et muutujate valik võib olla väga valimipõhine ja empiirilised järeldused ei pruugi sobida üldistustega (Edmister 1972). Samuti võib esineda ootamatuid kordajaid, mis võivad põhjustada kõrge korrelatsiooni erinevate suhtarvude vahel (Ooghe, Balcaen 2002).

Muutujate valikus on kasutusel ka mittefinantsilised muutujad, mille osatähtsus ajas ainult suureneb, eriti krediidiriski hindamise osas. Näiteks kvalitatiivsed näitajad juhatuse, personali, toote ja varustuse kohta. Siiski kasutatakse valdavalt muutujate osas finantssuhtarve (Dimitras *et al* 1996). Kui kõrvutada krediidiriski prognoosimisel erinevates uuringutes kasutatud muutujad, siis tekib muster eristamiseks paremaid muutujaid (Balcaen, Ooghe 2006: 80). Seega leitakse järgnevalt erinevates uuringutes kasutatud kõige populaarsemad muutujad.

**Tabel 1.2.** Uuringutes enimkasutatud muutujad

<b>Muutujad</b>	<b>Esinemissagedus uuringutes</b>
Puhaskasum / varad kokku	54
Käibevara / lühiajalised kohustused	51
(Käibevara – lühiajalised kohustused) / varad kokku	45
Jaotamata kasum / varad kokku	42
Tegevuskasum / varad kokku	35
Äritulud / varad kokku	32
Raha / lühiajalised kohustused	30
Kohustused kokku / varad kokku	27
Käibevara / varad kokku	26
Neto tulu / omakapital	23

Allikas: (Bellovary *et al* 2007: 42); autori kohandatud.

Bellovary *et al* (2007) analüüsisid 165 enimtuntud pankroti prognoosimise kohta avaldatud uuringut aastast 1965 tänapäevani. Nagu eelnevalt arutletud, siis on need antud töö raames võrreldavad krediidiriski hindamisega. Kasutatakse ühesuguseid mudeleid ja muutujaid. Tabelis 1.2. on välja toodud vähendatud kokkuvõtte selle analüüsi ühest tulemusest. Bellovary *et al* (2007) leidsid sellest valimist muutujatena enimkasutatud finantssuhtarvud. Kogu uuringus varieerus muutujate arv uuringu kohta ühest viiekümne

seitsmeni. Nagu tabel 1.2.-st (lk. 20) näha, siis kõige sagedamini kasutati muutujat puhaskasum jagatud varad kokku, mis esines lausa 54-s uuringus. Antud finantssuhtarvude populaarsust kinnitab ka asjaolu, et Dimitras *et al* (1996) koondab oma analüüsis 47 tööstusettevõtte kohta tehtud uuringu, millest järeldeb, et enimkasutatud suhtarvude paremik kattub Bellovary *et al* (2007) uuringuga. Tabelis 1.3 on näha, et kõik välja toodud finantssuhtarvud on esindatud tabelis 1.2. (lk. 20), ainult erinevas järjekorras. See ei olegi väga oluline, kuna sõltub palju meetoditest ja nende kasutamisspetsiifikast. Seega, Bellovary *et al* (2007) poolt koostatud tabelis kasutatud muutujaid võib lugeda olulisteks finantssuhtarvudeks krediidiriski prognoosimisel.

**Tabel 1.3.** Tööstusettevõtete uuringus enimkasutatud muutujad

<b>Muutujad</b>	<b>Esinemissagedus uuringutes</b>
(Käibevara – lühiajalised kohustused) / varad kokku	16
Kohustused kokku / varad kokku	15
Käibevara / lühiajalised kohustused	12
Jaotamata kasum / kogu vara	12
Puhaskasum / varad kokku	12

Allikas: (Dimitras *et al* 1996: 492); autori koostatud.

Oluline on siinkohal välja tuua, et tabelis 1.2. (lk. 20) ja 1.3. toodud muutujad on küll kõige sagedamini esinenud finantssuhtarvud, aga populaarsuse järjekord ei näita ühes uuringus kasutatud muutujaid. Erinevaid finantssuhtarve on kasutatud erinevates mudelites leitud parimale kooslusele. Antud järjestust ei saa kasutada juba seetõttu, et mõned muutujad on omavahel tugevas korrelatsioonis.

Abdou ja Pointon (2011: 67) usuvad, et ei ole olemas optimaalset muutujate arvu, vaid toovad välja, et muutujate valik ja arv sõltub andmete iseloomust, kultuurilistest ja majanduslikest mõjuritest muutujatele ning seetõttu peab mudel olema vastavalt turule koostatud. Dimitras *et al* (1996: 489) toovad välja, et rolli võib mängida ka riigispetsiifiline või ka ülemaailmne majandusolukord, mis võib muuta hea mudeli ebatäpseks, näiteks majanduskriiside aegadel. Samuti leiavad Bellovary *et al* (2007) oma uurimuses, et muutujate arv omab vähe mõju prognoosivõimele. Seega, suurem number muutujaid ei taga paremat hinnangut. Pigem on olemas selged tõendid, et suurimate klassifitseerimistäpsustega mudelid on suhteliselt lihtsad mudelid väheste muutujatega.

Sisuliselt kehtib 80/20 printsiip – väiksema arvuga muutujatega saavutatakse suurema täpsusega mudel (Balcaen, Ooghe 2006: 81). Muutujate arv ei tohi olla liiga suur juba seetõttu, et andmete kogumine võib osutuda liiga keeruliseks.

Hamer (1983) kirjeldab põhimõtet, kuidas peaks muutujate valik tehtud olema:

- 1) minimeerides andmete kogumise kulu;
- 2) maksimeerides mudeli rakendusvõimet.

Mudelite täpsuse koha pealt on oluline kaaluda, kui kaugemale ette on mudel võimeline prognoosima. Paljud mudelid ennustavad riski üks aasta ette. Mõned mudelid suudavad prognoosida 2, 3 ja rohkem aastat ette. Näiteks El Hennawy ja Morris (1983) mudel suutis 100% täpsusega ennustada riski viis aastat ette. Mida rohkem suudab mudel ette ennustada, seda väärtuslikum mudel on (Bellovary *et al* 2007: 10).

Kuna eelneva käsitlemise kohaselt on leitud krediidiriski hindamise mudeli loomisel olulise asjaoluna eelnevates uuringutes kasutatud muutujad ning antud kooslusest saadud klassifitseerimistäpsus, siis järgnevalt on autori poolt koostatud tabel 1.4. (lk. 23), kus on kasutatud erinevate analüüside poolt kogutud informatsiooni, millest on tehtud valik tuntumatest uuringutest. Tabel 1.4. (lk. 23) on koostatud selleks, et tekiks parem arusaam erinevatest meetoditest, täpsustest ja nendes kasutatud muutujatest. Tabel 1.4. (lk. 23) lugemiseks on abiks lisas 1 toodud muutujate lühendite seletused. Samuti tuleb arvestada, et tabelis toodud kasutatud finantssuhtarvud ei ole alati 100% täpsusega, st et mõnes uuringus ei olnud võimalik kõiki finantssuhtarve leida ja mõnes kasutati küll rohkem finantssuhtarve, aga tulemusest lähtuvalt peeti oluliseks neist näiteks ainult kolme. Samuti, mõnes töös kasutati ka mittefinantssuhtarvulisi muutujaid lisaks. Antud töö kontekstis ei ole see oluline, kuna tabeli eesmärk on informatiivne, tekitamaks üldist arusaama finantssuhtarvudes, kasutatud meetoditest ja nende tulemustest.

**Tabel 1.4.** Ülevaade varasematest uuringutest

Uuring	Meetod/ Muutujate arv	Klassifitseerimis-täpsus	Kasutatud finantssuhtarvud
Beaver (1966)	Diskriminantanalüüs/ 30	50% - 92%	TD/TA, NI/TA, CF/TD
Altman (1968)	Diskriminantanalüüs/ 5	79 %	WC/TA, EBIT/TA, RE/TA, S/TA, MVE/TD
Dambolena ja Khoury (1980)	Lineaar tõenäosusmudel/ 21	Ebaõnnestunud – 66% – 91%; Mitte ebaõnnestunud – 75% - 100%	TD/TA, NI/TA, FA/NW, NI/S
Ohlson (1980)	Logistiline regressioonanalüüs/ 9	1 aasta enne – 96%, 2 aastat enne – 96%	WC/TA, NI/TA, CA/CL, TD/TA, TA/GNP, CL/TD, FA/TA
Zavgren (1985)	Logistiline regressioonanalüüs/ 7	1 – 69%, 2 – 69%, 3 – 69%, 4 – 69%, 5 – 69%	TD/TA, NI/TA, QA/CL, raha/TA, Inv./S, R/Inv.
Karels ja Prakash (1987)	Diskriminantanalüüs/ 5	Pankrotistunud – 54,5%; Ei pankrotistunud – 96%	-
Messier ja Hansen (1988)	Ekspert süsteem/ 3	100%	CA/CL, NI/TA, RE/TA
Laitinen (1991)	Diskriminantanalüüs/ 6	Pankrotistunud – 1 - 90%, 2 - 72,5%, 4 - 57,5%, 6 - 65%; Ei pankrotistunud – 1 - 87,5%, 2 - 65%, 4 - 52,5%, 6 - 60%	TD/TA, CA/CL, NI/TA, CF/S, S/TA
Theodossiou (1991)	Logistiline regressioonanalüüs/ 8  Lineaar tõenäosusmudel/ 8	Pankrotistunud – 95,5%; Ei pankrotistunud – 92,6% Pankrotistunud – 96,4%; Ei pankrotistunud – 77,8%	WC/TA, TD/TA, NI/TA, RE/TA, LTD/TA
Guan (1993)	Närvivõrkude meetod/ 5	0 1 2 3 4 Pankrotistunud – 0 - 83%, 1 - 96%, 2 - 100%, 3 - 100%, 4 - 100% Ei pankrotistunud – 0 - 97%, 1 - 70%, 2 - 83%, 3 - 87%, 4 - 93%	-

Allikad: (Bellovary *et al* 2007; Dimitras *et al* 1996); autori koostatud.

Tabelis 1.4. (lk. 23) on läbiv kokkuvõte uuringutest aastatel 1966 kuni 1993. Meetoditena on esindatud kõik antud töös kirjeldatud meetodid. Nagu eelnevates peatükkides arutletud, siis levinuim kasutatud meetod on diskriminantanalüüs, millele järgneb logistiline regressioonanalüüs. Valdavalt jääb muutujate arv 5 – 9 vahele, kuna eelneva arutelu käigus selgus, et liiga suur muutujate arv ei pruugi mudeli täpsusele kasuks tulla. Beaveri (1966: 106 - 108) moodustas 30 kasutatud muutujast grupid, kus oli korraga kasutatud 3 kuni 5 finantssuhtarvu. Uuringute klassifitseerimistäpsused jäävad vahemikku 50% kuni 100%. Tulemustena tuleb esile tuua Messieri ja Hanseni (1988) kasutatud ekspertsüsteem, mis sai täpsuseks 100%. Samuti tuleb välja tuua asjaolu, et kasutati ainult kolme muutujat, mis on ka esindatud tabelis 1.2. (lk. 20). Oluliseks tuleb pidada uuringuid, mis suudavad rohkem kui aasta ette ennustada. Siinkohal jääb silma Guani (1993) närvivõrkude meetodil leitud mudel, mis prognoosib 2, 3 ja 4 aastat ette 100% ettevõtte pankrotistumise. Logistilise regressioonanalüüsi parimaks tulemuseks sai Ohlson (1980), leides aasta ette täpsusega 96% ja kaks aastat ette täpsusega samuti 96%.

Üldiselt ei saa ühtegi meetodit eraldi esile tuua ning hea klassifitseerimistäpsus on võimalik saavutada kõigi kirjeldatud meetoditega. Nagu Hand ja Henley (1997: 535) leidsid, ei ole parimat meetodit vaid see sõltub paljudest detailidest. Oluliseks tuleb lugeda ka meetodi valikul selle lihtsust ja kasutusmugavust. Samuti võrreldes tabelite 1.2. (lk. 20) ja 1.3. (lk. 21), kerkib esile asjaolu, et kaks enimkasutatud finantssuhtarvu on puhaskasum jagatud varad kokku ja kohustused kokku jagatud varad kokku. See näitab lisaks nende kahe finantssuhtarvu populaarsusest, mis omakorda viitab nende olulisusele mudelites.

Kuna eelnevast järeldub, et ei ole ühte ja parimat meetodit krediidiriski prognoosimiseks ja oluliseks komponendiks on ikkagi erinevad muutujad ja nende kasutamine, siis peab autor modelleerimisel oluliseks ka mudelite koostamise praktilist poolt ja levinud tavaid ning kasutab empiirilise osa analüüsi läbiviimiseks logistilist regressioonanalüüsi. Samuti on kavas võimalusel kasutada eelnevalt välja toodud enimlevinud finantssuhtarve, et leida AS Tartu Terminali põhjal klientide ajutise maksehäire tekkimise tõenäosust.

## **2. KREDIIDIRISKI PROGNOOSIMISE MUDELI KOOSTAMINE**

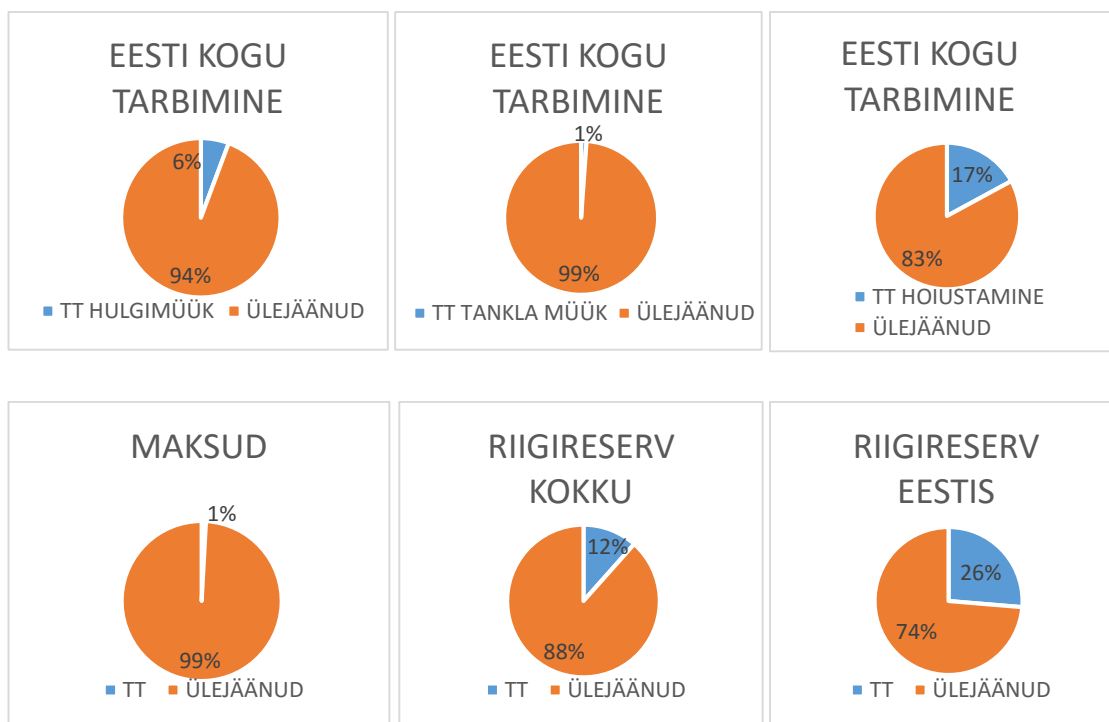
### **2.1. Ettevõtte tutvustus ja senine krediteerimise poliitika**

Käesoleva bakalaureusetöö mudelite koostamise aluseks on AS Tartu Terminali (edaspidi – TT) andmebaas. Ettevõtte on asutatud 1994. a. ja tegutseb peamiselt Kärkna kütuseterminalis, mis asub Tartu linna läheduses, Tartu vallas. Kütuseterminal rajati algselt 1968. a. tollaegse ettevõtte Eesti Kütus poolt. Ettevõtte esialgne nimi oli Kärkna Naftabaas. Eesti Kütus oli riiklik ettevõtte, kuhu kuulusid ka Tallinna, Pärnu, Narva, Rakvere, Valga, Võru, Viljandi, Kuressaare, Haapsalu ja Kärkna terminalid. Eesti Kütusest parema ülevaate saamiseks on oluline välja tuua, et ENSV kütusepoliitika oli ainult ühe suunaline. Nõukogude Liidu erinevatest naftatehastest, peamiselt Kirishist, toodi erinevaid liiki kütuseid Eestisse, tarbimiseks. See tähendab, et jaotati terminalide vahel ära, mis tagas „plaanide“ täitmise eesmärgi. Eestis puudusid mereterminalid, st. et tänapäevane transiidi mõiste täielikult puudus. Samamoodi puudus ka konkurents. Eesti Vabariigi taasiseseisvusega loodi riiklik ettevõtte ESOIL AS, mis asutas ka 1994. a. ühe tütarettevõttena AS Tartu Terminaali. Hiljem erastati AS ESOIL USA ettevõtte Houstoni Coastal Corporationi poolt. 1996 a. müüdi tütarettevõtte AS Tartu Terminaal tagasi Eesti kapitalile. Täna on ettevõtte 100% Eesti kapitali omanduses.

AS Tartu Terminali põhitegevuseks on mootorikütuste ladustamine, jae- ja hulgimüük. Seega ettevõtte siseselt on olemas kolm suuremat osakonda. Laoosakond tegeleb peamiselt Lõuna – Eesti jaoks mõeldud kütuste ladustamisega ja vastuvõtu - väljastamisega. See tähendab erinevate ettevõtete toodud vedelkütuste (ka TT enda) vagunitest mahutitesse pumpamist, mahutites hoiustamist, kvaliteedikontrolli, riiklike maksude kogumist ja kütuseautodesse väljastamist. Hulgimüügiosakond tegeleb aastast

1997. Peamine klientuur on olnud Lõuna – Eesti põllumehed ja transpordiettevõtted, lisaks erinevad väiksemad tanklaketid ja kütjad. TT-le endale kuulub autopark 4 masinaga ja 2 järel haagisega. Alates aastast 2014 on TT enda hulgimüüki üle-eestiliseks kasvatanud, mille tagab koostöö Põhja – Eesti terminalidega. Jaemüügis oli pikka aega TT ainus müügikoht 1991. a. asutatud Kärkna tankla. Alates 2012. a. on TT hakanud erinevate turuolukordade tõttu järjest rohkem investeerima tanklaketi arendusse. Praeguseks hetkeks on TT süsteemis kokku 5 tanklat ja kuues on hetkel projekteerimises. Seega loob TT Eestis unikaalse süsteemi, kus mootorikütus liigub maale toomisest kuni lõpptarbijani ühe ettevõtte sees. Antud süsteem tagab ka ainulaadse kvaliteedikontrolli, mis tähendab, et kvaliteet on algusest peale jälgitav ning ei ole vaheahelaid, kus ei suudeta kvaliteeti tagada. Samuti loob antud süsteem tänu mastaabisäästule tihtipeale ka hinnaeelise.

TT kütuseterminal asub 15,6 hektarilisel territooriumil mahutipargiga  $53\,000\ m^3$ , ca 30 aktiivselt kasutuses oleva mahutiga. Raudteeestakaad võimaldab ca 2 – 3 tunniga maha laadida 10 vagunit, kogusega 600 tonni kütuseid. Autoestakaadil saab korraga kütuseid peale laadida 3 autot, ühe auto laadimiskiirus on 28 minutit kuni 1 tund, mis sõltub produktide koosseisust. See teeb ca 100 000 kuni 200 000 liitrit tunnis. Nagu eelpool kirjeldatud, siis ettevõtte opereerib 4 auto ja kahe järelkäruga, mille kogumaht on 131000 l. Samuti on ettevõttel kasutada 3 diislipunkti, mille kaudu toimub kütuse jaotus suurematele klientidele. TT opereerib hetkel 5 teenindusjaamaga, mille 2016 a. märtsikuu kütusemüügi maht oli 1,1 miljonit liitrit. 2015. a. kogu TT müügimaht oli 55 miljonit liitrit erinevaid kütuseid ning läbi TT lao liikus kokku ca 150 000 tonni erinevaidprodukte. 2015. a. tasus TT makse kokku ca 60 miljonit eurot. Lisaks hoiustab TT Eesti riigi kütusevaru 28 300 tonni.



**Joonis 2.1.** AS Tartu Terminali osalus Eesti turul võrreldes erinevate näitajatega (allikad: TT 2015 aastaaruanne; TT andmebaas; Statistikaameti andmebaas; Maksu ja Tolliamet; AS Eesti vedelkütusevaru agentuur; autori koostatud).

Joonisel 2.1. on AS Tartu Terminali osalust võrreldud Eesti riigi statistikaga, siis olenevalt näitajast on osakaalud erinevad. Kogu Eesti sisemaine tarbimine diislikütuse ja autobensiini lõikes oli 2015. a. 878 000 tonni, mis teeb TT osaks kogu kauba käitlemises läbi ladustamise ca 17 %. Hulgimüügi osa on vastava näitaja järgi ca 6% ja jaemüük moodustab ca 1%. Eesti riik kogus makse 2015 a. ca 7 miljardit eurot, millest TT osa on peaaegu 1%. Kuna TT hoiustab Eesti vedelkütusevaru agentuuri poolt hoiule antud kütuseid, siis on TT Eesti riigi jaoks strateegiliselt oluline partner. Kärknas hoitav maht moodustab kogu Eesti riigireservist ca 12%, samas Eesti territooriumil hoitavast reservist moodustab see 26%. TT on olnud Eesti Õliühingu, mis koondab endas suurimaid kütuse ettevõtjaid Eestis, liige juba 23 aastat, selle loomisest alates.

AS Tartu Terminal sõnastab oma missiooni järgmiselt: „Tuua Eesti kliendini kütus võimalikult mugavalt, lihtsalt, kvaliteetselt ja soodsalt. Anda Eesti kütuseturule omapoolne panus. Riigireservi kvaliteetne ja pikaajaline hoiustamine. Olla Eesti riigi jaoks oluline ettevõtte“. Siit tulenevalt, laienedes üha rohkem jaemüügiturule, on TT

mõtestanud lahti oma jaemüügituru kontseptsiooni ning nimetab oma jaamu „teenindusjaamadeks“. Selle mõte on, et klient saaks võimalikult kiiresti, mugavalt, soodsalt head ja kvaliteetset kaupa ning teenust tarbida. Seega, teenindusjaamad on nagu minikeskused, mis jäävad inimeste tegemiste ristumispunktidesse. Vaadeldes TT-d teenindusjaamade poolt, siis pole tegemist kütuseettevõttega, vaid teeninduskeskuste ketiga, mille üks nomenklatuur on mootorikütus.

Kuna teenindusjaamade võrgustik on väga kiiresti laienenud ja eelnevalt kirjeldatud kontseptsioon toimib väga edukalt, siis on viimase kolme – nelja aasta jooksul TT klientide arv kordades suurenenud. 2012. aastal oli see ca 1000, kui arvestada kõiki ladustamise, hulgimüügi ja Kärkna tankla kliente. 2015. a. lõpuks oli kliendibaas kasvanud ca 10 000 kliendini. Seetõttu on antud teema aktuaalne AS Tartu Terminali jaoks, kuna senine krediteerimise poliitika on olnud just nagu Abdou ja Pointon (2011: 60-61) sõnastavad subjektiivne süsteem (*Judgemental System*). Sullivan (1981) ja Bailey (2004) iseloomustavad seda süsteemi järgnevalt: krediidihindamise süsteem, kus igat krediidisoovi ja selle kohta käivat informatsiooni töötleb eraldi üks isik/analüütik ehk krediteerija. Subjektiivse süsteemi hindamise edu sõltub analüütiku kogemustest ja võimest õigesti kliente hinnata. Sarnane süsteem on seni olnud ka TT-s. Järgnevalt kirjeldataksegi, kuidas toimub klientide krediteerimine AS Tartu Terminalis.

TT kliendid selekteeritakse gruppide alusel: juhuslik klient (isik, kes ei ole TT andmebaasis), deebetmüügiklient ja krediidimüügiklient. Krediidimüügikliendid jagunevad omakorda gruppidesse vastavalt hinnaklassile, mis sõltub ostetavast igakuisest kogusest ja kliendi strateegilisest tähtsusest. Lisaks saab TT klient olla veel ka hulgimüügis, kus selekteeritakse vastavalt ettemaksuklient ja krediidimüügiklient. Samamoodi on kliendid ka hoiustamise poolel, kus toimub samamoodi krediteering ehk TT annab arvele maksetähtaja. Erinevalt kliendi tüübist ja grupist saavad kliendid maksetähtaegu süsteemis 7, 14, 21 ja 30 päeva ning on üksikuid erandeid lisa kokkulepetega. Teenindusjaamade arenguga on klientide soovil tekkinud ka lisaks iga kuu kindla kuupäevaga maksetähtaeg.

Kliendid, kes soovivad arvele maksetähtaega ehk siis krediiti saada, täidavad kõigepealt TT kaubakrediidi taotluse blanketi, mis on illustreeritud lisas 2. Antud taotluses kogutakse andmeid kliendi kohta, järgides põhimõtet, et võimalikult väikese kliendi

vaevaga koguda võimalikult palju informatsiooni. Blanketi esimeses osas on tavalised informatiivset laadi küsimused: ettevõtte nimi, ettevõtte juhi nimi, registrikood, käibemaksukohuslase number, juriidiline aadress, posti aadress, telefon, e-mail, arveldusarve number, raamatupidaja nimi, faks, kodulehekülg, pank ja raamatupidaja telefon. Ettevõtte juhi nimi iseloomustab ettevõtet kõige paremini. Kui on teada isik ja tema põhimõtted ja käitumismaneerid, siis selline on ka ettevõtte. Raamatupidaja nimi on küsitud, kuna see võib viidata mõnele teisele ettevõttele või ettevõtete grupile. Näiteks võib olla olukord, kus uuel ettevõttel on sama raamatupidaja mõne probleemse ettevõttega, sellisel juhul on võimalus, et ettevõtte omanikud on samad või omavahel seotud. Samas on see ka lihtsalt informatiivne küsimus, kuna raamatupidaja käest ettevõtte kohta informatsiooni koguda on kõige lihtsam ja kiireim viis.

Teises sektsioonis on küsimusteks ettevõtte põhitegevusala, käive, omakapital, vanus, hinnanguline ostumaht kütuste lõikes ning volitatud isikute nimed ja telefoninumbrid. Siinkohal tuleb teistest eristada kahte olulist küsimust, milleks esimene on ettevõtte vanus. Kui number on keskmisest suurem, siis on tegemist traditsiooniliselt tegutseva ettevõttega ning tõenäoline pettuserisk on maandatud. Sellisel juhul jäävad muud äritegevuse ohukohad vaatluse alla. Teiseks tuleb vaadelda krediidisoovi ja enda hinnangut kütuste planeeritava ostumahu kohta. See küsimus lõikub järgmise sektsiooni küsimusega, selle kohta kui suur on krediidisoov. Antud numbrid peavad ligikaudselt ühtima, kui korrutada kogused hinnaga. Kui hinnavahe on liiga suur, tihtipeale krediidisoovi kasuks, siis tuleb antud ettevõtte kohta informatsiooni hoolsamalt vaadelda.

Kolmandas - neljandas sektsioonis on küsitud krediidisoov, taotletav maksetähtaeg, krediitkaardi tüüp, taotleja nimi ja amet, kuupäev, allkiri ja samamoodi ettevõttepoolne otsus ja allkirjad – kuupäevad. Kaardi tüüp on küsitud, kuna TT teenindusjaamadest on tehniline võimalus osta ka kõiki muid kaupu krediiti.

Seejärel analüütik, kelle funktsioon TT-s on jagatud, kogub järgnevalt kirjeldatud lisaandmeid ja hakkab saadud informatsiooni töötleva. Teenindusjaamade krediidiotsused teeb kütuste jaemüügijuht, hulgimüügi otsused teeb müügiosakonna juhataja. Hoiustamise poolel ei ole klientuur väga suur ning kliendid on tihtipeale väga traditsioonilised ja kindlad ettevõtted, nende krediidiotsused teeb juhatus. Lisaks taotlusele võetakse eelmise majandusaastaaruanne portaalist taust.ee või

krediidiinfo.ee. Sama moodi jälgitakse maksehäireid ning vajadusel tellitakse maksehäireraport. Kui otsus on keeruline, siis nn. „googeldatakse“ ettevõtet ja seotud isikuid. Antud meetod omab oskuslikul kasutamisel väga suurt tähtsust, tänu ettevõtete ja isikute suurele osalusele sotsiaalkeskkonnas. Seejärel, peale analüütilise töö tegemist ja sellest välja kujunenud soovitusel juhataja liikmele teatavaks tegemist, teeb blanketi viimases seksioonis TT juhataja liige otsuse: kes, kui palju, kui pikalt saab krediiti. Vajadusel lisatakse müügilepingule (lisa 3) ka käendusleping, mis on toodud lisa 4.

Krediidimüügipoliitikat teostab TT suures osas oma vahenditega. Lisaks kasutab ta ka pankade poolseid erinevaid tooteid, mille kasuks räägib hetke maailmamajanduse olukord, kus finantsvahendid on väga odavad. Suuremate ja kindlamate klientidega on tehtud faktooringkokkulepped. Samamoodi on koostöös Swedbankiga välja töötatud spetsiaalselt TT vajadusi silmas pidades toode nn. sisseostufaktooring, mida kasutatakse vajadusel krediteerimaks kütuste maaletoomist. Lisaks kasutab TT põllumajandussektoris teatud klientide puhul ka kindlustusega faktooringut. Viimase tootena on TT-l ka arvelduskrediit, mis on ettevõttes kasutusel kui stabilisatsiooni mehhanism.

Nagu eelnevalt kirjeldatud, on TT krediidiriski hindamise subjektiivne süsteem koos kliendibaasi suure kasvuga saanud kitsaskohaks krediidimüügipoliitikas. Selleks on oluline leida krediidiriski hindamise mudel, mis suudaks toime tulla ka suurema arvu klientidega. Samas on oluline, et senise süsteemi kogemuslik kvaliteet oleks ka mudeli puhul olemas, see tähendab, et see hindaks võimalikult täpselt. Järgnevas peatükis tuuakse välja krediidiriski modelleerimiseks kasutatavad andmed ja muutujad.

## **2.2. Töös kasutatavad andmed ja muutujad**

Käesolevas peatükis koostatakse ülevaade hindamiseks vajalikest andmetest, koostatud valimist, valitud muutujatest ning tutvustatakse kuidas need saadi ja samuti teostatakse analüüs. Töös kasutatakse kahte võrdlevat uurimust, millest üks baseerub eelnevates peatükkides kirjeldatud finantssuhtarvudele ja teine varasemale maksekäitumisele. Kuna antud töös kasutatakse logistilist regressioonanalüüsi, siis selleks oli vaja koostada kõigepealt valim, mis koosneb kahest osast. Nagu teooria osas kirjeldatud, siis

moodustatakse kaks gruppi, kus ühes on kohustusi korrektselt täitvad kliendid ja teises kes seda ei tee. Eesmärk oli leida situatsioonile ehk antud töö kontekstis esitatud arvele eelneva aasta andmed, mille alusel leida võimalus ette ennustada, millisesse gruppi ettevõtte aasta pärast kuulub. Andmed saadi Äriregistri andmebaasist, millest oli koostatud majandusaastaruannete finantsandmete põhjal tabel perioodil 2011 kuni 2013 aasta.

Antud töö jaoks koostati valim AS Tartu Terminali kliendibaasi põhjal. Selleks kasutati TT-s kasutusel olevat raamatupidamisprogrammi NOOM. Kuna andmeid ei olnud võimalik vajalikul kujul automaatselt võtta, siis koostati programmile lisaliides, millega oli võimalik teha väljavõtte. Seega, kuna kliendid tuli jagada heaks krediteeringuks ja halvaks, siis loodi esimeseks grupiks „makstud õigeaegselt“. Sinna kuulusid ettevõtted, kellel ettenähtud perioodil ei olnud mitte ühtegi üle maksetähtaja olnud arvet. Siia alla kuulusid ka kliendid, kes maksid enne tähtaega. Teiseks grupiks loodi ettevõtted, kes liigitati kui „maksetähtaeg ületatud rohkem kui 30 päeva“. Gestel ja Baesens (2009: 25) toovad välja, et panganduses on tõekspidamine lugeda ettevõtte probleemseks, kui maksetähtaeg on ületatud rohkem, kui kolm kuud. Kuna TT puhul on tegemist suures osas hulgikaubandusega tegeleva ettevõttega, siis on ettevõtte sisekorra järgi valitud probleemseteks klientideks need, kes ei suuda hiljemalt 30 päeva peale maksetähtaega arveid tasuda.

Mõlemas grupis moodustati ettevõtete nimekiri, kelle kohta olid välja toodud järgmised andmed: registrikood, nimi, arve kuupäev, arve number, maksetähtaeg, millal tagasi makstud, ületatud päevi ja võlgnevus. Kogu valim moodustati perioodil 01.01.2012 kuni 31.12.2014. Selline periood valiti, kuna oluline oli välja jätta majanduskriisiperiood, mis võib tulemusi mõjutada ja 2015. a. andmeid ei ole seetõttu, et töö koostamine algas juba 2015 aasta. Seejärel tekitati valimist üks grupp, mis eristati üksteisest lahtriga, kus ettevõtte taga oli märke 1 või 0. Üks tähendas head ettevõtet ja null kehva maksekäitumisega ettevõtet.

Esialgne valimi suurus oli kokku 2453. Mõlemad grupid olid võrdses suuruses. Kuna TT kliendibaas ei ole statistilise töötluse jaoks mõeldud, siis tuli saadud ettevõtete nimekiri üle kontrollida. Esiteks eemaldati valimist FIE-d, kelle kohta andmebaasis puudus info. Samamoodi eemaldati eraisikud, keda oli üllatavalt palju õigeaegselt maksjate hulgas. Nende nimede hulgas oli isikuid, kelle ettevõtte oli samuti klient ja oli

isikuid, keda üldsuse mõistes liigitatakse „prominentideks“. Usutavasti oli nende isikute lisamine kliendibaasi tulnud üheltpoolt tuntuusest ja teisalt heade kliendisuhete tõttu. Igal juhul oli tegu ennast õigustanud, kuna nende isikute arv õigeaegselt maksjate hulgas oli päris suur. Lisaks eemaldati õigeaegselt maksnud klientide hulgast ka ettemaksukliendid, kuna enamjaolt on sellised kliendid kas probleemsed või ei suuda oma usaldusväärset kuidagi tõestada. Selline grupp kliente on tekkinud TT andmebaasi, kuna nende krediitväärilisus ei ole saanud heakskiitu ning TT-l huvi müüa ja kliendil osta on endiselt olemas.

Järgnevalt võrreldi andmebaasist saadud andmeid valimiga ning kuna kõigi ettevõtete kohta ei olnud andmed 100% korrektsusega, siis eemaldati valimist ettevõtteid, kelle kohta ei saadud vajalikku informatsiooni. TT andmebaasis esines ka lihtsamaid vigu, nagu ettevõtte nime valesti kirjutamine. Samuti oli vahel kirjutatud ettevõtte nime asemel mõni osakond, kes sellest ettevõttest kütust tarnis. Põhimõtteliselt oli tegemist vigadega, mille tõttu ei sobinud andmed Äriregistri andmebaasiga. Kuna valimi töötlus oli väga suuremahuline, siis jäi lõpuks järgi 317 ettevõtet, neist 251 halba ja 106 hea klassifikatsiooniga ettevõtet. Saadud valimi suurus ei ole kõige parem, kuna Kryzhanovskiy (2016: 38) koostas oma magistritöös kokkuvõtva tabeli erinevatest uuringutest, millest saab järeldada, et keskmine valimi suurus jääb vahemikku 2000 kuni 4000. Samast tabelist nähtub, et Angelis *et al* (2008) saavutasid valimiga suurusel 350 logistilist regressioonanalüüsi kasutades klassifitseerimistäpsuseks 71,87%. Sellest võib järeldada, et saadud valimi suurusega on võimalik saada küllaltki täpseid tulemusi. Lõplik valim oli 357. Kuna käesoleva töö jaoks vajalikud andmed koguti arvete järgi, st kui ettevõtteil oli antud perioodil rohkem arveid, siis ta võis valimis korduda. Siinkohal on oluline välja tuua, et lõplik valim ei olnud koostatud mitte ettevõtetest vaid vaatlustest, mis valimis tähendasid arveid. Samuti on oluline toonitada, et kõik vaatlused olid unikaalsed, kuna iga ettevõtte sai korduda maksimaalselt kuni kolm korda – kord iga aasta kohta, mis tähendas, et iga kord olid erinevad muutujad, vastavalt arve koostamise kuupäevale eelneva aasta aastaaruandest saadud andmetega. Antud töös oli periood kolm aastat – 2012 algus kuni 2014 aasta lõpp.

Käesolevas töös valiti logistilise regressioonanalüüsi mudeli leidmiseks muutujateks finantsuhtarvulised muutujad, mis on välja toodud tabelis 2.1. (lk. 33). Peamiseks

kriteeriumiks on seatud nende varasem kasutamine uurimustes. Nagu töö teoreetilises osas leiti kõige populaarsemad kasutatud finantssuhtarvud, siis autori arvates on mõistlik järgida eelnevat hästi õnnestunud praktikat. Nagu Balcaen ja Ooghe (2006: 81) leidsid, et parimad mudelid on tihtipeale koostatud suhteliselt väikesearvulise muutujatega, siis antud töös ei olnud samuti plaanis kasutada palju muutujaid. Eesmärgiks oli järgida põhimõtet, et võimalikult väikesearvulise muutujatega saavutada võimalikult täpne tulemus ehk 80/20 printsiipi.

**Tabel 2.1.** Töös kasutatud finantssuhtarvud

<b>Muutujad</b>
Puhaskasum/varad kokku
Käibevara/lühiajalised kohustused
(Käibevara-lühiajalised kohustused)/varad kokku
Omakapital kokku/varad kokku
Äritulud/varad kokku
Raha/lühiajalised kohustused
Puhaskasum/äritulud

Allikas: autori koostatud.

Valitud muutujatest kuus on Bellovary *et al* (2007: 42) põhjal koostatud uurimustes enimesinenud muutujatest olemas. Antud nimekirja vaadeldi kokku sobivuse kohalt kriitiliselt ning eemaldati tugeva korrelatsiooniohuga muutujad. Seega kokku saadi seitse muutujat, mida käesoleva töö empiirilise poole kolmandas osas kasutama hakatakse.

Kuna juhendajaga koostöös leiti, et väga hea probleemsete ettevõtete näitaja võiks olla eelnev maksekäitumine, siis antud töös koostatakse üks mudel veel. Selle eesmärk on kinnitada või lükata ümber antud tundmused ja võrrelda saadud tulemusi traditsiooniliste finantssuhtarvude tulemusega. Selleks kasutatakse portaalist Taust.ee – st saadud andmebaasi ettevõtete maksuvõlgnevuste kohta, mis põhineb avalikul maksuameti infomatsioonil. See andmestik on ainulaadne ja ainus võimalik korrektne variant andmete saamiseks. Üheltpoolt ei ole võimalik paremat andmebaasi kasutada, kuna ettevõtete kohta puudub ühtne maksehäire andmestik. Maailmas ei ole ühtset andmebaasi, mis koguks infot ettevõtete maksekäitumise kohta. Selle tingib asjaolu, et klientide andmed ja nende kohta käiv informatsioon ei ole avalik, mis muudab maksuameti poolt andmebaasiks kokku kogutud avaliku informatsiooni maksutasumise kohta maailmas ainulaadseks. Teadaolevalt ei ole teist sellist avalikult saadavat informatsiooniallikat.

Ülesande püstitamise saadi valimi suuruseks 926. 317 head ja 607 halba vaatlust. Nagu eelnevalt oli kirjeldatud, siis antud töö raames käsitletakse valimit vaatluste arvuna, mis tähendab esitatud arveid. Maksuvõlgnevuste informatsiooni vaadeldi eelneva aasta andmeid alates arve kuupäevast ja kuna andmebaasis oli informatsioon esitatud kuude lõikes, siis sammuks oli üks kuu ning vaadeldi eelnevat 12 kuud. Seetõttu on ka valim palju suurem. Jällegi, kõik vaatlused olid ainulaadsed. Andmestik ise oli leitud TT andmebaasist saadud ettevõtete kohta tehtud päringust, kus kuvati ettevõtted, kelle kohta oli maksuameti poolt tulnud märge. Andmebaas koosnes registrinumbrist, ettevõtte nimest ja alates 2011 aasta lõpust kuni 2015 aasta juuli kuuni oli iga kuu lõpu seisuga kuvatud võlgnevus maksuameti ees.

**Tabel 2.2.** Varasemale maksekäitumisele põhinevad muutujad

<b>Muutujad</b>
Kõige suurem maksuvõlg eelneva aasta jooksul
Keskmine maksuvõlg eelneva aasta jooksul
Mediaan eelneva aasta maksuvõla kohta
Maksuvõlaga kuude arv eelneva aasta jooksul
Maksuvõlaga alates 100€ kuude arv eelneva aasta jooksul

Allikas: autori koostatud.

Modelleerimise jaoks leiti viis muutujat, mis on esitatud tabelis 2.2. Muutujad valiti intuiitselt, arutledes võimalike variantide üle, kuna puudub arvestatav teooria maksuvõlgnevuse kohta. Tabeli kaks viimast muutujat on valitud üldise praktika järgi, et mida kauem on ettevõttel võlgu, seda probleemsem ta on, tuginedes ka eelnevalt arutletud makstähataja ületanud päevade arvule, millal loetakse ettevõtte probleemseks. Nende muutujate vahe on selles, et ühel juhul on kõik maksuvõlaga kuud arvestatud eelneval aastal, aga teisel puhul on välistatud maksuvõlaga kuud, millal oli maksuvõlg väiksem kui 100 eurot. Andmestikust nähtus ka ettevõtteid, kellel oli maksuvõlg mõnest sendist paarikümne euroni, mis tundus olevat pigem hooletus või siis valesti arvestamine ja üldsegi mitte tahtlik võlgnevus. Seega tundus oluline eristada ettevõtteid, kellel ei pruugi probleeme üldse olla.

## 2.3. Krediidiriski modelleerimine ja tulemuste analüüs

Logistilise regressioonanalüüsiga modelleerimiseks kasutati SPSS andmetöötlusprogrammi. Eelmises peatükis kirjeldatud andmed töödeldi Microsoft Excelis. Käesolevas peatükis kirjeldatakse modelleerimisel saadud tulemusi ja analüüsitakse neid. Samuti tehakse järeldus ja ettepanek edaspidiseks.

Kõigepealt tuuakse välja oluline asjaolu, et kuna mõlema mudeli puhul on heade ja halbade vaatluste suhe erinev, siis kasutatakse osakaalude võrdsustamist. Laitinen ja Suvas (2013: 7) kirjeldavad protsessi järgmiselt: head ja halvad saavad võrdsed hindamise kaalud ning vaatluste arv seatakse võrdseks valimi suurusega. Kaalumise välistab mõlema mudeli puhul kallutatuse suurema vaatluste arvu poole, mis antud töös on halvad ning tagab õiglase hinnangu.

Kuna töös kasutatakse kahte erinevat modelleerimist, siis esimesena kirjeldatakse finantsuhtarvudel baseeruvat mudelit. Logistilist regressioonanalüüsi mudeleid koostatakse kasutades *forward stepwise* tehnikat ehk muutujaid lisatakse järjest juurde mudeli parandamise eesmärgil kuni parima mudeli saamiseni. Kasutatud on olulisusenivood 0,05 ehk 5%.

**Tabel 2.3.** Muutujate kirjeldav statistika finantsuhtarvudel põhineva mudeli kohta

Halb/hea		Puhaskasum/varad kokku	Käibevara/lühiajalised kohustused	(Käibevara-lühiajalised kohustused)/varad kokku	Omakapital kokku/varad kokku	Äritulud/varad kokku	Raha/lühiajalised kohustused	Puhaskasum/äritulud
0	N	251	251	251	251	251	251	251
	Aritmeetiline keskmine	0,042*	8,68	0,09*	0,47*	2,17	7,22	0,04*
	Mediaan	0,03	1,28*	0,08*	0,45*	1,14*	0,10*	0,03*
1	N	106	106	106	106	106	106	106
	Aritmeetiline keskmine	0,10*	7,88	0,23*	0,67*	1,91	4,70	0,17*
	Mediaan	,07	2,38*	0,17*	0,74*	0,62*	0,66*	0,07*
Kokku	N	357	357	357	357	357	357	357
	Aritmeetiline keskmine	0,06*	8,44	0,14*	0,53*	2,09	6,47	0,08*
	Mediaan	0,04	1,44*	0,10*	0,54*	0,92*	0,19*	0,04*

\* - olulisusenivool 0,05 statistiliselt oluline.

Allikas: autori koostatud.

Tabelis 2.3. (lk. 35) on toodud muutujate aritmeetilised keskmiste ja mediaanide tulemused eristades häid ja halbasid ettevõtteid. Lisaks on märgitud kahe grupi lõikes statistiliselt oluliselt erinevad muutujad tärniga, vastavalt testile. Dispersioonanalüüs teostati aritmeetiliste keskmiste puhul ANOVA *Brown-Forsythe* testiga ja mediaanide puhul kasutati Sõltumatute valimite mediaanitesti (*Independent Samples Median Test*).

Lõplik finantssuhtarvudega logistiline regressioon mudel avaldub kujul:

$$(5) X_1 = -1,476 + 2,268 \frac{\text{omakapital}}{\text{koguvabad}} + 1,756 \frac{\text{puhaskasum}}{\text{äritulud}},$$

kus  $X_1$  on skoor ja tähistab krediidiriski hindamise tõenäosust kujul  $p = \frac{e^{X_1}}{1+e^{X_1}} = \frac{1}{1+e^{-X_1}}$ .

Ettevõtte krediidiriski hinnatakse skaalal 0 – 1. Murdepunkt on 0,5. See tähendab, et vaatlused/ettevõtted, kes klassifitseeruvad 0 kuni 0,5 skaalale prognoositakse halvaks ja vaatlused/ettevõtted, mis klassifitseeruvad ülespoole, hinnatakse heaks. Nagelkerke  $R^2$  saadi 0,186. Kuna mudel on koostatud kahte gruppi (head ja halvad) võrdseteks kaaludes, siis muutujate olulisust mudelis pole välja toodud, kuna kaalumise korral pole olulisustõenäosuse väärtused korrektsed.

Tabel 2.4. on toodud finantssuhtarvudel baseeruva logistilise regressioonanalüüsi mudeli klassifitseerimis täpsused. See näitab, et halbadeks prognoositud vaatlustest olid 117 halvad ja 61 osutusid heaks. Seega, halbade õigesti klassifitseerimise täpsus oli 65,7%. Headest prognoositi heaks 111 ja halvaks 67, mis teeb täpsuseks 62,3%. Kogu prognoosimise täpsus oli finantssuhtarvude puhul 64%.

**Tabel 2.4.** Klassifitseerimistabel

		Prognoos		Õigesti klassifitseeritud
		halb/hea		
Vaadeldud		0	1	
halb/hea	0	117	61	65,7
	1	67	111	62,3
Kokku				64,0

Allikas: autori koostatud.

Kokkuvõtvalt näitab eelnev tabel ära, et 65,7% tõenäosusega tuvastab mudel probleemse ettevõtte, mis TT kontekstis tähendab, et klient ületab maksetähtaega rohkem kui 30

päeva. Samuti 62,3% tõenäosusega tuvastab mudel korrektselt käituvat ettevõtet. Kui võrrelda tulemust teoorias osas toodud varasemate uuringute täpsustega, siis antud mudeli tulemus ei ole kindlasti parimate seas, aga samas saab järeldada, et tulemust võib lugeda rahuldavaks.

Antud töös kasutati võrdluseks ka teist logistilise regressioonanalüüsi mudelit, mis baseerus maksu- ja tolliameti informatsioonil maksuvõlgnevuse kohta. Kasutati *forward stepwise* tehnikat ja mudelisse jäävate muutujate p-väärtus (olulisustõenäosus) ei tohi olla suurem kui 5% ehk 0,05. Dispersioonanalüüs teostati aritmeetiliste keskmiste puhul ANOVA *Brown-Forsythe* testiga ja mediaanide puhul kasutati Sõltumatute valimite mediaanitesti (*Independent Samples Median Test*).

**Tabel 2.5.** Muutujate kirjeldav statistika maksevõlgnevusel põhineva mudeli kohta

Halb/hea		Suurim	12 kuu aritmeetiline keskmine	Mediaan	kuid	kuidüle100
0	N	607	607	607	607	607
	Aritmeetiline keskmine	3184,17*	1130,37*	1021,47*	1,44*	1,36*
	Mediaan	0*	0*	0*	0*	0*
1	N	319	319	319	319	319
	Aritmeetiline keskmine	69,75*	7,41*	0,75*	0,07*	0,04*
	Mediaan	0*	0*	0*	0*	0*
Kokku	N	926	926	926	926	926
	Aritmeetiline keskmine	2111,28*	743,52*	669,84*	0,97*	0,90*
	Mediaan	0*	0*	0*	0*	0*

\* - olulisuse nivool 0,05 statistiliselt oluline.

Allikas: autori koostatud.

Tabelis 2.5. on toodud eelmises peatükis kirjeldatud viis muutujat, mille kohta on leitud aritmeetilised keskmised ja mediaanid. Nagelkerke  $R^2$  saadi 0,214. Mediaanide puhul jääb silma just asjaolu, et kõik tulemused on 0. Mõningates tulpades on see tulemus loogiline, aga kõigi puhul ei tohiks tavapärane olla. Üldiselt saab seda seletada asjaoluga, et halbadeks klassifitseeritud ettevõtete/vaatluste osas on maksuameti järgi korrektseid ettevõtteid/vaatlusi. Kõik muutujad on statistiliselt oluliselt erinevad.

Lõplik maksuvõlgnevusega logistiline regressioonimudel avaldub kujul:

$$(6) X_1 = 0,331 - 1,478 * \text{kuidüle}100,$$

kus  $X_1$  on skoor ja tähistab krediidiriski hindamise tõenäosust kujul  $p = \frac{e^{X_1}}{1+e^{X_1}} = \frac{1}{1+e^{-X_1}}$ .

Parimaks osutus mudel, milles oli ainult üks muutuja ja mis näitas kuude arvu eelneva aasta jooksul, millel oli maksuvõlg alates 100€. Järgnevalt on tabelis 2.6. välja toodud maksuvõlgnevuse muutujatega logistilise regressioonanalüüsi mudeli klassifitseerimistäpsuste tabel. Mudeli halbadeks klassifitseeritute hindamise täpsus on üllatuslikult ainult 32,5%. Samas on headeks klassifitseerimistäpsus lausa 98,7%, mis on suurpärase tulemus. 463 vaatlusest ainult 6 prognoositi valesti. Kokku on mudeli hindamistäpsus 65,6%.

**Tabel 2.6.** Klassifitseerimistabel

		Prognoos		Õigesti klassifitseeritud
		halb/hea	0	
Vaadeldud halb/hea	0	150	313	32,5
	1	6	457	98,7
Kokku				65,6

Allikas: autori koostatud.

Kokkuvõtvalt saab maksuvõlgnevuste andmete põhjal koostatud logistilise regressioonanalüüsi mudeli kohta järeldada, et osaliselt annab see äärmiselt täpseid tulemusi, kuigi mudeli lõplik täpsus on lihtsalt hea. Halbade vaatluste/ettevõtete klassifitseerimistäpsuse madal protsent näitab seda, et ettevõtted, kes TT järgi olid probleemsed, ei olnud seda maksuameti järgi olnud. See tähendab, et klientidel, kelle maksetähtaeg oli ületatud rohkem kui 30 päeva, ei olnud 67,5% eelneva aasta jooksul maksuameti ees rohkem võlgnevust kui kuni 100 eurot, kui üldse oli. Samas, mudeli heade ettevõtete klassifitseerimistäpsus on väga hea. Põhimõtteliselt oli ainult kuue vaatluse puhul 463-st eelneva aasta jooksul maksuameti andmebaasis võlgnevuse märke suurem, kui 100 eurot. Antud mudeli puhul on suur risk teha tüüp I viga, mille puhul halb ettevõtte klassifitseeriti heaks.

Analüüsidest saadud mudelit, siis võime järeldada, et ettevõtte, kes on TT ees võlgu jäänud, ei pruugi seda maksuameti eest olla. See viitab olukorrale, et kliendid jäävad pigem võlgu TT-le, kui maksuametile. Ühelt poolt on see loogiline käitumine. Krediidiosuste tegemiseks tuleb ainukesel avaliku maksuvõlgnevuste infoportaali ees võlgnevuste vaba paista ning julgelt võib käituda tarnijatega, kelle võlgnevus avalikult välja ei paista. Samas on üldtuntud praktika, et raskustes ettevõtted tasuvad võlad kõigepealt pankadele, siis tarnijatele ning seejärel maksuametile, kuna kasutatakse kõrge intressiga nn. „maksulaenu“. Enamjaolt ilma pankade ja tarnijateta ei saa ju ettevõtte tegutseda.

Kui nüüd analüüsida, miks probleemsed kliendid TT-le nii julgelt võlgu jäävad ja maksuameti ees on laitmatu resümeega, siis selline käitumine näitab kindlust tarnijate ees. See omakorda viitab tugevale konkurentsile kütuseturu maastikul: kui avalik resümee on laitmatu ja ei suudeta tarnijale tasuda, siis võetakse kütust järgmise ettevõtte käest, kuna uue tarnija jaoks on tegemist hea ettevõttega. Samas võib siin välja tuua veel ühe mõtte, et suures osas on TT kliendid põllumajandusettevõtted, kelle väga suur osa tulubaasist moodustavad erinevad toetused. Kuna maksuvõlgnevusega ettevõtted ei saa toetust, siis esmajärjekorras tasutakse maksuametile.

Võrreldes mõlemat saadud mudelit, siis klassifitseerimistäpsused kokku on mõlemal suhteliselt sarnased ning antud mudelid on ka praktikas kasutatavad. Aga maksuvõlgnevuse klassifitseerimistäpsuste puhul tasub vaadelda heade ja halbade täpsusi erinevalt. Põhimõtteliselt tuleks vaadelda seda tagurpidi, et antud modelleerimisega saadi tulem, ehk et ettevõtte, kes on jäänud maksuametile võlgu on suure tõenäosusega probleemne. Samuti annab siit järeldada, et ettevõtted, kes maksuametile võlgu ei ole, ei pruugi olla mitteprobleemsed. Võrreldes finantssuhtarvudega saadud mudeliga, siis mõlemas grupis on sarnane ettevõtete klassifitseerimistäpsus. Võrdselt on eksimusi nii heade kui halbade juures. Antud olukord muudab tulemuse analüüsimise väga keeruliseks.

Analüüsidest tulemusi TT krediidiriski hindamise seisukohast, siis saadakse kaks arvestatavat mudelit, mis aitavad tublisti toime tulla suurenenud klientide arvuga, aga eraettevõtte jaoks võib risk ikkagi veel suureks jääda. Eriti seetõttu, et võib tekkida tüüp I vigu ehk kulukamat tüüpi vigu. Kindel on, et see mudel, mis kasutab maksuvõlgade infot on väga hea täpsusega ja seda tasub kindlasti edaspidi kasutada. Pigem teeb autor

ettepaneku proovida siduda finantssuhtarvudel baseeruv mudel maksevõime näitaja omaga, kasutades finantssuhtarvude mudelis maksevõime näitajat mittefinantssuhtarvulise muutujana. Samamoodi proovida siduda mitte finantssuhtarvulisi muutujaid senise TT krediiditaotlusblanketil küsitud küsimustega nt. ettevõtte vanus, krediidisoov jne kohta. Kindlasti on üks suurimaid näitajaid ettevõtte kohta juht ise, seega soovitab autor ka tähelepanu pöörata ettevõtte juhtidele ja nende käitumistele.

## KOKKUVÕTE

Mõiste krediit, erinevas sõnastuses, on olnud kasutusel tõenäoliselt sama kaua kui on kasutatud kaubanduses laenamist. Olenemata selle mõiste pikast ajaloost ei ole krediidiriski kontseptsioon väga pika ajalooga - hinnanguliselt 50-60 aastat, millest alles viimased aastakümned on aktiivsemalt tegeletud krediidiriski hindamisega. Antud mõiste muutis oluliseks panganduse kiire areng, millele aitas kaasa tehnoloogia areng. Üksikud laenutehingud läksid ühtäkki massidesse ning tekkis tarbimislenu ühiskond. Finantsinstitutsioonide ja pankade jaoks muutus väga oluliseks teema, kuidas hinnata väga kiiresti väga paljude klientide maksevõimet. Seega sai alguse krediidiriski hindamine, mida on uuringust uuringusse järjest edasi arendatud. Tänu tehnoloogia arengule ja informatsiooni odavusele on järjest rohkem hakatud krediidiriski hindamist kasutama laialdasemalt ettevõtluses.

Krediidiriski hindamine on oluline seetõttu, et aitab krediteerijal leida, kas anda laenu või mitte. Antud informatsioon aitab vältida kahjusid, mis võivad kaasneda, kui klient ei suuda laenu tagasi maksta. Erinevalt pankroti prognoosimisest on krediidiriski hindamise eesmärk tuvastada ettevõtte, kellel on finantsraskused. Vaadeldakse ettevõtte maksevõime korrektsust ning probleemide korral välistatakse igasugused juriidilised nüansid, mis kaasnevad pankroti prognoosimisega. Ettevõtteid vaadeldakse kui „häid“ ja „halbu“ krediteeringuid.

Väga tihti kasutatakse finantssuhtarvudel baseeruvaid muutujaid, kuna ettevõtte finantsnäitajaid on võimalik kätte saada suhteliselt lihtsalt aastaaruannetest. Antud töös oli võimalik kätte saada ka andmed maksekäitumise kohta, seega teostati ka teine modelleerimine, mis põhines mittefinantssuhtarvulistele muutujatele.

Käesoleva töö mudelite koostamise aluseks oli AS Tartu Terminali andmebaasist saadud ettevõtted. Esialgse valimi suurus oli 2453 klienti, millest moodustati kaks gruppi: ühed

head ja teised halvad. Pärast valimi töötlust jäi ettevõtete arv palju väiksemaks ning valimite proportsioonid ei olnud võrdsed. Seetõttu kasutati kaalusid.

Finantssuhtarvudel põhineval mudelil kasutati varem kasutatud enim levinud finantssuhtarve ning maksekäitumisele põhineval mudelil valiti muutujad intuiitiivselt, arutledes võimalike variantide üle, kuna puudub arvestatav teooria maksuvõlgnevuse kohta. Mõlema mudeli leidmisel kasutati logistilist regressioonanalüüsi.

Lõplik finantssuhtarvudega logistiline regressioon mudel avaldub kujul:

$$X_1 = -1,476 + 2,268 \frac{\text{omakapital}}{\text{koguvarad}} + 1,756 \frac{\text{puhaskasum}}{\text{äritulud}},$$

Vastava mudeli õigesti klassifitseerimistäpsus oli 64%. Halbade õigesti klassifitseerimistäpsus oli 65,7%, heade prognoositäpsus oli 62,3%.

Lõplik maksuvõlgnevusega logistiline regressioonmudel avaldub kujul:

$$X_1 = 0,331 - 1,478 * \text{kuidüle}100,$$

Kokku on mudeli hindamistäpsus 65,6%. Oluline on antud mudeli puhul välja tuua headeks ja halbadeks prognoosimise täpsused eraldi. Halbadeks klassifitseeritute hindamise täpsus on 32,5%, headeks klassifitseerimistäpsus on 98,7%.

Kokkuvõtvalt võib öelda, et kui vaadelda lõplikku mudeli täpsust tundub, et mõlemal mudelil on võrreldavad klassifitseerimistäpsused, siis tegelikult on maksevõlgnevuse mudelis suur erinevus heade ja halbade prognoosimisel. Antud mudeli headeks klassifitseerimise täpsus on väga hea, millest saab järeldada, et kui ettevõtte on jäänud maksuametile võlgu, siis on väga suure tõenäosusega tegemist „halva“ krediteeringuga. Samuti annab siit järeldada tänu madalale täpsusele halbadeks klassifitseerimisel, et ettevõtted, kes maksuametile võlgu ei ole, ei pruugi olla mitteprobleemsed.

Käesoleva bakalaureusetöö suurim väärtus on eelneva maksekäitumise kasutamine krediidiriski hindamises. Autorile teadaolevalt ei ole varem teadustöodes ja uurimustes sellist mudelit kasutatud. Antud mudeli kasutamise tegi võimalikuks Eesti Maksu ja Tolliameti avaliku andmebaasi kogutud informatsioon, mida oli töödeldud vajalikule kujule Taust.ee-s. Eestis kasutatav eelneva maksevõlgnevuse informatsiooni avalik

jagamine on üldse maailma praktikas ainulaadne. Antud töö tulem viib arusaamisele, et kui ettevõttel on Maksu ja Tolliameti ees võlgnevus, siis väga suure tõenäosusega võib teda klassifitseerida halvaks krediteeringuks. Autori ettepanekul võiks edaspidi kaaluda eelneva maksekäitumise kasutamist edaspidistes uuringutes ühe olulise komponendina.

## VIIDATUD ALLIKAD

1. **Abdou, H. A., Pointon, J.** Credit Scoring, Statistical Techniques and Evaluation Criteria: A Review of the Literature. – *Intelligent Systems in Accounting, Finance and Management*, 2011, Vol. 18, pp. 59-88.
2. **Abdou H, Pointon J, El Masry A.** Neural nets versus conventional techniques in credit scoring in Egyptian banking. *Expert Systems with Applications*, 2008, Vol. 35, No. 3, pp. 1275-1292.
3. **Al Amari A.** The credit evaluation process and the role of credit scoring: a case study of Qatar. PhD thesis, University College Dublin. 2002.
4. **Altman, E.I.**, Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 1968, Vol. 23, No. 4, pp. 589–609.
5. **Altman, E.I., Eisenbeis, R.A.**, Financial applications of discriminant analysis: a clarification. *Journal of Financial and Quantitative Analysis*, 1978, pp. 185–195.
6. **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.
7. **Bailey M.** Consumer Credit Quality: Underwriting, Scoring, Fraud Prevention and Collections. White Box Publishing: Bristol. 2004.
8. **Balcaen, S., Ooghe, H.** 35 Years of Studies on Business Failure: an Overview of the Classical Statistical Methodologies and Their Related Problems. – *The British Accounting Review*, 2006, Vol. 38, No. 1, pp. 63–93.
9. **Beaver, W.**, Financial ratios as predictors of failure. *Journal of Accounting Research*, 1966, Vol. 5, pp. 71-111.
10. **Bellovary, J., Giacomino, D., Akers, M.** A Review of Bankruptcy Prediction Studies: 1930 to Present. – *Journal of Financial Education*, 2007, Vol. 33, pp. 1–42.
11. **Bishop CM.** *Neural Networks for Pattern Recognition*. Oxford University Press: New York, 1995.

12. **Cade, E.** Managing Banking Risks. New York: AMACOM, 1999, 237 p.
13. **Chandler GG, Coffman JY.** A comparative analysis of empirical vs. judgemental credit evaluation. *The Journal of Retail Banking*, 1979, Vol. 1, No. 2, pp. 15-26.
14. **Crook JN.** Credit scoring: an overview. Working paper series No. 96/13, British Association, Festival of Science, University of Birmingham, The University of Edinburgh. 1996.
15. **Crook J, Edelman D, Thomas L.,** Recent developments in consumer credit risk assessment. *European Journal of Operational Research*, 2007, Vol. 183, No. 3, pp. 1447-1465.
16. **Dambolena, I., Khoury, S.,** Ratio stability and corporate failure. *Journal of Finance*, 1980, Vol. 33, No. 4, pp. 1017–1026.
17. **Dimitras, A. I., Zankis, S. H., Zopounidis, C.** A Survey of Business Failures With Emphasis on Prediction Methods and Industrial Applications. – *European Journal of Operational Research*, 1996, Vol. 90, No. 3, pp. 487-513.
18. **Doing Business 2015: Going Beyond Efficiency.** The World Bank, 2014, pp. 331  
[<http://www.doingbusiness.org/~media/GIAWB/Doing%20Business/Documents/Annual-Reports/English/DB15-Full-Report.pdf>]. 20.01.2016.
19. **Doumpos, M., Zopoudinis, C.,** A multicriteria discrimination method for the prediction of financial distress: the case of Greece. *Multinational Finance Journal*, 1999, Vol. 3, No. 2, pp. 71–101.
20. **Durand D.** Risk Elements in Consumer Instalment Financing, *Studies in Consumer Instalment Financing*. National Bureau of Economic Research: New York, 1941.
21. **Edmister, R.,** An empirical test of financial ratio analysis for small business failure prediction. *Journal of Financial and Quantitative Analysis*, 1972, pp. 1477–1493.
22. **Eisenbeis, R.A.** "Pitfalls in the application discriminant analysis in business and economics", *The Journal of Finance*, 1977, Vol. 32, pp. 875-900.
23. **El Hennawy, R. and R. Morris.,** The significance of base year in developing failure prediction models. *Journal of Business Finance and Accounting*, 1983, Vol. 10, No. 2, pp. 209-223.
24. **Fletcher I. F.** Insolvency in Private International Law. National and International Approaches. Oxford: Oxford University Press, 1999, pp. 3.

25. **Freund RJ, William WJ.**, Regression Analysis: Statistical Modeling of a Response Variable. Academic Press: San Diego, 1998, CA.
26. **Gallant S. I.**, Connectionist Expert Systems. Commun. ACM, 1988, Vol. 31, pp. 152-169.
27. **Gately E.** Neural Networks for Financial Forecasting: Top Techniques for Designing and Applying the Latest Trading Systems. John Wiley and Sons, Inc., New York, 1996.
28. **Gestel, T., Baesens, B.**, Credit Risk Management: Basic Concepts. Oxford: Oxford University Press, 2009, 552 p.
29. **Greene W.**, Sample selection in credit scoring models. Japan and the World Economy, 1998, Vol. 10, No. 3, pp. 299-316.
30. **Guan, Q.**, Development of optimal network structures for back-propagation trained neural networks. Ph.D. dissertation, University of Nebraska, 1993.
31. **Gujarati**, Basic Econometrics, Fourth Ed. McGraw-Hill, London, 2003.
32. **Hamer, M.M.**, "Failure prediction: Sensitivity of classification accuracy to alternative statistical methods and variable sets", *Journal of Accounting and Public Policy*, 1983, Vol. 2, pp. 289-307.
33. **Hand DJ, Jacka SD.** Statistics in Finance, 1998, Arnold: London.
34. **Hand, D. J., Henley, W.E.** Statistical Classification Methods in Consumer Credit Scoring: - A Review. – J. R. Statist. Soc. A, 1997, Vol 160, No. 3, pp. 523-541.
35. **Haykin S.**, Neural Networks: A Comprehensive Foundation. Prentice Hall, London, 1994.
36. **Hosmer DW, Lemeshow S.** Applied Logistic Regression. John Wiley and Sons, Inc., New York, 1989.
37. **Jensen J. L.**, Using Neural Networks for Credit Scoring. Manag. Fin., 1992, Vol. 18, pp. 15-26.
38. **Karels, G.V., Prakash, A.J.**, Multivariate normality and forecasting of business bankruptcy. Journal of Business Finance & Accounting, 1987, Vol. 14, No. 4, pp. 573–593.
39. **Keasey, K., Watson, R.**, Non-financial symptoms and the prediction of small company failure: a test of Argenti's hypotheses. Journal of Business Finance & Accounting, 1987, Vol. 14, No. 3, pp. 335–354.

- 40. Keasey, K., Watson, R.**, Financial distress models: a review of their usefulness. *British journal of Management*, 1991, Vol. 2, No. 2, pp. 89–102.
- 41. Kryzhanovskiy, N.**, Erasikute krediidiriski hindava mudeli koostamine ettevõtte Snel grupp õü näitel. TÜ majandusteaduskond, 2016, 93 lk. (magistritöö)
- 42. Kumar, P. R., Ravi, V.** Bankruptcy Prediction in Banks and Firms via Statistical and Intelligent Techniques – A Review. – *European Journal of Operational Research*, 2007, Vol. 180, No. 1, pp. 1–28.
- 43. Lachenbruch, P.A.**, Discriminant Analysis. Hafner Press, New York, 1975.
- 44. Laitinen E. K., Suvas A.**, International Applicability of Corporate Failure Risk Models Based on Financial Statement Information: Comparisons across European Countries, 2013, Vol. 1, No. 3, pp. 1-26.
- 45. Lee T, Chiu C, Lu C, Chen I.** Credit scoring using the hybrid neural discriminant technique. *Expert Systems with Applications*, 2002, Vol. 23, No. 3, pp. 245-254.
- 46. Liang Q.**, Corporate financial distress diagnosis in China: empirical analysis using credit scoring models. *Hitotsubashi Journal of Commerce and Management*, 2003, Vol. 38, No. 1, pp. 13-28.
- 47. Lukason, O.** Maksejõuetuse põhjuste analüüs: Kokkuvõte olulisematest uurimistulemustest. 2010, 38 lk. [https://riigikantselei.ee/sites/default/files/contenteditors/TOF/TOF\\_uuringud/20\\_uuringu\\_aruanne\\_maksejouetus.pdf](https://riigikantselei.ee/sites/default/files/contenteditors/TOF/TOF_uuringud/20_uuringu_aruanne_maksejouetus.pdf). 12.01.2016.
- 48. Masters T.** Advanced Algorithms for Neural Networks: A C++ Sourcebook. John Wiley and Sons, Inc., New York, 1995.
- 49. Messier, W.F., and Hansen, J.V.**, "Including rules for expert system development: An example using default and bankruptcy data", *Management Science*, 1988, Vol. 34, No. 12, pp. 1403-1415.
- 50. Nelson, M. M., Illingworth, W. T.**, A Practical Guide to Neural Nets. Addison Wesley, New York.
- 51. Ohlson, J.**, Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 1980, Vol. 18, No. 1, pp. 109–131.
- 52. Ong C, Huang J, Tzeng G.** Building credit scoring models using genetic programming. *Expert Systems with Applications*, 2005, Vol. 29, No. 1, pp. 41-47.

- 53. Ooghe, H., Balcaen, S.,** Are failure prediction models transferable from one country to another? An empirical study using Belgian financial statements, Proceedings of the 9th Annual Conference of the Multinational Finance Society, 2002, Cyprus.
- 54. Ooghe, H., Joos, P.,** Failure prediction, explanation of misclassifications and incorporation of other relevant variables: result of empirical research in Belgium, Working paper, Department of Corporate Finance, Ghent University, 1990.
- 55. Ooghe, H., Joos, P., De Bourdeaudhuij, C.,** Financial distress models in Belgium: the results of a decade of empirical research. *International Journal of Accounting*, 1995, Vol. 30, pp. 245–274.
- 56. Ooghe, H., Verbaere, E.,** Predicting business failure on the basis of accounting data: The Belgian experience. *The International Journal of Accounting*, 1985, Vol. 9, No. 2, pp. 19–44.
- 57.** Pankrotid Eestis 2014. – Krediidinfo, 2016, 29 lk. [<http://www.krediidinfo.ee/files/pankrotid2014.pdf>]. 15.01.2016.
- 58.** Pankrotiseadus. Vastu võetud Riigikogus 22. jaanuaril 2003. a. – Riigi Teataja I osa, 2003, nr. 17, art. 95. [<http://www.riigiteataja.ee/akt/257670?leiaKehtiv>] 21.01.2016
- 59. Pretorius, M.** Critical Variables of Business Failure: a Review and Classification Framework. – *South African Journal of Economic and Management Sciences*, 2008, Vol. 11, No. 4, pp. 408–430.
- 60. Rosenberg E, Gleit A.** Quantitative methods in credit management: a survey. *Operations Research*, 1994, Vol. 42, No. 4, pp. 589–613.
- 61. Scott, J.,** The probability of bankruptcy: a comparison of empirical predictions and theoretical models. *Journal of Banking and Finance*, 1981, Vol.5, No. 3, pp. 317–344.
- 62. Sullivan AC.** Consumer finance. In *Financial Handbook*, Altman EI (ed.). John Wiley and Sons, Inc.: New York; 9.3–9.27. 1981.
- 63. Theodossiou, P.,** Predicting shifts in the mean of a multivariate time series process: an application in predicting business failures. *Journal of the American Statistical Association*, 1993, Vol. 88, No. 422, pp. 441–449.
- 64. Thomas LC, Edelman DB, Crook LN.** *Credit Scoring and Its Applications*. Society for Industrial and Applied Mathematics: Philadelphia, PA. 2002.

65. **Tucker, J.**, Neural networks versus logistic regression in financial modelling: a methodological comparison, Proceedings of the 1996 World First Online Workshop on Soft Computing (WSC1), Nagoya University (Japan), August, 1996, pp. 19–30.
66. **Warner, J.B.**, Bankruptcy costs: Some evidence, - The Journal of Finance, 1977, Vol. 32, No. 2, pp. 337-347.
67. **Wilson R. L., Sharda R.**, Bankruptcy Prediction Using Neural Networks. Dec. Support Syst., 1991.
68. **Zekic-Susac M, Sarlija N, Bensic M.** Small business credit scoring: a comparison of logistic regression, neural networks, and decision tree models. In 26th International Conference on Information Technology Interfaces, Croatia, 2004.
69. **Zopounidis, C.** "A multicriteria decision making methodology for the evaluation of the risk of failure and an application", *Foundations of Control Engineering*, 1987, Vol. 12, No. 1, pp. 45-67.

## LISAD

### Lisa 1. Lühendid finantsnäitajate ja suhtarvude kohta

CA	Käibevara ( <i>Current assets</i> )
CF	Rahakäive ( <i>Cash Flow</i> )
CL	Lühiajalised kohustused ( <i>Current Liabilities</i> )
EBIT	Kasum enne intresse ja makse ( <i>Earnings Before Interest &amp; Taxes</i> )
FA	Põhivara ( <i>Fixed Assets</i> )
GNP	SKT ( <i>Gross National Product – GNP</i> )
Inv.	Varud ( <i>Inventory</i> )
LTD	Pikaajaline võlakohustus ( <i>Long Term Debt</i> )
MVE	Aktiaturuväärtus ( <i>Market Value of Equity</i> )
NI	Puhaskasum ( <i>Net Income</i> )
NW	Omakapital ( <i>Net Worth</i> )
QA	Raha ja pangakontod ( <i>Quick Assets</i> )
R	Nõuded ( <i>Receivables</i> )
RE	Jaotamata kasum ( <i>Retained Earnings</i> )
S	Äritulud ( <i>Sales</i> )
TA	Varad kokku ( <i>Total Assets</i> )
TD	Kohustused kokku ( <i>Total Debt</i> )
WC	Käibekapital ( <i>Working Capital</i> )

Allikas: (Dimitras *et al* 2007: 493); autori kohandatud.

Lisa 2. AS Tartu Terminali kaubakrediidi taotlus



**KAUBAKREDIIDI TAOTLUS**

Ettevõtte nimi: _____ Ettevõtte juhi nimi: _____ Registrikood: _____ Käibemaksukohustlase nr. _____ Jur. aadress: _____ Posti aadress: _____ Telefon: _____ Faks : _____ E-mail : _____ www: _____ Arveldusarve nr. _____ Pank: _____ Raamatupidaja nimi: _____ Tel: _____
Ettevõtte põhitegevusala: _____ Ettevõtte käive: _____ Ettevõtte omakapital: _____ Ettevõtte vanus: _____ Hinnanguline ostumaht kütuste lõikes kuus: _____ Volitatud isikute nimed ja telefonid: _____
<b>TAOTLETAVAD TINGIMUSED</b> Taotletav krediit: _____ EUR Taotletav maksetähtaeg: _____ päeva Tellitavad krediitkaardid: Tüüp 0 – kõik kütused ja kõik kaubad: ___ kaarti Tüüp 1 – Kõik kütused ja autokaubad: ___ kaarti Tüüp 2 – Kõik kütused: ___ kaarti Tüüp 3 – Diislikütus: ___ kaarti Taotleja nimi, amet: _____ Kuupäev: _____ Allkiri : _____
<b>KREDIIDI OTSUS</b> Lubatav krediit: _____ EUR Maksetähtaeg : _____ päeva Märkused: _____
Kuupäev : _____ Allkiri : _____ <b>Muudatused:</b> _____

### Lisa 3. AS Tartu Terminali müügileping



#### MÜÜGILEPING nr

Kärkna  
2015

17. märts

**Aktsiaselts Tartu Terminal**, juhatuse liige **Raido Raudsepp**'a isikus, kes tegutseb põhikirja alusel, edaspidi nimetatud **MÜÜJA** või **POOL** ja ....., tegevdirektor ..... isikus, kes tegutseb põhikirja alusel, edaspidi nimetatud **OSTJA** või **POOL**, sõlmisid käesoleva lepingu, edaspidi nimetatud LEPING ja leppisid kokku alljärgnevas:

#### **1. LEPINGU OBJEKT.**

1.1. MÜÜJA müüb ja OSTJA ostab naftasaadusi jm. kaupu (edaspidi nimetatud KAUP), vastavalt OSTJA poolt esitatud ja MÜÜJA poolt vastuvõetud (e. aktsepteeritud) tellimustele ning OSTJA kohustub eelnimetatud KAUBA vastu võtma ja selle eest MÜÜJALE tasuma LEPINGUS ettenähtud korras ja tähtaegadel.

1.2. KAUBA kogused, hind, tarnetingimused ja nomenklatuur kinnitatakse iga tellimuse puhul eraldi kokkuleppega, võttes aluseks MÜÜJA poolt väljastatud või viimase juures väljapandud kehtiva kaubapakumise (s.o. hinnakirja).

1.3. MÜÜJA poolt müüdava ja OSTJA poolt ostetava KAUBA nimetus, kogus, hind ja käibemaks märgitakse arvel, arve-ostukviitungil ja veokirjal või arve-veokirjal iga müüdü kaubakoguse kohta eraldi. Eelviidatud dokumentidele märgitakse ostetava KAUBA nimetus, kogus ja hind iga müüdü kaubakoguse kohta eraldi.

#### **2. KVALITEET**

2.1. KAUBA kvaliteet peab vastama Eesti Vabariigis kütusele kehtestatud normidele ning kvaliteeti kinnitavad MÜÜJA poolt KAUBAGA kaasa antavad LEPINGU punktis 1.3. viidatud dokumendid.

2.2. Kvaliteedialaste pretensioonide aluseks saab OSTJA poolt olla kütuseproov, mis on võetud MÜÜJA transpordivahendist, mahutist v. väljastuskohast vahetult enne KAUBA üleandmist OSTJALE järgmiselt:

2.2.1. Võetakse kaks proovi, mis pitseeritakse ning allkirjastatakse POOLTE volitatud esindajate poolt.

2.2.2. Proovid võetakse kohapeal kinnipitseeritava korgiga pudelitesse või muudesse anumatesse, mis võimaldavad plommi või tõkendi paigaldamist proovidele võimaliku hilisema laboratoorse analüüsi tegemiseks.

2.2.3. P-s 2.2.2. viidatud kahe anuma olemasolu tagab oma kulul OSTJA. Pärast proovi võtmist jääb üks proov OSTJALE ja teine MÜÜJALE, mida MÜÜJA säilitab p-s 2.3 märgitud tähtaja jooksul.

2.3. KAUBA kvaliteedist jm. asjaoludest tulenevad pretensioonid kohustub OSTJA esitama kirjalikult MÜÜJALE mitte hiljem kui kolmekümne kalendripäeva jooksul peale KAUBA vastuvõtmist. Hilisemaid pretensioone ei arvestata.

## **Lisa 3 järg**

### **3. MÜÜJA kohustused.**

3.1. MÜÜJA väljastab KAUBAD koos LEPINGU p-s 1.3 viidatud dokumentidega. KAUBA koguseline ja kvaliteediline üleandmine ja vastuvõtmine loetakse toimunuks ülalnimetatud dokumentidele allakirjutamisega.

### **4. MÜÜJA õigused**

4.1. MÜÜJAL on õigus nõuda OSTJALT KAUBA eest tasumist ning kohaldada leppetrahvi, viivist ja muid õiguskaitsevahendeid vastavalt seadusele või LEPINGUS ettenähtud tingimustel.

4.2. Juhul, kui OSTJA viivitab MÜÜJALT saadud KAUBA eest tasumisega, on MÜÜJAL õigus nõuda lisaks kauba maksumusele ka viivist null koma kakskümmend viis protsenti (0,25 %) päevas tähtajaks tasumata summalt iga tasumisega viivitatud kalendripäeva eest kuni võlgnevuse täieliku kustutamiseni ning peatada OSTJA tellimuste vastuvõtmine ning LEPINGUGA MÜÜJALE ettenähtud kohustuste täitmine ühepoolsetl.

### **5. OSTJA kohustused.**

5.1. OSTJA kohustub käesoleva LEPINGU p.1 märgitud KAUBA vastu võtma ja tasuma MÜÜJALE KAUBA eest LEPINGU p-s 1.3 viidatud dokumentidele märgitud tasumisele kuuluvad summad kuni neljateist ( 14) kalendripäevase maksetähtaja jooksul.

5.2. OSTJAL ei ole õigust LEPINGUST tulenevaid kohustusi kolmandatele isikutele üle kanda ilma MÜÜJA eelneva kirjaliku nõusolekuta.

5.3. OSTJA on kohustatud viivitamatult teatama MÜÜJALE pankroti-, likvideerimis- või kohtumenetluse algatamisest kolmandate isikute poolt OSTJA suhtes, samuti likvideerimis- või pankrotimenetluse algatamisest iseenda suhtes.

### **6. Arveldused.**

6.1. Arveldused poolte vahel toimuvad sularahas, arveldustshekiga või pangalaekandega. Pangalaekandega tasumisel loetakse MÜÜJA arve tasutuks, kui arvel märgitud summa on laekunud MÜÜJA pangakontole.

6.2. Maksekorraldusele ja arveldustshekile märgib OSTJA lisaks muudele rekvisiitidele ka kauba arve, arve-ostukviitungi ja veokirja või arve-veokirja numbrit ja kuupäeva.

### **7. Tähtajad.**

LEPING on sõlmitud tähtajaga kaks aastat, arvates sellele allakirjutamisest. Lepingu tähtaeg pikeneb ühe aasta võrra juhul, kui kumbki POOLTEST ei ole hiljemalt 10 päeva enne lepingu tähtaja lõppu teatanud teisele POOLELE oma vastuväidetest lepingu jätkumise osas. Käesoleva LEPINGU tähtaja möödumine või enneaegne lõpetamine ei lõpeta OSTJA kohustusi, millised on OSTJA poolt täitmata.

### **8. Muud kokkulepped.**

8.1. LEPINGUT võib muuta ja täiendada vaid POOLTE kirjalikul kokkuleppel.

8.2. MÜÜJA vastutab ainult enda poolt teostatud vedude eest. Kui OSTJA organiseerib KAUBA veo, siis vastutab veol tekkivate võimalike kahjude eest OSTJA või tema volitusel KAUBA vedu teostav isik.

8.3. MÜÜJA poolt aktsepteerimata jäetud OSTJA tellimus ei sea kohustusi MÜÜJALE.

8.4. Lepingust tulenevaid omavahelisi vaidlusi ja nõudeid püüavad MÜÜJA ja OSTJA lahendada esmalt läbirääkimiste teel, seejärel kohtus. Käesolevast LEPINGUST tulenevad vaidlused ja nõuded kuuluvad lahendamisele Tartu Maakohtus.

8.5. LEPING on koostatud kahes identses eksemplaris, millest kumbki POOL saab ühe eksemplari.

**Lisa 3 järg**

**Poolte juriidilised aadressid, rekvisiidid ja allkirjad:**

**MÜÜJA:**

Tartu Terminal AS  
Registrikood: 10171518  
Jur.aadress: Kärkna, 60513 Tartumaa

Tel: 749 7240  
Faks: 749 7238  
Pank: Swedpank, kood 767  
A/a nr 221010788803

**OSTJA:**

.....  
Registrikood:  
Jur.aadress:  
Postiaadress:  
Tel:  
Faks:  
Pank:  
A/a nr .

#### Lisa 4. AS Tartu Terminali käendusleping



### KÄENDUSLEPING

proj

Kärknas, ..... 2015.a.

AS Tartu Terminaal (edaspidi ka „võlausaldaja“), keda esindab juhatuse liige ..... ja ..... (edaspidi ka „käendaja“), koos nimetatult ka „pooled“, leppisid kokku alljärgnevas:

1. pooled kasutavad lepingus järgnevaid mõisteid:

**võlgnik** – .....

/Terminaaliga müügilepingu sõlminud äriühing/

**müügileping** – võlgniku ja võlausaldaja vahel ..... sõlmitud

/müügilepingu kuupäev/

müügileping nr ..... koos võimalike lisadega.

2. Käendaja vastutab müügilepingust tulenevate maksekohustuste täieliku ja kohase täitmise eest võlausaldaja ees solidaarselt võlgnikuga. Käendaja vastutab võlgnetava summa, kuid mitte rohkem kui .....

/summa sõnadega/

(..... EURO) tasumise eest

3. Käendaja kinnitab, et on tutvunud müügilepingu tingimustega ja on teadlik oma kohustusest tasuda müügilepingu alusel võlgnikule või tema poolt näidatud isikule üleantud ja tulevikus üleantavate naftasaaduste eest. Käendajal on õigus saada võlausaldajalt teavet, kui palju on müügilepingu alusel võlgnikule naftasaadusi väljastatud ning milline on võlgniku võla suurus käendaja näidatud ajahetkel.

4. Käendajal ei ole õigust esitada käendusega tagatud nõudele vastuväiteid, sealhulgas pärija vastutuse piiratud vastuväidet ja võlgniku kohustuse lõppemise või vähendamise vastuväidet võlgniku likvideerimis- või pankrotimenetluses.

5. Võlausaldajal on õigus pöörduda käendaja poole 21 pärast võlgniku poolt müügilepingust tuleneva maksega hilinemist ning nõuda käendaja käest sisse lisaks maksmisele kuuluvale summale ka müügilepingu järgsed leppetrahvid, viivised ja kohustuse rikkumisega põhjustatud kulud. Käendaja ei vastuta kohtukulude eest, kui tasub võla talle antud tähtaja jooksul enne kohtusse pöördumist.

6. Käendus kehtib kuni müügilepingust tulenevate nõuete täieliku täitmiseni.

7. Käendaja kohustub võlausaldajat viie päeva jooksul kirjalikult informeerima järgmiste asjaolude aset leidmisest: isikuandmete, elu- ja/või töökoha muutus, majandusliku olukorra halvenemine või muud asjaolud, mis võivad põhjustada käenduslepingust tulenevate kohustuste mittekohast täitmist.

8. Käesolev leping on konfidentsiaalne, kuid võlausaldaja on õigustatud avaldama informatsiooni käenduslepingu ja käendaja kohta AS-ile Krediidinfo (või samalaadsele institutsioonile), kui käendaja ei täida oma kohustusi nõuetekohaselt.

## Lisa 4 järg

9. Lepingust tulenevad vaidlused lahendatakse kokkuleppele mitte jõudmisel Tartu Maakohtu Tartu kohtumajas.

AS TARTU TERMINAAL  
Ärireg.kood: 10171518  
Aadress: Kärkna, Tartu vald, Tartu mk.  
Tel. 7497 248, fax 7497 238

---

.....  
Isikukood: .....  
Aadress: .....  
kontaktandmed:

---

## SUMMARY

The most important goal of a business is to maximize its value, which also ensures its sustainability. Not all businesses succeed and at worst, it may end up in bankruptcy. It often starts out with not being able to fill obligations on time and may lead up to persistent payment problems. A company with payment problems, may be a big credit risk to its partners. To reduce these risks, one has to find a way to separate successful companies from the unsuccessful ones. There are several ways to do that, for example expert ratings, analysis of financial ratios and models based on economic indicators of a company.

Credit risk evaluation is important for creditors to decide whether to give out loans or not. This information helps to prevent losses in case the client is not able to pay back the loan. Unlike bankruptcy predictions, the goal of evaluating credit risk, is to allocate businesses with financial difficulties. Credit worthiness is taken under examination and if problems appear, all jurisdictional nuances, that are accompanied with bankruptcy predictions, are ruled out. Companies are viewed as „good“ and „bad“ credit decisions.

This subject of study is actual for AS Tartu terminal, since the company has expanded to the retail market through the founding of service stations. Thanks to the changes made to the conception of the company, the number of retail clients as well as wholesale clients have increased. Due to all this, the current credit policy is starting to deplete itself and it is important to find new methods to cope with the increased number of clients. One possibility is to develop a model for credit risk predictions, that best meets the needs of AS Tartu Terminal and is specific to the company.

The main objective of this Bachelor's thesis is to develop a model of credit risk predictions for AS Tartu Terminal. To meet the goal, it is necessary to find the best way to evaluate the credit worthiness of its clients and through that improve and simplify today's credit policy in AS Tartu Terminal.

These following tasks help to fill the objective:

1. To give an overview of the content of credit risk, methods and variables
2. To analyze credit risk prognosis models used in previous researches
3. To give an overview of AS Tartu Terminal and its current credit risk politics
4. To describe used variables and present statistics to describe them
5. To model the credit risk of AS Tartu Terminal by using logistic regression analysis
6. To analyse different models by comparing them in different scientific researches

This current thesis is built up by using articles and researches most used and cited in previous works. It also uses different data from Taust.ee and Äriregister data bases.

A lot of the variables used are based on financial ratios, because they are easily accessible through annual reports. The current thesis also used data about payment behavior and used it to create another model that based on non-financial ratios.

The base of creating the models in the current thesis, were data about companies in the AS Tartu Terminal database. The initial sample was 2453 clients, made up by two groups: good and bad. After processing the sample, it became much smaller and the proportions of the two groups were not equal. To fix this, scales were used.

To create the model based on financial ratios, most common financial ratios were used. For the model based on payment behavior, the variables were chosen by intuition, since there is no considerable theory about tax indebtedness. Logistic regression analysis was used, to create both models.

The final logistical regression model of financial ratios is:

$$X_1 = -1,476 + 2,268 \frac{\text{equity}}{\text{total assets}} + 1,756 \frac{\text{net income}}{\text{earned income}},$$

The classification accuracy of this model was 64%, thereby 65,7% for the „bad“ and 62,3% for the „good“.

The final logistical regression model of tax indebtedness is:

$$X_1 = 0,331 - 1,478 * monthsover100,$$

The classification accuracy of this model was 65,6%, thereby 32,5% for the „bad“ and 98,7% for the „good“.

The biggest value of the current Bachelor thesis is the usage of previous payment behavior in credit risk evaluation. The author has not come across a model like this in previous researches. The usage of this model was enabled by the information collected into the database of the Estonian IRS and processed into usable form in Taust.ee. The public division of previous payment behavior in Estonia is unique in the whole world. The outcome of this thesis makes it clear, that if a company is owes to the IRS, it may probably be classified as bad crediting. The author suggests using previous payment behavior as a relevant component in future researches.

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

Mina, Rauno Raudsepp,

(sünnikuupäev: 26.01.1982)

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) enda loodud teose „Krediidiriski prognoosimise mudeli koostamine Tartu Terminal AS näitel“, mille juhendaja on Olive Lukason,
  - 1.1.reprodutseerimiseks säilitamise ja üldsusele kättesaadavaks tegemisel 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, **22.05.2016**