

TARTU ÜLIKOOL

Majandusteaduskond

Maarika Jahhu, Maarja-Brit Pihelgas

ERINEVA KESTUSEGA MAKSUVÕLGADE TEKKE PROGNOOSIMINE EESTI  
ETTEVÕTETE NÄITEL

Magistritöö

Juhendaja: kaasprofessor Oliver Lukason (PhD)

Tartu 2025

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

**Sisukord**

Resümee .....	4
Sissejuhatus .....	5
1. Majandusteaduslikud lähenemised ettevõtte ebaõnnestumise prognoosimiseks ja varasemate teadusuuringute tulemused.....	7
1.1. Ebaõnnestumise prognoosimise teaduslik taust .....	7
1.2. Ettevõtte maksuvõlgasid käsitlevate prognoositeemaliste uuringute tulemused .....	11
2. Andmed, muutujad ja meetodid .....	16
2.1. Andmed ja muutujad .....	16
2.2. Meetodid ja nende rakendamine .....	20
3. Tulemused ja arutelu.....	21
Kokkuvõte.....	31
Viidatud allikad.....	34
Lisad.....	40
Lisa A. Ennustavate muutujate väärtuste aritmeetilised keskmised erinevate maksuvõlgade tüübiga ettevõtete lõikes.....	40
Summary .....	41

### Resümee

Käesoleva magistritöö eesmärk on prognoosida Eesti ettevõtete erineva kestusega maksuvõlgade teket, kasutades selleks varasemaid maksuvõlgade andmeid, ettevõtte üldiseid tunnuseid ning finantssuhtarve. Magistritöö erineb varasematest uuringutest maksuvõla kestusastmete (ajutine, lühiajaline, keskmine, pikaajaline) eristamise ning ajatamata maksuvõlgade eraldiseisva käsitluse poolest. Magistritöö käsitleb Eesti käibemaksukohustuslasest ettevõtete maksuvõla teket 2018. aastal ning ennustavate muutujate puhul kasutatakse sellele eelneva kahe aasta (2016–2017) andmeid.

Magistritöös kasutati logistilise regressiooni ja tehisnärvivõrgu meetodeid kahel erineval andmestikul: kogu maksuvõlgade ning ainult ajatamata maksuvõlgade andmestikul. Tulemused näitavad, et tehisnärvivõrk edestas logistilist regressiooni kõigis mudelites. Kõrgeim prognoositäpsus (97,9%) saavutati ajatamata maksuvõlgade andmestikul keskmise kestusega maksuvõlgade prognoosimisel. Uuring kinnitab varasemate tööde tulemusi, mille kohaselt on maksuvõlgade ennustamisel varasemate maksuvõlgade lisamine mudelisse oluliseks täpsust parandavaks teguriks, ületades prognoosivõimes nii finantsnäitajad kui ka ettevõtte üldised tunnused. Muutujad lähemast minevikust võimaldavad maksuvõla teket prognoosida kõrgema täpsusega, võrreldes kaugema mineviku omadega. Lisaks teaduslikule panusele saavad kõrgete prognoositäpsuste tõttu erinevad osapooled neid mudeleid rakendada ka praktikas.

Märksõnad: maksuvõlg, maksejõuetus, prognoosimine, logistiline regressioon, tehisnärvivõrk

CERCS: S181, S190, S192

### Sissejuhatus

Maksuvõlgade prognoosimine on majandus- ja finantsanalüüsis oluline uurimissuund, sest maksuvõlad võivad olla ettevõtte finantsraskuste ja võimaliku maksejõuetuse varajane indikaator. Maksude tasumine on nii seaduslik kohustus kui ka vastutustundliku äritegevuse osa, mis tagab riigi teenuste, nagu näiteks infrastruktuuri ja sotsiaalse kaitse rahastamise. Siiski satuvad paljud ettevõtted maksuvõlgadesse erinevatel põhjustel, nagu valed juhtimisotsused või vähene teadlikkus maksuseadustest. Ebapiisav maksukuulekus võib riigile põhjustada märkimisväärse maksutulude vähenemise (Zheng & Li, 2023), kuid samas võib pidev maksuvõlg viidata ettevõtte sügavamatele finantsprobleemidele, mis võivad lõpuks viia püsiva maksejõuetuseni (Lukason & Andresson, 2019). Seetõttu on maksuvõlgade ennetamine oluline nii ettevõtete jätkusuutlikkuse kui ka riigi maksutulude tagamiseks. Maksuvõlgade prognoosimine võimaldab paremini mõista ettevõtete finantskäitumist, ennetamaks võimalikke makseraskusi ja prognoosida ning hinnata ettevõtte võimalikku maksejõuetust.

Ettevõtte finantsprobleemide prognoosimisel on oluline määratleda, millal makseraskused muutuvad kriitiliseks ning viitavad püsivale maksejõuetusele. Erinevates uuringutes määratakse maksehäired sõltuvalt erinevatest ajaperioodidest. Näiteks, Altman et al. (2023) uuringus käsitletakse väikese- ja keskmise suurusega ettevõtteid maksehäirega, kui nende pangakonto on blokeeritud 30 kuni 60 päeva. Samas, Basel II regulatsioonide kohaselt käsitletakse ettevõtet maksehäirega, kui ettevõtte laenumaksed on rohkem kui 90 päeva tasumata (Basel Committee on Banking Supervision, 2016). Andresson ja Lukason (2024) uuringus on fookuses ajahetk, millal ettevõttel tekib tasumata kohustus, olgu see siis võlg riigi või eravõlausaldajate ees. Maksuvõlgade prognoosimisel tuleb arvestada, et lühiajalised maksehäired ei pruugi viidata püsivatele finantsprobleemidele. Enamik ettevõtteid püüavad vältida riigile võlgu jäämist ning neil puuduvad enamusel ajast maksuvõlad (Siimon & Lukason, 2021). Sageli võivad maksuvõlad olla ajutised, näiteks kui ettevõttel tekib lühiajaline maksevõime langus ostjate viivitustega arvete tasumisel või ootamatute kulude tõttu. Need võivad põhjustada lühiajalisi viivitusi ka maksude tasumisel. Kuna ettevõtted teevad otsuseid, kelle nõuded esmajärjekorras rahuldada (Kohv & Lukason, 2021), siis võib maksuvõlgade kuhjumine asetseda tulemuslikkuse languse ja tegevuse lõpetamise vahel. Üheks põhjuseks on see, et maksuvõlgade ajatamine on sageli lihtsam kui kommerts krediidi pikendamine, mistõttu võivad ettevõtted lükata maksude tasumist edasi, saamaks ajutist finantsilist paindlikkust. Siiski, kui ettevõtte ei suuda

täita maksegraafikus ettenähtud kohustusi, võib see viidata sügavamatele finantsprobleemidele. Maksuhalduril on õigus ajakava kehtetuks tunnistada, kui maksukohustuslane ei järgi maksegraafikut (Maksukorralduse seadus, 2025). Jõudes olukorda, kus ei suudeta tasuda ka ajatatud maksuvõlgu, võib see olla märk püsivast maksejõuetusest.

Käesoleva magistritöö eesmärk on prognoosida Eesti ettevõtete erineva kestusega maksuvõlgade teket, kasutades selleks varasemaid maksuvõlgade andmeid, ettevõtte üldiseid tunnuseid ning finantssuhtarve. Maksuvõla teket käsitletakse nelja erineva kestusega perioodi näitel: ajutise kestusega, mis kestab kuni 2 kuud (k.a), lühiajalise kestusega maksuvõlg 3–5 kuud (k.a) järjest, keskmise kestusega maksuvõlg 6–11 kuud (k.a) järjest ning pikaajalise kestusega maksuvõlg, mis kestab vähemalt 12 kuud järjest. Sellist, kestusel põhinevat jaotust ei ole varasemates uuringutes maksuvõlgade prognoosimisel kasutatud, mistõttu pakub käesolev magistritöö uudset vaatenurka prognoosides nii maksuvõla tekkimist kui ka maksuvõlgade kestust. Kestusel põhinev prognoosimine on oluline, sest lühiajalised maksuvõlad võivad viidata vaid ajutistele likviidsusprobleemidele, samas kui pikemaajalised maksuvõlad viitavad pidevatele finantsraskustele ja suurendavad maksejõuetuse riski. Seetõttu võimaldab kestus eristada juhuslikke ja püsivaid finantsprobleeme ning aitab paremini suunata järelevalvemeetmeid ja krediidiriski hindamist. Prognoosimiseks kasutatakse kahte erinevat andmestikku: esimeses on sõltuv muutuja kodeeritud arvestades 2018. aasta kogu maksuvõlga ning teises ainult 2018. aasta ajatamata maksuvõlga. Mõlemad andmestikud on ennustavate muutujate osas identsed, milleks on ettevõtete üldised tunnused, varasemad maksuvõlad ja finantssuhtarvud. Selle lähenemise eesmärk on välja selgitada, kas ajatatud võlgade eemaldamine mõjutab mudeli prognoositäpsust. Ennustavad muutujad pärinevad aastatest 2017 ja 2016, st. sõltuva muutuja kodeerimiseks kasutatud aastale eelnev ja üle-eelmine aasta. Uuringusse on kaasatud ettevõtted, mis 2017. aasta novembris olid käibemaksukohustuslased ning millel oli 2016. ja 2017. aastal vähemalt 40 000 euro suurune müügitulu. See müügitulu suurus on ka piirmäär, mille ületamisel tekib ettevõttel vastavalt käibemaksuseaduse (2025) kohaselt kohustus end maksukohustuslasena registreerida. Kuigi ettevõtjatel on võimalus end registreerida maksukohustuslaseks ka siis kui müügitulu jääb alla 40 000 euro, on antud uuringus alla selle piiri jääva müügituluga ettevõtted kõrvale jäetud. Maksuvõlgnikeks loetakse ettevõtted, millel esines 2018. aasta jooksul vähemalt ühe kuu lõpus maksuvõlg ja maksuvõlata on ettevõtted, millel 2018. aastal maksuvõlgasid ühegi kuu lõpus ei esinenud.

Prognoosimudel võib olla väärtuslik tööriist audiitoritele aitamaks hinnata ja teha järeldusi jätkuvuse printsiibi kehtivuse kohta (Alaka et al., 2018; Jayasekera, 2018). Samuti Maksu- ja Tolliametile ettevõtete valimisel maksuauditiks, võlausaldajatele krediidiriski hindamiseks ja ettevõtjale endale finantsseisundi jätkusuutlikkuse hindamiseks.

Töö koosneb kolmest peatükist. Esimeses peatükis antakse ülevaade varasemast teaduskirjandusest mikro- ning väikese ja keskmise suurusega ettevõtete (VKE-de) ebaõnnestumise prognoosimisel, keskendudes varem kasutatud finantsilistele ja mittefinantsilistele ennustavatele muutujatele ning tehakse kokkuvõtte varasematest uuringutest, kus maksuvõlga on prognoositud või kasutatud ennustava muutujana. Teises peatükis kirjeldatakse kasutatavaid andmeid, muutujaid ja meetodeid. Kolmandas peatükis tuuakse välja analüüsi tulemused koos aruteluga, millele järgneb kokkuvõtte.

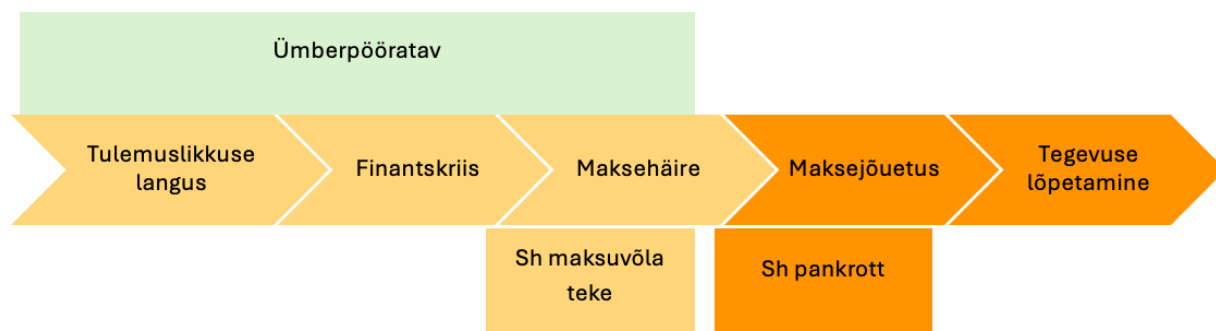
## **1. Majandusteaduslikud lähenemised ettevõtte ebaõnnestumise prognoosimiseks ja varasemate teadusuuringute tulemused**

### **1.1. Ebaõnnestumise prognoosimise teaduslik taust**

Ettevõtte ebaõnnestumine (ingl *business failure*) on mitmetahuline nähtus, mida teaduskirjanduses seostatakse mitmete erinevate sündmustega. Pretorius (2009) toob välja, et ebaõnnestumine võib avalduda üldise mitteeduna, otsustusvigadest tekkinud probleemidena, tulemuslikkuse langusena, finantskriisina, maksehäiretena, maksejõuetusena, likvideerimisena ja pankrotina. Varasemad uuringud on käsitlenud erinevaid finantsraskuste vorme, sealhulgas maksehäireid (Altman et al., 2023; Höglund, 2017; Mramor & Valentincic, 2003), pankrotti (Altman, 1968; Beaver, 1966; Cultrera & Brédart, 2016; Gilbert et al., 1990) ja tegevuse lõpetamist tasumata kohustusega (Lukason & Valgenberg, 2021), mis näitab, et tegemist on laialdaselt uuritud, kuid sageli eraldiseisvalt käsitletud nähtustega. Nende nähtuste ühine joon on ettevõtte suutmatus täita oma kohustusi ja jätkata jätkusuutlikku tegevust. Üheks oluliseks ebaõnnestumise vormiks on maksejõuetus, mida Beaver (1966) defineerib kui olukorda, kus ettevõtte ei suuda püsivalt oma finantskohustusi täita. Maksejõuetusega tihedalt seotud on maksehäire, mis Andressoni ja Lukasoni (2024) uuringu järgi on ajutine tasumata võlg, mis võib, kuid ei pruugi viia püsiva maksejõuetuseni. Pankrot seevastu on kohtumäärusega ametlikult välja kuulutatud maksejõuetus (Pankrotiseadus, 2025).

Kuigi maksejõuetuse prognoosimise uuringutes on pankrot kõige sagedamini käsitletud ebaõnnestumise vorm (Andresson & Lukason, 2024; Weitzel & Jonsson, 1989), siis ei pruugi

makseraskustes olev ettevõtte kunagi jõuda pankrotini (Jayasekera, 2018). Weitzel ja Jonsson (1989) ja Pretorius (2009) käsitlevad tulemuslikkuse langust ja ebaõnnestumist omavahel seotuna, kuid erinevate nähtusena. Nad rõhutavad, et tulemuslikkuse langus on ebaõnnestumise varasem etapp ehk loomulik eelstaadium, mille jooksul kogeb ettevõtte tegevuse jätkamisel raskusi. Tulemuslikkuse langusega seotud mõiste, nagu “elavad surnud”, pidevalt makseraskustes ja kahjumlikud ettevõtted, viitab ettevõtetele, mis küll tegutsevad, kuid ei suuda pikaajaliselt kohustusi täita (Pretorius, 2009). Weitzel ja Jonsson (1989) toovad esile, et tulemuslikkuse langus algab sageli siis, kui ettevõtte ei suuda õigeaegselt tuvastada või reageerida oma majandustulemuste halvenemisele ning varajaste hoiatavate signaalide ignoreerimine võib viia olukorra süvenemiseni. Joonisel 1 on näidatud ettevõtte ebaõnnestumise tüüpiline protsess, alustades tulemuslikkuse langusest ja lõppedes tegevuse lõpetamisega. Faasid on kujutatud loogilise järjestusena, kus iga järgnev faas hõlmab eelnevat probleemi süvenenud kujul. Maksuvõla teke paigutub maksehäire faasi alla ning toimib varajase hoiatava signaalina, mis võib viidata finantsraskuste süvenemisele. Kuigi ettevõtted ei pruugi läbida kõiki faase kindlaksmääratud viisil, peegeldab joonis 1 ebaõnnestumise võimalikku kulgu, mille varajastes etappides on veel võimalik ümberpöördumine ning finantsiline taastumine.



Joonis 1. Ettevõtte ebaõnnestumise protsess

Allikas: autorite koostatud

Maksuvõlgade prognoosimine on osa laiemast ebaõnnestumise prognoosimise valdkonnast, mille eesmärk on tuvastada ettevõtete tulemuslikkuse languse ja võimaliku pankroti varajased märgid. Erinevalt pankrotiprognosidest, mis keskenduvad sageli ebaõnnestumise lõppfaasile, võimaldab maksuvõlgade prognoosimine tuvastada raskustes ettevõtteid varasemas

etapis, potentsiaalselt enne pöördumatut kriisi (Siimon & Lukason, 2021). Selles kontekstis on oluline ümberpööramise (ingl *turnaround*) mõiste (Pretorius, 2009), mis tähistab ettevõtte taastumist langusfaasist ja jätkusuutlikkuse saavutamist.

Üheks enam kui pool sajandit kestnud lähenemiseks ettevõtete ebaõnnestumise prognoosimisel on finantssuhtarvude kasutamine. Selle lähenemise aluseks on ettevõtte finantsseisundi hindamine erinevate finantssuhtarvude abil. Esimesed olulised prognostilised uuringud pärinevad Beaverilt (1966) ja Altmanilt (1968), kes tuvastasid, et pankroti ennustamisel on kõige olulisemad näitajad rentaablust, lühiajalist maksevõimet ehk likviidsust ja pikaajalist maksevõimet ehk solventsust mõõtvad suhtarvud. Eriti heaks prognoosijaks osutus rahavoogude ja koguvõla suhe (Beaver, 1966), mille ennustusviga jäi oluliselt madalamaks juhuslikule mudelile ega sõltunud ettevõtte suurusest. Üheks kõige laialdasemalt rakendatavaks raamistikuks selles vallas on Altmani Z-skoor, mis algselt loodi börsil noteeritud tootmisettevõtete pankrotiriski hindamiseks (Altman, 1968), kuid mida on hiljem kohandatud ka noteerimata ja mittetööstuslikele ettevõtetele (Altman et al., 2017). Z-skoori väärtus on pöördvõrdelises seoses ettevõtte pankrotistumise riskiga (Altman, 1968). Altman et al. (2017) näitasid, et Eesti ettevõtete puhul annab parima klassifitseerimistulemuse Z-skoor, kui see hinnatakse ümber riigipõhiselt, kasutades logistilist regressiooni.

Läbi aastakümnete on mikro- ning väikeste ja keskmise suurusega ettevõtete (VKE) maksejõuetuse prognoosimisel kõige sagedamini kasutatud finantssuhtarve (Cheraghali & Molnár, 2023), eesmärgiga tuvastada parima prognoosivõimega näitaja. Näiteks Dimitras et al. (1996) leidsid, et kõige parema prognoosivõimega on koguvõla ja koguvara suhtarv. See näitaja on otseses seoses omakapitali suhtarvuga (omakapital/koguvarad). Ravi Kumar ja Ravi (2007) uuringust selgub, et suhtarve kasutatakse endiselt palju, kuid neile on lisandunud erinevad keerulised andmeanalüüsimeetodid. Masinõppe algoritmid (otsustuspuud, närvivõrgud ja juhumets) on aidanud parandada prognoosimistäpsust (Barboza et al., 2017). Lukason ja Vissak (2024) analüüsisid Eesti ettevõtete ebaõnnestumist, kasutades likviidsuse näitajana puhta käibekapitali ja varade suhtarvu (puhas käibekapital/varad kokku), pikaajalise maksevõime näitajana solventsuse suhtarvu (omakapital kokku/varad kokku), rentaabluste näitajana varade netorentaabluste suhtarvu (puhaskasum/varad kokku) ja tootlikkuse näitajana varade käibekordajat (müügitulu/varad kokku). Nende uuring näitas, et esmalt ilmneb tootlikkuse

langus, millele järgneb kasumlikkuse kriis, seejärel solventsus-, ning lõpuks tõsine likviidsuskriis.

Siiski on finantsuhtarvudel põhineval prognoosimisel teatud piirangud. Uuringud on näidanud, et VKE-d kasutavad sageli raamatupidamisandmetega manipuleerimist, et lükata edasi oma majanduslike ja finantsiliste probleemide ilmnemist (Ciampi et al., 2021). Eesti ettevõtete näitel läbi viidud uuringust selgus, et makseraskuste teke on tõenäolisem, kui ettevõtte oma majandusaasta aruannet õigeaegselt ei esita (Lukason & Camacho-Miñano, 2021). Seega, kui isegi nõuetekohaselt esitatud finantsaruannete analüüs ei suuda usaldusväärselt prognoosida VKE-de tulevast ebaõnnestumist, siis muudab olukorra veelgi keerulisemaks värskete finantsandmete puudumine: näiteks Eesti VKE-de näitel läbi viidud uuringus tuli välja jätta 35% ettevõtteid, sest nende värsked finantsandmed polnud kättesaadavad (Andresson & Lukason, 2024).

Lähtuvalt eeltoodust on lisaks finantsaruannetest pärinevatele finantsandmetele hakatud teadusuuringutes rakendama ka muid ennustavaid muutujaid eesmärgiga saada kõrgema prognoosivõimega mudeleid. Back (2005) leidis, et muutujad, mis mõõdavad varasemat maksekäitumist, on olulised tulevaste finantsraskuste ennustamisel. Marmor ja Valentincic (2003) leidsid oma uuringus, et kui ettevõttel on esinenud likviidsusprobleeme käesoleval aastal, on väga tõenäoline, et need tekivad ka edaspidi. Käitumusliku geneetika ja isikuomaduste püsivust käsitlevad uuringud viitavad sellele, et isiksuseomadused, sealhulgas need, mis mõjutavad finantskäitumist, on ajas suhteliselt stabiilsed ning suunavad inimest korduvalt sarnaselt käituma ka erinevates olukordades (Briley & Tucker-Drob, 2014). Lisaks on leitud, et isiku käitumisel erinevates situatsioonides on täheldatud märkimisväärset järjekindlust ning laboratoorses tingimustes tuvastatud käitumusmustrid kajastuvad ka päriselus, viidates püsivale käitumuslikule kalduvusele (Funder & Colvin, 1991). See omakorda peegeldub ka ettevõtte tasandil, kus juhi isikuomadustel, näiteks finantskäitumisel ja riskitaluvusel, võib olla otsene mõju ettevõtte strateegilistele valikutele ja finantstulemustele (Marmor & Lukason, 2024). Eriti oluline on see VKE-de puhul, kus ettevõtte juht ja omanik on sageli sama isik, mistõttu mõjutavad tema isiklikud finantsotsused otseselt ettevõtte majanduslikku olukorda. See tähendab, et halb või hea finantskäitumine võib ajas korduda ja seetõttu on oluline arvestada ettevõtja varasemat maksekäitumist püsivate likviidsusprobleemide ennustamisel. VKE-de jaoks on piisava likviidsuse tagamine väga oluline, sest neil on väiksem juurdepääs finantsturgudele

ning nad võivad väga kiiresti ebaõnnestuda, kui tekib likviidsete vahendite puudus (Ekanem, 2010). Eelnev on oluline, sest maksuvõlg paikneb ebaõnnestumise protsessis pankrotist oluliselt eespool (Andresson & Lukason, 2024) ja VKE-d suudavad pankrotti sageli vältida, kuid mitte alati maksehäireid. Kuigi mõned maksehäired võivad olla ajutised, muutuvad paljud neist püsivateks finantsraskusteks, mis viivad lõpuks maksejõuetuseni. On leitud, et ettevõtte varasemad maksehäired ennustavad hästi tulevast maksejõuetust (Andresson & Lukason, 2024; Back, 2005). Ciampi et al. (2020) leidsid, et varasema maksekäitumisega seotud muutujate lisamine mudelisse parandab ebaõnnestumise prognoosimise täpsust eriti VKE-de puhul. Ciampi et al. (2021) uuringust selgub, et VKE-de maksejõuetusrisiki aitavad kõige paremini prognoosida finantssuhtarvud, ettevõtte vanus ja suurus, makromajanduslikud tegurid ja piirkondlikud karakteristikud, varasem maksekäitumine, auditite kvaliteet ja ettevõtte juhtide kohta teadeolev teave. Lisaks on uuringud näidanud, et mittefinantsilised tegurid, nagu ettevõtte tegevusvaldkond ja suurus, mõjutavad oluliselt maksehäire ennustamise täpsust, sest need määravad ettevõtte tegutsemisvõimalused, kohanemisvõime ning ligipääsu ressurssidele (Kohv & Lukason, 2021). Samuti on seotud ebaõnnestumise riskiga ettevõtte vanus (Wiklund et al., 2010), ning on leitud, et ettevõtte vanus ja suurus on pöördvõrdelises seoses VKE-de maksejõuetuse tõenäosusega (Back, 2005). Altman et al. (2017) leidsid, et nooremad ettevõtted on suuremas maksejõuetuse riskis ning kõige keerulisem on ebaõnnestumist vältida esimesel kuuel tegutsemisaastal. Gupta et al. (2018) uuringust selgus, et kõik VKE-d ei ole sarnased ja nende ebaõnnestumise määr varieerub mikro- ning väikese ja keskmise suurusega ettevõtete hulgas. Eelmainitud näitajate edukat kasutamist eelnevates uuringutes kinnitab ka Cheraghali ja Molnár (2024) kirjanduse ülevaade. Varasemad uuringud on leidnud, et eksportivate ettevõtete finantstulemused ja jätkusuutlikus on paremad (Srebro et al., 2024; Rashid et al., 2021). See tulemus annab alust arvata, et eksportööride eristamine mudelis võiks täpsust suurendada.

## **1.2. Ettevõtte maksuvõlgasid käsitlevate prognoositeemaliste uuringute tulemused**

Varasemates uuringutes on maksuvõlgu käsitletud kahel viisil: esiteks, kui ennustavat muutujat ettevõtte maksehäire, maksejõuetuse või pankroti prognoosimisel, ning teiseks, kui sõltuvat muutujat, mille esinemist püütakse selgitada erinevate ennustavate muutujatega. Uuringud, kus maksuvõlgu on kasutatud ühe ennustava muutujana maksehäire või pankroti prognoosimisel on toodud välja tabelis 1. Lukason ja Valgenberg (2021) leidsid, et varasemate maksuvõlgade andmete kasutamine suurendab maksejõuetuse prognoosi täpsust, olles eriti

väärtuslik olukordades, kus finantsaruanded ei ole kättesaadavad. Samuti näitasid Kohv ja Lukason (2021), et maksuvõlgade kaasamine suurendas laenumaksehäire prognoosi täpsust, kusjuures maksuvõlgadel põhinev mudel ületas oluliselt finantssuhtarvudel põhineva mudeli täpsuse (vastavalt 83,5% ja 65,9% tehisnärvivõrkude meetodit kasutades). Lukason ja Andresson (2019) kasutasid maksuvõlgu pankroti prognoosimiseks ning leidsid, et vahetult enne pankrotti suudavad prognoosimudelid, mis kasutavad varasemate maksuvõlgade andmeid, jõuda kõrgema täpsuseni kui ainult finantssuhtarvudel põhinevad mudelid (vastavalt 89,9% ja 81,9%). Andresson ja Lukason (2024) püsiva maksejõuetuse uuringus saavutas varasemate maksehäire näitajatel põhinev mudel otsustuspuu meetodiga 73,7% täpsuse, mis näitab varasemate maksehäirete paremat prognoosivõimet võrreldes finantssuhtarvudega, milleks oli 66,1%.

Tabel 1

*Ülevaade uuringutest kus on kasutatud ühe ennustava muutujana maksuvõlga*

<b>Autorid</b>	<b>Lukason &amp; Andresson (2019)</b>	<b>Lukason &amp; Valgenberg (2021)</b>	<b>Kohv &amp; Lukason (2021)</b>	<b>Andresson &amp; Lukason (2024)</b>
<b>Uuringu käsitlusala</b>	Pankroti prognoosimine	Maksejõuetuse prognoosimine	Laenumaksehäire prognoos	Püsiva maksehäire prognoos
<b>Ettevõtete arv</b>	Tegutsevad: 4003 Pankrotis: 512	Maksejõulised: 45041 Maksejõuetud: 358	Maksehäireta: 12 745 Maksehäirega: 156	Maksehäireta: 42 803 Maksehäirega: 1 380
<b>Meetodid Ennustavad muutujad</b>	LR, ANN Maksuvõlad, finantssuhtarvud	LR, ANN, DT Maksuvõlad, finantssuhtarvud	LR, ANN Maksuvõlad, finantssuhtarvud, aastaruande esitamise viivitus	LR, ANN, DT Maksehäired (sh maksuvõlad), finantssuhtarvud
<b>Kõrgeima täpsusega mudeli ennustusmäär finantssuhtarvudega</b>	79,5% LR 81,9% ANN	64,9% LR 69,4% ANN 70,6% DT	61,9% LR 65,9% ANN	59,5% LR 62,1% ANN 66,1 % DT
<b>Kõrgeima täpsusega mudeli ennustusmäär maksuvõlga</b>	89,9% LR 86,7 % ANN	95,1% DT 93,5% LR 93,5% ANN	83,0% LR 83,5% ANN	70,9%LR 72,9% ANN 73,7% DT

*Märkus:* ANN – tehisnärvivõrk, DT – otsustuspuu, LR – logistiline regressioon

Allikas: autorite koostatud

Maksuvõla tekke prognoosimist on senises teaduskirjanduses käsitletud oluliselt vähem kui pankroti ja ebaõnnestumise prognoosimist. Selle valdkonna olulisemad uuringud on koondatud tabelisse 2. Höglund (2017) keskendus maksuvõlgade prognoosimisele tööandjamaksude ja käibemaksu osas ning leidis, et rentaabluse suhtarvudel on maksuvõlgade prognoosimisel väike mõju, samas kui solventsus ja likviidsus on olulisemad indikaatorid. Samuti näitasid Marghescu et al. (2010), et maksuvõlgade tuvastamine ainult finantssuhtarvude põhjal on keeruline, sest suur osa maksuvõlgadega ettevõtetest jäi tuvastamata, viidates vajadusele täiendavate muutujate järele. Abedin et al. (2020) leidsid, et ettevõtteid, millel on madal omakapitali osakaal ja madal likviidsus, on suurema tõenäosusega maksuvõlgased. Batista et al. (2012) leidsid, et finantssuhtarvude ja maksustamise efektiivse määra kombinatsioon võimaldab eristada maksuvõlgadeta ja maksuvõlgasest ettevõtteid, saavutades kõrgeima täpsuse 2008. aasta andmetel diskriminantanalüüsiga (72,4%).

Tabel 2

*Ülevaade varasematest maksuvõlgu prognoosivatest uuringutest*

<b>Autorid</b>	<b>Marghescu et al. (2010)</b>	<b>Batista et.al. (2012)</b>	<b>Höglund (2017)</b>	<b>Abedin et al. (2020)</b>
<b>Uuringu käsitlusala</b>	Tööandjamaksude tasumata jätmise prognoosimine järgmisel aastal	Järgmise aasta maksuvõla prognoos	Maksuvõlgade prognoosimine järgmisel ja ülejäägisel aastal	Maksuvõlgade prognoosimine samal ja järgmisel aastal
<b>Vaatluste periood</b>	2004	2007–2009	2014	2012–2014
<b>Ettevõtete arv ja riik</b>	328 Soome ettevõtet	600 Portugali kinnisvarabürood	768 Soome ettevõtet	768 Soome ettevõtet
<b>Meetodid</b>	LR	MDA, LR	MDA	LR ja 11 masinõppe meetodit
<b>Ennustavad muutujad</b>	Finantssuhtarvud	Finantssuhtarvud, maksustamise efektiivne määr	Finantssuhtarvud, kreditoorse võlgnevuse käibevalde	Finantssuhtarvud pankrotirisk, maksehäirerisk tööstuses
<b>Kõrgeima täpsusega mudeli ennustumäär</b>	61,6%	72,4%	73,8%	73,2%

*Märkus:* LR - logistiline regressioon, MDA - diskriminantanalüüs

Allikas: autorite koostatud

Üksikud uuringud (vt Tabel 3), on käsitletud maksuvõlga samaaegselt nii sõltuva kui ka ennustava muutujana ehk prognoosinud maksuvõla teket varasemate maksuvõlgade näitajatega. Siimon ja Lukason (2021) näitasid, et ettevõtte varasem maksukäitumine, eriti maksuvõlgade esinemine vahetult enne prognoositavat perioodi, on maksuvõla tekkimise prognoosimisel oluline tegur, saavutades maksimaalseks täpsuseks 95,28%. Eelmainitud uuring oli keskendunud järgmise kuu maksuvõlgade prognoosile, kuid sellised võlad võivad olla sageli ajutised ning tuleneda rahavoogude lühiajalisest volatiilsusest. Seetõttu oleks oluline prognoosida mitte ainult maksuvõlgade tekkimist lühiajalises perspektiivis, vaid püsivamaid maksuvõlgu, mis viitavad kestvamatele finantsraskustele. Lisaks on Su et al. (2018) uuringus käsitletud maksuvõlgade mõju nende tekkimisele järgmisel aastal, kus tulemused näitasid, et maksuvõlgade olemasolu on oluline tulevase maksuvõla tekkimise indikaator. Zheng ja Li (2023) töötasid välja maksuvõla prognoosimudeli, mis kasutas lisaks ettevõtte enda andmetele ka andmeid sellega seotud teiste ettevõtete kohta (nt ühised kontaktandmed ja juriidilised isikud). Uuring näitas, et ettevõtete võrgustikuga arvestamine võimaldab prognoositäpsust suurendada.

Tabel 3

*Ülevaade uuringutest, kus on kasutatud maksuvõlgade prognoosimisel ennustava muutujana maksuvõlgu*

<b>Autorid</b>	<b>Su et al. (2018)</b>	<b>Siimon &amp; Lukason (2021)</b>	<b>Zheng &amp; Li, (2023)</b>
<b>Uuringu käsitusala</b>	Maksuvõlgade prognoosimine järgmisel aastal	Maksuvõlgade prognoosimine järgmisel kuul	Maksuvõlgade prognoosimine järgmisel aastal
<b>Vaatluste periood</b>	2015–2016	2011–2018	2014–2021
<b>Ettevõtete arv ja riik</b>	120 000 Hiina ettevõtet	49 156 Eesti ettevõtet	986 471 Hiina ettevõtet
<b>Meetodid</b>	k-lähima naabri meetod, ANN, neli erinevat DT	DT, juhumets, k-lähima naabri meetod, ANN	DT
<b>Ennustavad muutujad</b>	Maksuvõlad, finantssuhtarvud, mittefinantsnäitajad	Maksuvõlad	EV-de ja nendega seotud EV-de maksuvõlad, EV karakteristikud ja makromajanduslikud näitajad
<b>Kõrgeima täpsusega mudeli ennustumäär</b>	90,6%	95,3%	99,2%

*Märkus:* ANN – tehisnärvivõrk, DT – otsustuspuu, EV – ettevõtte

Allikas: autorite koostatud

Üldiselt on maksuvõla prognoosimisele pühendatud uuringuid senises teaduskirjanduses vähe. Varasemad maksehäirete ja pankroti prognoosimise uuringud on näidanud, et erinevate maksehäirete (sh maksuvõlad) või muude mittefinantsmuutujate kaasamine prognoosimudelitesse parandab nende täpsust võrreldes lähenemisega, mis tuginevad üksnes finantsuhtarvudele. Maksuvõla kui sõltuva muutuja prognoosimist on senistes uuringutes käsitletud harva. Need tööd, mis prognoosisid maksuvõla teket, kuid kasutasid peamiselt finantsnäitajaid, saavutasid suhteliselt madala täpsuse (61,6–73,8%). Oluliselt täpsemad tulemused (90,6–99,2%) saavutati mudelites, kuhu lisati ka varasemad maksuvõlad ennustavate muutujatena, viidates varasema maksukäitumise olulisele rollile maksuvõla prognoosimisel.

Kui seni on keskendutud peamiselt maksuvõla prognoosimisele järgmisel kuul või aastal, siis käesoleva magistritöö uudsus seisneb selles, et lisaks maksuvõla tekke prognoosile prognoositakse ka selle ajalist kestust. Eelnevad uuringud on näidanud, et varasemate maksuvõla andmete lisamine prognoosimudelitesse tõstab mudeli prognoosivõimet pankroti ja maksehäirete prognoosimisel (tabel 1). Siiski on nende uuringute fookus olnud peamiselt maksehäire või pankroti olemasolul kui binaarsel nähtusel, käsitledes seda seega kas esineva või mitteesinevana. Üksikutes varasemates uuringutes on käsitletud ka maksuvõla prognoosimist sõltuva muutujana (Tabelid 2 ja 3). Nendes uuringutes leiti, et ainult finantsnäitajatel põhinevate mudelite täpsused jäid sageli madalamaks võrreldes mudelitega, kuhu oli lisatud ka varasemate maksuvõlgade andmed. Eriti selgelt tuli see esile Siimon ja Lukasoni (2021) ning Zheng ja Li (2023) uuringutes: esimeses kasutati ainult maksuvõlgade andmeid ja saavutati prognoositäpsus 95,28%, teises kaasati lisaks maksuvõlgadele ka ettevõtetevahelised seosed, mille tulemusena ulatus täpsus 99,17%-ni. See kinnitab, et maksuvõlgade tekkimine on tugevalt seotud varasema maksukäitumisega.

Senine teaduskirjandus ei ole eristanud maksuvõlgade kestusastmeid, kuigi varasemad uuringud (nt Marghescu et al., 2010; Höglund, 2017) on viidanud vajadusele täiendavate indikaatorite järele, et paremini eristada ajutisi likviidsusprobleeme püsivatest makseraskustest. Maksuvõlad ei pruugi alati viidata ettevõtte püsivatele makseraskustele, sest osa maksuvõlgadest võivad olla ajutise iseloomuga ning tuleneda näiteks ostjate poolsetest tasumiste viivitustest. Seetõttu on oluline prognoosimisel eristada maksuvõlgade kestusastmeid eraldamaks ajutised või lühiajalised maksuvõlad pikemaajalistest, mis viitavad võimalikule finantsilise jätkusuutlikkuse riskile.

Käesolev magistritöö keskendub maksuvõla eri kestusastmete (ajutine, lühiajaline, keskmise kestusega, pikaajaline) prognoosimisele. Prognoosimiseks kasutatakse kahte erinevat andmestikku: esimeses on sõltuv muutuja kodeeritud arvestades 2018. aasta kogu maksuvõlga ning teises ainult 2018. aasta ajatamata maksuvõlga. Autoritele teadaolevalt ei ole varasemates empiirilistes uuringutes eraldatud maksuvõlgade koguanandmestikust ajatamata maksuvõlgu. Siiski võib oluliseks osutada ajatamata maksuvõlgade eristamine, sest need võivad olla täpsemaks indikaatoriks ettevõtte finantsseisundi halvenemisest võrreldes ajatatud maksuvõlgadega. Ajatamata maksuvõlad võivad viidata vahetule maksejõuetusele (näiteks kui ettevõttel ei ole ajatamise võimalusel piisavalt raha maksuvõlgade osamakseteks) ja lahenduste puudumisele edasiseks jätkusuutlikuks tegevuseks.

## **2. Andmed, muutujad ja meetodid**

### **2.1. Andmed ja muutujad**

Käesolevas magistritöös kasutatakse kõigi 2017. aasta novembris Eestis tegutsevate residendist käibemaksudokumentatsioonist ettevõtete andmeid, kelle müügitulu oli nii 2016. kui 2017. aastal vähemalt 40 000 eurot. Maksuvõla andmed pärinevad Maksu- ja Tolliameti andmebaasist ning ettevõtete finants- ja muud (vanus ja eksportija staatus) andmed Äriregistrist. Magistritöö eesmärgiks on prognoosida maksuvõlgade teket, mitte jätkuvust, seetõttu on andmetest eemaldatud ettevõtted, millel esines maksuvõlg seisuga 31.12.2017. Lõplik andmestik koosnes 29 308 maksuvõlata ning 3 744 maksuvõlaga ettevõttest. Maksuvõlgadeta ettevõtetel puudusid maksuvõlad 2018. aasta kõikide kuude viimase kuupäeva seisuga ning maksuvõlaga ettevõtete jagunemine on toodud välja tabelis 4.

Käibemaksudokumentatsioonist ettevõtjal on kohustus esitada Maksu- ja Tolliametile tulu- ja sotsiaalmaksu, kohustusliku kogumispensioni ja töötuskindlustusmaksu deklaratsioon (TSD) iga järgneva kuu 10. kuupäevaks. Käibemaksu deklaratsioon (KMD) tuleb esitada iga järgneva kuu 20. kuupäevaks. (Maksu- ja Tolliamet, 2023; Käibemaksuseadus, 2025) TSD ja KMD esitamise kuupäevad varieeruvad ning ei võimalda ajaliselt ühtset võrdlusmomenti, seetõttu vaadeldakse käesolevas magistritöös maksuvõlgasid kuulõpu seisuga. Vältimaks COVID-19 kriisi põhjustatud mõju, on analüüsi kaasatud ainult 2018. aastal alanud maksuvõlgade episoodid. Maksuvõlgade andmestikus käsitletakse maksuvõlgade ajaperioode kuulõppude lõikes, kus igale ettevõttele tuvastati 2018. aastal alanud pikim maksuvõlgade jada. Sõltuva muutuja väärtus on 1 kui ettevõttel on maksuvõlg ning käesolevas magistritöös kasutatavad prognoositava maksuvõla

kestuse lühendid on järgnevad: ajutine, kestusega kuni 2 kuud (k.a) (AJUTMV), lühiajaline maksuvõlg kestusega vähemalt 3–5 kuud (k.a) järjest (LÜHMV), keskmise kestusega maksuvõlg 6–11 kuud (k.a) järjest (KESKMV) ning pikaajaline maksuvõlg kestusega vähemalt 12 kuud järjest (PMV). Maksuvõla kestuse kategooriaid käsitletakse kahel viisil, kogu andmestikus (sh nii ajatatud kui ka ajatamata maksuvõlad) ning eraldi kategooriana ainult ajatamata maksuvõlad (sõltuva muutuja tähisele lisatud tähis AJ). Maksu- ja Tolliameti andmestik ei kajastata eraldi ajatamata maksuvõlga, seetõttu on ajatamata maksuvõla väärtus arvatud kogu maksuvõla ja ajatatud maksuvõla vahena. Kui ettevõttel polnud 2018. aasta jooksul üksi kuu lõpp maksuvõlga, on sõltuva muutuja väärtus 0.

Tabel 4

*Maksuvõla kestuse ja ajatamise alusel liigitunud ettevõtete arv aastal 2018*

<b>Sõltuv muutuja</b>	0 – käibemaksukohustuslasest ettevõtte, millel ei esine 2018. aasta jooksul üksi kuu lõpp maksuvõlga (ettevõtete arv 29 308) 1 – käibemaksukohustuslasest ettevõtte, millel esineb vähemalt ühe kuu lõpu seisuga 2018. aastal maksuvõlg (ettevõtete arv on toodud all ning sõltub maksuvõla kestusest ja staatusest, st kas kokku või ainult ajatamata)
<b>Sõltuva muutuja lühend maksuvõla kestuse ja staatuse järgi</b>	<b>Ettevõtete arv</b>
AJUTMV	2 183
LÜHMV	618
LÜHMVAJ	264
KESKMV	448
KESKMVAJ	121
PMV	495
PMVAJ	128
<b>Maksuvõlaga ettevõtete arv kokku</b>	<b>3 744</b>

*Märkus:* Erineva kestusega maksuvõlaga ettevõtteid on kokku 3 744, s.t nelja erineva kestusega maksuvõlaga ettevõtete (järelliide MV) summa. Ajatamata võlga ettevõtted (järelliide MVAJ) on osakogum vastava kestusega üldkogumist.

Allikas: autorite koostatud

Ennustavad muutujad on jaotatud kolme rühma: maksuvõla näitajad, ettevõtte üldised tunnused ja finantssuhtarvud. Varasemad uuringud on näidanud otsevärdelist seost eelnevate maksehäirete ja tulevaste finantsraskuste tõenäosuse vahel (Andresson & Lukason, 2024; Back,

2005; Lukason & Valgenberg, 2021). Käesolevas magistritöös kasutatakse prognoosimisel varasemate perioodide andmeid maksuvõlgnevuste kohta, sh maksimaalse, keskmise ja mediaanväärtusena esitatud maksuvõla suurust ning maksuvõlga kuu lõppude arvu.

Käesolevas magistritöös käsitletakse ettevõtte üldiste tunnustena varade mahtu (bilansimaht), müügitulu suurust, ettevõtte vanust ning ekspordiva ettevõtte staatust (binaarne muutuja, mis näitab, kas ettevõtte tegeleb ekspordiga või mitte). Ettevõtte suurust ja vanust on peetud olulisteks teguriteks ebaõnnestumise prognoosimisel (Ciampi et al., 2021), mistõttu kaasati käesoleva magistritöö analüüsi vastavad muutujad hindamaks nende rolli maksuvõlgade prognoosimisel. Ühe ennustava muutujana on kasutatud binaarset tunnust, mis eristab ekspordiga tegelevaid ja mittetegelevaid ettevõtteid. Varasemates uuringutes (Forte & Salomé Moreira, 2018) on ekspordivaid ettevõtteid on peetud finantsiliselt edukamateks. Sellest lähtuvalt võib eeldada, et ekspordiga tegelemine vähendab maksuvõlgade tekke tõenäosust.

Tabelis 5 on analüüsis kasutatud ennustavad muutujad koos nende lühendite ja selgitustega. Lisaks on tabelis 5 iga ennustava muutuja juurde lisatud tähis  $\uparrow$  või  $\downarrow$ , mis tähistab kuidas maksuvõlgade tekke tõenäosus muutub tulenevalt ennustava muutuja käitumisest:  $\uparrow$  näitab, et muutuja suurenemisel kasvab maksuvõlgade tekkimise tõenäosus ja  $\downarrow$  näitab, et muutuja vähenemisel kasvab maksuvõlgade tekkimise tõenäosus.

Finantssuhtarvude valik põhineb kirjanduse ülevaatel ning praktilistel kaalutlustel. Kuna raamatupidamise seaduse (2025) §15 alusel võivad Eesti VKE-d esitada lühendatud raamatupidamise aastaaruande, siis valiti suhtarvud, mis on arvutatavad ka piiratud andmemahu korral. Kuigi finantssuhtarvude individuaalne täpsus on olnud madal, on nende lisamine prognoosimudelitesse suurendanud mudelite täpsust (Back, 2005; Lukason & Andresson, 2019).

Käesolevas magistritöös kasutatud finantssuhtarvud kajastavad ettevõtte likviidsust (LIKV), solventsust (SOLV), rentaablust (RENT) ja tootlikkust (PROD). Magistritöös kasutatud finantssuhtarvude väärtuste suurenemine peaks vähendama maksehäire tekkimise tõenäosust (Lukason & Vissak, 2024). Maksejõuetuse tõenäosuse hindamiseks rakendati tõenäosuslikku maksejõuetuse prognoosimudelit, mis põhineb Altmani Z-skoor mudeli edasiarendusel (Altman et al., 2017). Mida lähemal on vastava mudeli põhjal arvutatud tõenäosus  $p$  nullile, seda väiksema tõenäosusega esineb ettevõttel maksejõuetus. Tõenäosuse  $p$  suurenemisega, kasvab risk, et ettevõtte muutub maksejõuetuks. Antud mudeli puhul on murdepunktiks  $p = 0,5$ , millest

suuremate väärtuste korral on maksejõuetus tõenäolisem kui vastupidine olukord. Ennustavate muutujate väärtusi kasutatakse andmetes nii 2017. kui 2016. aasta kohta.

Tabel 5

*Analüüsis kasutatud ennustavad muutujad (rühmitatuna kolme domeeni)*

<b>Ennustava muutuja lühend ja eeldatava seose suund</b>	<b>Selgitus</b>
<b>Maksuvõla näitajad</b>	
MAXMV ↑	Maksuvõla maksimaalne väärtus – vaatlusperioodi jooksul esinenud suurim maksuvõlg ( <i>ln</i> )
KESKMV ↑	Maksuvõla keskmine väärtus ( <i>ln</i> )
MEDMV ↑	Maksuvõla mediaanväärtus ( <i>ln</i> )
MVK ↑	Maksuvõlaga kuu lõppude arv
<b>Ettevõtte üldised tunnused</b>	
VARAD ↓	Ettevõtte varade maht ( <i>ln</i> )
MÜÜK ↓	Ettevõtete müügitulu ( <i>ln</i> )
VANUS ↓	Ettevõtte vanus arvatud seisuga 31.12.2017
EKS ↓	Binaarne muutuja: 0 – ettevõtte tegeles vaatlusperioodi jooksul ekspordiga 1 – ettevõtte ei tegelenud vaatlusperioodi jooksul ekspordiga
<b>Finantssuhtarvudel põhinevad näitajad</b>	
LIKV ↓	(käibevara-lühiajalised kohustused)/koguvarad
SOLV ↓	omakapital/koguvarad
RENT ↓	puhaskasum/koguvarad
PROD ↓	müügitulu/koguvarad
RS ↑	$p = 1/(1 + e^{-P})$ $p$ = pankroti tõenäosus $P = 0,035 - 0,495 \times$ puhas käibekapital/koguvarad - $0,862 \times$ (omakapital-osa-/aktsiakapital)/koguvarad - $1,721 \times$ intresside ja maksude eelne kasum/koguvarad - $0,017 \times$ omakapital/kohustused kokku

*Märkus:* ↑-muutuja suurenemisel kasvab maksuvõlgade tekkimise tõenäosus, ↓- muutuja vähenemisel kasvab maksuvõlgade tekkimise tõenäosus. Ettevõtte vanus on arvatud seisuga 31.12.2017, lähtudes asutamise kuupäevast. Töös on ennustavatele muutujatele lisatud ka tähis T-1 või T-2, mis indikeerib sõltuvalt muutujale eelnevat või üle-eelnevat perioodi. Muutujat VANUS pole ainsana vajalik sellisel kujul eristada. Kõik maksuvõlgade muutujad põhinevad kaheteistkümne kuu lõpu väärtustel.

Allikas: autorite koostatud

Maksuvõlgade andmeid kasutatakse perioodi 31.12.2015–30.11.2017 kohta, sest ajahetk 31.12.2017 oli juba kasutusel andmestiku loomisel. Vastavalt maksukorralduse seaduse (2025) §14 lõikele 5 väljastab maksuhaldur tõendi maksuvõlgade puudumise kohta, kui ettevõtte maksuvõlg on alla 100 euro. Seetõttu eemaldati andmestikust ettevõtted, mille maksuvõlg oli seisuga 31.12.2017 alla 100 euro. Lisaks on andmestikust eemaldatud ettevõtted, millel oli 2016. ja 2017. majandusaasta aruanne esitamata. Edaspidises töös on ennustavate muutujate nimetustes lisatud tähis T-1 või T-2. Kõik ennustavad muutujad, mille nimetuses on tähis T-1, põhinevad 2017. aasta andmetel ja ennustavad muutujad, mille nimetuses on tähis T-2, põhinevad 2016. aasta andmetel.

## 2.2. Meetodid ja nende rakendamine

Pankroti ja maksejõuetuse prognoosimiseks on kasutatud nii statistilisi kui ka masinõppe meetodeid. Enim kasutatud meetodid on olnud logistiline regressioon (LR), tehisnärvivõrk (ANN) ja diskriminantanalüüs (MDA) (Alaka et al., 2018; Shi & Li, 2019; Veganzones & Severin, 2021). Ettevõtte maksejõuetuse prognoosimisel leidis mitme muutujaga diskriminantanalüüs esmakordselt kasutust Altman (1968) poolt.

Maksejõuetuse prognoosimisel on oluline arvestada veaga. Mida madalam on I tüübi vea (st. tegelikult maksejõuetuks muutuva ettevõtte ellu jäävaks klassifitseerimine) määr, seda sobivamaks mudelit peetakse. Seetõttu peetakse eelistatumaks ANN, otsustuspuu ja LR meetodeid, kuna nende I tüübi vead on väiksemad kui II tüübi vead, vastupidiselt MDA-le. (Alaka et al., 2018) I tüüpi vea vähendamiseks on olemas ka täiendav võimalus, mille kasutamist antud töös on järgnevalt kirjeldatud.

Käesolevas magistritöös on maksuvõlaga ja maksuvõlata ettevõtete jaotused oluliselt tasakaalust väljas ning see võib mõjutada masinõppemeetodite toimimist nii, et need optimeerivad ennast maksuvõlata ettevõtete täpsele klassifitseerimisele. Selle tulemusel võib väheneda mudeli täpsus maksuvõlaga ettevõtete tuvastamisel. Andmete tasakaalustamiseks kasutati sünteetilise vähemusklassi ülevalimise meetodit (SMOTE), mille abil loodi vähemusgrupi andmete põhjal kunstlikke vaatlusi seni, kuni mõlema grupi vaatluste arv ühtlustus. Sama meetodit on kasutatud ka teistes teadustöodes (nt. Altman et al., 2023; Andresson & Lukason, 2024; Cheraghal & Molnar, 2024). Finantssuhtarvude ekstreemsete väärtuste vähendamiseks rakendati andmestikus vinsoriseerimist, mille eesmärk on piirata väga suurte või väga väikeste väärtuste moonutavat mõju. Ettevõtete müügitulu, bilansimahu ja

maksuvõla muutujate puhul kasutati naturaalloogarithmimist (tabelis 5 on naturaalloogarithmitud näitajate väärtuste juures tähis  $ln$ ). Antud lähenemist on kasutatud varasemates teadustöödes (nt. Andresson & Lukason, 2024; Altman et al., 2017; Mramor & Valentincic, 2003).

Käesolevas magistrisööses kasutatakse maksuvõlgade prognoosimiseks meetodeid, mis kuuluvad populaarsemate ja tõhusamateks peetud meetodite hulka: logistilist regressiooni ja tehisnärvivõrku. Samasugust meetodite kombinatsiooni on kasutatud ka varasemates teadustöödes (nt. Andresson & Lukason, 2024; Charitou et al., 2004; Lukason & Valgenberg, 2021). Logistiline regressioon võimaldab hinnata üksikute ennustavate muutujate mõju suunda ja olulisust. Kuid tehisnärvivõrk masinõppe meetodina suudab keerukamate mustrite kaudu sageli saavutada kõrgema prognoositäpsuse (Alaka et al., 2018; Ravi Kumar & Ravi, 2007; Sun et al., 2014).

Logistilist regressiooni kasutades leiti prognoositäpsused kõigi üksikmuutujate lõikes. Seejärel leiti prognoositäpsus domeenide siseselt (st kasutades kõiki vastava domeeni ennustavaid muutujaid korraga) maksuvõlgade, ettevõtte üldiste tunnuste ja finantsuhtarvude lõikes ning lõpuks kõigi domeenide peale kokku. Sama lähenemist rakendati nii ajatamata kui ka kogu maksuvõlgade andmestiku puhul. Ennustava muutuja kordaja (+/-) näitab kas selle suurenemisel suureneb (kordaja +) või väheneb (kordaja -) maksuvõla tekke tõenäosus. Logistilise regressiooni puhul kasutati kõiki vaatlusi korraga, kuid tehisnärvivõrkude puhul kasutati 70% vaatlustest mudeli treenimiseks ja 30% testimiseks, et vältida ülehindamist. Mudeli usaldusväärsuse suurendamiseks on seda lähenemist soovitanud ka Cheraghali ja Molnár (2024). Sarnaselt logistilisele regressioonile koostati ANN mudelid domeenide põhiselt ja üleselt. Lisaks prognoositäpsusele toodi ANN mudelite puhul välja AUC<sup>1</sup> näitaja. AUC väärtust üle 0,7 loetakse heaks ja üle 0,9 suurepäraseks klassifitseerimise tulemuseks (Zheng & Li, 2023). Statistiliseks analüüsiks kasutati statistikaprogrammi SPSS.

### 3. Tulemused ja arutelu

Tabelites 6 ja 7 on esitatud üksikmuutujate mõju suund ning prognoositäpsus sõltuvalt järgmisel perioodil kujuneva maksuvõla kestusest. Tabel 6 käsitleb kõiki maksuvõlgasid (sh ajatatud) ja tabel 7 keskendub vaid ajatamata maksuvõlgadele.

---

<sup>1</sup> AUC tähendab ROC kõvera alust pindala, pikema lühendina AUROC, mis inglise keeles on „area under the receiver operating characteristic curve“

Tabel 6

*Kogu maksuvõla prognoosil üksikmuutujate seos maksuvõlgade tekkimise tõenäosusega ja prognoositäpsus*

Ennustav muutuja	PMV	Täpsus	KESKMOV	Täpsus	LÜHMV	Täpsus	AJUMV	Täpsus
MAXMV T-1	+	75,8%	+	79,4%	+	78,6%	+	67,9%
MAXMV T-2	+	71,5%	+	74,1%	+	72,1%	+	65,7%
KESKMOV T-1	+	75,8%	+	79,4%	+	78,6%	+	67,9%
KESKMOV T-2	+	71,5%	+	74,1%	+	72,1%	+	65,7%
MEDMV T-1	+	63,0%	+	64,2%	+	60,2%	+	52,7%
MEDMV T-2	+	60,4%	+	60,7%	+	59,0%	+	53,6%
MVK T-1	+	75,8%	+	79,4%	+	78,6%	+	67,9%
MVK T-2	+	71,5%	+	74,1%	+	72,1%	+	65,7%
VARAD T-1	-	52,1%	-	53,9%	-	53,7%	-	55,2%
VARAD T-2	-	52,9%	-	54,6%	-	53,3%	-	54,9%
MÜÜK T-1	+	53,3%	-	51,2%	-	52,4%	-	55,4%
MÜÜK T-2	+	52,2%	-	52,6%	-	52,2%	-	55,4%
VANUS	-	57,8%	-	54,9%	-	54,5%	-	53,8%
EKS T-1	-	50,7%	-	54,8%	-	53,2%	-	52,6%
EKS T-2	-	50,6%	-	54,8%	-	52,8%	-	52,3%
LIKV T-1	-	61,7%	-	59,0%	-	56,6%	-	53,5%
LIKV T-2	-	59,9%	-	59,0%	-	56,4%	-	53,2%
SOLV T-1	-	65,2%	-	62,9%	-	59,7%	-	55,3%
SOLV T-2	-	62,1%	-	60,9%	-	57,8%	-	55,0%
RENT T-1	-	55,2%	-	56,0%	-	55,4%	-	52,8%
RENT T-2	-	53,0%	-	53,6%	-	54,8%	-	51,6%
PROD T-1	+	53,2%	+	53,5%	+	52,5%	+	50,8%
PROD T-2	+	53,6%	+	53,7%	+	51,8%	+	51,1%
RS T-1	+	62,6%	+	61,9%	+	60,6%	+	55,3%
RS T-2	+	60,8%	+	60,3%	+	58,0%	+	54,6%

*Märkus:* + muutuja suurenemisel kasvab maksuvõlgade tekkimise tõenäosus, - muutuja suurenemisel väheneb maksuvõlgade tekkimise tõenäosus

Allikas: autorite koostatud

Kõik eelnevate perioodide maksuvõlaga seotud näitajad on positiivselt seotud maksuvõla tekkimise tõenäosusega tulevikus, mis viitab sellele, ettevõtte maksekäitumine on ajas püsiv ning varasemad makseraskused on olulised korduvate maksehäirete ennustajad (Lukason & Valgenberg, 2021; Marmor & Lukason, 2024; Back, 2007). Samas ettevõtte üldiste tunnuste ja finantssuhtarvude väärtuste suurenemine vähendab tõenäosust maksuvõla tekkeks. Erandina ilmneb kogu maksuvõla kontekstis, et pikaajalises horisondis (vähemalt 12 kuud) suurendab müügitulu suurenemine maksuvõla tekke tõenäosust nii perioodil T-1 kui T-2. Samas viitab väga madal prognoositäpsus (MÜÜK T-1=53,3%, MÜÜK T-2=52,2%) sellele, et antud muutujal sisuliselt puudub võime maksuvõlaga ja maksuvõlata ettevõtteid eristada. Ka Höglund (2017)

Soome ettevõtete maksuvõlgade prognoosimise uuringus ei täheldatud olulisi erinevusi maksuvõlaga ja maksuvõlata ettevõtete müügitulus. Küll aga ilmned Höglund (2017) uuringu kirjeldava statistika andmetest, sarnaselt käesoleva magistr töö tulemustega, erinevused rentaablu sees ja solventsuses, mis viitavad maksuvõlaga ettevõtete finantsraskustele. Varasemates uuringutes (nt Weitzel & Jonsson, 1989) on madalamat finantstulemuslikkust käsitletud kui ettevõtte võimaliku langustrendi varajast näitajat. Isegi kui lühiajaline rentaablu langus ei pruugi viia maksejõuetuseni, võib see tähendada halvenenud solventsust ja suurenenud likviidsusriski.

Käesolevas magistr töödes ilmneb teaduskirjanduses tavapäraselt esitatud ootustest erinev mõju ka tootlikkusele. Tootlikkuse kasv on positiivselt seotud maksuvõla tekkimise tõenäosusega kõigis prognoosihorizontides ja mõlemas andmestikus (st kogu või ajatamata maksuvõlga prognoosimisel). See tulemus on kooskõlas varasemate uuringutega (nt Lukason & Andresson, 2019; Lukason & Valgenberg, 2021; Lukason & Vissak, 2024), mille kohaselt võib varade tootlikkus ebaõnnestuvates VKE-des näiliselt suurened, kuna bilansimaht väheneb kiiremini kui müügitulu. Antud andmestikus kinnitab seda ka kirjeldav statistika (vt Lisa A), kus tootlikkuse keskmised on mitmetes maksuvõlaga gruppides kõrgemad kui maksuvõlata ettevõtetes (nt PROD T-2 maksuvõlata ettevõtetel on 2,30, aga pikaajalise kestusega ajatamata maksuvõlaga ettevõtetel 2,78). See viitab sellele, et tootlikkuse suhtarvu kasutamine üksinda võib olla piiratud usaldusväärsusega, eriti väiksemate ettevõtete puhul, kuid sellel võib olla oluline roll keerukamates prognoosimudelites, mis arvestavad muutujate omavahelist koostoimet.

Ennustavad muutujad, mis mõõdavad varasemat maksuvõlgade olemasolu (MAXMV, KESKMV, MEDMV, MVK), saavutavad järjepidevalt kõrge täpsuse ka ajatamata maksuvõla prognoosimisel. Kõrgeimad täpsused saavutati nende muutujatega keskmise kestusega ajatamata maksuvõla prognoosimisel. Näiteks MAXMV T-1 ja KESKMV T-1 prognoositäpsus ulatus kuni 87,3%-ni. See tulemus on seotud asjaoluga, et nendel juhtudel esineb varasemate maksuvõlanäitajate keskmistes väärtustes suur erinevus maksuvõlata ja maksuvõlaga ettevõtete vahel. Näiteks on maksuvõlata ettevõtetel 2017. aastal keskmine maksuvõla logaritmitud väärtus (KESKMV T-1) 0,29, samas kui keskmise kestusega ajatamata maksuvõlaga ettevõtetel on sama näitaja 5,32. Sarnased mustrid kehtivad ka teiste maksuvõlanäitajate puhul, viidates sellele, et maksuvõlgade olemasolu ja suurus on tugevalt seotud maksuvõlgade tekkimisega tulevikus. Samale järeldusele jõudsid oma uuringus ka Lukason ja Valgenberg (2021), leides, et

maksuvõlgadega seotud muutujad, sealhulgas keskvaärtused ja mediaanid, võimaldavad olulisel määral eristada maksejõulisi ja maksejõuetuid ettevõtteid.

Tabel 7

*Ajamatata maksuvõla prognoosil üksikmuutujate käitumine ja prognoositäpsus*

<b>Ennustav muutuja</b>	<b>PMVAJ</b>	<b>Täpsus</b>	<b>KESKMVAJ</b>	<b>Täpsus</b>	<b>LÜHMVAJ</b>	<b>Täpsus</b>
MAXMV T-1	+	76,5%	+	87,3%	+	83,0%
MAXMV T-2	+	72,6%	+	83,6%	+	78,2%
KESKMV T-1	+	76,5%	+	87,3%	+	83,0%
KESKMV T-2	+	72,6%	+	83,6%	+	78,2%
MED T-1	+	65,7%	+	70,0%	+	61,9%
MED T-2	+	60,8%	+	66,4%	+	61,0%
MVK T-1	+	76,5%	+	84,4%	+	83,0%
MVK T-2	+	72,6%	+	81,4%	+	78,2%
VARAD T-1	-	55,4%	-	56,5%	-	56,2%
VARAD T-2	-	55,8%	-	59,4%	-	55,5%
MÜÜK T-1	-	49,8%	-	55,0%	-	56,7%
MÜÜK T-2	-	52,7%	-	54,8%	-	56,9%
VANUS	-	58,6%	-	53,9%	-	52,2%
EKS T-1	-	55,0%	-	54,3%	-	53,6%
EKS T-2	-	52,9%	-	53,8%	-	53,9%
LIKV T-1	-	58,2%	-	54,4%	-	54,2%
LIKV T-2	-	56,0%	-	53,1%	-	55,4%
SOLV T-1	-	65,5%	-	62,2%	-	58,2%
SOLV T-2	-	61,5%	-	60,1%	-	58,1%
RENT T-1	-	55,0%	-	57,1%	-	56,8%
RENT T-2	-	55,0%	-	53,1%	-	53,5%
PROD T-1	+	53,4%	+	53,6%	+	50,3%
PROD T-2	+	51,3%	+	54,1%	+	49,7%
RS T-1	+	61,7%	+	61,0%	+	59,6%
RS T-2	+	60,6%	+	57,8%	+	57,7%

*Märkus:* + muutuja suurenemisel kasvab maksuvõlgade tekkimise tõenäosus, - muutuja suurenemisel väheneb maksuvõlgade tekkimise tõenäosus

Allikas: autorite koostatud

Nii kogu maksuvõla kui ka ajamatata maksuvõla prognoosimisel näitasid ettevõtte üldised tunnused oluliselt madalamat prognoositäpsust (alla 60%) võrreldes varasemate maksuvõlanäitajatega. Prognoositäpsus jäi ettevõtte vanuse puhul vahemikku 52,2–58,6%, eksportijaks olemise puhul 50,6–55,0% ning müügitulu korral 49,8–56,9%. Need tulemused viitavad sellele, et maksuvõlaga ja maksuvõlata ettevõtted ei erine ettevõtte üldiste tunnuste lõikes oluliselt. Seda järeldust toetab ka kirjeldav statistika, sest näiteks logaritmitud müügitulu keskmised maksuvõlaga ja maksuvõlata ettevõtete puhul olid väga sarnased (nt MÜÜK T-1:

maksuvõlata ettevõtetel 12,64, aga pikaajalise kestusega maksuvõlaga ettevõtetel 12,72). Ka finantssuhtarvud eraldivõetuna ei oma kõrget prognoosimistäpsust. Parima prognoosivõimega on solventsuse suhtarv (SOLV), täpsusega 55–65,5%. Ülejäänud kasutatud finantssuhtarvude prognoositäpsus jäi veel madalamaks (49,7%-61,7%). Kirjeldava statistika analüüsis on märgata maksuvõlgu omavatel ettevõtetel finantssuhtarvude väärtuste vähenemist, samas maksuvõlgadeta ettevõtete finantssuhtarvude keskmised perioodil T-1 on kõrgemad võrreldes eelneva perioodiga. Kuigi nende prognoositäpsus üksikmuutujatena on madal, erinevad nende väärtused maksuvõlaga ja maksuvõlata ettevõtete vahel. Näiteks on maksuvõlaga ettevõtete rentaablus perioodil T-1 keskmiselt kaks korda madalam kui pikaajalise maksuvõlata ettevõtetel (RENT T-1 maksuvõlata ettevõtetel on 0,1, aga pikaajalise kestusega ajatamata maksuvõlaga ettevõtetel on 0,05). Samuti on likviidsusnäitaja pikaajalise maksuvõlaga ettevõtetel madalam (nt LIK T-1: maksuvõlata ettevõtetel on 0,36, aga pikaajalise kestusega ajatamata maksuvõlaga ettevõtetel 0,12), viidates nende väiksemale võimekusele katta lühiajalisi kohustusi. Erandiks on tootlikkuse suhtarv, mis oli maksuvõlaga ettevõtetel analüüsitud kahe perioodi jooksul kõrgem. Ka Lukason ja Vissak (2024) uuringus käitus see finantssuhtarv Eesti ja Prantsusmaa ettevõtete puhul teistest finantssuhtarvudest erinevalt, sest tootlikkuse suhtarvu suurenemine suurendas ebaõnnestumise tõenäosust. Uuringust selgub, et ebaõnnestunud ettevõtetel püsib tulude teenimise võime veel suhteliselt stabiilsena, kuid samal ajal halvenevad järk-järgult rentaablus, solventsus ja likviidsus, viidates süvenevatele finantsprobleemidele.

Üksikmuutujate prognoositäpsus sõltub selgelt muutuja olemusest ja kontekstist. Kõige paremini ennustavad maksuvõla teket varasemad maksuvõlanäitajad, eeskätt keskmise kestusega ja ajatamata maksuvõlgade prognoosimisel, mille põhjuseks on varasem maksukäitumine. Siimon ja Lukason (2021) tuvastasid maksuvõla ennustamisel seaduspära, et mida sagedamini on ettevõttel varasematel kuudel esinenud maksuvõlga, seda suurem on tõenäosus, et maksuvõlg esineb ka järgmisel kuul. Samas on ettevõtte finantssuhtarvude individuaalne täpsus madal, kuigi kirjeldav statistika toob välja selged erinevused maksuvõlaga ja maksuvõlata ettevõtete finantssuhtarvude väärtustes. Eelnev on kooskõlas varasema kirjandusega, kus näiteks Altman (1968) leidis, et osa suhtarve ei oma märkimisväärset prognoosivõimet, kuid võimaldavad mudelisse lisatuna selle täpsust suurendada.

Alljärgnevatel tabelites 8 ja 9 on esitatud domeenipõhiste ja domeeniüleste mudelite prognoositäpsused. Tabel 8 kajastab kogu maksuvõla ja tabel 9 ajatamata maksuvõla

prognoositulemusi. Domeenipõhise logistilise regressiooni tulemused näitasid, et nii kogu maksuvõla kui ka ajatamata maksuvõla prognoosimisel andsid maksuvõlaga seotud ajaloolised andmed (nii perioodil T-1 kui ka T-2) kõrgema prognoositäpsuse kui ettevõtte üldised tunnused või finantssuhtarvud. Kõige madalama täpsusega olid ettevõtte üldised tunnused, mille prognoositäpsus ületas 60% ainult ajatamata pika maksuvõla mudelis. Finantssuhtarvudel põhinevate mudelite prognoositäpsus ületas ettevõtte üldiste tunnuste prognoositäpsuse, kuid jäi siiski märkimisväärselt madalamaks võrreldes maksuvõlanäitajatel põhinevate mudelitega.

Tabel 8

*Domeenipõhiste ja domeeniüleste mudelite prognoositäpsused logistilise regressiooniga kogu maksuvõla korral*

<b>Ennustavad muutujad</b>	<b>PMV</b>	<b>KESKMOV</b>	<b>LÜHMV</b>	<b>AJUMV</b>
Maksuvõlad T-1	75,8%	79,4%	78,6%	67,9%
Maksuvõlad T-2	71,5%	74,1%	72,1%	65,7%
Maksuvõlad mõlemad aastad	78,4%	81,7%	80,4%	71,9%
Ettevõtte üldised tunnused T-1	58,6%	57,2%	55,4%	55,9%
Ettevõtte üldised tunnused T-2	59,1%	55,6%	55,2%	55,9%
Ettevõtte üldised tunnused mõlemad aastad	59,2%	56,0%	55,4%	55,9%
Finantssuhtarvud T-1	64,8%	63,5%	60,0%	55,1%
Finantssuhtarvud T-2	61,9%	61,9%	58,5%	55,3%
Finantssuhtarvud mõlemad aastad	66,1%	63,0%	60,0%	56,1%
Kõik muutujad T-1	77,9%	80,9%	78,9%	68,1%
Kõik muutujad T-2	73,1%	75,7%	72,7%	66,3%
Kõik muutujad mõlemad aastad	81,0%	82,6%	80,4%	71,8%

Allikas: autorite koostatud

Tulemused viitavad sellele, et ajaliselt lähim periood (T-1 aasta andmed) võimaldab üldjuhul kõrgemat prognoosivõimet kui T-2 aasta andmed. See kinnitab, et ettevõtte hiljutine finants- ja maksukäitumine on maksuvõla kujunemisel suurema tähendusega. Sarnasele järeldusele jõudsid ka Lukason ja Andresson (2019). Nende uuringust selgus, et maksuvõlgade prognoosivõime on kõrgem pankrotile eelneval perioodil ning väheneb kui ebaõnnestumiseni jääv ajaperiood pikeneb. Samas selgus käesolevas magistritöös, et parima täpsuse tagas kahe aasta andmestiku kombineeritud kasutamine, sest see võimaldab mudelil arvestada nii lühi- kui ka pikemaajalisi mustreid ja suundumusi. Ka Lukason ja Vissak (2024) uuring näitas, et ennustavate muutujate olulisus võib ajas varieeruda. Ebaõnnestuvatel ettevõtetel halvenevad vastavate näitajate väärtused aja jooksul ning kahe perioodi andmete kombineeritud kasutamine annab prognoosimisel parima tulemuse.

Kogu maksuvõla prognoosimisel osutus kõige täpsemaks keskmise kestusega maksuvõlga prognoosiv (KESKMV) domeeniülene mudel, mille täpsus ulatus mõlema ajaperioodi kõikide muutujate kasutamisel 82,6 protsendini. Ajatamata maksuvõla prognoositäpsused olid tervikuna kõrgemad kui kogu maksuvõla prognoositäpsused. Kõikide ajatamata maksuvõla kestushorisontide prognoositäpsus oli üle 80%. Mõlema aasta andmeid kombineerides saavutati kõrgeim prognoositäpsus KESKMVAJ mudeliga, mille täpsus ajatamata maksuvõla prognoosimisel ulatus 92,1%-ni. See oli ligikaudu 10 protsendipunkti kõrgem võrreldes kogu maksuvõla andmetel põhineva mudeliga.

Keskmise kestusega ajatamata maksuvõla kõrgem prognoositäpsus tuleneb sellest, et selliste juhtumite puhul esineb sageli korduv võlatsükkel, mis tähendab, et perioodil T tekkinud võlale on eelnenud mitmeid kuid kestnud võlg perioodil T-1, mis on lühiajaliselt katkenud. Seda tulemust toetavad ka varasemad uuringud, mis on näidanud, et halb maksekäitumine kipub ajas korduma (Mramor & Valentincic, 2003). Samas osutus kõige vähem täpseks ajutise kestusega maksuvõla (AJUTMV) mudel, mille kõrgeim prognoositäpsus oli 71,8%, viidates sellele, et ajutise maksuvõla kujunemine on juhuslikum ja vähem mudelitega prognoositav.

Tabel 9

*Domeenipõhiste ja domeeniüleste mudelite prognoositäpsused logistilise regressiooniga ajatamata maksuvõla korral*

<b>Ennustavad muutujad</b>	<b>PMVAJ</b>	<b>KESKMVAJ</b>	<b>LÜHMVAJ</b>
Maksuvõlad T-1	76,5%	87,3%	83,0%
Maksuvõlad T-2	72,6%	83,6%	78,2%
Maksuvõlad mõlemad aastad	79,4%	89,7%	85,0%
Ettevõtte üldised tunnused T-1	61,5%	57,9%	57,8%
Ettevõtte üldised tunnused T-2	62,2%	59,6%	56,5%
Ettevõtte üldised tunnused mõlemad aastad	62,1%	57,9%	58,1%
Finantssuhtarvud T-1	66,8%	61,4%	57,6%
Finantssuhtarvud T-2	63,3%	59,8%	58,8%
Finantssuhtarvud mõlemad aastad	66,9%	63,1%	60,0%
Kõik muutujad T-1	80,7%	88,3%	83,6%
Kõik muutujad T-2	76,2%	85,2%	77,5%
Kõik muutujad mõlemad aastad	82,5%	92,1%	84,6%

Allikas: autorite koostatud

Tabelis 10 on esitatud ANN tulemused, mis näitavad, et tehisnärvivõrk saavutas kõrgemad täpsused kui logistiline regressioon kõigis mudelites, parandades prognoositäpsust märkimisväärselt pikaajalise, keskmise ja lühiajalise kestusega ajatamata maksuvõla

prognoosimisel. Pikaajalise kestusega ajatamata maksuvõla prognoosimisel ületasid ANN kahe perioodi finantssuhtarvude kombineeritud kasutamisel saavutatud täpsusnäitajad maksuvõlgade prognoositäpsust (mõlema aasta maksuvõlgade täpsus 80,9%, mõlema aasta finantssuhtarvude täpsus 81,1%).

Lisaks kõrgele täpsusele on mudelitel ka suurepärased AUC näitajad. Kõigi mudelite, välja arvatud ajutise maksuvõla mudeli, AUC väärtused on suuremad kui 0,9. Kõrgeimad AUC väärtused saavutati mudelitega KESKMVAJ (0,986) ja PMVAJ (0,971). Cheraghali ja Molnár (2024) kirjanduse ülevaates oli ANN parim AUC tulemus Da ja Pengi (2023) krediidiriski prognoosimudel (0,949), kusjuures selles kirjanduse ülevaates oli Da ja Peng (2023) mudeli prognoositäpsus üks kõrgeima täpsusastmega mudeleid ka ANN-ist veel keerukamate meetodite hulgas.

Tabel 10

*Domeenipõhiste ja domeeniüleste mudelite prognoositäpsused tehisnärvivõrguga.*

<b>Ennustavad muutujad</b>	<b>PMV</b>	<b>PMVAJ</b>	<b>KESKMV</b>	<b>KESKMVAJ</b>	<b>LÜHMV</b>	<b>LÜHMVAJ</b>	<b>AJUTMV</b>
Maksuvõlad T-1	76,7%	77,2%	79,5%	87,7%	78,8%	83,2%	68,7%
Maksuvõlad T-2	72,2%	73,2%	74,2%	83,8%	72,4%	78,3%	66,4%
Maksuvõlad mõlemad aastad	79,0%	80,9%	82,2%	89,7%	80,5%	85,4%	72,3%
Ettevõtte üldised tunnused T-1	61,9%	65,4%	58,1%	64,6%	57,2%	59,5%	57,2%
Ettevõtte üldised tunnused T-2	61,4%	64,6%	57,4%	63,8%	56,6%	59,0%	57,0%
Ettevõtte üldised tunnused mõlemad aastad	61,7%	72,1%	59,9%	68,6%	56,0%	63,2%	57,2%
Finantssuhtarvud T-1	67,3%	73,9%	63,5%	66,2%	60,9%	62,5%	55,9%
Finantssuhtarvud T-2	65,6%	72,1%	62,7%	62,6%	60,2%	61,0%	55,9%
Finantssuhtarvud mõlemad aastad	69,6%	81,1%	66,1%	74,4%	63,5%	67,3%	56,8%
Kõik muutujad T-1	82,8%	92,2%	83,6%	95,8%	80,7%	89,0%	68,9%
Kõik muutujad T-2	78,2%	91,3%	78,8%	94,2%	75,0%	82,9%	66,8%
Kõik muutujad mõlemad aastad	87,3%	95,5%	88,3%	97,9%	85,2%	93,0%	72,5%
AUC	0,924	0,971	0,938	0,986	0,917	0,953	0,781

*Märkus:* AUC on viimase mudeli ehk “Kõik muutujad mõlemad aastad” kohta

Allikas: autorite koostatud

LR kasutamisel olid maksuvõlaga seotud ennustavad muutujad järjepidevalt kõige kõrgema täpsusega. Samas paranesid ANN kasutamisel pikaajalise ja keskmise kestusega ajatamata maksuvõla prognoosimisel finantssuhtarvude prognoositäpsused. Erinevate maksuvõla muutujate sarnasuse (sh ka korreleerituse) tõttu ei paranenud nende prognoositäpsus. See

tulemus kinnitab, et ANN suutis finantssuhtarvude puhul keerukamaid mustreid ja mittelineaarseid seoseid andmetes tõhusamalt tuvastada kui LR (Jayasekera, 2018).

Tulemused näitavad, et nii logistilise regressiooni kui ka tehisnärvivõrgu puhul prognoosivad tulevast maksuvõlga kõige täpsemalt varasemate perioodide maksuvõlad. Saadud tulemus on kooskõlas varasemate uuringutega, kus maksuvõlgade muutujad on näidanud kõrgemat prognoosivõimet ebaõnnestumise prognoosimisel (Lukason & Andresson, 2019; Lukason & Valgenberg, 2021; Kohv & Lukason, 2021; Andresson & Lukason, 2024) ning uuringutega, mis on näidanud, et varasemad maksehäired suurendavad tõenäosust nende tekkimiseks ka tulevikus (Back, 2007; Marmor & Lukason, 2024). Nii LR kui ka ANN saavutasid kahe perioodi võrdluses kõrgemad prognoositäpsused kui kasutati perioodil T-1 andmeid. See viitab sellele, et maksuvõla tekkimisele ajaliselt lähema perioodi andmete kasutamine tõstab mudelite prognoositäpsust. Seevastu kaugema perioodi andmete kasutamisel (T-2) jääb mudelite prognoosivõime madalamaks, mis on kooskõlas varasemate uuringutega (Lukason & Andresson, 2019; Siimon & Lukason, 2021). Kõrgeimad prognoositäpsused saavutati aga mõlema perioodi andmete kombineeritud kasutamisel. See näitab, et kahe järjestikuse perioodi andmete kasutamine prognoosimudelites võimaldab paremini kajastada ettevõtte finantsolukorra dünaamikat ning tuvastada mustreid, mis ei pruugi ilmnedagi ühe perioodi andmeid kasutades. Ka Lukason ja Vissak (2024) on välja toonud, et paljude VKE-de raamatupidamise aastaaruannetes kajastatud finantsnäitajad ei näita vahetult enne ebaõnnestumist tulemuslikkuse langust. Seetõttu võib ainult viimase majandusaasta andmete põhjal tehtud hinnang olla ekslik, aga samas võib mitme perioodi vaatluses ilmnedagi järkjärguline finantsseisundi halvenemine.

Varasemad uuringud on näidanud finantssuhtarvude tagasihoidlikku prognoositäpsust maksuvõlgade (Marghescu et al., 2010), pangalaenu maksejõuetuse (Kohv & Lukason, 2021) või pankroti prognoosimisel (Lukason & Andresson, 2019). Ka käesoleva magistr töö tulemused näitavad, et kuigi finantssuhtarvud ilma täiendavate muutujateta omavad piiratud prognoosivõimet, paranevad mudelite prognoositäpsused oluliselt, kui lisaks kasutada maksuvõlgade ajaloolisi andmeid aga ka ettevõtte üldiseid tunnuseid. Need tulemused on kooskõlas varasemate uuringutega, mille kohaselt finantssuhtarvudele täiendavate muutujate lisamine on suurendanud prognoosimudelite täpsust (Lukason & Andresson, 2019; Kohv & Lukason, 2021). Käesolevas magistr töö saadakse üldjuhul kõrgemad prognoositäpsused

ajatamata maksuvõlgade prognoosimisel kui kogu maksuvõlgade prognoosimisel. Kõrgeim prognoositäpsus saavutati tehiskäitumise kasutades keskmise kestusega ajatamata maksuvõla prognoosimisel, kui mudelis kasutati mõlema perioodi (T-1 ja T-2) ennustavate muutujate andmeid. Vastava ANN mudeli prognoositäpsus ulatus 97,9%-ni. Selle mudeli AUC väärtus 0,986 on üks kõrgemaid tulemusi ka varasemate keerukamate meetodite hulgas (vt Cheraghal & Molnar, 2024). See viitab sellele, et ajatamata maksuvõlgade teke on statistiliselt paremini eristatav kasutades ettevõtte finantsnäitajaid, varasemate maksuvõlgade andmeid ja ettevõtte üldisi tunnuseid. Üheks võimalikuks põhjuseks on asjaolu, et ajatamata maksuvõlad on sageli seotud püsivamate likviidsusprobleemidega ning ettevõtetel esineb järjepidevam maksuvõla ajalugu, mille tõttu ajatamist ei võimaldata ning mille olemasolu peegeldub finantsnäitajates. Ka Siimon ja Lukason (2021) leidsid, et kui VKE satub likviidsuskriisi, mida näitab maksuvõlg mitmel kuul järjest, siis on väga tõenäoline, et olukord ei lahene iseenesest, vaid kujuneb pikemaks maksuvõlgade jadaks. Samas võivad väiksemad ja lühiajalised maksuvõlad jääda menetluspraktika või -kriteeriumide tõttu ajatamata või ei peeta neid ajatamist väärivateks. Sellest hoolimata võivad need võlad esineda püsivalt korduvate episoodidena, andes märku ettevõtte likviidsusprobleemidest. Ajatatud maksuvõlad võivad seevastu peegeldada ettevõtte teadlikke finantsotsuseid, mis ei pruugi otseselt viidata makseraskustele, mistõttu nende prognoosimine on keerulisem.

Käesolev magistritöö annab panuse maksuvõlgade prognoosimise ja ettevõtete finantskäitumise uurimisse, täiendades senist teaduskirjandust mitmel viisil. Esiteks käsitleti maksuvõlga erineva kestuse alusel, mis võimaldab hinnata mitte üksnes võla olemasolu, vaid ka selle püsimist. Teiseks kasutati nii kogu maksuvõla kui ka ajatamata maksuvõla andmeid, mis võimaldas hinnata, mis tüüpi andmestik aitab paremini prognoosida erineva kestusega maksuvõlgu. Kolmandaks võrreldi eraldi T-1 ja T-2 perioodi andmetel põhinevaid mudeleid ning nende kombineeritud kasutamist. Tulemused näitasid, et kahe aasta andmete kombineeritud kasutamine parandab mudelite täpsust. Samas osutusid T-1 andmed eraldiseisvalt täpsemaks kui T-2 andmed, viidates sellele, et maksukäitumise hiljutine ajalugu on tugevam indikaator. Magistritöös rakendati kahte erinevat prognoosimeetodit, logistilist regressiooni ja tehiskäitumisküsimusi. Tulemused näitavad, et masinõppepõhised lähenemised saavutavad kõrgemad klassifitseerimistäpsused, mis on kooskõlas varasemate uuringutega (Alaka et al., 2018; Ravi Kumar & Ravi, 2007; Sun et al., 2014). Tulemused viitavad, et ettevõtte varasemate

maksuvõlgade olemasolu on tugev indikaator maksuvõla tekkimise prognoosimisel ja kõrgemad prognoositäpsused saavutatakse, kui prognoosimiseks kasutatakse ajatamata maksuvõlgade andmestikku.

### **Kokkuvõte**

Analüüsi keskmeks oli maksuvõla prognoosimine ning eraldi käsitleti nelja ajaperioodi: ajutise kestusega kuni 2 kuud (k.a), lühiajalise kestusega maksuvõlg, mis kestab vähemalt 3–5 kuud (k.a) järjest, keskmise kestusega maksuvõlg 6–11 kuud (k.a) järjest ning pikaajalise kestusega maksuvõlg, mis kestab vähemalt 12 kuud järjest. Analüüsis rakendati logistilist regressiooni (LR) ja tehisnärvivõrkude (ANN) meetodeid. Kasutatud andmestik hõlmas kogu populatsiooni, mis koosnes 2017. aasta novembri seisuga Eestis tegutsenud käibemaksukohustuslasest mikro- ning väikese ja keskmise suurusega ettevõtetest ning kelle müügitulu oli mõlemal aastal vähemalt 40 000 eurot. Maksuvõlgnikuks loeti ettevõtte, mille esines 2018. aasta jooksul vähemalt ühe kuu lõpus maksuvõlg ja maksuvõlata ettevõttel ei olnud 2018. aastal ühegi kuu lõpus maksuvõlga. Prognoosimiseks kasutati kahte erinevat andmestikku: esimeses on sõltuv muutuja kodeeritud arvestades 2018. aasta kogu maksuvõlga ning teises ainult 2018. aasta ajatamata maksuvõlga. Mõlemad andmestikud on ennustavate muutujate osas identsed, milleks on ettevõtete üldised tunnused, varasemad maksuvõlad ja finantssuhtarvud.

Magistritöö tulemused näitavad, et LR kasutamisel olid kõigi mudelite klassifitseerimistäpsused kõrged, välja arvatud ajutise maksuvõla puhul, mille puhul oli täpsus kõige madalam (72,5%). Kogu maksuvõla prognoosimisel oli kõige kõrgema täpsusega mudel keskmise kestusega maksuvõlga (KESKMV) prognoosiv domeeniülene LR, mille prognoositäpsus kahe aasta andmeid kasutades oli 82,6%. Ajatamata maksuvõlgade andmestikku kasutades oli prognoositäpsus veelgi kõrgem ning kõrgeim prognoositäpsus (92,1%) saavutati samuti keskmise kestusega maksuvõla (KESKMVAJ) prognoosimisel. ANN kasutamisel saavutati võrreldes LR-iga kõrgem klassifitseerimistäpsus kõigis prognoosihorizontides nii kogu kui ka ajatamata maksuvõla prognoosimisel. ANN mudelite prognoositäpsus jäi vahemikku 85,2–97,9%. Kõrgemad prognoositäpsused saadi ajatamata maksuvõla prognoosimisel, kus kõigi mudelite prognoositäpsus ületas 90%.

Üksiknäitajatest olid LR-i kasutades kõrgeima täpsusega eelmise perioodi maksuvõla näitajad, kuid ANN tõstis mõnedel juhtudel finantssuhtarvude prognoosivõime võrreldavale tasemele. Pikaajalise kestusega ajatamata maksuvõla prognoosimisel ületas kahe ajaperioodi

finantssuhtarvude kombineeritud kasutamine maksuvõlgadel põhineva prognoosimudeli täpsust. See näitab, et ANN suudab paremini tuvastada keerukamaid, mitte-lineaarseid seoseid finantsnäitajate ja maksukäitumise vahel.

Tulemuste põhjal on ajatamata maksuvõlad täpsemini prognoositavad kui kogu maksuvõlad. Samas osutus ajutise kestusega maksuvõlgade prognoosimine kõige keerulisemaks, mis viitab sellele, et ajutise kestusega maksuvõlgade kujunemise taga võivad olla erinevad tegurid, mida mudelid ei suuda piisava täpsusega tuvastada. Kuna kogu maksuvõla andmestik sisaldab ka ajatatud maksuvõlgu, viitab see asjaolule, et ajatatud maksuvõlga on keerulisem prognoosida. Üheks võimalikuks põhjuseks võib olla see, et ettevõtted kasutavad ajatatud maksuvõlga osana oma likviidsusplaneerimisest. Sisuliselt tähendab see, et ajatatud maksuvõlg toimib kui intressiga laen riigilt. Seega võivad pikema kestvusega maksuvõlgade kõrgemad prognoositäpsused olla põhjendatavad üksteisele järgnevate võlatsükklitega.

Väljatöötatud prognoosimudeleid saab rakendada mitmesugustes praktilistes olukordades. Krediidiasutused saavad neid kasutada ettevõtete krediidivõimekuse hindamisel ja laenuotsuste tegemisel. Tarnijatel on võimalik prognoosimudeleid kasutada potentsiaalsete või olemasolevate äripartnerite maksekäitumise hindamiseks, mis aitab ennetada krediidikahjusid ja teha otsuseid maksetingimuste määramisel. Maksu- ja Tolliamet võiks mudelit kasutada auditivaliku toetamiseks või ajatamisotsuste tegemiseks. Lisaks on võimalik ettevõtjal endal kasutada mudelit oma finantsseisundi jätkusuutlikkuse hindamiseks ning vajadusel rakendada ennetavaid meetmeid, nagu maksegraafikute ümberkorraldamine või kulude optimeerimine. Kuna ettevõtete maksuvõlgade andmed ja finantsandmed on Eestis avalikult kättesaadavad, suurendab see mudeli praktilist väärtust – võimaldades ettevõtetel, krediidiasutustel, tarnijatel ja avaliku sektori asutustel teha otsuseid ilma täiendava andmekogumise vajaduseta. Just maksuvõla kestusel põhinev lähenemine annab parema ülevaate ettevõtte finantsilisest olukorrast, aidates eristada lühiajalisi likviidsusprobleeme pikaajalistest. See võimaldab teha täpsemaid strateegilisi otsuseid nii avalikus kui ka erasektoris, aidates ennetada suuremaid finantsriske. Edasised uurimissuunad võiksid keskenduda täiendavate andmete lisamisele mudelisse (näiteks juhtkonna varasem maksekäitumine, makseviivitused pankadele ja tarnijatele) ja keerukamate meetodite kasutamisele parandamaks mudelite prognoositäpsust.

Magistritöö peamiseks piiranguks on uurimuse fookus Eesti kontekstile. Kasutatud andmestik põhineb Eesti ettevõtete maksukäitumisel ning prognoosimudelid on treenitud Eesti

Maksu- ja Tolliameti avalike andmete põhjal. Kuna maksusüsteemid, järelevalvemehhanismid ja aruandlusnõuded erinevad riigiti, võib tulemuste otsene rakendamine teistes riikides olla keeruline. Lisaks ei pruugi mitmetes riikides varasemad maksuvõlgade andmed olla avalikult kättesaadavad. Teine piirang tuleneb majanduskeskkonna dünaamilisusest. Stabiilses majanduskeskkonnas võib mudelite täpsus olla kõrge, kuid majanduskriisid või ootamatud sündmused võivad muuta ettevõtete maksukäitumise mustreid. Seetõttu võib olla vajalik mudelite perioodiline kohandamine vastavalt majanduskeskkonna muutustele.

**Viidatud allikad**

1. Abedin, M. Z., Chi, G., Uddin, M. M., Satu, M. S., Khan, M. I., & Hajek, P. (2020). Tax default prediction using feature transformation-based machine learning. *IEEE Access*, *9*, 19864–19881.
2. Alaka, H. A., Oyedele, L. O., Owolabi, H. A., Kumar, V., Ajayi, S. O., Akinade, O. O., & Bilal, M. (2018). Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert Systems with Applications*, *94*, 164–184. <https://doi.org/10.1016/j.eswa.2017.10.040>
3. Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, *23*(4), 589–609. <https://doi.org/10.2307/2978933>
4. Altman, E. I., Balzano, M., Giannozzi, A., & Srhoj, S. (2023). Revisiting SME default predictors: The Omega Score. *Journal of Small Business Management*, *61*(6), 2383–2417. <https://doi.org/10.1080/00472778.2022.2135718>
5. Altman, E. I., Iwanicz-Drozowska, M., Laitinen, E. K., & Suvas, A. (2017). Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z- Score Model. *Journal of International Financial Management & Accounting*, *28*(2), 131–171. <https://doi.org/10.1111/jifm.12053>
6. Altman, E. I., & Narayanan, P. (1997). An International Survey of Business Failure Classification Models. *Financial Markets, Institutions & Instruments*, *6*(2), 1–57. <https://doi.org/10.1111/1468-0416.00010>
7. Andresson, A., & Lukason, O. (2024). Corporate default prediction with payment disturbances in managers' earlier entrepreneurial practices. *Cogent Business & Management*, *11*(1), 2302203. <https://doi.org/10.1080/23311975.2024.2302203>
8. Back, P. (2005). Explaining financial difficulties based on previous payment behavior, management background variables and financial ratios. *European Accounting Review*, *14*(4), 839–868. <https://doi.org/10.1080/09638180500141339>
9. Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, *83*, 405–417. <https://doi.org/10.1016/j.eswa.2017.04.006>

10. *Basel Committee on Banking Supervision* (2016). Prudential treatment of problem assets — definitions of non-performing exposures and forbearance.
11. Batista Pereira, J., Cerqueira, A., & Brandão, E. F. M. (2012). Modeling Corporate Tax Risk: Evidence from Portugal. *SSRN Electronic Journal*.  
<https://doi.org/10.2139/ssrn.2179068>
12. Beaver, W. H. (1966). Financial Ratios As Predictors of Failure. *Journal of Accounting Research*, 4, 71–111. <https://doi.org/10.2307/2490171>
13. Briley, D. A., & Tucker-Drob, E. M. (2014). Genetic and environmental continuity in personality development: A meta-analysis. *Psychological Bulletin*, 140(5), 1303–1331.  
<https://doi.org/10.1037/a0037091>
14. Charitou, A., Neophytou, E., & Charalambous, C. (2004). Predicting corporate failure: Empirical evidence for the UK. *European Accounting Review*, 13(3), 465–497.  
<https://doi.org/10.1080/0963818042000216811>
15. Cheraghali, H., & Molnár, P. (2024). SME default prediction: A systematic methodology-focused review. *Journal of Small Business Management*, 62(6), 2847–2905.  
<https://doi.org/10.1080/00472778.2023.2277426>
16. Ciampi, F., Cillo, V., & Fiano, F. (2020). Combining Kohonen maps and prior payment behavior for small enterprise default prediction. *Small Business Economics*, 54(4), 1007–1039. <https://doi.org/10.1007/s11187-018-0117-2>
17. Ciampi, F., Giannozzi, A., Marzi, G., & Altman, E. I. (2021). Rethinking SME default prediction: A systematic literature review and future perspectives. *Scientometrics*, 126(3), 2141–2188. <https://doi.org/10.1007/s11192-020-03856-0>
18. Cultrera, L., & Brédart, X. (2016). Bankruptcy prediction: The case of Belgian SMEs. *Review of Accounting and Finance*, 15(1), 101–119. <https://doi.org/10.1108/RAF-06-2014-0059>
19. Da, F., & Peng, Y. (2023). Non-financial indicators for credit risk analysis of Chinese technology-oriented micro and small enterprises. *Journal of the Operational Research Society*, 74(4), 1198–1210. <https://doi.org/10.1080/01605682.2022.2072781>
20. Dimitras, A. I., Zanakis, S. H., & Zopounidis, C. (1996). A survey of business failures with an emphasis on prediction methods and industrial applications. *European Journal of Operational Research*, 90(3), 487–513. [https://doi.org/10.1016/0377-2217\(95\)00070-4](https://doi.org/10.1016/0377-2217(95)00070-4)

21. Ekanem, I. (2010). Liquidity management in small firms: A learning perspective. *Journal of Small Business and Enterprise Development*, 17(1), 123–138.  
<https://doi.org/10.1108/14626001011019161>
22. Forte, R., & Salomé Moreira, A. (2018). Financial Constraints and Small and Medium-Sized Firms' Export Propensity: Evidence from Portuguese Manufacturing Firms. *International Journal of the Economics of Business*, 25(2), 223–241.  
<https://doi.org/10.1080/13571516.2018.1437011>
23. Funder, D. C., & Colvin, C. R. (1991). Explorations in behavioral consistency: Properties of persons, situations, and behaviors. *Journal of Personality and Social Psychology*, 60(5), 773–794. <https://doi.org/10.1037/0022-3514.60.5.773>
24. Gilbert, L. R., Menon, K., & Schwartz, K. B. (1990). Predicting Bankruptcy for firms in financial distress. *Journal of Business Finance & Accounting*, 17(1), 161–171.  
<https://doi.org/10.1111/j.1468-5957.1990.tb00555.x>
25. Gupta, J., Barzotto, M., & Khorasgani, A. (2018). Does size matter in predicting SMEs failure? *International Journal of Finance & Economics*, 23(4), 571–605.  
<https://doi.org/10.1002/ijfe.1638>
26. Höglund, H. (2017). Tax payment default prediction using genetic algorithm-based variable selection. *Expert Systems with Applications*, 88, 368–375.  
<https://doi.org/10.1016/j.eswa.2017.07.027>
27. Jayasekera, R. (2018). Prediction of company failure: Past, present and promising directions for the future. *International Review of Financial Analysis*, 55, 196–208.  
<https://doi.org/10.1016/j.irfa.2017.08.009>
28. Kohv, K., & Lukason, O. (2021). What Best Predicts Corporate Bank Loan Defaults? An Analysis of Three Different Variable Domains. *Risks*, 9(2), 29.  
<https://doi.org/10.3390/risks9020029>
29. Käibemaksuseadus (2025). RT I, 11.12.2024, 9. Loetud aadressil  
<https://www.riigiteataja.ee/akt/111122024009>
30. Lukason, O., & Andresson, A. (2019). Tax Arrears Versus Financial Ratios in Bankruptcy Prediction. *Journal of Risk and Financial Management*, 12(4), 187.  
<https://doi.org/10.3390/jrfm12040187>

31. Lukason, O., & Camacho-Miñano, M.-M. (2021). What Best Explains Reporting Delays? A SME Population Level Study of Different Factors. *Sustainability*, 13(9), Article 9. <https://doi.org/10.3390/su13094663>
32. Lukason, O., & Valgenberg, G. (2021). Failure Prediction in the Condition of Information tAsymmetry: Tax Arrears as a Substitute When Financial Ratios Are Outdated. *Journal of Risk and Financial Management*, 14(10), 470. <https://doi.org/10.3390/jrfm14100470>
33. Lukason, O., & Vissak, T. (2024). Exporters' failure predictors and processes: A multi-country analysis based on the theoretical concept of firms' financial crisis types. *Cogent Economics & Finance*, 12(1), 2399957. <https://doi.org/10.1080/23322039.2024.2399957>
34. Maksu- ja Tolliamet (2023). Deklaratsioonid TSD esitamiseks. Loetud aadressil <https://www.emta.ee/ariklient/maksud-ja-tasumine/tulumaks-ja-sotsiaalmaks/deklaratsioonid-tds-esitamiseks>
35. Maksukorralduse seadus (2025). RT I, 19.12.2024, 4. Loetud aadressil <https://www.riigiteataja.ee/akt/MKS>
36. Marghescu, D., Kallio, M., & Back, B. (2010). Using Financial Ratios to Select Companies for Tax Auditing: A Preliminary Study. M. D. Lytras, P. Ordonez De Pablos, A. Ziderman, A. Roulstone, H. Maurer, & J. B. Imber (Toim), *Organizational, Business, and Technological Aspects of the Knowledge Society* (Kd 112, lk 393–398). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-16324-1\\_45](https://doi.org/10.1007/978-3-642-16324-1_45)
37. Marmor, M., & Lukason, O. (2024). Financial performance persistence in serial entrepreneurship. *Cogent Business & Management*, 11(1), 2423895. <https://doi.org/10.1080/23311975.2024.2423895>
38. Srebro, B., Mavrenski, B., Arsić, V.B., Knežević, S., Milašinović, M., & Travica, J. (2021). Bankruptcy Risk Prediction in Ensuring the Sustainable Operation of Agriculture Companies. *ResearchGate*. <https://doi.org/10.3390/su13147712>
39. Mramor, D., & Valentincic, A. (2003). Forecasting the liquidity of very small private companies. *Journal of Business Venturing*, 18(6), 745–771.
40. Pankrotiseadus (2025). RT I, 14.03.2025, 17. Loetud aadressil <https://www.riigiteataja.ee/akt/PankrS>

41. Pretorius, M. (2009). Defining Business decline, failure and turnaround: A content analysis. *The Southern African Journal of Entrepreneurship and Small Business Management*, 2(1), Article 1.
42. Raamatupidamise seadus (2025). RT I, 07.01.2025, 11. Loetud aadressil <https://www.riigiteataja.ee/akt/107012025011>
43. Rashid, A., Hassan, M. K., & Karamat, H. (2021). Firm size and the interlinkages between sales volatility, exports, and financial stability of Pakistani manufacturing firms. *Eurasian Business Review: A Journal in Industrial Organization, Innovation and Management Science*, 11(1), 111–134. <https://doi.org/10.1007/s40821-020-00162-w>
44. Ravi Kumar, P., & Ravi, V. (2007). Bankruptcy prediction in banks and firms via statistical and intelligent techniques – A review. *European Journal of Operational Research*, 180(1), 1–28. <https://doi.org/10.1016/j.ejor.2006.08.043>
45. Shi, Y., & Li, X. (2019). An overview of bankruptcy prediction models for corporate firms: A Systematic literature review. *Intangible Capital*, 15(2), 114. <https://doi.org/10.3926/ic.1354>
46. Siimon, Õ. R., & Lukason, O. (2021). A Decision Support System for Corporate Tax Arrears Prediction. *Sustainability*, 13(15), 8363. <https://doi.org/10.3390/su13158363>
47. Su, A., He, Z., & Su, J. (2018). Detection of Tax Arrears Based on Ensemble Learning Model. Proceedings of International Conference on Wavelet Analysis and Pattern Recognition. <https://ieeexplore.ieee.org/abstract/document/8521362>
48. Sun, J., Li, H., Huang, Q.-H., & He, K.-Y. (2014). Predicting financial distress and corporate failure: A review from the state-of-the-art definitions, modeling, sampling, and featuring approaches. *Knowledge-Based Systems*, 57, 41–56. <https://doi.org/10.1016/j.knosys.2013.12.006>
49. Zheng, J., & Li, Y. (2023). Machine learning model of tax arrears prediction based on knowledge graph. *Electronic Research Archive*, 31(7), 4057–4076. <https://doi.org/10.3934/era.2023206>
50. Veganzones, D., & Severin, E. (2021). Corporate failure prediction models in the twenty-first century: A review. *European Business Review*, 33(2), 204–226. <https://doi.org/10.1108/EBR-12-2018-0209>

51. Weitzel, W., & Jonsson, E. (1989). Decline in Organizations: A Literature Integration and Extension. *Administrative Science Quarterly*, 34(1), 91–109.  
<https://doi.org/10.2307/2392987>
52. Wiklund, J., Baker, T., & Shepherd, D. (2010). The age-effect of financial indicators as buffers against the liability of newness. *Journal of Business Venturing*, 25(4), 423–437.  
<https://doi.org/10.1016/j.jbusvent.2008.10.011>

## ERINEVA KESTUSEGA MAKSUVÕLGADE TEKKE PROGNOOSIMINE

## Lisa A

## Ennustavate muutujate väärtuste aritmeetilised keskmised erinevate maksuvõlgade tüübiga ettevõtete lõikes

Ennustav muutuja	HEA	PMV	PMVAJ	KESKMV	KESKMVAJ	LÜHMV	LÜHMVAJ	AJUTMV
MAXMV T-1	0,40	4,68	4,57	5,20	6,48	4,89	5,37	3,06
MAXMV T-2	0,53	4,07	4,05	4,38	5,73	4,00	4,84	2,83
KESKMV T-1	0,29	3,84	3,75	4,23	5,32	3,85	4,18	2,25
KESKMV T-2	0,38	3,31	3,25	3,55	4,68	3,17	3,82	2,10
MED T-1	0,04	1,97	2,27	2,06	2,82	1,40	1,53	0,39
MED T-2	0,08	1,62	1,61	1,61	2,38	1,32	1,55	0,56
MVK T-1	0,13	3,16	3,60	3,42	4,65	2,72	3,15	1,23
MVK T-2	0,20	2,72	2,86	2,88	4,21	2,44	3,11	1,31
VARAD T-1	12,33	12,16	11,85	11,91	11,56	11,92	11,77	11,86
VARAD T-2	12,23	11,94	11,66	11,76	11,43	11,81	11,69	11,74
MÜÜK T-1	12,64	12,72	12,45	12,42	12,18	12,39	12,19	12,25
MÜÜK T-2	12,53	12,54	12,25	12,29	12,09	12,27	12,09	12,14
VANUS	11,85	9,87	8,96	10,51	10,46	10,59	10,95	10,74
EKS T-1	0,32	0,3	0,22	0,22	0,23	0,25	0,25	0,27
EKS T-2	0,32	0,31	0,27	0,23	0,25	0,27	0,25	0,28
LIKV T-1	0,35	0,12	0,16	0,19	0,22	0,23	0,25	0,28
LIKV T-2	0,34	0,15	0,21	0,20	0,25	0,22	0,23	0,27
SOLV T-1	0,60	0,36	0,34	0,41	0,38	0,47	0,46	0,52
SOLV T-2	0,58	0,39	0,38	0,43	0,41	0,46	0,45	0,51
RENT T-1	0,11	0,05	0,05	0,04	0,00	0,04	0,03	0,07
RENT T-2	0,12	0,07	0,06	0,09	0,07	0,07	0,08	0,10
PROD T-1	2,30	2,6	2,83	2,58	2,90	2,50	2,41	2,42
PROD T-2	2,30	2,75	2,78	2,73	3,18	2,40	2,32	2,42
RS T-1	0,30	0,4	0,41	0,39	0,41	0,37	0,37	0,35
RS T-2	0,31	0,39	0,39	0,37	0,38	0,37	0,37	0,34

Märkus: HEA-ettevõtte, millel ei olnud 2018. aastal ühegi kuu lõpus maksuvõlga. Ülejäänud sõltuvate muutujate osas vt Tabel 4 ning ennustavate muutujate osas vt Tabel 5

Allikas: autorite koostatud

**Summary****PREDICTION OF TAX ARREARS OF VARYING DURATIONS: THE CASE OF  
ESTONIAN COMPANIES**

Maarika Jahhu, Maarja-Brit Pihelgas

The aim of this master's thesis is to forecast the emergence of tax arrears of varying durations among Estonian companies, using historical tax arrears data, general company characteristics, and financial ratios. Tax arrears are analyzed across four duration-based categories: temporary arrears lasting up to 2 months (inclusive), short-term arrears lasting 3–5 months (inclusive), medium-term arrears lasting 6–11 months (inclusive), and long-term arrears persisting for at least 12 consecutive months.

Two datasets are used for forecasting: the full dataset of tax arrears and a dataset excluding deferred tax arrears. Both datasets contain information on general company characteristics, previous tax arrears, and financial ratios. The objective of this approach is to determine whether excluding deferred tax arrears debts affects the predictive accuracy of the models. Previous studies have focused on forecasting the emergence of tax arrears for the upcoming month or year, or more generally, without considering duration-based segmentation. Thus, this study offers a novel perspective not only for forecasting tax arrears but also for assessing the dynamics of arrears based on their duration. Duration-based forecasting is crucial, as short-term tax arrears may reflect temporary liquidity issues, whereas long-term arrears indicate systematic financial distress and increase the risk of insolvency.

The study utilizes data from Estonian VAT-liable companies with a minimum sales revenue of at least 40,000 euros in both 2016 and 2017. A company is classified as having tax arrears if it had outstanding tax debt at the end of at least one month in 2018; those without any tax arrears during that year are classified as debt-free. The dataset includes 29,308 companies without tax arrears and 3,744 with tax arrears. Logistic regression (LR) and artificial neural networks (ANN) are used as forecasting methods, while the predictors variables originate from 2017 and 2016.

The results show that logistic regression models (except for temporary arrears) achieved high classification accuracy (80.4–92.1%). The best result using the full dataset was achieved for medium-term arrears (82.6%). Forecasting accuracy was even higher for non-deferred arrears, reaching up to 92.1%. When using ANN, accuracy exceeded that of logistic models across all

duration categories, ranging from 85.2% to 97.9%. Non-deferred tax arrears were the most accurately predicted, with all models achieving over 90% accuracy. Among individual variables, previous period tax arrears were the most accurate predictors in LR models, whereas ANN elevated the predictive power of financial ratios to a comparable level. The lower prediction accuracy for total tax arrears may be attributed to the inclusion of deferred debts, which are inherently more difficult to forecast. This may reflect companies' use of deferred tax arrears as a liquidity management tool, effectively treating them as interest-bearing loans from the state.

The results support data-driven decision-making across various sectors. For instance, tax authorities can use the forecasting models to better target supervisory efforts, credit institutions and financial analysts can assess companies' credit risk based on arrears duration, and companies themselves can evaluate their financial sustainability. A duration-based approach to tax arrears provides deeper insight into a company's financial condition, helping distinguish between short-term liquidity issues and long-term solvency risks, thereby enabling more precise strategic decisions in both the public and private sector and contributing to the prevention of broader financial risks.

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Maarika Jahhu,

Mina, Maarja-Brit Pihelgas,

anname Tartu Ülikoolile tasuta loa (lihtlitsentsi) meie loodud teose

ERINEVA KESTUSEGA MAKSUVÕLGADE TEKKE PROGNOOSIMINE EESTI  
ETTEVÕTETE NÄITEL

mille juhendaja on Oliver Lukason (PhD)

reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada digitaalarhiivi DSpace kuni autoriõiguse kehtivuse lõppemiseni.

Anname Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi DSpace kaudu Creative Commons'i litsentsiga CC BY NC ND 4.0, mis lubab autoritele viidates teost reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, kuni autoriõiguse kehtivuse lõppemiseni.

Oleme teadlikud, et punktides 1 ja 2 nimetatud õigused jäävad alles ka autoritele.

Kinnitame, et lihtlitsentsi andmisega ei riku me teiste isikute intellektuaalomandi ega isikuandmete kaitse õigusaktidest tulenevaid õigusi.

*Maarika Jahhu*  
21.05.2025

*Maarja-Brit Pihelgas*  
21.05.2025