

TALLINNA TEHNIKAÜLIKOOL

Majandusteaduskond

Ärikorralduse instituut

Kadi Vinglas

**FINANTSARUANNETE PETTUSTE TUVASTAMISE
MEETODITE KASUTATAVUS**

Magistritöö

Õppekava ärirahandus ja majandusarvestus, peeriala majandusarvestus

Juhendaja: Paavo Siimann, PhD

Tallinn 2022

Deklareerin, et olen koostanud lõputöö iseseisvalt ja olen viidanud kõikidele töö koostamisel kasutatud teiste autorite töödele, olulistele seisukohtadele ja andmetele, ning ei ole esitanud sama tööd varasemalt ainepunktide saamiseks. Töö pikkus on 13 033 sõna sissejuhatusest kuni kokkuvõtte lõpuni.

Kadi Vinglas

(allkiri, kuupäev)

Üliõpilase kood: 204318TARM

Üliõpilase e-posti aadress: kadi.vinglas@gmail.com

Juhendaja Paavo Siimann, PhD:

Töö vastab kehtivatele nõuetele

.....

(allkiri, kuupäev)

Kaitsmiskomisjoni esimees:

Lubatud kaitsmisele

.....

(nimi, allkiri, kuupäev)

SISUKORD

LÜHIKOKKUVÕTE	5
SISSEJUHATUS	6
1. FINANTSARUANNETE PETTUSTE OLEMUS JA TUVASTAMINE	9
1.1. Pettuse mõiste ning vajalikud komponendid	9
1.2. Finantsaruannete pettused: kõige tulusam ametialase pettuse liik	11
1.3. Finantsaruannete pettuste tuvastamise protsess	14
1.4. Finantsaruannete pettuste tuvastamise protsessis kasutatavad meetodid ja varasemad uuringud	16
1.4.1. Beneishi M-skoori olemus ja rakendamine	18
1.4.2. Altmani Z-skoori olemus ja rakendamine	20
1.4.3. Dechow' F-skoori olemus ja rakendamine	23
1.4.4. Benfordi seaduse olemus ja rakendamine	26
1.4.5. Mitut meetodit kasutavad uuringud	28
2. FINANTSARUANNETE PETTUSTE TUVASTAMISE MEETODITE RAKENDAMINE PETTUSEID SISALDAVATE FINANTSARUANNETE PEAL	30
2.1. Uuringu metoodika	30
2.2. Uuringus kasutatav andmekogum	32
2.3. Uuringu tulemused	35
2.3.1. Beneishi M-skoor	35
2.3.2. Altmani Z-skoor	39
2.3.3. Dechow' F-skoor	43
2.4. Arutelu ja järeldused	47
KOKKUVÕTE	51
SUMMARY	54
KASUTATUD ALLIKATE LOETELU	57
LISAD	62
Lisa 1. Uuringu andmekogumis olevad ettevõtted ning nende juhtumi kirjeldus	62
Lisa 2. Beneishi M-skoori tulemused	70
Lisa 3. Altmani Z-skoori tulemused	71
Lisa 4. Dechow' F-skoori tulemused	72
Lisa 5. Beneishi M-skoori regressiooni- ja korrelatsioonanalüüs (M5)	73

Lisa 6. Beneishi M-skoori regressiooni- ja korrelatsioonanalüüs (M8)	74
Lisa 7. Altmani Z-skoori regressiooni- ja korrelatsioonanalüüs	75
Lisa 8. Dechow' F-skoori regressiooni- ja korrelatsioonanalüüs	76
Lisa 9. Kokkuvõttev tabel uuringu tulemustest	77
Lisa 10. Lihflitsents	81

LÜHIKOKKUVÕTE

Finantsaruannete pettus on keeruline ning suurte tagajärgedega ametialane kuritegu. Selle tuvastamine on äärmisel keeruline ja seda eriti neil, kelle kasutada on vaid avalikustatud finantsandmed. Probleemi lahendamiseks on välja töötatud hulk meetodeid, millest populaarseimad põhinevad regressioonivõrranditel. Mudeleid on palju testitud ning mitmetes varasemates uuringutes on soovitatud parima tulemuse saamiseks testida ühel andmekogumil vähemalt kahte meetodit. Testides mitut mudelit samal andmekogumil, on nende tulemused ka paremini võrreldavad. Magistritöö eesmärk on välja selgitada, kas Beneishi M-skoori, Altmani Z-skoori ja Dechow' F-skoori on võimalik kasutada pettuseid sisaldavate finantsaruannete tuvastamiseks.

Uuringu andmestiku moodustamiseks kasutati Ameerika Ühendriikide väärtpaberi- ja börsikomisjoni avaldatud dokumente, mis teavitavad avalikkust raamatupidamis- ja/või auditeerimisprotsessi rikkumisest. Magistritöö autor analüüsis aastatel 2017–2021 avaldatud teavitusi ning eemaldades ebasobivad andmed, jäi andmekogumisse 25 ettevõtet. Nende andmeid analüüsiti erinevate statistiliste meetodite abil, kasutades programmi Excel võimalusi.

Uuringu tulemusena selgus, et ükski mudel ei suutnud tuvastada kõiki ettevõtteid. Kõige paremini tõstis esile problemaatilisi aruandeid pankroti tõenäosuse leidmiseks kasutatav Altmani Z-skoor, kuid siiski ei saavutanud ükski mudel varasemate uuringutega võrreldes samaväärset tulemust. Uuringu tulemusi mõjutasid nii kogu andmekogumi kui ka ühe ettevõtte tasandil andmetes esinevad erandid. Magistritöö uuringu käigus ei tuvastatud üheski mudelis konkreetset mustrit, mis põhjendaks mudelite tulemusi ehk miks osa ettevõtteid klassifitseeritakse õigesti ning osa mitte. Üks järeldus oleks, et kuna ettevõtete ärivaldkonnad on erinevad, erinevad ka tulemused. Autori arvates ei ole mõistlik uurida korraga suurt andmekogumit, vaid uurida tuleks ühe ettevõtte tasandil. Seda seetõttu, et igasugust erindit peaks eraldi analüüsima, kuna see võib tähendada andmetega manipuleerimist, kuid võib samas olla ka põhjendatud.

Võtmesõnad: finantsaruannete pettused, Beneishi M-skoor, Altmani Z-skoor, Dechow' F-skoor

SISSEJUHATUS

Organisatsioon *Association of Certified Fraud Examiners* (ACFE) tegi 2020. aastal 11. ülemaailmse uuringu ametialaste pettuste ja töökoha kuritarvitamise kohta. 2504 toimunud pettusejuhtumi analüüsimise tulemusena järeldati, et igal aastal kaotavad ettevõtted pettuste tõttu umbes 5% oma tulust, mis tähendab 4,5 triljoni dollari suurust kahju ühes aastas. Ametialaseid kelmuseid pannakse toime eri viisidel. Kõige vähem levinud, kuid suurimate tagajärgedega moodus on tahtlik valeinfo esitamine finantsaruannetes ehk finantsaruannete pettus (FAP). (*Report to ... 2020*)

Pettustest tekkinud kahju vähendamiseks on kõige olulisem tegeleda ennetamisega. Täielik vältimine on ebatõenäoline, seega on äärmiselt tähtis toimunud pettused võimalikult vara avastada. FAPi tuvastamine on komplitseeritud. Väljakutse on see eelkõige nende huvitatud osapoolte jaoks, kellele on kättesaadavad vaid avalikustatud finantsandmed. Ettevõtete osanikud, järelevalveasutused, kliendid, audiitorid ja paljud teised huvitatud isikud soovivad saada kindlust avaldatud finantsandmete õigsuses. Nende huvides oleks, et nad saaksid ise mõne meetodi abil kiiresti ja lihtsalt tuvastada, kas finantsaruanne sisaldab tahtlikku väärkajastamist või mitte. Nende eesmärk on leida üles risk ning see lähemal uurimisel ja võimaluse korral maandada. Sellest lähtuvalt on töös käsitletav uurimisprobleem järgmine: kuidas tuvastada tahtlikult manipuleeritud finantsaruandeid, kasutades vaid avalikustatud finantsandmeid ja jõukohaseid meetodeid.

Probleemi lahendamiseks on välja töötatud hulk meetodeid, mida on juba ka palju testitud. Uuringutes on kasutatud mitmesuguseid andmekogumeid ja meetodeid ning nende lugejad saavad teada, kas ühes konkreetses uuringus testitud meetodit on võimalik kasutada sellesse kaasatud ettevõtete FAPide tuvastamiseks. Vähem on selliseid uuringuid, milles kasutatakse ühte andmekogumit mitme meetodi testimiseks. Selliste uuringute vähesuse tõttu on keeruline hinnata, milline meetod on kõige täpsem. Enim kasutatud meetodid põhinevad regressioonivõrranditel, mis ei võimalda leida sõltuva tunnuse täpset väärtust. Seetõttu ei ole lõpuni korrektne võrrelda eri andmete peal testitud meetodite täpsust omavahel. Samuti tuleb märkida, et testides

andmekogumil vaid ühte meetodit, puudub võrdlus teiste võimalike meetoditega ning teadmine, kas mõnel muul viisil oleks võimalik saada täpsem tulemus.

Mitmes varasemas uuringus on soovitatud parima tulemuse saamiseks testida ühel andmekogumil vähemalt kahte meetodit. Siinses magistritöös testitakse kolme meetodit, kasutades pettuseid sisaldavaid finantsaruandeid.

Magistritöö eesmärk on välja selgitada, kas Beneishi M-skoori, Altmani Z-skoori ja Dechow' F-skoori on võimalik kasutada pettuseid sisaldavate finantsaruannete tuvastamiseks.

Eesmärgi saavutamiseks on püstitatud järgmised uurimisküsimused:

- 1) Mis on finantsaruannete pettused ning millised on nende komponendid?
- 2) Milliseid meetodeid on varasemates uuringutes finantsaruannete pettuste tuvastamiseks kasutatud?
- 3) Kui head on Beneishi M-skoor, Altmani Z-skoor ja Dechow' F-skoor finantsaruannete pettuste tuvastamiseks?
- 4) Milline nendest kolmest pettuse tuvastamise meetodist on kõige täpsem?

Magistritöö koosneb kahest peatükist. Esimene peatükk sisaldab ülevaadet FAPide olemusest ning nende tuvastamise võimalustest. Esmalt käsitletakse pettuse definitsiooni, selle esinemise põhjuseid ja liigitusi. Seejärel selgitatakse FAPide tuvastamise protsessi ning eri autorite poolt välja töötatud meetodikaid. Samuti antakse ülevaade varasematest uuringutest. Töö teine osa on empiiriline. Alapeatükkides tuuakse välja kolme FAPi tuvastamise meetodi testimise tulemused, mida analüüsitakse kvantitatiivsete uurimismeetodite abil. Töö lõpus tehakse kokkuvõtte sellest, milline meetoditest on kõige täpsem, ning arutletakse, millised on testitud meetodite tugevused ja puudujäägid.

Magistritöö uurimisobjektiks on FAPi sisaldavad finantsaruanded. Andmekogumi moodustab autor, kasutades Ameerika Ühendriikide väärtpaberi- ja börsikomisjoni (*U.S. Securities and Exchange Commission*, SEC) avaldatud dokumente, mis teavitavad avalikkust raamatupidamis- ja/või auditeerimisprotsessi rikkumisest (*Accounting and Auditing Enforcement Releases*, AAER). (*Accounting and ...* 2022) Teavituste läbitöötamise toel leitakse ettevõtted, mille aruanded sisaldavad FAPi. Seejärel kogutakse andmebaasidest ettevõtete finantsaruanded ning muu vajalik finantsinformatsioon.

Magistritöö tulemus võiks huvi pakkuda neile osapooltele, kelle huvides on esmatähtis, et ettevõtete finantsaruanded on õiged. Need magistritöös kasutatavad meetodid võiksid olla abiks huvitatud osapooltele, et määrata paremini ühe konkreetse ettevõttega seotud riski või tuvastada ettevõtete seast need, mille andmed vajaksid lähemalt uurimist.

Magistritöö autor tänab juhendaja Paavo Siimanni, kes aitas kaasa töö valmimisele.

1. FINANTSARUANNETE PETTUSTE OLEMUS JA TUVASTAMINE

Magistritöö esimene peatükk on jaotatud kaheks alapeatükiks. Esimeses alapeatükis antakse ülevaade finantsaruannete pettuste olemusest. Autor kirjeldab pettuse definitsiooni, toimepaneku stiimuleid ning ametialaste pettuse liiki (FAP). Teises alapeatükis kirjeldatakse finantsaruannete pettuste tuvastamise meetodeid ning antakse ülevaade varasematest uuringutest, mis käsitlevad nende tuvastamise meetodite kasutatavust.

1.1. Pettuse mõiste ning vajalikud komponendid

Pettus ehk kelmus (Kelmused ... 2022) on Eesti karistusseadustikus defineeritud kui “teisele isikule varalise kahju tekitamine tegelikest asjaoludest teadvalt ebaõige ettekujutuse loomise teel varalise kasu saamise eesmärgil” (KarS § 209). ACFE kodulehel on välja toodud, et “pettus hõlmab mis tahes tahtlikku tegevust, mille eesmärk on pettuse või muul ebaausal viisil võõra vara või raha äravõtmine” (*What is ...* 2022). Lihtsamalt öeldes kasutab pettuse toimepanija mitmesuguseid ebaõiglaseid viise (valetamine või tõe rääkimata jätmine), et saada mingeid eeliseid (Rezaee 2002). Petturite eesmärk on saada kasu ning selleks kasutavad nad tahtlikult väärased võtteid.

Tõenäoliselt on kõik inimesed puutunud kokku mõne pettusega. Järjest enam saadakse telefonikõnesid petturitelt, kes pakuvad suurepäraseid investeerimisvõimalusi, või e-kirju, milles teavitatakse võõra Mehhiko sugulase hiiglaslikust pärandusest. Ettevõtluses mõjutavad äritegevust majanduskuriteod ja -pettused.

PricewaterhouseCoopers (PwC) avaldas 2020. aastal ülevaate, milles esitleti ülemaailmse majanduskuritegusid ja pettuseid kajastava uuringu tulemusi. Selle raames küsitleti 5000 ettevõtet 99 riigist. Uuringu tulemusena selgus, et 47% ettevõtetest oli pettusega kokku puutunud ning nende tagajärjel tekkinud kogukahju oli 42 miljardit dollarit. Nimetatud uuringus rõhutati, et

pettuse oht on tõsine ja kasvav ning ükski ettevõtte ei ole selle eest kaitstud. Ettevõtte on kohustatud suurendama oma teadlikkust ning mõistma murekohti, sest nende puudumine ei ole vabanduseks, kui pärast kuriteo avastamist selgitusi nõudma tullakse. (*PwC's Global ... 2020*)

Ettevõtete ning kogu majanduse jaoks on kõige olulisem pettuseid ennetada. Nende toimumise tõenäosuse määramisel on abiks pettuse kolmnurga teooria, mille töötas 1953. aastal välja Ameerika penoloog, sotsioloog ja kriminoloog Donald Ray Cressey. Tuginedes psühholoogilistele teadmistele, väitis ta, et pettuse toimepanemiseks peavad inimesel olema järgmised stiimulid: võimalus, surve ja õigustus. (*Yendrawati et al. 2019*)

Võimalus on esimene vajalik komponent pettuse toimumiseks. Ettevõtetes väljendub võimalus enamasti puudulikus sisekontrollikeskkonnas. Pettuse ärahoidmiseks on oluline, et juhatuse tegevuse üle oleks järelevalve ja kontroll. (*Huang et al. 2017*) Pidev kontroll peaks hõlmama ka ettevõttes kasutusel olevaid süsteeme ning oluliseks teguriks on ka ülesannete lahusus (*Ringkiri pettuse ... 2009*). Samuti jätavad organisatsiooni struktuurist ja tegevusest tulenev keerukus ning nendest sõltuvad tehingud ruumi subjektiivseteks tõlgendusteks, millegi avalikustamata jätmiseks või valeandmete esitamiseks. (*Huang et al. 2017*)

Motivatsioon pettuse toimepanemiseks on enamasti surve. See võib olla nii ettevõttesisene kui ka väliline. Ettevõtluses on lõppeesmärgiks enamasti raha teenimine ning pettuse toimepanemise surve on põhjustanud kas vajadus või ahnus raha järele (*Ringkiri pettuse ... 2009*). Finantsaruannete pettuste puhul on sageli tegu ka survega täita analüütikute prognoose või olla sobilik välisrahastuseks. Finantsiliselt kehvast seisust olevad ettevõtte on varasemate uuringute tulemusena tõenäolisemad panema toime pettust. Samuti on surve põhjustajaks sageli tulemuspõhine tasustamisviis ehk lisaraha saamiseks manipuleeritakse näiteks oma müügitulemustega või soovib juhatuse esimees näidata ettevõtte finantsandmeid paremana, tõstes nii aktsia hinda. (*Huang et al. 2017*)

Õigustus on Cressey teooria kolmas element. Pettuse sooritanud on alati suutelised oma tegemisi õigustama ehk tooma välja argumente, miks oli õige nii toimida. Need isikud ei näe konflikti moraali või eetikanormide vahel, kuna on suutelised oma tegemisi väga hästi põhjendama. (*Ibid.*)

2004. aastal tegid David T. Wolfe ja D. R. Hermanson pettuse kolmnurgale omapoolse täienduse, lisades neljanda stiimulina võimekuse. Teooriat koos viimati nimetatud neljanda teguriga nimetatakse pettuse teemandiks. (Yendrawati *et al.* 2019)

Võimekus oli Wolfe ja Hermansoni arvates oluline täiendus, kuna pettust ei saa toime panna, kui selle täideviimise sooviga isik selleks võimeline ei ole. Nad kirjeldasid pettuse toimepanemise protsessi järgmiselt (*Ibid.*):

- 1) esmalt avaldub inimesele teatav surve, mis annab talle motivatsiooni pettuse teostamiseks (surve);
- 2) järgnevalt hakkab inimene otsima võimalusi, kuidas pettust toime panna (võimalus);
- 3) oluline samm on tegudeks õigustuse leidmine (õigustus);
- 4) kolme eelneva teguri olemasolul on viimane samm analüüsida, kas inimene on selleks võimeline (võimekus).

Pettuse puhul on tähtis asjaolu, et selle toimepanija on teadlik oma väärast käitumisest. Seega ei saa oskamatuses tulenevaid vigu justkui pidada pettuseks. Samas olukord, kui raamatupidaja teadlikult otsustab oma teadmisi mitte täiendada ning mõistab, et tulevikus teeb ta oma töös seetõttu vigu, on sarnane petturi käitumisega. Oskamatus on hõlbus väide, millele hiljem seletusi andes tugineda. Seetõttu on mõnes olukorras kohane väita, et väidetav oskamatus oli tegelikult tahtlik valesti käitumine ehk pettus.

Pettus on väga aktuaalne teema nii isikute kui ka ettevõtete jaoks. Cressey teooria on abiks teadlikkuse tõstmisel ja murekohtade teadvustamisel. Selleks, et vähendada pettuseid, tuleb olla kursis nii võimaluste, surve, õigustuse kui ka võimekuse aspektiga.

1.2. Finantsaruannete pettused: kõige tulusam ametialase pettuse liik

PwC ülevaatest selgus, et ligi pooltes ettevõtetes on olnud olukordi, mil keegi paneb surve, võimaluse, õigustuse ja võimekuse toel toime pettuse. Pettuseid, millega ettevõtluskeskkond iga päev kokku puutub, on palju. Kõige levinum on tarbijapettus ehk petturiks on ettevõtteväline isik, sageli klient. Teisel kohal on üha laiemalt levivad küberpettused. Järgnevad ametialased pettused ehk vara omastamine ja altkäemaksu andmine / korruptsioon ning viiendal kohal on FAP. (*PwC's Global ... 2020*)

Ametialased pettused on valdkond, mida *Association of Certified Fraud Examiners* on põhjalikult uurinud. Nende 2020. aasta ülevaatest selgub, et kolmest ametialase pettuse põhiliigist on petturid kõige rohkem tegelenud vara omastamisega. ACFE toob välja, et 86% ametialastest pettustest on seotud töötajate poolse varastamise või vara väärkasutamisega. Samuti selgub samast uuringust, et 43% petuskeemidest on sisaldanud ka korrupsiooni ehk altkäemaksu andmist, huvide konflikti või väljapressimist. Sarnaselt PwC uuringuga selgus, et vaid 10% skeemidest sisaldas finantsandmete sihilikku väärkajastamist või andmete avalikustamata jätmist ehk FAPI. Statistika näitab, et mida vähem on pettuse liiki kasutatud, seda suurem on keskmine kahju. Seega kui varguse puhul on keskmine kahjusumma 100 000 dollarit, siis finantsaruannete pettuste tagajärjel tekkis kahju keskmiselt 954 000 dollarit. (*Report to ... 2020*) Uuringu tulemus ei ole üllatav, kuna varguse sooritamiseks või vara väärkasutamiseks on inimestel rohkem võimalusi ja võimekust. FAPI saavad toime panna vaid isikud, kellel on võimalus finantsandmeid muuta või mõjutada ning kelle teadmised võimaldavad seda teha, jätmata selgesti märgatavaid jälgi.

Finantsaruande pettus on üks pettuse liikidest. ACFE definitsiooni järgi on see pettus “oluliste faktide või raamatupidamisandmete tahtlik väärkajastamine või väljajätmine, mis on eksitav ning kogu kättesaadavaks tehtud teabega arvestatuna sunniks lugejat muutma oma hinnangut või otsust”. (Rezaee 2002)

Finantsaruannete pettused on oma keerukuse tõttu kõige vähem levinud ametialase pettuse viis, kuid neil on teiste liikide ees mitu eelist (*Ibid.*):

- 1) saadav tasu on kõrgem;
- 2) füüsiline oht on minimaalne;
- 3) avastamise tõenäosus on pigem väike;
- 4) karistused ei ole sageli väga karmid.

Kuigi finantsaruannete pettuste avastamine on võrreldes teiste pettustega väiksema tõenäosusega, on järjest enam ettevõtteid süüdi mõistetud FAPI toimepanemises. Üheks põhjuseks on investeerimise olemuse muutumine. Kui sada aastat tagasi osteti nende ettevõtete aktsiaid, mille äri tunti ja mille edusse usuti, siis aastal 2022 on aktsiate valiku puhul kõige olulisem enamasti nende tulevane hinnakasv. Aktsiahinna tõusu taga peavad olema head ja perspektiivikad finantsnäitajad ning seega on ettevõtete huvides neid finantsnäitajaid heal tasemel hoida, mis ka ei juhtuks. Selline surve paneb ettevõtteid vahetevahel arvudega manipuleerima. Samuti on viimase

saja aasta jooksul palju kasvanud inimeste üldine jõukus ning koos sellega ka ahnus. Arvatakse, et olukorraga kaasnev ebaetilisus on ka põhjuseks, miks rohkem pettuseid toime pannakse. Arvestama peab ka sellega, et pettuste tuvastamise protsess on samuti arenenud. Aastate jooksul on järjest enam saadud selles valdkonnas teadmisi juurde ning arendatud välja eri meetodeid pettuste tuvastamiseks. (Zack 2013)

Organisatsioon *Anti-Fraud Collaboration* (AFC), mis loodi eesmärgiga tõsta ettevõtluskeskkonna teadlikkust finantspettustest, avaldas 2021. aasta jaanuaris ülevaate, milles analüüsiti FAPide skeeme, mis tuvastati SECi AAERidest. Ülevaatest selgub, et kõige sagedamini toimub tahtlik väärkajastamine järgmistel kontodel (*Mitigating the ...* 2021):

- 1) tulu (ebaõige kajastamine, mis on seotud väärastuse, hindamise, valmidusastme või fiktiivsusega);
- 2) reservid (manipuleerimine, mis on seotud ebaõige vähendamise, väärastuse ja klassifitseerimisega, valesti arvutatud allahindluse või kohustiste kajastamata jätmisega);
- 3) varud (väärkajastamine või ülehindamine, sh müügikulude ebaõige märkimine);
- 4) väärtuse langus (väärastus, sh allahindluse edasilükkamine, kajastamata jätmine, vigased hinnangud ning manipuleerimine).

Ameerika energia-, tooraine- ja teenusteettevõtet Enronit, Jaapani elektroonikaseadmete ja -komponentide tootjat Toshiba ning Ameerika meedia mõõtmise ja analüüsi ettevõtet Comscore'i ühendab asjaolu, et kõik kolm on olnud finantskandaalide keskmes. Ettevõtted tekitasid väärtalt kajastatud finantsandmete kaudu informatsiooni kasutavatele isikutele kahju mitme miljardi dollari eest, kasutades just neid kõige levinumaid pettuse viise ja kontosid.

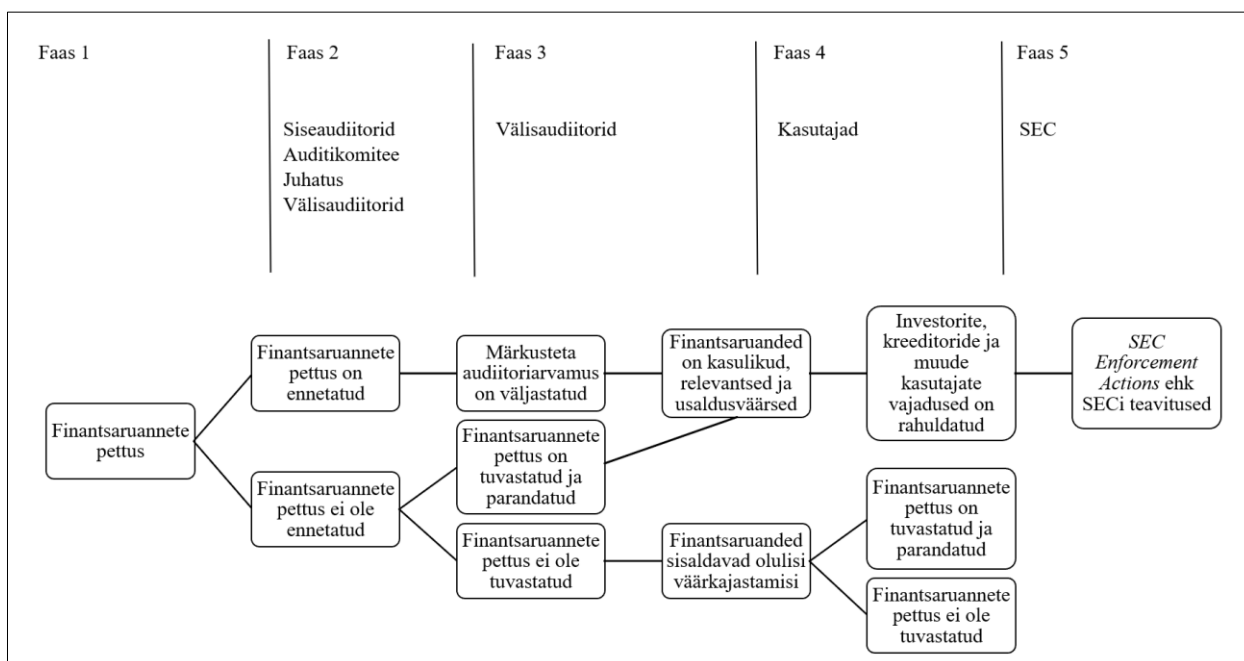
Enroni puhul on tegemist tüüpilise pettuse näitega, kus kasumi kahanedes ning aktsionäride surve all hakati finantsprobleeme peitma. Ettevõtte kasutas näitajatega manipuleerimiseks peamiselt kahte viisi: realiseerimata tulevikutulu kanti jooksvasse kasumiaruandesse ning probleemsed varad kanti bilansist välja usaldusühingutele. (Bondarenko 2016) Ka Toshiba juhtum sai alguse eesmärgiga parandada halvenevaid finantsnäitajaid. 2008. aastal ülemaailmse finantskriisi ajal alustati ettevõttes vääraste raamatupidamistavade kasutuselevõttuga ning ülehinnatud kasumi kajastamisega. Meetodeid paremate finantsnäitajate saamiseks kasutati palju, kuid nagu ka Enroni puhul, toodi Toshiba aruannetes tulevast tulu väärtalt jooksvasse aruandesse. (Carpenter 2021) Investoritele ettevõtte tulemuslikkuse näitamiseks manipuleeris oma andmetega ka Comscore.

Tulueesmärkide täitmiseks tegi ettevõtte mitterahalisi tehinguid ning kajastas need kasumiaruandes ülehinnatud turuväärtuses. (Jarvey 2019)

Pettuste ennetamisega tegeletakse järjest aktiivsemalt, kuid kõiki pettuseid ei ole võimalik vältida. Selleks, et hoida kahju võimalikult väiksena, on oluline pettus võimalikult vara avastada. Audiitoritel on küll aastatega välja töötatud protsessid, mis on pettuste tuvastamisel abiks, kuid kuna auditid on valimipõhised ning toimuvad eeldatavasti korra aastas, ei saa alati vaid auditi tulemustele toetuda. Ettevõttevälistel huvipooltel on analüüsimiseks kasutada vähem infot ehk vaid avalikustatud finantsandmeid. Paljud autorid on leidnud võimalusi, kuidas finantsaruannetes leiduva info abil FAPi tuvastada.

1.3. Finantsaruannete pettuste tuvastamise protsess

Rezaee (2002) illustreeris FAPi ennetamise ja avastamise protsessi (vt joonis 1). Protsess koosneb viiest faasist ning selle eesmärk on tuvastada FAP varajases faasis, mille järel tuleb teha vajalikud korrektuurid väärkajastamise eemaldamiseks.



Joonis 1. Finantsaruannete pettuste ennetamise ja avastamise protsess
Allikas: Rezaee (2002)

Joonisel 1 toodud protsessi igas faasis on osapool, kelle tegevuse või tegevusetuse tulemustest lähtuvalt tehakse edasised otsused. Kõikide osapoolte huvides on saada kindlustunne finantsaruannetes kajastatud info suhtes. Selle tunde saamiseks on kaks varianti: kas uskuda eelmise faasi osapooli või kontrollida andmeid ise. Peamiselt on finantsaruannete kasutajad need, kes tuginevad enim eelmise faasi tulemustele ehk välisaudiitori väljastatud aruandele.

Audiitoritel on tähtis roll pettuste tuvastamisel, kuna nende ülesanne on teostada järelevalvet, pääsedes töö käigus ligi ka siseinformatsioonile. Nende tegevuse tulemusena valmib aruanne, milles tuuakse välja, kas ettevõtte finantsaruanded on kooskõlas finantsaruandluse raamistikuga või mitte, teisisõnu kas see dokument peaks aruannete kasutajatele andma kindlust või neid hoopis hoiatama. Siiski on teada, et tuntud finantsskandaalid on sageli lahvatanud pärast audiitorite märkusteta aruande väljastamist. ACFE uuringust selgus, et vaid 4% ametialastest pettustest avastati välise audiitori poolt (*Report to ...* 2020). Sellest tulenevalt võiks aruannete kasutajate huvides olla nende endi teostatav lisakontroll.

Protsessi viimase faasi osapooliks on SEC, mille peamine eesmärk on edendada informatsiooni täielikku avalikustamist ning kaitsta investoreid pettuste ja manipuleerivate tavade eest turul. SEC esitab igal aastal arvukalt tsiviilõiguslikke hagiid ettevõtete ja üksikisikute vastu, kes rikuvad väärtpaberiseadusi. Oma kodulehel teavitab organisatsioon avalikkust raamatupidamis- või auditeerimisrikkumise uurimise ajal või lõpus, avaldades vastavad dokumendid, mida nimetatakse *Accounting and Auditing Enforcement Releases* (AAERid). (*Accounting and ...* 2022) Pettuse tuvastamine selles faasis on viimane võimalus, kuid paljude finantsaruannete kasutajate jaoks on kahju selleks hetkeks juba väga suur.

Razae (2002) välja toodud protsessi eesmärgi täitmise teeb keeruliseks mitu asjaolu. Peatükis 1.1 toodi välja neli kõige levinumat raamatupidamiskontot, mida FAPide jaoks kasutatakse. Loendist on näha aga see, et tahtlikuks väärkajastamiseks ühel kontol on mitu viisi, seega kindlat mustrit pettustes ei ole. Samuti peatükis 1.1 kirjeldatud kolm suurt finantsskandaali olid küll kõik sama eesmärgiga (näidata suuremat kasumit), kuid meetodid, kuidas eesmärgini jõuda prooviti, erinesid. Eri tegevusviiside kasutamine ning kontode manipuleerimine teeb pettuste avastamise keerulisemaks.

Samuti raskendab avastamist kõik muu, mis ärikeskkonnas rolli mängib. Ettevõtetel on erinevad võimalused, neil lasuv surve ei pruugi olla alati sama ning õigustus erineb enamasti juba isiku

tasandil. Nendest teguritest tulenevalt on iga pettus omamoodi ning sageli manipuleeritakse eri kirjetega.

Finantsaruannete pettuste tuvastamine ei ole lihtne. Kõik meetodid, mida akadeemilises kirjanduses on kasutatud, otsivad finantsaruannetest anomaaliaid. Oluline on siinkohal märkida, et igasugune üldisest seaduspärasusest kõrvalekaldumine ei ole pettus. Seetõttu tuleks väita, et eri meetodid peaksid kiirelt ja tõhusalt aitama tuvastada finantsaruanded, mis sisaldavad mingisugust anomaaliat. Nende abil tuvastatud aruanded ning nende kirjed vajavad süvitsi analüüsimist, et kinnitada või ümber lükata pettuse olemasolu. Kuigi FAPi toimumise kinnitamine või ümberlükkamine ei ole finantsaruannete kasutajate võimuses, võiksid need meetodid nende enda riski määramise jaoks abiks olla. Kasutajate huvides oleks meetodite lihtsus ja tõhusus, samuti võimalikult väike kaotus ehk varajases faasis tuvastamine.

1.4. Finantsaruannete pettuste tuvastamise protsessis kasutatavad meetodid ja varasemad uuringud

FAPi tuvastamiseks on välja pakutud mitu võimalust. Mantone (2013) raamatus on nimekiri nii lihtsamatest kui ka keerulisematest meetoditest, mis aitavad väärkajastatud finantsandmeid tuvastada:

- suhtarvuanalüüs;
- horisontaalanalüüs;
- vertikaalanalüüs;
- Beneishi M-skoor;
- Dechow' F-skoor;
- *Sloan's Accruals*;
- *Jones Nondiscretionary Accruals*;
- Piotroski F-skoor;
- Lev-Thiagarajani 12 signaali mudel;
- Benfordi seadus;
- Z-skoori erinevad analüüsid (nt Altmani Z-skoor);
- korrelatsioonanalüüs;
- regressioonanalüüs.

Meetodeid on palju ning siinse magistritöö raames ei ole võimalik kõikide headust hinnata. Selleks, et valida välja töö empiirilises osas kasutatavad meetodid, analüüsis lõputöö autor varasemaid uuringuid.

Tehnoloogia areneb järjest enam ning see olukord on ka FAPi tuvastamiseks loonud uudeid võimalusi. Dong *et al.* (2014) tegid kokkuvõtte varasemates uuringutes kasutatud meetoditest. Nende analüüsi tulemusena selgus, et väga populaarsed ja edukad on olnud andme- ja tekstikaeve (*data and text mining*). Need vajavad edukaks toimimiseks eriti suurt andmekogumit, seega on nende kasutamiseks vaja spetsiifilist tarkvara. Samuti nõuab töö suurandmetega vastavaid oskusi ja teadmisi. See on ka põhjus, miks suurem osa huvitatud osapooli ei saa andme- ja tekstikaevet kasutada. Palju kasutatakse kvantitatiivsed uurimismeetodid. Eelmainitud suhtarvuanalüüsi, horisontaalanalüüsi, vertikaalanalüüsi ja korrelatsioonanalüüsi on varasemates uuringutes kasutatud enamasti vaid kombineerituna teiste meetoditega. Suur osa uuringutest, milles ka need neli meetodit on mingil määral kasutust leidnud, kasutavad sihilikult väärkajastatud finantsandmete tuvastamiseks regressioonanalüüsi. Levinud on kaks lähenemisviisi: uuringu läbiviijad koostavad ise analüüsi abil regressioonivõrrandi või kasutavad teiste autorite võrrandeid. Mõned regressioonanalüüsi kasutavad uuringud on esitletud järgnevas tabelis (vt tabel 1). Samuti on välja toodud Benfordi seadust kasutanud autorite artiklid. See meetod ei põhine küll regressioonivõrrandil, kuid võiks olla samuti hõlpsasti kasutatav kõigil huvitatud osapooltel.

Tabel 1. Kvantitatiivseid uurimismeetodeid kasutavad uuringud

Meetod	Viide
Autorite enda koostatud regressioonivõrrand	Guan <i>et al.</i> (2007); Skousen <i>et al.</i> (2009); Wuerges, Borba (2014); Yendrawati <i>et al.</i> (2019); Noble (2019); Khamainy <i>et al.</i> (2021)
Beneishi M-skoor	Ghosh <i>et al.</i> (1998); Roxas (2011); Fazli <i>et al.</i> (2016); Bhavani, Amponsah (2017); MacCarthy (2017); Mehta, Bhavani (2017); Özcan (2018) Kukreja <i>et al.</i> (2020); Hakami <i>et al.</i> (2020);
Altmani Z-skoor	Bhavani, Amponsah (2017); MacCarthy (2017); Mehta, Bhavani (2017); Kukreja <i>et al.</i> (2020); Hakami <i>et al.</i> (2020); Saleh <i>et al.</i> (2021)
Dechow' F-skoor	Fazli <i>et al.</i> (2016); Hung <i>et al.</i> (2017); Hakami <i>et al.</i> (2020); Saleh <i>et al.</i> (2021)
Benfordi seadus	Durtschi <i>et al.</i> (2004); Roxas (2011); Nigrini, Wells (2012); Haynes (2012); Mehta, Bhavani (2017); Ollén, Wennberg (2021)

Allikas: autori koostatud

Varasemates uuringutes, kus autorid on ise regressioonanalüüsi abil võrrandi koostanud, saadakse väga erinevaid tulemusi, mis on sageli sõltuvuses konkreetse kasutatud andmekogumiga, ning see asjaolu piirab võrrandi kasutatavust. Ülejäänud tabelis 1 toodud meetodid peaksid olema edukad erinevaid andmeid kasutades, seega on magistritöö autor otsustanud analüüsida ning hinnata just neid meetodeid. Järgnevates alapeatükkides antakse ülevaade Beneishi M-skoori, Altmani Z-skoori, Dechow' F-skoori ja Benfordi seaduse olemusest ning rakendamisest.

1.4.1. Beneishi M-skoori olemus ja rakendamine

Messod D. Beneish esitles oma mudelit 1999. aastal. Selle abil peaks saama eristada tahtlikult manipuleeritud ja mittemanipuleeritud aruandeid. Mudel on peamiselt suunatud tulu väärkajastamise tuvastamiseks. Tuluga manipuleerimise defineeris Beneish kui "juhtumi, mil ettevõtte juhid rikuvad üldtunnustatud raamatupidamis põhimõtteid selleks, et näidata ettevõtte finantstulemusi soodsalt". (Beneish 1999)

Mudelil on kaks versiooni. Üks põhineb kaheksa muutujaga regressioonivõrrandil, teine sisaldab viit muutujat. Beneishi M-skoori kaheksa muutujaga versioon (M8) on järgmine (Mehta, Bhavani 2017):

$$M = -4,84 + 0,92 \times DSRI + 0,528 \times GMI + 0,404 \times AQI + 0,892 \times SGI + 0,115 \times DEPI - 0,172 \times SGAI + 4,679 \times TATA - 0,327 \times LVGI \quad (1)$$

kus

$$DSRI = (\text{nõuded ostjate vastu}_t / \text{müügitulu}_t) / (\text{nõuded ostjate vastu}_{t-1} / \text{müügitulu}_{t-1})$$

$$GMI = [(\text{müügitulu}_{t-1} - \text{COGS}_{t-1}) / \text{müügitulu}_{t-1}] / [(\text{müügitulu}_t - \text{COGS}_t) / \text{müügitulu}_t]$$

$$AQI = [1 - (\text{käibevara}_t + \text{materiaalne põhivara}_t) / \text{koguvara}_t] / [1 - (\text{käibevara}_{t-1} + \text{materiaalne põhivara}_{t-1}) / \text{koguvara}_{t-1}]$$

$$SGI = \text{müügitulu}_t / \text{müügitulu}_{t-1}$$

$$DEPI = [\text{amortisatsioon}_{t-1} / (\text{materiaalne põhivara}_{t-1} + \text{amortisatsioon}_{t-1})] / [\text{amortisatsioon}_t / (\text{materiaalne põhivara}_t + \text{depretsatsioon}_t)]$$

$$SGAI = (\text{müügi-, üld- ja halduskulud}_t / \text{müügitulu}_t) / (\text{müügi-, üld- ja halduskulud}_{t-1} / \text{müügitulu}_{t-1})$$

$$TATA = (\text{puhaskasum}_t - \text{puhasrahakäive}_t) / \text{koguvara}_t$$

$$LVGI = [(\text{lühiajalised kohustised}_t + \text{pikaajalised kohustised}_t) / \text{koguvara}_t] / [(\text{lühiajalised kohustised}_{t-1} + \text{pikaajalised kohustised}_{t-1}) / \text{koguvara}_{t-1}]$$

Mudelis tähistab näitaja t perioodi (olenevalt juhtumist kas ühte aastat või kvartalit), mil avaldatud finantsandmed olid esimest korda väärkajastatud, ning t-1 selle perioodi aruande andmeid, mis pettusele vahetult eelnes.

Muutujate arvutamiseks kasutatakse andmeid finantsaruannetest. Beneish konstrueeris muutujad, mis peaksid kajastama nii manipuleerimise mõju kui ka eeldust ehk ajendit selleks tegevuseks. Pärast näitajate väljaarvutamist on võimalik leida näitaja M. Beneishi järelduste kohaselt saab ettevõtte liigitada manipulaatoriks, kui näitaja M on suurem kui $-1,78$. (Beneish 1999) Mitu autorit on hiljem Beneishi mudelit modifitseerinud. Hilisemates uuringutes on sageli kasutatud kontrollmõõduna väärtust $-2,22$ ning välja on jäetud osa näitajatest. Viie muutujaga mudel (M5) ei sisalda näitajaid SGAI, TATA ja LVGI (Mehta, Bhavani 2017):

$$M = -6,065 + 0,823 \times DSRI + 0,906 \times GMI + 0,593 \times AQI + 0,717 \times SGI + 0,107 \times DEPI \quad (2)$$

Mudeli muutujate valiku tegemisel oli Beneishi jaoks oluline tüüpilise ettevõtte profiil, mille finantsandmetes on manipuleeritud tuluga. Sellist (manipuleeritavat) ettevõtet iseloomustab tema väitel väga kiire kasv, mitme põhinäitaja halvenemine ning agressiivsete raamatupidamistavade kasutuselevõtt. Ta lisas mudelisse näitajad eeldusel, et väärkajastamised tulenevad tuluga manipuleerimisest (DSRI, AQI, DEPI ja TATA) või eelsoodumusest tegeleda tulu tahtliku väärkajastamisega (GMI, SGI, SGAI ja LVGI). Beneish kasutab oma mudelis näitajaid, mille suurenemine tõstab manipuleerimise tõenäosust. Järgnevas tabelis (vt tabel 2) on toodud välja kokkuvõtte Beneishi valitud muutujatest. Mudeli testimisel tuleb arvesse võtta, et muutujad ei ole alati sama tähtsusega, kuid peaksid ühiselt looma potentsiaalse manipulaatori profiili (Beneish *et al.* 2013).

Tabel 2. Potentsiaalselt manipuleeritava ettevõtte omadused, omadustega seotud mudeli muutuja(d) ja iseloomustavad näitajad Beneishi väitel

Potentsiaalselt manipuleeritava ettevõtte omadus	Seotud mudeli muutuja(d)	Iseloomustavad näitajad
kiire tulu kasv	SGI	tulu kasvab sama valdkonna ettevõtete keskmisest palju kiiremini
halvenevad peamised finantsnäitajad	GMI, SGAI, LVGI, AQI	brutokasumi taseme halvenemine; müügi-, üld- ja halduskulude suurenemine; võlgade ja varade suhte suurenemine; suureneb investeringute maht immateriaalsetesse varadesse, väheneb materiaalse põhivara osatähtsus koguvast
agressiivne raamatupidamine	DSRI, DEPI, TATA	nõuete ebatavaline suurenemine vaatamata kiiresti kasvavale müügile; depretsatsioonikulu vähenemine; kajastatud viitlaekumiste mahu suurenemine

Allikas: Beneish *et al.* (2013)

Beneish on märkinud, et kuna tema mudel vajab vaid kahe aasta andmeid ehk ühte majandusaasta aruannet, on see hõlpsasti kasutatav suurel andmekogumil. Ta arvas, et seda saaksid kasutada nii SEC, audiitorid kui ka investorid, kelle huvi oleks potentsiaalse pettuse tuvastamine. (Beneish 1999)

Mudeli võimekust on analüüsitud palju. Beneishi esimese uuringu tulemusena 1999. aastal väitis ta, et mudeli klassifitseerimisvõime on umbes 50% (*Ibid.*). 2012. aastal tegid Beneish, Lee ja Nichols uue uuringu, mille tulemusena tuvastas mudel õigesti 71% tuntumatest FAPi juhtumitest (Beneish *et al.* 2012). Türgi ettevõtete andmete põhjal korraldatud uuringus väitis Özcan lausa 85,63%-list klassifitseerimise täpsust. (Özcan 2018)

Siiski ei ole kõik uuringud mudeli võimekust kinnitanud. 2017. aasta uuringus, milles analüüsiti FAPi sooritanud Toshiba aruandeid, ei tuvastanud Bhavani ja Amponsah seitsme aasta valimist mitte ühtegi aastat, mil M-skoor oleks olnud suurem kui $-2,22$. Seejuures testisid nad nii kaheksa kui ka viie näitajaga mudelit. (Bhavani, Amponsah 2017) Tulemus on mõneti üllatav, sest Toshiba pettus seisnes tulu väärkajastamises ning Beneishi mudel on selle tuvastamiseks loodud. Samas nagu Beneish on rõhutanud, on M-skoor tõenäosusmudel, mille abil ei ole võimalik täpselt ennustada (Beneish 1999).

Üks tuntumaid uuringuid tehti Cornelli Ülikoolis. Tudengid analüüsisid ettevõtte Enroni andmeid enne, kui suur raamatupidamiskandaal avalikkuse ette jõudis. Juba 1998. aastal leidsid nad, et M-skoor oli kontrollmõõdust kõrgem, seega oli tegu potentsiaalse manipulaatoriga. (Ghosh *et al.* 1998)

Beneishi mudel on üks kirjanduses enim käsitletud tahtlikult manipuleeritud finantsandmete tuvastamise meetodeid. Mudeli näitajate arvutamiseks vajalik informatsioon on lihtsasti leitav ettevõtte majandusaasta aruandest ning selle lühem versioon sisaldab vaid viit muutujat. Suurem osa uuringutest on leidnud, et M-skoor on kasutatav FAPide tuvastamiseks.

1.4.2. Altmani Z-skoori olemus ja rakendamine

Altmani (1968) loodud mudelil oli teistsugune eesmärk. Altman oli arvamusel, et akadeemikud kasutavad järjest vähem suhtarve, analüüsima ettevõtete maksejõuetust. Ta asus uurima suhtarvude analüüsi sobivust analüütiliseks tööriistaks. Uuringu raames töötas ta välja pankroti

prognoosimudeli, millesse valis eri suhtarve, mis peaksid aitama ennustada seda, kas ettevõtte on lähema kahe aasta jooksul minemas pankrotti.

Altmani Z-skoori mudel põhineb viie muutujaga regressioonivõrrandil (Mehta, Bhavani 2017):

$$Z = 1,2 \times A + 1,4 \times B + 3,3 \times C + 0,6 \times D + 1,0 \times E \quad (3)$$

kus

A = käibekapital / koguvara

B = jaotamata kasum / koguvara

C = intressi- ja maksueelne kasum / koguvara

D = omakapitali turuväärtus / kohustised kokku

E = müügitulu / koguvara

Altman valis oma mudelisse näitajad 22 suhtarvu seast, mis 1968. aastal eri korporatsioonide probleeme potentsiaalselt kirjeldasid ning olid kirjanduse põhjal populaarsemad. Näitaja A võrdleb ettevõtte käibekapitali koguvaraga. Eeldatavasti on pidevalt kahjumit kandvatel üksustel käibevara osatähtsus koguvarast madalam ehk näitaja väiksem. Teine suhtarv B mõõdab ettevõtte võimet teenida kasumit. Ettevõttel, mille tõenäosus pankroti minna on suur, oodatakse väiksemat suhtarvu. Altman märkis ära tähtsa asjaolu, et kuna näitajat ei kohaldata vastavalt ettevõtte vanusele, diskrimineerib see noori ettevõtteid. C omakorda on ettevõtte varade tegeliku tasuvuse mõõt. Varade tasuvus on määravaks asjaoluks ettevõtte tegutsemisele, seega oodatakse eduka ettevõtte puhul pigem suuremat näitajat. Suhtarv D näitab, kui palju võib ettevõtte varade turuväärtus langeda enne, kui kohustised ületavad varasid ning ettevõtte muutub maksejõuetuks. Pankrot on tõenäolisem väiksema näitajaga ettevõtetel. Viimane näitaja ehk E on sagedasti kasutatav suhtarv, mis näitab varade müügivõimet. Nagu kõigi eelmiste näitajate puhul, iseloomustab jätkusuutlikku ettevõtet suurem suhtarv, maksejõuetuse poole liikuvat väiksem. (Altman 1968)

Arvutades välja muutujad ning asetades need valemisse, on võimalik leida näitaja Z . Altmani järelduste kohaselt liigitub ettevõtte vastavalt saadud tulemusele järgmiselt (Mehta, Bhavani 2017):

- rahaliselt stabiilne, kui Z on suurem kui 2,99;
- ettevaatus on vajalik, kui Z on vahemikus 2,77–2,99;
- tõenäoliselt läheb ettevõtte kahe aasta jooksul pankrotti, kui Z on vahemikus 1,88–2,77;
- pankroti tõenäosus on kõrge, kui Z on alla 1,88.

Mudeli tulemuste liigitus näitab, et mida madalam on saadud Z-skoor, seda tõenäolisem on, et ettevõtte on rahalistes raskustes. Raskustes olemine on aga motivatsiooniks, et manipuleerida finantsnäitajaid. (Dalnial *et al.* 2014) Tuginedes sellele seosele, on teisedki autorid järeldanud, et Altmani mudelit on võimalik kasutada ka FAPi tuvastamiseks. Seega mida väiksem on ettevõtte Z-skoor, seda olulisem on vaadata ettevõtte finantsandmeid lähemalt ning lükata ümber või kinnitada finantsaruannete pettuste esinemine.

Palju on analüüsitud maailma suurimat finantsskandaali, mille keskmes oli 2001. aastal Ameerikas asuv ettevõtte Enron. Kasutades Altmani skoori, tuvastati, et 1997. aasta aruanded näitasid tulemusega 1,611 kõrget pankroti tõenäosust. Beneishi skoor tuvastas finantsaruannete manipulatsiooni 1998. aasta aruannetest. Sellised tulemused on hea näide kõrgest tõenäosusest, et kehvad finantsnäitajad motiveerivad ettevõtteid oma finantsaruandeid manipuleerima, ning samuti sellest, et nimetatud mudelid näitasid riskitaset kohe. (Hakami *et al.* 2020)

Altmani Z-skoor on olnud edukas ka Toshiba aruannete analüüsil. Arvutatud skoorid näitasid aastatel 2009–2014, et pankroti tõenäosus oli kõrge. Hiljem selgus, et ettevõtte oli finantsandmeid kajastanud väärtalt. (Bhavani, Amponsah 2017) Edukaks peeti meetodit ka Ameerika Ühendriikide ettevõtte Comscore'i aruandeid kasutades. Ettevõtte avalikustas sihilikult väärkajastatud aruandeid aastatel 2014–2016. Nende aastate finantsandmete põhjal arvutatud Z-skoor oli vahemikus 4,3–8,9, mis näitas, et ettevõtte oli rahaliselt stabiilne. 2017. aastal langes näitaja 1,2 ning 2018. aastal juba 0,08 peale. (Kukreja *et al.* 2020) Tulemused näitavad drastilist muutust ning kuna ettevõtte ka andmete manipuleerimise eest süüdi mõisteti, kinnitab olukord mudeli edukust. Siiski andis selles uuringus Z-skoori väärtus vihje alles pärast pettuse toimumist. Aasta enne pettust oli ettevõtte sama skoori alusel samuti rahaliselt stabiilne, seega antud olukorras ennetamiseks see mudel ei oleks sobinud. Olgugi et Comscore'i näite puhul oli Altmani mudel tulemuslik tagantjärele, on siiski keeruline leida uuringuid, milles Z-skoor petturi puhul probleeme üldse ei tuvastanud. Uuringuid, kus Altmani mudelit oleks testitud vaid pettuseid sisaldavate aruannete kogumil, magistritöö autor ei leidnud.

Kui Beneishi M-skoor on FAPi tuvastamise eesmärgil tehtavates uuringutes kõige levinum meetod, siis järjest rohkem on hakatud kasutama ka Altmani mudelit. Pankrotti ennustav mudel on olnud edukas paljudes uuringutes. Sarnaselt Beneishi mudeliga saab tulemuse arvutamiseks kasutada vaid ühe majandusaasta aruande andmeid ning vajalike muutujate arv on viis.

1.4.3. Dechow' F-skoori olemus ja rakendamine

Dechow *et al.* (2011) avaldas artikli, milles esitles oma kolme mudelit. Mudelid on suunatud oluliste raamatupidamislike väärkajastamiste tuvastamiseks, saanud nimeks Dechow' F-skoor ning nii nagu eelnevalt välja toodud mudelid, põhinevad ka need regressioonivõrrandil.

Kolme mudeli erinevus seisneb muutujate arvus ja olemuses. Neis on muutujaid vastavalt kas 7, 9 või 11. Esimene variant sisaldab vaid finantsaruannetest pärit informatsiooni, mudel 2 lisab bilansivälised ja mitterahalised näitajad. Kõige pikem võrrand võtab arvesse ka turuga seotud tegurid. (Fazli *et al.* 2016) Siinses magistritöös kasutatakse mudeli esimest varianti. Dechow on mudelisse pannud ka ühe sagedasti kasutatava tasuvuse suhtarvu ehk muutuja, mis iseloomustab varade tootlust (*return on assets*, ROA).

Dechow' F-skoori mudel sisaldab seitset muutujat (*Ibid.*):

$$\begin{aligned} \text{VALUE} = & -7,893 + 0,790 \times \text{RSST} + 2,518 \times \Delta \text{REC} + 1,191 \times \Delta \text{INV} + 1,979 \times \\ \text{SOFTASSETS} & + 0,171 \times \Delta \text{CASHSALES} - 0,932 \times \Delta \text{ROA} + 1,029 \times \text{ISSUE} \end{aligned} \quad (4)$$

kus

$$\text{RSST} = (\Delta \text{WC} + \Delta \text{NCO} + \Delta \text{FIN}) / [0,5 \times (\text{koguvara}_{t-1} + \text{koguvara}_t)]$$

kus

$\text{WC} = (\text{käibevara} - \text{raha ja lühiajalised finantsinvesteeringud}) - (\text{lühiajalised kohustised} - \text{intressi kandvad lühiajalised võlakohustised});$

$\text{NCO} = (\text{koguvara} - \text{käibevara} - \text{pikaajalised finantsinvesteeringud}) - (\text{kohustised kokku} - \text{lühiajalised kohustised} - \text{intressi kandvad pikaajalised võlakohustised});$

$\text{FIN} = (\text{lühiajalised finantsinvesteeringud} + \text{pikaajalised finantsinvesteeringud}) - (\text{intressi kandvad pikaajalised võlakohustised} + \text{intressi kandvad lühiajalised võlakohustised} + \text{eelisaktsiad})$

$$\Delta \text{REC} = (\text{nõuded ostjate vastu}_t - \text{nõuded ostjate vastu}_{t-1}) / [0,5 \times (\text{koguvara}_{t-1} + \text{koguvara}_t)]$$

$$\Delta \text{INV} = (\text{varud}_t - \text{varud}_{t-1}) / [0,5 \times (\text{koguvara}_{t-1} + \text{koguvara}_t)]$$

$$\text{SOFTASSETS} = (\text{koguvara}_t - \text{põhivara}_t - \text{raha ja raha ekvivalendid}_t) / \text{koguvara}_t$$

$$\Delta \text{CASHSALES} = [\text{müügitulu}_t - (\text{nõuded ostjate vastu}_t - \text{nõuded ostjate vastu}_{t-1})] / [\text{müügitulu}_{t-1} - (\text{nõuded ostjate vastu}_{t-1} - \text{nõuded ostjate vastu}_{t-2})] - 1$$

$$\Delta \text{ROA} = [\text{puhaskasum}_t / (0,5 \times (\text{koguvara}_t + \text{koguvara}_{t-1}))] - [\text{puhaskasum}_{t-1} / (0,5 \times (\text{koguvara}_{t-2} + \text{koguvara}_{t-1}))]$$

$\text{ISSUE} = \text{näitaja kodeeritud numbriga 1, kui äriühing emiteeris pikaajalise võlakirja või lihtaktsiad aastal } t; \text{ kui ei, on väärtus } 0$

Nii nagu Beneishi mudeli puhul, näitavad ka F-skoori mudelis tähised t , $t-1$ ja $t-2$ eri perioode.

Tähisega $t-2$ on muutujateks selle perioodi aruande andmed, mis eelnes perioodile $t-1$.

Näitaja *RSST* on Dechow *et al.* (2011) jaoks väga oluline muutuja, kuna nende arvates vastab kirjanduses püstitatud hüpotees, et sissetulekuid kajastatakse peamiselt tulu tekkepõhise komponendi kaudu, tõele ning seega kajastatakse aruannetes tulu, mis on tekkinud, kuid raha on laekumata. *RSST* nimetus on lühend selle välja töötanud autorite nimedest (Richardson, Sloan, Soliman ja Tuna) ning see muutuja kirjeldab viitvõlgu. Viitvõlgade mõistet kasutatakse käibevara muutuste mõõtmiseks ilma raha kaasamata (Hakami *et al.* 2020). See konkreetne F-skoori mudeli muutuja peaks pakkuma varasemale viitlaekumiste mõistele laiemat määratlust. *RSST* arvates ei hõlmanud eelmine mõiste muutusi pikaajalistes tegevusvarades ja -kohustistes. Nende määratluse kohaselt kujutavad muutused kõigis mitterahaliste varade ja kohustiste kontodel eeldatavate tulevaste hüvede või kohustiste kogunemist ning seega hõlmavad viitvõlad nende määratluses kokku käibekapitali muutuseid (näitaja *WC*), muutuseid põhivaras (näitaja *NCO*) ja rahastamist iseloomustavaid viitvõlgu (näitaja *FIN*). (Richardson *et al.* 2006)

Arvutades välja muutujad ning sisestades need valemisse, on võimalik leida näitaja *VALUE*. Saadud väärtus teisendatakse tõenäosuseks (Fazli *et al.* 2016):

$$TÕENÄOSUS = 2,71828183^{(VALUE)} / (1 + 2,71828183^{(VALUE)}) \quad (5)$$

Väärtus *TÕENÄOSUS* jagatakse väärkajastamise tingimusteta tõenäosusega ehk väärtusega 0,0037 ning leitakse väärtus *F* (*Ibid.*):

$$F = TÕENÄOSUS / 0,0037 \quad (6)$$

Dechow *et al.* (2011) järelduste kohaselt on tavapäraseks F-skooriks 1. Sellest kõrgem näitaja viitab sellele, et ettevõtte aruanded sisaldavad tõenäolisemalt tahtlikke väärkajastamisi. Alla ühe saadud F-i puhul on väärkajastamise risk suhteliselt väike. (Hakami *et al.* 2020) Mitme teise autori arvates hinnatakse skoori üle 1,85 kõrgeks riskiks ning üle 2,45 väga kõrgeks. Finantsaruannete pettuse toime pannud Enroni 2000. aasta finantsandmete põhjal arvutatud F-skoor on 2,76. See tulemus kinnitab mudeli kasutatavust. (Hung *et al.* 2017) Dechow' valitud muutujate olemus ning võimalikud viited pettustele on lahti kirjutatud tabelis 3.

Tabel 3. Dechow' F-skoori mudeli muutuja, selle sisu, võimalikud viited pettusele ning pettuse potentsiaalne asukoht

Muutuja	Mõõdetav näitaja	Potentsiaalne viide pettusele	Potentsiaalne pettuse asukoht
RSST	viitvõlgade muutuse osatähtsus keskmisest kogugarast	suured muutused viitvõlgade osatähtsuses (osatähtsuse tõus) kogugarast	väärkajastatud tulu
Δ REC	nõuete muutuse osatähtsus keskmisest kogugarast	suured muutused nõuete osatähtsuses kogugarast	väärkajastatud tulu, nõuded ostjate vastu, puhasrahakäive
Δ INV	varude muutuse osatähtsus keskmisest kogugarast	suured muutused varude osatähtsuses kogugarast	varude arvestusest tingitud väärkajastatud tulu
SOFTASSETS	nende varade osatähtsus kogugarast, mis ei ole raha ning raha ekvivalendid ning põhivara	selliste varade osatähtsus, mis ei ole raha ning raha ekvivalendid ning põhivara, kogugarast on väga kõrge	väärkajastatud tulu (eriti lühiajaliselt)
Δ CASHSALES	kassamüügi muutus	kassamüük kasvab oluliselt (eriti võrdluses tulu kasvuga)	väärkajastatud tulu
Δ ROA	ROA muutus	ROA langus	väärkajastatud tulu
ISSUE	pikaajalise võlakirja- või aktsiate emissioon	emissioonide toimumine	rahavoo probleeme kompenseeritakse lisarahastusega; juhtkond kasutab aktsioptsioone

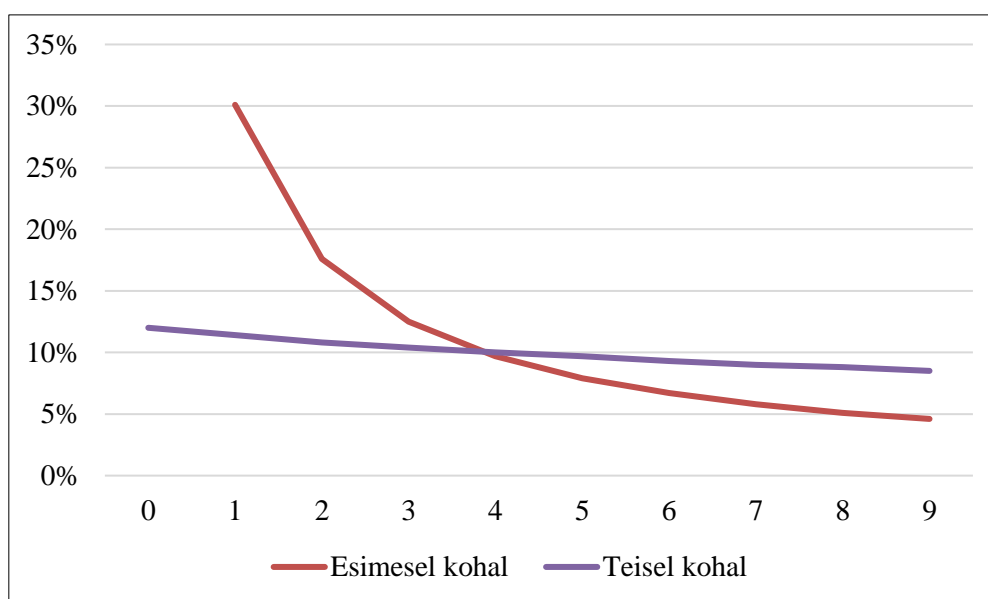
Allikas: Hakami *et al.* (2020); Fazli *et al.* (2016)

Dechow' F-skoor on võrreldes teiste selles peatükis välja toodud meetoditega uuem, seetõttu on meetodit kasutanud uuringuid vähem. Siiski on autoreid, kes on seda testinud ning kinnitavad mudeli tõhusust. Uuringutes on F-skoori mudelit võrreldud teiste populaarsete meetoditega. Malaisia ettevõtete andmete peal tehtud uuringu tulemusena selgus, et kui Beneishi meetod tuvastas pettuseid keskmiselt täpsusega 73,17%, siis Dechow' skoori tulemus oli 76,22%. (Fazli *et al.* 2016) Sama tulemuse said ka Vietnami börsil olevate ettevõtete andmete põhjal korraldatud uuringu autorid. Mudeli prognoositavust hinnati tasemele 77,1%. (Hung *et al.* 2017)

F-skooril põhinev mudel on võrreldes Beneishi ja Altmanni mudelitega laiem ulatuses, sisaldades enim näitajaid. Mudeli kasutatavust on peetud tänu näitajate rohkusele paremaks, kuid selle kasutamine on keerulisem. F-skoori arvutamiseks on vaja kolme majandusaasta andmeid ning seega on informatsiooni vaja koguda rohkem.

1.4.4. Benfordi seaduse olemus ja rakendamine

Teistsugune lähenemine finantsandmete tahtliku väärkajastamise tuvastamiseks tugineb astronoomi ja matemaatiku Simon Newcombi teorial, millele füüsik Frank Benford aastaid hiljem kinnitust leidis ning sellele ka oma nime andis (Durtschi *et al.* 2004). Teadlased tuvastasid oma igapäevatoös, et nad kasutavad matemaatiliste tehete tegemiseks logaritmitabelite puhul esimesi lehti rohkem, viimaseid vähem. Tabelites on numbrid tavapärasel järjekorras ehk alates ühest, seega spekulatiiviti, et järelikult on esimeste numbritega algavaid andmeid rohkem kui viimastega. Benford korraldas seejärel uuringu, kogudes kõikvõimalikku numbrilist informatsiooni ning pööras tähelepanu üksikute numbrite esinemisele selles andmestikus. (Benford 1938) Tema andmekogumis oli 20 229 täielikult juhuvalimi alusel kaasatud kirjet. Andmestikus olid näiteks nii numbrid ajalehtede esikülgedelt, majanumbrid kui ka rahvaarvud. Uuringu tulemusena sai tema kahtlus kinnitust. (Nigrini, Wells 2012) Joonisel 2 on näha, kuidas Benfordi kogutud andmete esimesel ja teisel kohal asetsevate numbrite jaotus keskmiselt kujunes (vt joonis 2). Tegu on numbrite 0–9 eeldatava sagedusega eri andmetes.



Joonis 2. Benfordi seaduse kohaselt esimese ja teise numbri jaotus
Allikas: Benford (1938)

Selle meetodi kasutamine eeldab suurt andmekogumit ning rangete piirideta ja ümardamata andmeid. Paljud autorid väidavad, et andmemah peaks olema 50–100 numbrit, kuid on ka arvamusi, et sobivam on testida 500 või enama andmekirje suurust andmestikku. (Ollén, Wennberg 2021) Sellest tulenevalt on analüüsi teostamiseks ettevõtete kohta vaja andmeid raamatupidamisest ehk näiteks palju erinevaid deebet- ja krediidkandeid. See meetod võiks olla abiks järgmiste andmete väärkajastamise tuvastamisel (Nigrini 2017):

- pearaamatu kanded (tehingud);
- nõuded ostjate vastu klientide põhised (saldod);
- nõuded ostjate vastu ja krediitkaardi võlad (saldod);
- varude seis artiklite kaupa (saldod);
- võlad tarnijatele tarnija põhised (saldod).

Väidetavalt kasutavad Benfordi seadust oma töös ka neli suurimat audiitor- ja muud finantskonsultatsiooni teenuseid pakkuvat ettevõtet ehk *Big Four*. Sellest võib järeldada, et need ettevõtted on leidnud enda jaoks meetodi kasuteguri. (Mehta, Bhavani 2017) Samuti vajab märkimist asjaolu, et kuigi meetod on abiks raamatupidajatele ja audiitoritele, siis selle seaduse kasutamine on välisele infotarbijale keeruline, kuna avalik finantsinformatsioon ei ole analüüsiks enamasti piisavas mahus.

Varasemaid uuringuid, mis testivad Benfordi seaduse kasutatavust, on korraldatud palju. Üks põhjalikku uurimistööd teinu on Nigrini, kes väitis koos teiste teadlastega juba 1997. aastal, et see meetod on abiks tuvastamiseks ettevõtteid, mille andmete Benfordi jaotusele mittevastavuse korral on potentsiaalsed finantsaruannete pettuste toimepanijad. (Nigrini 1997) Ka Haynesi uuringu tulemusena leiti, et seadus on kasulik, tuvastamiseks varakult potentsiaalset pettust ning samuti pankrotistumist. Ta tõi välja, et tegu on teistsuguse lähenemisega numbritele, ning rõhutas, et lisaks sellele meetodile tuleks pettuse tuvastamiseks kasutada lisaks ka mõnda muud meetodit. (Haynes 2012)

Ka Ollén ja Wennberg (2021) uurisid oma bakalaureusetöös, kuidas seadus on kasutatav. Nad kasutasid testimiseks kahte andmekogumit: Oklahoma osariigi valitsuse 2019. aasta kulutused ning Danske Panga Eesti filiaalis toimunud pettusega otseselt seotud ülekanded. Eeldus oli, et esimene andmestik peaks alluma Benfordi seaduse jaotusele, kuna ei sisalda teadaolevat pettust, ning teise andmed peaksid olema normaaljaotusest väljas. Töö tulemusena väideti, et andmete põhjal valminud graafikutelt on küll näha, et esimene kogum järgib normaaljaotust rohkem kui

teine, kuid viimase jaotus ei olnud graafikul siiski nii ebatavaline, et viitaks kohe pettusele. Nii nagu paljudes teistest uuringutes, leidsid ka Ollén ja Wennberg pärast statistiliste testide abil hüpoteeside testimist, et kumbki andmekogum ei allu siiski Benfordi seadusele.

Benfordi seaduse testimine on paljude autorite jaoks olnud edukas, kuid siiski on osa neist pidanud tõdemata, et statistilised meetodid kinnitust ei anna. Meetod nõuab suurt andmekogumit ning ühe ettevõttega seotud andmed avalikkusele sellises mahus kättesaadavad ei ole. Seetõttu väliste finantsaruannete kasutajatele meetod pigem kasutatav ei ole. See on ka põhjus, mis Benfordi seadust siinses magistritöös ei testita.

1.4.5. Mitut meetodit kasutavad uuringud

Siinses peatükis kirjeldatud meetodid lähenevad FAPI tuvastamisele erinevalt ning igal mudelil on oma tugevused ja puudujäägid. Alati ei ole teada, milline meetod konkreetsetes olukorras kõige paremini toimiks, seega on paljud autorid väitnud, et parima tulemuse saamiseks tuleks FAPI tuvastamiseks kasutada mitut meetodit korraga. Seda on väitnud Bhavani ja Amponsah (2017), argumenteerides seda tulemustega oma uuringust, mille alusena oli kasutatud ettevõtte Toshiba finantsaruandeid. Beneishi M-skoori mudel FAPI ei tuvastanud, kuid Z-skoori kasutamine oli tulemuslik. Toodud näite põhjal saab järeldada, et õige mudeli valimine on pettuse tuvastamisel äärmiselt oluline, kuna see võib mõjutada uuringu tulemust. Ka Mantone (2013) rõhutas oma raamatus, et finantsandmete manipulatsiooni tuvastamiseks väiksema vale tulemuse saamise tõenäosusega tuleks kasutada mitut meetodit korraga.

Beneishi M-skoor, Altmani Z-skoor ja Dechow' F-skoor põhinevad kõik regressioonivõrranditel, kuid sisaldavad eri muutujaid. Seetõttu on kõigi mudelite fookus erinev. Beneishi mudeli muutujad on valitud eesmärgiga tuvastada tulu väärkajastamine. Altmani Z-skoori abil hinnatakse ettevõtte jõudluse ning potentsiaalse pankroti võimalust. Dechow' mudel on laiemas suunitlusega ning selle fookuseks on oluliste raamatupidamislike väärkajastamiste tuvastamine. Nagu peatükis 1.4.2. välja toodud Hakami *et al.* (2020) uuringu tulemusest selgus, on oluline mõista mudelite erinevusi ning nende koostoimimist.

Tuginedes varasemate uuringute tulemustele, teeb magistritöö autor järgmises peatükis uuringu, kasutades kolme eespool kirjeldatud FAPI tuvastamise meetodit: Beneishi M-skoori, Altmani Z-skoori ja Dechow' F-skoori. Uuringu lõpus selgub, kas need mudelid on võimelised

klassifitseerima andmekogumis olevad ettevõtted manipuleeritavateks ning kui head need selleks on. Arutelu ja järelduste peatükis teeb autor kokkuvõtte mudelite headusest, tuginedes siinse uuringu tulemustele.

2. FINANTSARUANNETE PETTUSTE TUVASTAMISE MEETODITE RAKENDAMINE PETTUSEID SISALDAVATE FINANTSARUANNETE PEAL

Magistritöö teises peatükis kirjeldatakse uuringus kasutatud meetodikat ja andmekogumit. Samuti esitatakse uuringu tulemused ning nende põhjal teeb autor järeldused ja ettepanekud. Arutelu ja järelduste peatükis võrdleb autor kolme mudeli kasutatavust ning toob välja kõige olulisemad uuringu tulemused. Magistritöö empiiriline osa on koostatud, tuginedes teoreetilisele peatükile.

2.1. Uuringu meetodika

Siinse magistritöö esimeses peatükis andis autor ülevaate varasemates uuringutes kasutatud FAPI tuvastamisel abiks olevatest meetoditest. Autor otsustas oma uuringus kasutada regressioonivõrrandil põhinevaid meetodeid ehk Beneishi M-skoori, Altmani Z-skoori ja Dechow' F-skoori (vt peatükk 1.4.). Regressioonivõrrand on statistilise analüüsi tulem, mis kirjeldab selles sisalduvate tunnuste vahelisi seoseid. Võrrandi üldkuju:

$$y = b_0 + b_1 x_1 + b_2 x_2 \dots + b_n x_n \quad (7)$$

Regressioonivõrrandis on üldjuhul üks sõltuv tunnus (y) ning üks või mitu sõltumatut tunnust (x_1, x_2, x_n), mis peaksid aitama ennustada sõltuvat tunnust. Samuti on mudelis konstantsed arvtunnused (b_0, b_1, b_2, b_n). Regressioonivõrrandiga ei ole võimalik leida näitaja y täpset väärtust, kuid võrrand on abiks selle prognoosimisel. (Sauga 2005)

Beneishi, Altmani ja Dechow' mudelite eesmärk on leida sõltuv tunnus ehk näitajad M, Z ja $VALUE$. Meetodite loojad on lisanud konkreetse arvu nende arvates kõige paremini sõltuvat tunnust kirjeldavaid näitajaid ning leidnud regressioonianalüüsi käigus mudelitesse konstantsed arvtunnused. Siinses magistritöös tuli sõltuvate tunnuste leidmiseks arvutada tabelis 4 välja toodud näitajad (vt tabel 4).

Tabel 4. Magistritöös kasutatavate meetodite jaoks vajalikud sõltumatud tunnused

Meetod	Sõltumatud tunnused
Beneishi M-skoor	DSRI, GMI, AQI, SGI, DEPI, SGAI, TATA, LVGI
Altmani Z-skoor	A, B, C, D, E
Dechow' F-skoor	RSST, Δ REC, Δ INV, SOFTASSETS, Δ CASHSALES, Δ ROA, ISSUE

Allikas: autori koostatud

Pärast sõltumatute muutujate arvutamist ning nende lisamist võrrandisse oli võimalik arvutada näitaja y . See tulemus oli magistritöö autorile esimene osutis selle kohta, kas mudelid on suutelised tuvastama finantsaruannete pettuseid. Lisaks hindas autor kõikide mudelite headust, kasutades statistilisi meetodeid. Analüüsi tegemiseks kasutati tabelarvutus- ja tabeltöötlusprogrammi Microsoft Excel.

Algandmed sisestati Excelisse käsitsi ning kontrolliti pisteliselt kaks korda. Sisestatud andmete abil arvutati välja tabelis 4 välja toodud sõltumatud muutujad ning seejärel ka sõltuv tunnus. Tulemuste esmane analüüs kasutas kirjeldavat statistikat. Selleks koostas autor tabelleid, näitamaks tulemuste jaotumist kas manipuleeritavateks või mittemanipuleeritavateks. Samuti kasutati detailsema statistilise ülevaate saamiseks Exceli lisavõimalust Data Analysis ning selle valikut Descriptive Statistics. See andis võimaluse leida andmekogumi näitajate statistilised näitajad. Samuti kasutas autor Data Analysisi abi regressiooni- ja korrelatsioonanalüüsi tegemiseks (valikud Regression ja Correlation).

Mudelite võrdlus toimus järgmiste tegevuste abil:

- sõltumatu tunnuse võrdlus mudelite autorite etteantud väärtustega;
- sõltumatute tunnuste võrdlus mudelite autorite etteantud väärtustega ja/või mõne muu varasema uuringu tulemustega;
- sõltumatute tunnuste statistiline analüüs (standardhälve, miinimum, maksimum);
- regressioonanalüüs (determinatsioonikordaja, korrigeeritud determinatsioonikordaja, mudeli statistiline olulisus, sõltumatute muutujate statistiline olulisus);
- korrelatsioonanalüüs.


Andmeanalüüsi tulemusena hindab autor, kas meetodid on kasutatavad FAPi tuvastamisel. Uuringu andmekogumi koostamist ning andmete kogumist kirjeldatakse järgmises alapeatükis.

2.2. Uuringus kasutatav andmekogum

Hindamaks Beneishi M-skoori, Altmani Z-skoori ja Dechow' F-skoori kasutatavust ning nende headust, vajab autor andmeid. Võrrandeid sooviti testida mudelitest parema ülevaate saamiseks andmekogumil, mitte ühe konkreetse ettevõtte andmetel, seega ei saanud andmestikku moodustada Eesti ettevõtetest. Eestis ei ole avalikkusele teada palju ettevõtteid, kes oleks finantsandmeid tahtlikult väärkajastanud. Seetõttu moodustati magistritöö andmekogum, kasutades Ameerika Ühendriikide väärtpaperi- ja börsikomisjoni andmeid (AAER). Peatükis 1.3 selgitas autor, et AAERide puhul tegu on dokumentidega, mis kirjeldavad raamatupidamis- või auditeerimisrikkumisi ning mida SEC avalikustab oma kodulehel. AAER sisaldab informatsiooni asjaomase isiku ja/või ettevõtte kohta. Selles on kirjeldatud detailselt, millistel põhjustel teavitust väljastati ning milliseid seaduseid ja reegleid rikuti. AAERis on enamasti kirjas vastutava isiku nimi, vanus, elukoht ja ametipositsioon, ettevõtete puhul on samuti välja toodud nimi ja asukoht, aga ka kirjeldatud valdkonda, kus ettevõtte tegutses. Dokumendid annavad põhjaliku ülevaate toimunud rikkumisest.

Andmekogumi moodustamiseks analüüsis magistritöö autor viimase viie aasta AAERe ehk aastatel 2017–2021 avaldatud dokumente. Selle aja jooksul avaldas SEC 435 teavitust (vt joonis 3). Uuringu jaoks oli autori arvates väga oluline kasutada võimalikult uusi AAERe. Dokumentides viidatud rikkumiste juhtumid on enamasti juba mitu aastat vanad, kuid veelgi vanemate aruannetega uuringu korraldamine on riskantsem, kuna ettevõtluskeskkond ja finantsarvestus kogu aeg muutub. Soovides uuringu tulemusena välja selgitada sobivat meetodit praegu või tulevikus toimuvate FAPide tuvastamiseks, on vaja testida neid võimalikult uute andmete peal.

Magistritöö autor otsustas kasutada viimase viie aasta teavitusi ehk koostada andmekogum 435 AAERi põhjal. See kogus dokumente näis olevat piisavalt suur, et saada sobiv hulk andmeid ning samuti mahtuda magistritöö kirjutamise ajaraamistikku.



Joonis 3. Avaldatud AAERide koguarv aastatel 2017–2021

Allikas: *Accounting and ... 2022*; autori koostatud

AAERide analüüsi käigus luges autor läbi 435 dokumenti, kuid kõik ei olnud andmestiku moodustamisel tähtsad. SEC avalikustab mitmesugust rikkumisi puudutavat informatsiooni, kuid magistr töö jaoks oli vaja leida üles ettevõtted, kelle finantsaruanded sisaldasid finantsaruannete pettust. Teemad, mille kohta SEC oli küll AAERe välja andnud, kuid mis ei olnud magistr töö andmekogumi moodustamisel vajalikud, on järgnevad:

- siseteabe väärkasutamine;
- korrupsioon/alkäemaks;
- aruande esitamine ilma auditeerimiseta;
- huvide konflikt;
- vead audiitori töös;
- IPOdega seotud pettused;
- kehvast sisekontrollist tulenenud vead aruannetes.

FAPide juhtumitega seotud AAERidest oli vajalik eemaldada ka välismaa ettevõtted (väljaspool USA-d), kuna nende aruannete kättesaadavus on raskendatud ning nende aruanded võivad tulenevalt teiste raamatupidamistavade ja/või -standardite kasutamisest palju eristuda US GAAPi järgi koostatud aruannetest. jäid välja ka vaid väärkajastatud kvartaliaruandeid esitanud ettevõtted, kuna perioodi ning hetkeseisu kirjeldavate finantsnäitajate suhted erinevad aastaruannete omadest. Finants- ja investeerimisteenuseid pakkuvatel ettevõtetel on aruanded koostatud mõnevõrra teistel alustel, seega ei võetud uuringusse ka ühtegi selle valdkonna ettevõtet. Samuti eemaldati

andmekogumist ettevõtteid, kelle aruanded ei olnud kättesaadavad (näiteks liiga vana juhtum). Mõne ettevõtte juhtumi kohta oli avaldatud mitu AAERi, seega ei tähendanud AAERide koguarv potentsiaalselt andmekogumisse kuuluvate ettevõtete arvu.

Dokumentide analüüsi tulemusena jäi uuringu andmekogumisse 25 ettevõtet, kelle aruanded sisaldasid FAPi. Lisas 1 on kirjeldatud andmestikus olevaid ettevõtteid ning nende aruannetes sisaldunud pettuseid (vt lisa 1).

Selleks et koostada regressioonianalüüsi jaoks võimalikult täpselt sõltuvat muutujat ennustav regressioonivõrrand, on oluline kasutada piisavas suuruses andmestikku. Selle suuruse määramise suhtes ollakse eri arvamustel. Levinud on arusaam, et andmekogumi suurus peaks sõltuma sõltumatute tunnuste arvust (näiteks iga tunnuse kohta viie ettevõtte andmed) või on välja pakutud ka konkreetseid mahud (näiteks 300 või 400 ettevõtte andmed). (Green 1991) Piisav kogus andmeid on oluline võrrandi loomisel, kuna sellisel juhul on andmetes leiduv muster mudeliga paremini ennustatav. Siinses magistritöös uut võrrandit ei looda, vaid regressioonianalüüsi kasutatakse seniste võrrandite headuse hindamiseks. Seetõttu ei pea autor oluliseks andmekogumit suurendada. Siiski võivad uuringu tulemused olla mõjutatud pigem väikesest andmete hulgast.

Uuringuks vajalikud finantsandmed kogus autor kasutades ettevõtete esitatud 10-K vorme. Tegu on SECile esitatavate majandusaasta aruannetega (*Form 10-K ... 2022*). Neid vorme eelistas autor ettevõtte kodulehel avaldatud aruannete ees seetõttu, et paljud ettevõtteid on pärast SECi teavitust andmeid parandanud ning seega tõenäoliselt kodulehele uued aruanded üles laadinud. 10-K vormid on kättesaadavad sellisel kujul, nagu need esmalt esitati ehk need sisaldavad pettust. Ettevõtete esitatud 10-K vormid leidis autor järgnevatelt kodulehekülgedelt:

- SECi loodud andmebaas (*EDGAR ... 2022*);
- ettevõtte Fintel Ventures LLC loodud andmebaas (*The Equity ... 2022*).

Kui eespool välja toodud kodulehekülgedelt vajalikke andmeid ei leitud, guugeldas magistritöö autor ettevõtte nime ning lisas otsingusse märksõnadena „10-K“ ja otsitava aasta. Seejärel õnnestus leida sobivad andmed. Dokumendi asukoht oli interneti aadressirea põhjal SECi andmebaas, kuid miskipärast otse andmebaasis otsides vajalikku dokumenti ei leitud.

Kasutades loodud andmestikku ja peatükis 2.1 välja toodud metoodikat viis autor läbi uuringu. Uuringu tulemused on kirjeldatud järgmistes alapeatükkides.

2.3. Uuringu tulemused

2.3.1. Beneishi M-skoor

Beneishi M-skoori mudelil on kaks varianti: ühes kasutatakse kaheksat sõltumatut tegurit (M8), teises vaid viit (M5). Peatükis 1.4.1. tõi autor välja asjaolu, et uuringutes on kasutatud kahte eri kontrollmõõtu: osa arvates peaks M olema suurem kui $-1,78$, kuid teised kasutavad lävendina väärtust $-2,22$. Magistritöö autor kirjeldab selles alapeatükis tulemusi, võttes arvesse kõiki võimalikke mudelivariante ehk kahe eri muutujate arvuga võrrandeid ning kahte kontrollmõõtu.

25 ettevõtte andmete põhjal arvatud sõltumatud muutujad ning sõltuva teguri M väärtuse tulemuste kaks versiooni on välja toodud lisa 2 (vt lisa 2). Tulemused näitavad, et Beneishi mudel suutis tuvastada vaid osa FAPidest (vt tabel 5). Viie muutujaga Beneishi mudel suutis tuvastada 24% FAPidest. Tulemus ei sõltunud kontrollmõõdust. Kaheksa teguriga mudel oli edukam. Kasutades manipulaatori liigitusel väärtust $-1,78$, suutis mudel õigesti liigitada 32% ettevõtetest. Võrreldes saadud väärtuseid teise mõõduga, oli tulemus 40%.

Tabel 5. Beneishi M-skoori tulemuste kokkuvõte

Mudel	Kontrollmõõt	Manipuleeritav?	Koguarv	Osakaal
M5	$-1,78$	JAH	6	24%
		EI	19	76%
	$-2,22$	JAH	6	24%
		EI	19	76%
M8	$-1,78$	JAH	8	32%
		EI	17	68%
	$-2,22$	JAH	10	40%
		EI	15	60%

Allikas: autori arvutused lisa 2 välja toodud andmete põhjal

Tuginedes tabelis 5 välja toodud tulemustele, väidab autor, et kaheksa muutujaga Beneishi mudel suudab tuvastada rohkem FAPe kui M5. Kontrollmõõtu viie muutujaga mudeli puhul midagi ei määranud, küll aga oli M8 puhul võimalik mõõdu muutmisel tuvastada kaks ettevõtet rohkem. Seega oli väärtuse $-2,22$ kasutamine võrdluseks tulemuslikum.

Peatükis 1.4.1. tõi autor välja varasemate uuringute tulemused ning väitis, et mudeli klassifitseerimisvõimet on hinnatud olema näiteks nii 50% kui ka 86%. Siinne magistr töö uuring sellist võimekust ei kinnita. Lõplik tulemus ehk sõltuv muutuja M moodustub sõltumatutest muutujatest, seega on tulemuse erinevuse põhjenduse leidmiseks vaja vaadata iga muutujat eraldi. Tabelis 6 on kõrvutatud Beneishi 1999. aasta uuringu tulemusel leitud sõltumatute muutujate keskmised väärtused ning magistr töö autori arvutustel tuginevad keskmised väärtused (vt tabel 6). Nende andmete põhjal on välja arvutatud keskmiste erinevus. Seitsme näitaja puhul on magistr töös leitud muutujate väärtus väiksem kui Beneishi uuringus. Erinevuste intervall on arvuliselt $-0,3167$ kuni $0,0508$. Näitajate varieeruvused ei tundu olevat suured, kuid võttes arvesse muutuja väärtuste suurust, on vajalik vaadata, kuid suur on muutus protsendiliselt ehk mitu protsenti moodustab näitajate erinevus Beneishi mudeli tulemustest. Selle tulemusena on muutujate intervall paremini näha ning üsna märkimisväärne ehk alates $-426,6\%$ kuni $4,9\%$.

Tabel 6. Sõltumatute muutujate keskmiste võrdlus (Beneish 1999 *versus* magistr töö uuring)

Näitaja	Beneish	Autori arvutused	Erinevus	Erinevus (%)
DSRI	1,4650	1,2134	-0,2516	-17,2%
GMI	1,1930	1,0637	-0,1293	-10,8%
AQI	1,2540	1,2124	-0,0416	-3,3%
SIGI	1,6070	1,2903	-0,3167	-19,7%
DEPI	1,0770	1,0478	-0,0292	-2,7%
SGAI	1,0410	1,0918	0,0508	4,9%
TATA	0,0310	-0,1012	-0,1322	-426,6%
LVGI	1,1110	1,0640	-0,0470	-4,2%

Allikas: Beneish (1999); autori arvutused lisa 2 välja toodud andmete põhjal

Tabelis 6 näeme kõige suuremat erinevust protsendina näitaja TATA puhul, erinevus on $-426,6\%$. Sellise suure erinevuse puhul on tõenäoline, et andmekogumisse on sattunud mõni ettevõtte, kelle andmed erinevad ülejäänud ettevõtete omadest märkimisväärselt ehk need on erandid. Selle tuvastamiseks kasutame andmeid lisa 2 (vt lisa 2). Vaadates näitaja väärtuseid andmestikus, eristub selgelt ettevõtte DHG tulemusega $-0,7684$. Kui aga see ettevõtte andmekogumist eemaldada, oleks TATA keskmine tulemus $-0,0735$ ning erinevus Beneishi uuringu tulemusega väiksem.

Siiski ei ole suurt erinevust keskmistest tekitanud vaid üks erind. Silma jääb asjaolu, et Beneishi uuringus leitud TATA keskmine väärtus on positiivne, kuid magistr töö uuringu andmetel oli 19

ettevõtte näitaja hoopiski negatiivne. Näitaja TATA peaks kirjeldama sagedast manipulaatori profiili, mil raamatupidamises märgitud kasum on osaliselt kunstlikult tekitatud ning seega toetab seda puhasrahakäive vähem. Ettevõtetel, kelle puhaskasum on suurem puhasrahakäibest, on näitaja TATA positiivne. Positiivne näitaja on kaalukas indikaator kahtluse tekitamiseks ning seda kinnitab ka uuringu tulemus.

Magistritöö uuringu tulemustes oli näitaja positiivne vaid ettevõtete RLT, PSI, PPG, MAT, OST ja UNA puhul. Näitaja TATA mõju lõpptulemusele ehk väärtusele M on selgelt näha, kui kasutada mudelit M8 ning kontrollmõõtu $-2,22$. Nendest kuuest ettevõttes klassifitseeris mudel õigesti viit ettevõtet, tuvastamata jäi vaid PPG, mille näitaja väärtus oli napilt positiivne ehk $0,0014$. Uuring kinnitab, et positiivne TATA on oluline indikaator.

Sarnaselt näitajaga TATA peaksid kõik Beneishi mudeli näitajad olema suuremad neil ettevõtetel, kelle aruanded sisaldavad tõenäolisemalt tahtlikku väärkajastamist. Selle väite kinnitust otsis autor korrelatsioonanalüüsi abil. Lisades 5 ja 6 on välja toodud mudelite korrelatsioonimaatriksid (vt lisa 5 ja 6). Mudeli M5 näitajate korrelatsioonikordajad kinnitavad Beneishi väidet. Kõigi viie näitaja kordaja on positiivne, mis tähendab, et sõltumatu muutuja suurenedes avaldab see positiivset mõju ka sõltuvale tegurile M. Beneishi pikema mudeli kõik näitajad positiivset mõju ei avalda. Näitajate SGAI ja LVGI korrelatsioonikordajad on negatiivsed ning neil on keskmine seos, mis tähendab, et nende kasv hoopiski vähendab teguri M väärtust, seega väheneb manipuleerimise tõenäosus.

Tabelis 6 esitatud andmed näitavad, et magistritöö autori arvutatud nelja näitaja erinevus on üsna väike ehk alla 5% (SGAI, AQI, DEPI ja LVGI). Küll aga on seitsme näitaja keskmised väiksemad Beneishi tulemustest. Selleks, et leida olukorrale selgitust, tuleks vaadata magistritöös arvutatud sõltumatute muutujate olemust (vt tabel 7).

Tabel 7. Magistritöös arvatud sõltumatute muutujate kirjeldav statistika (Beneishi M-skoor)

Näitaja	Keskmine	Standardhälve	Miinum	Maksimum
DSRI	1,2134	0,5676	0,4276	3,1172
GMI	1,0637	0,3216	0,7688	2,5434
AQI	1,2124	1,0270	0,0146	5,3235
SGI	1,2903	0,4318	0,7353	2,4629
DEPI	1,0478	0,5704	0,5676	3,6228
SGAI	1,0918	0,3284	0,7457	1,9757
TATA	-0,1012	0,1749	-0,7684	0,1037
LVGI	1,0640	0,3561	0,1842	2,0795

Allikas: autori arvutused lisa 2 välja toodud andmete põhjal

Tabelis 7 näeme, et näitajate standardhälbed on üsna suured, seega on tulemused keskmise ümber väga hajuvad ning arvatud aritmeetiline keskmine ei anna päris adekvaatset tulemust. Näitajate hajuvus on selgelt näha ka siis, kui võrrelda miinimumi ja maksimumi väärtuseid. Sellise olukorra on tekitanud pigem väikeses andmekogumis (25 ettevõtet) esinevad üksteisest märkimisväärselt erinevad andmed.

Mudeli headuse hindamiseks tegi autor regressioonanalüüsi. Tulemused on näha lisades 5 ja 6 (vt lisa 5 ja 6). Mudeli M5 tulemused näitavad, et nii determinatsioonikordaja (*R Square*) kui ka korrigeeritud determinatsioonikordaja (*Adjusted R Square*) on ligilähedased väärtusele 1. Tulemus on ootuspärane, kuna mudelite loojad on valinud näitajad põhjusega, analüüsid eelnevalt eri võimalusi. Determinatsiooninäitaja väärtus tähendab, et 99,99% sõltuva muutuja M hajuvusest on kirjeldatud mudeli sõltumatute muutujatega. Korrigeeritud determinatsioonikordaja kõrge väärtus peaks näitama, et mudel ei pareneks muutujate lisamisel, vaid on juba piisavalt hea. Tuginedes mudeli näitajale *Significance F*, saab väita, et mudel on statistiliselt oluline võrreldes nivooga 1%. Seega on mudel kasutatav sõltuva tunnuse prognoosimiseks.

Regressioonanalüüsi tulemused on sarnased ka M8 puhul – determinatsioonikordaja, korrigeeritud determinatsioonikordaja ja mudeli olulisus kinnitavad selle headust. Magistritöö autor tõi peatüki alguses välja, et M8 klassifitseeris rohkem ettevõtteid õigesti. Mudelis M8 on kolm näitajat rohkem ehk minnes tagasi M5 tulemuste juurde, ei saa väita, et korrigeeritud determinatsioonikordaja annaks seal selge osutuse – näitajaid lisati mudelisse juurde ning mudeli headus (determinatsioonikordaja) on ikkagi samaväärne.

M8 regressioonianalüüsi tulemused aitavad selgitada, miks on osa autoreid jätnud mudelist välja kolm muutujat (SGAI, TATA ja LVGI). Seda valikut põhjendab nende muutujate *p-value*, mis näitab olulisust. Võrreldes olulisuse nivooga 1% on mudelis M5 kõik muutujad olulised. M8 tulemustest nähtub see, et viimased kolm näitajat ei ole sellise nivooga võrreldes olulised. Näitajate SGAI ja LVGI mudelist väljajätmist toetas ka korrelatsioonanalüüsi tulemus, kuna mõju M-ile ei olnud ootuspärane. Hoolimata näitaja TATA mitteolulisusest oli selle väärtusi analüüsides autori arvates siiski suur mõju FAPi tuvastamisel ning seda kinnitab ka korrelatsioonikordaja väärtusega 0,6728.

Mudelid M5 ja M8 on mõlemad statistiliselt olulised (võrreldes olulisuse nivooga 1%) ning nende headust kinnitas ka determinatsioonikordaja. Küsimusi tekitab siiski asjaolu, et kuigi M8 sisaldab mitteolulisi ning tulemust vastassuunas mõjutavaid muutujaid, klassifitseeris see manipuleeritavateks õigesti rohkem ettevõtteid. Vastuse saamiseks tuleb jällegi vaadata mudeli tugeid eraldiseisvalt. Enamiku ettevõtete puhul näeme, et kui M8 mudelisse lisatud kolm näitajat on andmestikus samade märkidega ehk näitajad SGAI ja LVGI on positiivsed, siis näitaja TATA suhtes eristuvad juba eespool välja toodud kuus ettevõtet, kelle näitaja on teise märgiga. Sellest tulenevalt on nende ettevõtete M5 tulemus väiksem kui mudelil M8 ning osa ettevõtete puhul tekkis olukord, mil M5 tulemus ei olnud kontrollmõõtudest suurem, kuid M8 oma küll. Seega näitaja TATA on mudelis oluline ning määrava tähtsusega. Kuigi SGAI ja LVGI ei ole regressioonianalüüsi kohaselt olulised, on neid vaja M8 mudelisse selleks, et toetada TATAt. Mingil määral annab sellele väitele kinnitust korrelatsioonimaatriks, mille andmetel on TATA ja nende näitajate vahel vähemalt väike seos olemas. On võimalik, et need kaks mitteolulist muutujat on võimalik oluliste vastu välja vahetada, kuid magistritöö raames uut võrrandit ei looda.

2.3.2. Altmani Z-skoor

Altmani Z-skoori mudel loodi selleks, et ennustada ettevõtete pankrotti minemise tõenäosust ehk rahalistest raskustes olemist. Nagu peatükis 1.4.2. välja toodi, on finantsraskused sageli tahtlike väärkajastamiste eelduseks. Altmani mudeli sõltuv muutuja peaks olema madalam neil ettevõtetel, kellel on pankrott tõenäolisem, seega võiks väiksem Altmani Z-skoor tõsta esile ka need ettevõtted, kelle finantsaruanded sisaldavad tõenäolisemalt FAPi.

Altmani Z-skoori sõltumatud muutujad ning nende abil arvutatud tegur Z on esitatud lisa 3 (vt lisa 3). Mudel ei klassifitseerinud kõiki ettevõtteid raskustes olevaks (vt tabel 8). Tabelis 8 on

näha, et Altmani mudel klassifitseeris uuringu andmekogumi 25 ettevõttest seitse rahaliselt stabiilseks ehk nende ettevõtete tõenäosus finantsandmetega tahtlikult manipuleerida peaks olema minimaalne. Kümne ettevõtte puhul hindas mudel riski kõrgeks ehk ettevõtete pankroti tõenäosust suureks. Ülejäänud kaheksa ettevõtte puhul on vajalik ettevaatus. Seega, uuringu tulemuste põhjal on risk väga kõrge 40% andmestiku ettevõtete puhul ning vihjeid annab see lisaks veel 32% ettevõtete puhul. Altmani mudel suutis tuvastada 72% ettevõtetest, kelle finantsandmeid võiks lähemalt vaadata. Võrdlus uuringutega, kus mudelit oleks testitud FAPI sisaldavate aruannete kogumil, puudub, kuna magistritöö autor selliseid uuringuid ei tuvastanud.

Tabel 8. Altmani Z-skoori tulemuste kokkuvõte

Hinnang/tulemus	Arv	Osakaal
Rahaliselt stabiilne (>2,99)	7	28%
Ettevaatus on vajalik (2,77–2,99)	8	32%
Tõenäoliselt läheb ettevõtte kahe aasta jooksul pankrotti (1,88–2,77)	0	0%
Pankroti tõenäosus on kõrge (<1,88)	10	40%

Allikas: autori arvutused lisas 3 välja toodud andmete põhjal

Nii nagu Beneishi mudel, jätab ka Altmani Z-skoori osa ettevõtetest tähelepanuta, kuigi nende aruanded sisaldavad FAPI. Põhjendust sellele võiks otsida tabelist 9, kus on võrreldud magistritöö uuringus leitud sõltumatute muutujate keskmisi mudeli looja Altmani välja pakutud keskmistega (vt tabel 9). Tabelis on näha, et 1968. aastal tehtud uuringu tulemused erinevad siinse magistritöö autori omadest. Muutuste protsendilise erinevuse varieeruvuse intervall on alates –459,7% kuni 953,9%. Põhjuseid sellisteks erinevusteks võib olla mitu. Sarnaselt Beneishi mudeliga võiks esimene selgitus olla see, et andmekogumisse võis sattuda üks või mitu erindit. Samuti on oluline ära märkida, et Altmani mudeli eesmärk ei ole FAPI tuvastada – see võiks olla abiks, kuid meeles peab pidama, et finantsraskustes olemine ei ole alati vajalik motivaator pettuse toimepanemiseks. Viimaseks võimalikuks selgituseks võib olla Altmani uuringu tegemise aasta. Tegu on vana uuringuga ning ettevõtetuskeskkond ja arvepidamise reeglid on selle ajaga palju muutunud.

Tabel 9. Sõltumatute muutujate keskmiste võrdlus (Altman 1968 *versus* magistritöö uuring)

Näitaja	Altman	Magistritöö	Erinevus	Erinevus, %
A	-0,0620	0,2230	0,2850	-459,7%
B	-0,6260	-0,3189	0,3071	-49,1%
C	-0,3180	-0,0513	0,2667	-83,9%
D	0,4000	4,2156	3,8156	953,9%
E	1,5000	0,8708	-0,6292	-41,9%

Allikas: Altman (1968); autori arvutused lisas 3 välja toodud andmete põhjal

Selleks, et saada parem võrdlus mõne varasema uuringuga, on tabelis 10 välja toodud magistritöö tulemuste võrdlus 2020. aastal avaldatud uuringu tulemustega (vt tabel 10). See uuring tehti, kasutades FAPi sisaldavaid ettevõtte Comscore aruandeid. Erinevused tulemustes on palju väiksemad kui tabelis 9, siiski eristub üks näitaja märkimisväärselt. Nelja näitaja puhul jääb erinevus vahemikku -37% kuni 41%, kuid näitaja A erinevus on 233%. Tuginedes lisas 3 välja toodud tulemustele, on näha, et magistritöö keskmist mõjutavad enim ettevõtete OST (0,87) ja DHG (0,63) tulemused – need on selged erandid. Samuti mõjutab erinevuse suurust asjaolu, et võrdluseks olev uuring on tehtud ühe ettevõtte andmeid kasutades. Comscore'i andmed võisid mingil põhjusel erineda tavapärasest tüüpilisest ettevõttest ehk kui need oleks kaasatud andmestikku, oleks selle ettevõtte andmed olnud erandid. Seetõttu ei saa ka sellest võrdlusest tulenevalt põhjanevaid järeldusi teha.

Tabel 10. Sõltumatute muutujate keskmiste võrdlus (Kukreja *et al.* 2020 *versus* magistritöö uuring)

Näitaja	Kukreja <i>et al.</i>	Magistritöö	Erinevus	Erinevus (%)
A	0,0670	0,2230	0,1560	232,9%
B	-0,3700	-0,3189	0,0511	-13,8%
C	-0,0800	-0,0513	0,0287	-35,9%
D	6,7440	4,2156	-2,5284	-37,5%
E	0,6180	0,8708	0,2528	40,9%

Allikas: Kukreja *et al.* (2020); autori arvutused lisas 3 välja toodud andmete põhjal

Kõige suuremat erinevust näitav muutuja A iseloomustab käibekapitali suhet koguvarasse. Altmani uuringus oli see näitaja negatiivne ehk ettevõtte käibekapital oli väiksem koguvarast. Kukreja *et al.* uuringu tulemus oli küll positiivne näitaja, kuid siiski palju väiksem kui magistritöö uuringus. Käibekapital on käibevara ja lühiajaliste kohustiste vahe ning näitab ettevõtte likviidsust. Magistritöö uuringu andmekogumi ettevõtetal oli järelikult käibekapitali osakaal koguvaradest

suurem ning seega ettevõtteid keskmiselt ka palju likviidsemad. Arvestades asjaolu, et üks võrdluseks olev uuring on üle 50 aasta vana ning teise tulemused tuginevad vaid ühe ettevõtte andmetel, on siinse magistr töö andmekogumi põhjal leitud näitaja suurus pigem päevakajalisem ja realistlikum. Seetõttu ei arva autor, et mudeli klassifitseerimisvõime oli selle näitaja tõttu madalam.

Mudel andis vihjeid 72% ettevõtete puhul, kuid tegu ei ole siiski vajaliku ehk ideaalse tulemusega. Magistr töö autor usub, et tulemus ei ole ideaalne erindite tõttu. Seda, et magistr töö andmekogumis esineb erindeid, on näha tabelis 11 (vt tabel 11). Kõige enam on seda näha näitaja D puhul, kus andmestiku on minimaalseks väärtuseks olnud 0,1157 ja maksimaalseks 37,8608, kusjuures keskmine tulemus on 4,2156. Suhtarv D näitab ettevõtte omakapitali turuväärtuse suhet kohustistesse. Positiivne arv näitab seda, et ettevõtte omakapitali turuväärtus on suurem kohustistest ning see on ettevõtete puhul tavapärane. Uuringus eristus teistest selgelt üks ettevõtte, OST tulemusega 37,86. Kõrget suhtarvu näitasid ka osa teisi ettevõtteid, nagu näiteks UNA (12,52), DHG (9,44) ja BLE (8,49). Muutujate varieeruvus on suur ning seetõttu on märkimisväärsed ka standardhälbed. Nagu Beneishi mudeli puhul selgitatud sai, ei ole aritmeetiline keskmine seetõttu päris adekvaatne.

Tabel 11. Magistr töös arvatud sõltumatute muutujate kirjeldav statistika (Altmani Z-skoor)

Näitaja	Keskmine	Standardhälve	Miinumum	Maksimum
A	0,2230	0,2167	-0,1190	0,8701
B	-0,3189	0,7587	-2,0745	1,0365
C	-0,0513	0,2255	-0,9920	0,1424
D	4,2156	7,7207	0,1157	37,8608
E	0,8708	0,5450	0,1192	2,1297

Allikas: autori arvutused lisa 3 välja toodud andmete põhjal

Nagu tabelis 8 välja toodi, klassifitseeris mudel seitse ettevõtet rahaliselt stabiilseks. Põhjuse leidmiseks tuleb vaadata näitajaid eraldi. Neljal ettevõttel on just näitaja D see, mis on andmekogumi keskmisest märksa kõrgem. Siiski ei saa see olla ainus mõjutav tegur, kuna näiteks ettevõtte DHG, kelle D väärtus on keskmisest palju kõrgem, sellist tulemust ei saavutanud. Autor ei leidnud tulemustest mustrit, mis selgitaks ettevõtte liigituse tulemusi. Rahaliselt stabiilseks klassifitseeritud ettevõtetel ei ole näitajates midagi sellist, mis neid ülejäänutest eristaks. Kui mõni nendest teguritest sarnaneb andmekogumi keskmisega, siis mõni muu tegur on keskmisest jällegi

mõnevõrra erinev. Selline lõpptulemus on tekkinud tegurite koosmõjul, kuid ühe konkreetse teguri väärtus lõpptulemuseks õiget vihjet ei anna.

Tuginedes regressioonianalüüsi tulemustele, leiab kinnitust Altmani Z-skoori mudeli headus ja olulisus (vt lisa 7). Nii nagu Beneishi mudeli puhul, on ka Altmani mudeli determinatsioonikordaja ja korrigeeritud determinatsioonikordaja 99,99%, mis näitab muutujate kõrget ennustusvõimet. Mudel on hõlpsasti kasutatav ennustamiseks, kuna see on oluline võrreldes olulisuse nivooga 1%.

Olulised on ka kõik mudeli muutujad, seega on nende esinemine mudelis õigustatud. Eelnevalt välja toodud näitaja D, millel esinesid suurimad erandid, mõjutab tulemust palju. Üks põhjuseid on erinevuse suurus, sest kui suurem osa andmestiku näitajate väärtustest asetsevad vahemikus -2 kuni 2 , siis näitaja mitme- või mitmekümnekordsel kasvul on märkimisväärne mõju andmekogumi keskmisele. Selle teguri mõju tulemusele on võrrandis pigem positiivne ehk see tõstab väärtust. See olukord on loogiline, kuna ettevõtte väga kõrge turuväärtus ning pankrotti minek ei käi kokku.

Altmani järelduste kohaselt on potentsiaalsemalt pankrotti minevate ettevõtete suhtarvud väiksemad ning seega on väiksem ka sõltuv muutuja Z. Mudeli korrelatsioonimaatriks kõikide muutujate puhul sellist seost ei kinnita (vt lisa 7). Korrelatsioonianalüüsi tulemusel on neljal näitajal positiivne mõju näitajale Z, kuid näitaja B langus hoopis suurendab Z-i väärtust. B ja sõltuva muutuja vahel on küll seos olemas, kuid see seos on nõrk. Analüüsi põhjal saab kinnitust näitaja D oluline mõju tulemusele – muutujate D ja Z-i vaheline korrelatsioonikordaja on 0,9304 ehk nimetatud mudelis on D muutusel suur mõju ka Z-i muutusele.

Altmani Z-skoori mudel ning kõik selle muutujad on võrreldes olulisuse nivooga 1% olulised. Samuti on kõrge determinatsioonikordaja, mis näitab, et mudeli näitajad kirjeldavad hästi Z-i hajuvust. Tulemused siiski ideaalsed ei olnud ning sellele konkreetset põhjendust ei ole. Meeles peab pidama, et see ei ole pettuste tuvastamiseks loodud mudel ning selle tulemus ehk potentsiaalne finantsraskustes olemine ei tähenda alati pettuse ohtu.

2.3.3. Dechow' F-skoor

Dechow' mudeli eesmärk on tuvastada raamatupidamislikke väärkajastamisi. Tulemuste tõlgendamisel kasutatakse kontrollmõõduna väärtust 1. Kui sõltuva muutuja F väärtus osutub

kõrgemaks, sisaldab ettevõtte aruanne tõenäolisemalt FAPI. Varasemates uuringutes on võrreldud tulemusi ka skooriga 1,85, üle mille peaks risk olema kõrge, ning 2,45, millest kõrgem näitaja tähendaks juba väga kõrget riski.

Magistritöö autor arvutas Dechow' mudeli jaoks vajalikud muutujad ning leidis teguri F. Tulemused on esitatud lisa 4 (vt lisa 4). Dechow' F-skoori mudel tuvastas 56% FAPIdest, seega tuvastamata jäi 44% ettevõtetest. Seejuures hindas mudel riski kõrgeks seitsme ning väga kõrgeks viie ettevõtte puhul.

Kuigi Dechow' mudeli klassifitseerimine on mõnevõrra parem Beneishi omast, ei ole ka selle võime isegi võrdne varasemate uuringute tulemustega – peatükis 1.4.3. tõi autor välja mudeli edukust testinud varasemate uuringute tulemused, milleks olid 76% ja 77%. Magistritöö uuring sellist võimekust ei tuvastanud. Nagu ka kahe teise mudeli puhul, üritab autor sellisele tulemusele põhjendust leida, analüüsides muutujaid eraldi. Esmalt on tabelis 13 võrreldud magistritöö uuringu tulemusi mudeli autori tulemustega (vt tabel 12). Näitajate erinevus varieerub –126% ja 8% vahel.

Tabel 12. Sõltumatute muutujate keskmiste võrdlus (Dechow *et al.* 2011 *versus* magistritöö uuring)

Näitaja	Dechow <i>et al.</i>	Magistritöö	Erinevus	Erinevus (%)
RSST	0,1350	0,0997	-0,0353	-26,2%
Δ REC	0,0710	0,0521	-0,0189	-26,6%
Δ INV	0,0460	0,0277	-0,0183	-39,8%
SOFTASSETS	0,6470	0,6979	0,0509	7,9%
Δ CASHSALES	0,4660	0,2362	-0,2298	-49,3%
Δ ROA	-0,0320	-0,0725	-0,0405	-126,4%
ISSUE	0,9380	0,7600	-0,1780	-19,0%

Allikas: Dechow *et al.* (2011); autori arvutused lisa 4 välja toodud andmete põhjal

Dechow' uuringu tulemustega võrreldes paistab silma erinevus selles, et magistritöös arvatud kuue näitaja keskmine on varasema uuringu tulemustest väiksem. F-i suurenemiseks on vaja enamiku näitajate puhul (välja arvatud Δ ROA) suuremat väärtust, kuna valemis toimub näitaja liitmine. Siiski, nagu ka Altmani mudeli puhul, ei ole näha mingit konkreetset mustrit, mis eristaks mudeli klassifitseeritud manipuleeritavad ettevõtted nendest, mida ei tuvastatud. Olukord on sarnane Altmani mudeliga ehk kui mõned muutujate väärtused on lähedal keskmisele tulemusele, siis mõni teine muutuja erineb keskmisest rohkem. F-skoor tekib muutujate koosmõjust.

Tabelis 12 näeme, et muutujate keskmiste tulemuste protsentuaalne erinevus on ühe näitaja puhul teistest eristuv. Näitaja ΔROA on Dechow' uuringu omast 126% madalam. Tabelis 13 on näha selle muutuja miinimum- ja maksimumväärtuseid (vt tabel 13). Autor eeldab, et andmekogumisse on sattunud erindeid, mis on tulemuste keskmist väärtust vähendanud. Kinnitust sellele leiab lisas 4 välja toodud tulemustest (vt lisa 4). Märkimisväärselt on siin keskmist mõjutanud ettevõtete DHG (-0,92) ja OST (-0,64) tulemused. Näitajal ΔROA on korrelatsioonimaatriksi järgi (vt lisa 8) positiivne ning näitajaga F nõrk seos. Positiivne seos tähendab, et näitaja suurenemisel suureneb ka F. Selle näitaja puhul peaks seos olema negatiivne. Nende kahe ettevõtte puhul on ΔROA keskmisest palju väiksem ning mudel on liigitanud ettevõtted manipulaatoriks. Mitme teise ettevõtete puhul, mille ΔROA on keskmisest kõrgem, mudel sellist tulemust ei saavutnud. Seega, kuigi seos on olemas, on see nõrk ning erinditel ei ole F-ile nii suurt mõju kui mõne teise näitaja puhul.

Mudeli sõltumatutest muutujatest parema ülevaate saamiseks on tabelis 13 välja toodud näitajate keskmised tulemused, nende standardhälbed ning minimaalne ja maksimaalne väärtus (vt tabel 13). Näitajate ΔREC ja ΔINV standardhälbed on väga väikesed (vastavalt 0,0628 ja 0,0530), seega arvatud tulemused nende näitajate puhul ei haju palju ümber keskmise. Teiste muutujate näitaja on palju suurem ning enamik näitajatest varieeruvad nii negatiivsete kui ka positiivsete väärtuste vahel. Kõige suurem hälve on näitajal ISSUE, kuid kuna tegu on binaarse näitajaga, ei nõua see tulemus tähelepanu.

Tabel 13. Magistritöös arvatud sõltumatute muutujate kirjeldav statistika (Dechow' F-skoor)

Näitaja	Keskmine	Standardhälve	Miinimum	Maksimum
RSST	0,0997	0,4126	-0,4459	1,3321
ΔREC	0,0521	0,0628	-0,0472	0,1771
ΔINV	0,0277	0,0530	-0,0249	0,1889
SOFTASSETS	0,6979	0,2158	0,2972	0,9836
$\Delta CASHSALES$	0,2362	0,3503	-0,2450	1,1834
ΔROA	-0,0725	0,2595	-0,9160	0,5104
ISSUE	0,7600	0,4359	0	1

Allikas: autori arvutused lisas 4 välja toodud andmete põhjal

Dechow' F-skoori mudeli regressioonianalüüsi tulemus erineb eespool välja toodud mudelite omast vähesel määral (vt lisa 8). Mudeli determinatsioonikordaja on 96,23%. Tegu on madalama

tulemusega kui Beneishi ja Altmanni mudelite puhul, kuid siiski on sõltumatud muutujad väga head kirjeldama F-i hajuvust. Korregeeritud determinatsioonikordaja selle skoori puhul on 94,68%. Jällegi on skoor natukene madalam, kuid teades mudeli klassifitseerimisvõimet magistritöö uuringus, ei tohiks erinevus olla märkimisväärse tähendusega. Küll aga jätab see võimaluse mudelit parendada. Sobiva muutuja lisamise korral võib see näitaja suurendada ning mudeli headus tõusta. Mudel on statistiliselt oluline võrreldes olulisuse nivooga 1%, seega on see kasutatav sõltuva tunnuse ennustamiseks.

Dechow' mudeli seitse muutujat on kõik positiivse korrelatsioonikordajaga (vt lisa 8). Mudeli autori väitel sisaldab nende ettevõtete aruanne tõenäolisemalt tahtlikke väärkajastamisi, kui näitaja F on suurem ühest. Positiivse korrelatsiooni kohaselt suurendab muutuja tõus F-i väärtust ning selle mudeli juures kehtib see kõikide muutujate puhul. Kõige tugevamalt on sõltuva muutujaga seotud muutuja RSST, mille korrelatsioonikordaja on 0,7552. Järgnevad näitajad Δ REC (0,5060) ja SOFTASSETS (0,4633). Korrelatsioonimaatriks ei näita Δ ROA puhul õiget tulemust. Tegu on teguriga võrrandis, mille väärtus lahutatakse, seega selle näitaja korrelatsioonikordaja peaks olema negatiivne ehk selle vähenemisel peaks F suurenema.

Autor tõi eespool välja, et kuigi Δ ROA näitaja puhul oli näha selgeid erinevusi, siis näitaja ei mõjuta mudeli tulemust palju ning seda kinnitas nõrk seos sõltuva ja sõltumatu muutuja vahel. Näitaja RSST tugevast seosest tulemusega võib järeldada, et erindid selle muutuja juures avaldavad suurt mõju lõpptulemusele. Selle muutuja standardhälve on üks kõrgemaid, väärtuste hajuvus on väga suur. Tuginedes lisas 4 välja toodud tulemustele, jäävad samuti silma erindid. Kui näitaja RSST keskmine väärtus on 0,0997, siis ettevõtete PAC ja BLE väärtused on lausa vastavalt 1,33 ja 1,25. Eemaldades need väärtused andmestikust ning leides sellele näitajale uue keskmise väärtuse, sai autor tulemuseks $-0,0037$. See väärtus oleks Dechow' uuringu omast veelgi madalam ning erinevus selle näitaja puhul hoopis suureneks mitu korda. Seega tuleks otsida erinevusi teisest intervalli otsast.

RSST näitaja on negatiivne üheksa ettevõtte puhul. Eelduslikult peaks FAPi sisaldavate aruannete andmetel arvutatud näitaja olema siiski suurem ehk aruannetes on kajastatud tavapärasest rohkem viitvõlgu. Siinses magistritöö uuringus puudub võrdlus pettust mittesisaldavate aruannetega, kuid on olemas võrdlus Dechow' uuringuga. Selles uuringus oli näitaja väärtus 0,135. Seetõttu väidab autor, et eelmises lõigus välja toodud erindite väärtused olid selge vihje FAPi sisaldavast aruandest, kuid vähemalt üheksa ettevõtte puhul see näitaja tulemust ei saavutanud.

Regressioonianalüüsi tulemusena leitud muutujate olulisuse tõenäosused (*p-value*) näitavad, et kõik ei ole võrrandis olulised. Võrreldes olulisuse nivooaga 1%, ei ole olulised näitajad Δ REC, Δ INV ja Δ CASHSALES. Siiski on need näitajad mudelite loojate poolt võrrandisse jäetud ning kuna kõigil kolmel näitajal on siinse magistritöö korrelatsioonianalüüsi tulemustele tuginedes kas nõrgem või tugevam seos mõne teise muutujaga, on nende esinemine mudelis siiski vajalik.

Dechow' F-skoori mudel tuvastas 56% FAPidest. Kuigi mudeli determinatsioonikordaja on 96,23% ning kõik mudeli näitajad ei ole olulised, on saadud tulemus hea. Mudel ei klassifitseerinud õigesti siiski kõiki ettevõtteid. Põhjust mudeli klassifitseerimisvõimele magistritöö autor ei leidnud. Andmetes ei ole näha mustrit, mis eristaks mudeli tulemusena määratletud manipuleeritavad ettevõtted ülejäänutest. Nagu ka teiste mudelite puhul, on erinditel väga suur mõju tulemustele.

2.4. Arutelu ja järeldused

Eelmistes alapeatükkides esitles autor uuringu tulemusi. Mitte ükski kolmest testitud mudelist ei saavutanud 100%-list klassifitseerimisvõimet. Tabelis 14 on näha magistritöö uuringu tulemuste kokkuvõte (vt tabel 14).

Tabel 14. Magistritöö uuringu tulemuste kokkuvõte

Mudeli statistiline näitaja	M5	M8	Z	F
Klassifitseerimisvõime	24%	32% / 40%	72%	56%
Determinatsioonikordaja	99,9%	99,9%	99,9%	96,2%
Korrigeeritud determinatsioonikordaja	99,9%	99,9%	99,9%	94,7%
Kas mudel on oluline?	jah	jah	jah	jah
Kas kõik näitajad on olulised?	jah	ei	jah	ei

Allikas: autori koostatud lisades 2 – 8 välja toodud andmete põhjal

Võrreldes uuringus testitud mudelite tulemusi, näeme, et kõige parem klassifitseerimisvõime oli Altmanni Z-skoori mudelil. Saavutatud tulemus 72% on arvesse võetud nii ettevõtted, millele mudel omistas pankroti kõrge tõenäosuse, kui ka need, mille puhul oleks ettevaatus vajalik. Mõlemad kirjed peaksid andma ettevõtte finantsandmete õigsusest huvituvatele osapooltele

vihjeid selle kohta, et midagi võib valesti olla. Siiski, nagu korduvalt mainitud, võib Altmani mudel olla abiks FAPide tuvastamisel, kuid finantsraskustes olemine ei vii alati andmete tahtliku manipuleerimiseni, samuti ei ole pankrotioht ainus FAPi põhjus. Dechow' mudel, mille eesmärk on leida finantsaruannetes väärkajastamisi, tuvastas üle poole ettevõtetest ehk see mudel liigitas manipuleeritavateks 56%. Beneishi mudeli kahe versiooni tulemused olid tagasihoidlikumad. Kasutades kahte eri kontrollmõõtu, suutis kaheksat muutujat sisaldav mudel tuvastada kas 40% või 32% manipuleeritavatest ettevõtetest. Viie muutujaga mudeli klassifitseerimisvõime oli vaid 24%.

Nende regressioonivõrrandite koostajad tegid eelnevalt põhjalikku analüüsi ning seetõttu ei ole uuringu tulemusena leitud mudelite tugevad headuse näitajad üllatav tulemus. Beneishi ja Altmani mudeli sõltumatu muutuja hajuvusest on 99,99% kirjeldatud võrrandi sõltuvate muutujatega. Samuti näitab korrigeeritud determinatsioonikordaja seda, et muutujate lisamisel võrrandisse selle juba saavutatud kirjeldatavus ei paraneks. Dechow' mudeli samade näitajate tulemused olid madalamad, kuid siiski piisavalt kõrged, et kinnitada selle headust. Samuti selgus regressioonianalüüsi käigus, et kõik mudelid on kasutatavad sõltuva tunnuse prognoosimiseks ning seda kinnitab ka mudelite statistiline olulisus, mida võrreldi olulisuse nivooga 1%. Sõltumatud muutujad olid sama nivooga võrreldes kõik olulised Beneishi viie muutujaga ning Altmani mudelis. Võrrandites M8 ja Dechow' F-skoor oli siiski ka tegureid, mis statistiliselt olulised ei olnud. Tulenevalt kõikide näitajate seosest tulemuse või mõne muu muutujaga, ei soovita magistritöö autor ühtegi statistiliselt mitteolulist muutujat välja jätta. Mudeli muutujate eemaldamine ja/või uute sissetoomine vajab väga suure andmekogumiga uuringut ning põhjalikku analüüsi.

Uuringu tulemusi mõjutasid andmestikus leiduvad erandid. Erindite tõttu ei ole mõistlik magistritöös arvatud näitajate keskmisi tulemusi varasemate uuringutega võrrelda. Paljude sõltumatute muutujate standardhälve oli pigem suur, mis näitab, et tulemused olid väga hajuvad. Sellest on mõjutatud ka aritmeetiline keskmine, mis ei ole enamiku näitajate puhul usaldusväärne.

Erindite tõttu on keeruline usaldada mudeli tulemusi, küll aga võivad need olla abiks, et leida üles ettevõtted, kelle andmeid lähemalt vaadata. Need võiksid olla vihjed potentsiaalsest FAPist. Näiteks üks erinditest oli ettevõtte DHG näitaja Δ ROA. Ettevõtte andmeid analüüsides selgus, et ettevõtte ROA oli ühel aastal üle 1 ehk ettevõtte puhaskasum oli sellel aastal suurem kui varade kogumaht. Tegu ei ole tavapärase olukorraga, seega annab see vihje, et otsida ettevõtte aruannetest

põhjendust, samuti võimaluse korral küsida juhtkonnalt selgitusi. Erind ei ole aga alati negatiivse tähendusega, sest näiteks Altmani mudeli näitaja D eristuvad tulemused ei näita suuremat pankrotiohtu, vaid annavad pigem vastupidise tulemuse.

Analüüsid mudelite sõltumatuid muutujaid, ei tuvastanud autor konkreetset mustrit ega põhjust sellele, miks mudelid klassifitseerivad mõnda ettevõtet manipuleeritavaks ning mõnda mitte. Nagu öeldud, mõjutasid tulemusi erindid ning seda ka ühe ettevõtte tasandil. Näiteks on ettevõtte OST turuväärtus niipalju kõrgem, et näitaja D väärtus ületas mitmekümnekordselt paljude teiste ettevõtete tulemuse. Ettevõtte OST teised näitajad jäid enam-vähem keskmisele tasemele, seega oli näitajal D suur mõju sõltuvale muutujale. Siiski tasub välja tuua Beneishi mudeli näitaja TATA väärtuse võimekus. Nimelt klassifitseeris mudel manipuleeritavaks ettevõtteks peaaegu kõik need, kelle näitaja TATA väärtus oli positiivne. Kuuest ettevõttest jäi tuvastamata vaid üks, kuid selle väärtus oli nulli lähedal. Seega võib väita, et TATA leidmine võib anda aimu juba ka tulemuste suhtes. Ükski teine sõltumatu muutuja sellist tulemust ei näidanud.

Nagu eelnevalt välja toodud, mõjutavad erindid mudeli tulemusi, seda just väikese andmekogumi puhul. Autor arvab, et kui andmete hulk oleks suurem, oleks erindite mõju mudelite tulemustele väiksem ning seega võiksid nende klassifitseerimisvõime protsendid ja näitajate keskmised olla paremad. Andmekogumi suurendamine ei oleks siiski lahendus mudelite tuvastuse parandamisele ühe ettevõtte tasandil. Siinses uuringus ei klassifitseerinud mudelid õigesti mitmeid ettevõtteid – suurendades andmekogumit, see olukord ei laheneks.

Autor analüüsis ka seda, kuidas mudelid koos toimivad. Lisas 9 on välja toodud mudelite tulemuste võrdlus (vt lisa 9). Vaid kahe ettevõtte puhul andsid kõik mudelid vihje sellest, et andmeid on tahtlikult väärkajastatud või pankroti tõenäosus on kõrge. Kahe ettevõtte puhul ei saavutanud ükski mudelitest tulemust. Ülejäänud ettevõtteid liigitas õigesti üks kuni viis mudelit. Konkreetset mustrit tulemustes näha ei ole. Tulenevalt sellest, et 23 ettevõtte puhul andis vähemalt üks mudelitest tulemust, soovitab magistritöö autor kasutada FAPi tuvastamisel mitut meetodit korraga. Magistritöö uuringu tulemusena võib väita, et kasutades neid kolme mudelit, on võimalik tuvastada 92% ettevõtetest, kelle aruanded vajaksid lähemalt vaatlust.

Magistritöö tulemus ei anna siiski kindlust selles, et kui mudel klassifitseerib ettevõtte manipuleeritavaks, siis sisaldavad tema aruanded kindlasti ka FAPi. Ka ei tohiks tugineda sellele, et kui mudel tulemust ei anna, siis ei ole finantsandmeid tahtlikult manipuleeritud. Magistritöö

autor ei saa viimast väidet kinnitada, kuna see eeldaks uuringut FAPi mittesisaldavate finantsandmete põhjal ning mudeli kõrget klassifitseerimisvõimet selles olukorras. Sellise uuringu tarbeks oleks andmestikku moodustada väga keeruline. Nagu eelnevalt välja toodud, siis pettuseid sageli ei avastata ning seega võib andmekogumisse sattuda ettevõtteid, kes avalikkusele ei ole teada kui väärkajastatud andmeid avaldavad ettevõtted, kuid tegelikult nende aruanded FAPi siiski sisaldavad.

Samuti vaatas autor, kuidas mudelite tuvastusvõime andmekogumis sõltub ettevõtte tegevusvaldkonnast (tootmine, teenuse osutamine, toiduainete töötlus või IT) ning pettuse olemusest (tulu ülehindamine, kulu alahindamine, fiktiivne kulu või fiktiivne tulu). Analüüsi tulemusena selgus, et teenust pakuvad ettevõtted olid pigem halvasti tuvastatavad ning nende pettuse tulemusena oli tulu aruannetes ülehinnatud. Samuti olid need kaks ettevõtet, mida ükski mudel ära ei märkinud, just teenuseid osutavad ettevõtted ning pettuse tulemuseks ülehinnatud tulu. Ainsat andmekogumis olevat töötlusega tegelevat ettevõtet mudelid hästi ei tuvastanud, tulemuse andis vaid Z-skoor. Kolm IT-valdkonnas tegutsevat ettevõtet tuvastasid mudelid pigem hästi – tulemused olid nende puhul 6, 5 ja 3. Ühe IT-ettevõtte aruannetes oli kajastatud fiktiivset tulu ning selle suutsid mudelid hästi tuvastada. Magistritöö uuringu põhjal ei saa väita, et mudelite tulemuslikkus sõltub pettuse olemusest, kuna näiteks tulu ülehindamise mudelid nii tuvastasid kui ka jätsid tuvastamata. Näib siiski, et tulemust mõjutab ettevõtte tegevusvaldkond. Sellele väitele kinnituse saamiseks oleks vaja korraldada uuring palju suuremal andmekogumil.

Siinses magistritöös kasutatud mudelid ei ole lihtsalt aru saadavad inimestele, kellel ei ole majandusarvestuse ja/või äriahanduse teadmisi või vähemalt suurt huvi selle vastu. Mudeli näitajad ei ole kõik võetavad otse ettevõtte majandusaasta aruandest. Osa näitajaid vajavad arvutamist ning aruande lisades oleva informatsiooni tõlgendamist. Lisades midagi ebavajalikku või jättes välja midagi olulist, on arvutuse tulemused väärad ning seega ei anna lõpptulemus õigeid vihjeid. Autori arvates ei ole tegu meetoditega, mis oleksid tavakasutajale lihtsasti kasutatavad. Samuti võivad need osapooled, kellel on küll vajalikud teadmised muutujate arvutamiseks, oma aega raisata, kuna tulemusi mõjutavad väga palju andmetes esinevad erandid.

KOKKUVÕTE

Finantsaruannete pettus (FAP) on kõige suuremate tagajärgedega ametialane kelmus. Tegu on keerulise kuriteoga ning seetõttu on see kõige vähem levinud viis. Üks eeliseid teiste ametialaste pettuste ees on väike avastamise tõenäosus. See ei ole aga meeltemööda kõikidele neile, kelle jaoks on oluline saada õiget informatsiooni ettevõtte finantsandmete kohta. Mitmed huvitatud osapooled saavad füüsiliselt ligi ettevõtte raamatupidamisele või isegi näiteks tootmishoonesse või ehitusplatsile. Siiski on palju ka neid, kelle kasutada on vaid avalikustatud finantsandmed. Nende huvides oleks midagi omalt poolt ära teha, et määrata paremini kindlaks enda riski ehk tuvastada kohti, mis vajaksid lähemalt uurimist.

Avalikustatud finantsandmete abil ohukohtade tuvastamise tarbeks on välja töötatud hulk meetodeid. Mõned neist vajavad spetsiifilist tarkvara, mõni väga suurt andmekogumit. Siiski on palju kasutatud regressioonivõrrandil põhinevaid meetodeid, mis võiksid olla lihtsasti kasutatavad ja tõhusad. Magistritöö autor analüüsis varasemaid uuringuid ning selle tulemusena otsustas uuringus testida kolme meetodit, kasutades pettuseid sisaldavaid aruandeid. Mitmes varasemas uuringus on soovitatud testida korraga vähemalt kahte meetodit. Tuginedes sellele soovitusele valitigi uuringuks kolm meetodit.

Magistritöö eesmärk oli välja selgitada, kas Beneishi M-skoori, Altmani Z-skoori ja Dechow' F-skoori on võimalik kasutada pettuseid sisaldavate finantsaruannete tuvastamiseks.

Uuringus kasutatav andmestik moodustati, kasutades Ameerika Ühendriikide väärtpaberi- ja börsikomisjoni avaldatud dokumente, mis teavitavad avalikkust raamatupidamis- ja/või auditeerimisprotsessi rikkumisest. Magistritöö autor analüüsis aastatel 2017–2021 avaldatud teavitusi, mida oli 435. Eemaldanud ebasobivad dokumendid, ettevõtted ja duplikaadid, jäi andmekogumisse 25 ettevõtet. Seejärel koguti nende finantsandmed vajalike perioodide kohta ning arvutati vajalikud muutujad. Andmeid analüüsiti erinevate statistiliste meetodite abil, kasutades programmi Excel võimalusi.

Uuringu tulemusena selgus, et ükski mudel ei suutnud tuvastada kõiki ettevõtteid. Kõige paremini tõstis esile problemaatilisi aruandeid pankroti tõenäosuse leidmiseks kasutatav Altmani Z-skoor. See mudel tõstis esile 72% ettevõtetest. Dechow' F-skoor suutis tuvastada 56% ettevõtetest, kuid varasemates uuringutes üks populaarsemaid Beneishi mudel sellist tulemust saavutada ei suutnud. Mudeli kaheksa muutujaga versioon tuvastas eri kontrollmõõtude juures kas 40% või 32% manipuleeritavatest ettevõtetest, viie muutujaga mudel vaid 24%. Kõik mudelid on siiski statistiliselt olulised ning sõltuv muutuja on peaaegu 100% kirjeldatud sõltumatute muutujate poolt.

Beneishi viie muutujaga ja Altmani Z-skoori mudelis olid kõik sõltumatud muutujad statistiliselt olulised. Teises Beneishi versioonis ning Dechow' mudelis see nii ei olnud. Kõigil näitajatel on korrelatsioonianalüüsi tulemusena siiski seos sõltuva muutuja või mõne muu võrrandi teguriga, seega ei soovita magistritöö autor ühtegi statistiliselt mitteolulist muutujat välja jätta.

Uuringu tulemusi mõjutasid nii kogu andmekogumi kui ka ühe ettevõtte tasandil andmetes esinevad erandid. Andmekogumis oli vaid 25 ettevõtet ning mõned erandid erinesid ülejäänud kogumist märkimisväärselt, seega mõjutasid need palju mudeli näitajate keskmisi tulemusi. Nende mõjul olid andmekogumi tulemuste aritmeetilised keskmised varasemate uuringute näitajatest sageli väga erinevad. Analüüsides ettevõtete tulemusi eraldi, oli mõne puhul näha, et kuigi suurem osa näitajatest on võrreldavad ülejäänud andmestiku muutujatega, siis ühe näitaja märkimisväärne väärtuse erinevus ülejäänud ettevõtete omadest mõjutab võrrandi tulemust väga palju. Igasugust erindit peaks analüüsima, kuna see võib tähendada andmetega manipuleerimist, kuid võib samas olla ka põhjendatud. Siiski tähendab see, et mudel ei pruugi erindi tõttu anda õiget tulemust.

Magistritöö uuringu käigus ei tuvastatud üheski mudelis konkreetset mustrit, mis põhjendaks mudelite tulemusi ehk miks osa ettevõtteid klassifitseeritakse õigesti ning osa mitte. Ettevõtete ärivaldkonnad on erinevad ning seetõttu erinevad ka tulemused. Mudeli näitajad sisaldavad eri andmeid ettevõtete aruannetest, kuid tulenevalt äride erinevusest ja vajadustest on normaalne, kui mõnel ettevõttel ei ole näiteks üldse varusid või pikaajalist võlga. Autori arvates ei ole mõistlik uurida korraga suurt andmekogumit, vaid uurida tuleks ühe ettevõtte tasandil. Siiski, kasutades neid kolme mudelit ühe ettevõtte andmete peal, ei pruugi mudel ettevõtet õigesti klassifitseerida.

Kuigi kõik meetodid klassifitseerisid osa ettevõtete aruandeid FAPi sisaldavaks, ei saa sellele tulemusele täielikult tugineda. Võimalik, et need mudelid saavutaksid sama tulemuse ka

finantsaruande pettust mittesisaldava aruande puhul. Seega oleks vaja korraldada uuring ka selliste andmete peal. Samuti võiks mudelite kasutatavuse hindamiseks vaadata ühe ettevõtte tulemuste muutumist ajas ehk kasutada uuringus aastaid enne teadaolevat pettust ning pärast seda.

SUMMARY

USABILITY OF FINANCIAL STATEMENT FRAUD DETECTION MODELS

Kadi Vinglas

Financial statement fraud (FAP) is an occupational fraud with the greatest consequences. Because of the complexity of that crime, it is the least used form of occupational fraud. One of the advantages over other occupational fraud schemes is the low probability of detection. However, this is pleasant to all of those who find it important to get the right information about a company's financial data. Some interested parties have physical access to the company's bookkeeping or even to a production building or construction site. However, many parties only have access to published financial information. It would be in their interests to do something to better identify their own risk regarding financial information or to identify places in data that need further investigation. Based on this statement, the research problem addressed in the thesis is the following: how to identify intentionally manipulated financial statements using only published financial data and attainable methods.

Many methods have been developed to identify hazards in published financial data. Some of them require specific software, some very large data sets. However, many regression equation methods could be easy to use and effective. Several previous studies have suggested testing at least two methods at once. Based on this recommendation, three methods were selected for the study. The author of the master's thesis analyzed the previous research and as a result, decided to test three methods in the study.

The master's thesis aims to determine whether the Beneishi M-score, the Altman Z-score, and the Dechow F-score can be used to identify fraudulent financial statements.

To achieve this goal, the following research questions have been raised:

1. What is financial statement fraud and what are its components?

2. What methods have been used in previous studies to detect financial statement fraud?
3. How good are Beneish M-score, Altman Z-score, and Dechow F-score to detect financial statement fraud?
4. Which of the three fraud detection methods is the most accurate?

The research object of the master's thesis is financial statements that contain FAP. The dataset is compiled by the author using documents published by the U.S. Securities and Exchange Commission (SEC) that informs the public of a breach of the accounting and/or auditing process (AAER) (Accounting and... 2022). The author of the master's thesis analyzed 435 AAER published in 2017–2021. Removing inappropriate documents, companies, and also duplicates, 25 companies remained in the data set. Their financial data for the required periods were then collected and the necessary variables were calculated. Data were analyzed using various statistical methods in Excel.

The survey revealed that no model was able to identify all companies. The Altman Z-score was the best to find the probability of bankruptcy highlighted problematic reports. This model highlighted 72% of companies. Dechow's F-score was able to detect 56% of companies, but one of the most popular models, the Beneish model, failed to achieve this kind of result. The eight-variable version of the model identified either 40% or 32% of the manipulated companies at different control measures, while the five-variable model only identified 24%. However, all models are statistically significant and the dependent variable is almost 100% described by the independent variables.

In the Beneishi five-variable and Altman Z-score models, all independent variables were statistically significant. This was not the case with the other Beneishi version and the Dechow model. However, as a result of correlation analysis, all indicators have a relationship with a dependent variable or with another variable in the equation, so the author of the master's thesis does not recommend removing any statistically insignificant variables.

The results of the survey were influenced by the outliers in the data. The impact of those was for the data set as a whole as well as at the level of one company. As there were only 25 companies in the data set and some outliers differed significantly from the rest of the set, they greatly affected the average results of the model indicators. As a result, the arithmetic means of the data set results were often very different from previous studies. Analyzing the results of the companies separately,

it was seen in some cases that although most of the indicators are comparable with the variables of the rest of the data, a significant difference in the value of one indicator from the rest of the companies greatly affects the result of the equation. Any exception should be analyzed, as it may involve manipulation of the data, but may also be justified. However, this means that the model may not give the correct result due to the outliers.

In the master's thesis study, no specific pattern was identified in any of the models, which would justify the results of the model – why some companies are classified correctly and some are not. The business areas of the companies are different and therefore the results are different. The indicators in the model contain different data from the companies' reports, but due to the differences and needs of the businesses, it is normal if some companies have no inventories or long-term debt at all. According to the author, it is not reasonable to study a large set of data at once, it should be examined at the level of one company. However, using these three models on the data of one enterprise, the model may not classify the enterprise correctly.

Although all methods classified some of the companies' reports as containing FAP, this result cannot be fully relied upon. The possibility is that these models would achieve the same result for a non-fraudulent financial statement. It would therefore be necessary to survey on such data as well. Also, it would be a good idea to look at the change in the results of one company over time to assess the usability of the models – use the years before and after the known fraud years.

The author wishes to thank her supervisor Paavo Siimann.

KASUTATUD ALLIKATE LOETELU

- Accounting and Auditing Enforcement Releases*. U.S. Securities and Exchange Commission. Kättesaadav: <https://www.sec.gov/divisions/enforce/friactions.htm>, 29. jaanuar 2022.
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23 (4), 589–609. Kättesaadav: <https://www.jstor.org/stable/pdf/2978933.pdf>.
- Beneish, M. D. (1999). The Detection of Earnings Manipulation. *Financial Analysts Journal*, 55 (5), 24–36. Kättesaadav: <https://www.tandfonline.com/doi/pdf/10.2469/faj.v55.n5.2296>.
- Beneish, M. D., Lee, C. M. C., Nichols, D. C. (2012). Fraud Detection and Expected Returns. *SSRN Electronic Journal*. Kättesaadav: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1998387.
- Beneish, M. D., Lee, C. M. C., Nichols, D. C. (2013). Earnings Manipulation and Expected Returns. *Financial Analysts Journal*, 69 (2), 57–82. Kättesaadav: <https://www.tandfonline.com/doi/pdf/10.2469/faj.v69.n2.1>.
- Benford, F. (1938). The Law of Anomalous Numbers. *Proceedings of the American Philosophical Society*, 78 (4), 551–572. Kättesaadav: https://www.inzichten.nl/contact/images/benford_law.pdf.
- Bhavani, G., Amponsah, C. T. (2017). M-Score and Z-Score for detection of accounting fraud. *Accountancy Business and the Public Interest*, 1 (1), 68–86. Kättesaadav: https://www.researchgate.net/profile/Ganga-Bhavani/publication/318489930_M-Score_and_Z-Score_for_detection_of_Accounting_Fraud/links/5a56f8cb45851547b1bf36e5/M-Score-and-Z-Score-for-detection-of-Accounting-Fraud.pdf.
- Bondarenko, P. (2016) *Enron scandal. Summary, Explained, History, & Facts*. Kättesaadav: <https://www.britannica.com/event/Enron-scandal>, 11. jaanuar 2022.
- Carpenter, J. W. (2021). *Toshiba's Accounting Scandal: How It Happened (OTCBB: TOSBF)*. Kättesaadav: <https://www.investopedia.com/articles/investing/081315/toshibas-accounting-scandal-how-it-happened.asp>, 11. jaanuar 2022.
- Dalnial, H., Kamaluddin, A., Sanusi, Z. M., Khairuddin, K. S. (2014). Accountability in Financial Reporting: Detecting Fraudulent Firms. *Procedia - Social and Behavioral Sciences*, 145, 61–69. Kättesaadav: <https://www.sciencedirect.com/science/article/pii/S1877042814038695>.

- Dechow, P. M., Ge, W., Larson, C. R., Sloan, R. G. (2011). Predicting Material Accounting Misstatements. *Contemporary Accounting Research*, 28 (1), 17–82. Kättesaadav: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1911-3846.2010.01041.x>.
- Dong, W., Liao, S., Fang, B., Cheng, X., Zhu, C., & Fan, W. (2014). The detection of fraudulent financial statements: An integrated language model approach. *18th Pacific Asia Conference on Information Systems, PACIS 2014*. Pacific Asia Conference on Information Systems.
- Durtschi, C., Hillison, W., Pacini, C. (2004). The effective use of Benford's law to assist in detecting fraud in accounting data. *Journal of forensic accounting*, 5 (1), 17-34. Kättesaadav: <http://www.agacgfm.org/AGA/FraudToolkit/documents/BenfordsLaw.pdf>.
- EDGAR. *Company Filings*. U.S. Securities and Exchange Commission. Kättesaadav: <https://www.sec.gov/edgar/searchedgar/companysearch.html>, 02.03.2022.
- Fazli, S., Mohamed, Z., Rahmat, M. M. (2016). Detecting Financial Statement Frauds in Malaysia: Comparing the Abilities of Beneish and Dechow Models. *Asian Journal of Accounting and Governance*, 7, 57–65. Kättesaadav: <http://journalarticle.ukm.my/10753/1/11847-43528-1-PB.pdf>.
- Form 10-K. Annual report pursuant to section 13 or 15(d) of the securities exchange act of 1934. general instructions. (2022). United States Securities and Exchange Commission. Kättesaadav: <https://www.sec.gov/files/form10-k.pdf>.
- Ghosh, P., Harris, L., Krueger, J., Ocampo, J., Simpson, E., Vaidhyanathan, J. (1998). *Cornell Research Report on Enron 1998*. Cornelli Ülikool. Kättesaadav: <https://pdfslide.net/reader/f/cornell-research-report-on-enron-1998>.
- Green, S. B. (1991). How Many Subjects Does It Take To Do A Regression Analysis. *Multivariate Behavioral Research*, 26 (3), 499–510. Kättesaadav: <https://parsmodir.com/wp-content/uploads/2013/03/green1991.pdf>.
- Guan, L., Kaminski, K. A., Wetzel, T. S. (2007). Can investors detect fraud using financial statements: An exploratory study. *Envisioning a New Accountability*. Emerald Group Publishing Limited.
- Hakami, T., Rahmat, M. M., Yaacob, M. H., Saleh, N. M. (2020). Fraud Detection Gap between Auditor and Fraud Detection Models: Evidence from Gulf Cooperation Council. *Asian Journal of Accounting and Governance*, 13, 1–13. Kättesaadav: <https://ejournal.ukm.my/ajac/article/viewFile/39162/10504>.
- Haynes, A. H. (2012). *Detecting Fraud in Bankrupt Municipalities Using Benford's Law*. (Bakalaureusetöö) Scripps College, Claremont. Kättesaadav: https://scholarship.claremont.edu/cgi/viewcontent.cgi?referer=https://scholar.google.com/&httpsredir=1&article=1043&context=scripps_theses.
- Huang, S. Y., Lin, C.-C., Chiu, A.-A., Yen, D. C. (2017). Fraud detection using fraud triangle risk factors. *Information Systems Frontiers*, 19 (6), 1343–1356. Kättesaadav: <https://link.springer.com/article/10.1007/s10796-016-9647-9>.

- Hung, D. N., Ha, H. T. V., Binh, D. T. (2017). Application of F-Score in Predicting Fraud, Errors: Experimental Research in Vietnam. *International Journal of Accounting and Financial Reporting*, 7 (2), 303. Kättesaadav: https://www.researchgate.net/profile/Dang-Hung-2/publication/321726792_Application_of_F-Score_in_Predicting_Fraud_Errors_Experimental_Research_in_Vietnam/links/5a30eef6a6fdccb7ef17569/Application-of-F-Score-in-Predicting-Fraud-Errors-Experimental-Research-in-Vietnam.pdf.
- Jarvey, N. (2019). *Comscore Fined \$5M for Accounting Fraud*. Kättesaadav: <https://www.hollywoodreporter.com/business/digital/comscore-fined-5m-accounting-fraud-1242992/>, 11. jaanuar 2022.
- KarS RT I, 21.05.2021, 9, §209.
- Kelmused*. Politsei- ja Piirivalveamet. Kättesaadav: <https://www2.politsei.ee/et/nouanded/levinuiimate-pektuste-ja-kelmuste-skeemid/kelmused.dot>, 15. jaanuar 2022.
- Khamainy, A. H., Ali, M., Setiawan, M. A. (2021). Detecting financial statement fraud through new fraud diamond model: the case of Indonesia. *Journal of Financial Crime*. Kättesaadav: <https://www.emerald.com/insight/content/doi/10.1108/JFC-06-2021-0118/full/pdf?title=detecting-financial-statement-fraud-through-new-fraud-diamond-model-the-case-of-indonesia>.
- Kukreja, G., Gupta, S. M., Sarea, A. M., Kumaraswamy, S. (2020). Beneish M-score and Altman Z-score as a catalyst for corporate fraud detection. *Journal of Investment Compliance*, 21 (4), 231–241. Kättesaadav: <https://www.emerald.com/insight/content/doi/10.1108/JOIC-09-2020-0022/full/html>.
- MacCarthy, J. (2017). Using Altman Z-score and Beneish M-score models to detect financial fraud and corporate failure: A case study of Enron Corporation. *International Journal of Finance and Accounting*, 6 (6), 159-166. Kättesaadav: https://www.researchgate.net/profile/John-Maccarthy/publication/321143663_Using_Altman_Z-score_and_Beneish_M-score_Models_to_Detect_Financial_Fraud_and_Corporate_Failure_A_Case_Study_of_Enron_Corporation/links/61cda4acd45006081678b24f/Using-Altman-Z-score-and-Beneish-M-score-Models-to-Detect-Financial-Fraud-and-Corporate-Failure-A-Case-Study-of-Enron-Corporation.pdf.
- Mantone, P. S. (2013). *Using Analytics to Detect Possible Fraud: Tools and Techniques*. Hoboken, New Jersey: John Wiley & Sons, Inc. A.
- Mehta, A., Bhavani, G. (2017). Application of Forensic Tools to Detect Fraud: The Case of Toshiba. *Journal of Forensic and Investigative Accounting*, 9 (1), 692–710. Kättesaadav: <http://web.nacva.com/JFIA/Issues/JFIA-2017-No1-8.pdf>.

- Mitigating the Risk of Common Fraud Schemes: Insights from SEC Enforcement Actions.* (2021). Anti-Fraud Collaboration. Kättesaadav: <https://www.thecaq.org/wp-content/uploads/2020/12/afc-mitigating-the-risk-of-common-fraud-schemes-2021-01.pdf>.
- Nigrini, M. J. (1997). The Use of Benford's Law as an Aid in Analytical Procedures' Auditing. *Journal of Practice & Theory*, 16 (2), 52–67. Kättesaadav: <https://www.proquest.com/openview/7d019c616546c4c5da54cba2c85d136d/1?cbl=31718&parentSessionId=KdbYzAE0Fd%2BRUFGLGgsbhhk10XA9SuuB9mQQm%2FF0%2FDUE%3D&pq-origsite=gscholar&accountid=28786>.
- Nigrini, M. J. (2017). Audit Sampling Using Benford's Law: A Review of the Literature with Some New Perspectives. *Journal of Emerging Technologies in Accounting*, 14 (2), 29–46. Kättesaadav: https://www.researchgate.net/publication/316502186_Audit_Sampling_Using_Benford's_Law_A_Review_of_the_Literature_With_Some_New_Perspectives.
- Nigrini, M. J., Wells, J. T. (2012). *Benford's Law: Applications for Forensic Accounting, Auditing, and Fraud Detection*. Hoboken, New Jersey: John Wiley & Sons, Inc.
- Noble, M. R. (2019). Fraud diamond analysis in detecting financial statement fraud. *The Indonesian Accounting Review*, 9(2), 121-132. Kättesaadav: <https://inkubator-bisnis.perbanas.ac.id/index.php/tiar/article/view/1632>.
- Ollén, E. R., Wennberg, J. (2021). *Assessing practicalities of Benford's Law. A study of the law's potential to detect fraud in transactional data.* (Bakalaureusetöö) Lund University majandusteaduskond. Kättesaadav: <https://lup.lub.lu.se/luur/download?func=downloadFile&recordOid=9037415&fileOid=9037418>.
- PwC's Global Economic Crime and Fraud Survey 2020.* (2020). PricewaterhouseCoopers. Kättesaadav: <https://www.pwc.com/gx/en/forensics/gecs-2020/pdf/global-economic-crime-and-fraud-survey-2020.pdf>.
- Report To The Nations. 2020 Global Study on Occupational Fraud and Abuse.* (2020). Association of Certified Fraud Examiners. Kättesaadav: <https://acfe-public.s3-us-west-2.amazonaws.com/2020-Report-to-the-Nations.pdf>.
- Rezaee, Z. (2002). *Financial statement fraud: Prevention and detection* (1st ed). Hoboken, New Jersey: John Wiley & Sons, Inc.
- Richardson, S. A., Sloan, R. G., Soliman, M. T., Tuna, İ. (2006). The Implications of Accounting Distortions and Growth for Accruals and Profitability. *The Accounting Review*, 81 (3), 713–743. Kättesaadav: <https://www.jstor.org/stable/4093111>.
- Ringkiri pettuse indikaatorite kohta Euroopa Regionaalarengu Fondi, Euroopa Sotsiaalfondi ja Ühtekuuluvusfondi puhul.* (2009). European Commission. Kättesaadav: https://ec.europa.eu/regional_policy/sources/docoffic/cocof/2009/cocof_09_0003_00_et.pdf.

- Roxas, M. L. (2011). Financial statement fraud detection using ratio and digital analysis. *Journal of Leadership, Accountability, and Ethics*, 8(4), 56-66. Kättesaadav: <http://www.na-businesspress.com/JLAE/Roxas84Web.pdf>.
- Saleh, M. M. A., Aladwan, M., Alsinglawi, O., Saleh, H., Mahmoud, I. (2021). Predicting fraudulent financial statements using fraud detection models. *Academy of Strategic Management Journal, suppl. Special*, 20(3), 1-17. Kättesaadav: https://www.researchgate.net/profile/Mohammad-Almerai/publication/355478325_PREDICTING_FRAUDULENT_FINANCIAL_STATEMENTS_USING_FRAUD_DETECTION_MODELS/links/6172df7eeef53e51e1cb5191/PREDICTING-FRAUDULENT-FINANCIAL-STATEMENTS-USING-FRAUD-DETECTION-MODELS.pdf.
- Sauga, A. (2005). Kvantitatiivsed meetodid majanduses. Kättesaadav: <https://www.sauga.pri.ee/audentes/download/kvantmeetodid.pdf>.
- Skousen, C. J., Smith, K. R., Wright, C. J. (2009). *Detecting and predicting financial statement fraud: The effectiveness of the fraud triangle and SAS No. 99*. Emerald Group Publishing Limited.
- The Equity Research Platform For Global Investors*. Fintel Ventures LLC. Kättesaadav: <https://fintel.io/>, 02.03.2022.
- Zack, G. M. (2013). *Financial Statement Fraud. Strategies for Detection and Investigation*. Hoboken, New Jersey: John Wiley & Sons, Inc.
- What Is Fraud?* ACFE. Kättesaadav: <https://www.acfe.com/fraud-101.aspx>, 27. veebruar 2022.
- Wuerges, A. F. E., Borba, J. A. (2014). Accounting Fraud: an estimation of detection probability. *Revista Brasileira de Gestão de Negócios*, 16, 466-483. Kättesaadav: <https://www.scielo.br/j/rbgn/a/ZxdGRxBTs75VhsWjgSZ5SJr/?format=pdf&lang=en>.
- Özcan, A. (2018). The Use of Beneish Model in Forensic Accounting: Evidence from Turkey. *Journal of Applied Economics & Business Research*, 8 (1), 57–67. Kättesaadav: <https://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=128868562&site=eds-live>.
- Yendrawati, R., Aulia, H., Prabowo, H. Y. (2019). Detecting the Likelihood of Fraudulent Financial Reporting: An Analysis of Fraud Diamond. *Asia-Pacific Management Accounting Journal*, 14 (1), 43–69. Kättesaadav: https://web.archive.org/web/20210924235339id_/https://apmaj.uitm.edu.my/images/Vol-14-1/03.pdf.

LISAD

Lisa 1. Uuringu andmekogumis olevad ettevõtted ning nende juhtumi kirjeldus

Lisas 1 on välja toodud uuringu andmekogumis olevad ettevõtted, nende juhtumit käsitlevad AAERid koos avaldamise aastaga, ettevõtte tegevusvaldkond, juhtumi kirjeldus ning tähised, millega autor ettevõtete nimed magistritöös asendanud on. Informatsioon on kogutud SECi kodulehel avaldatud AAERidest (*Accounting and ... 2022*).

1) Sequential Brands Group, Inc.

- AAERid: AAER-4241, AAER-4277.
- AAERide avaldamise aasta: 2021.
- Ettevõtte tegevusvaldkond: rõivaste ja muude kangast valmistoodete tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Peale järsku aktsiahindade langust ei suutnud ettevõtte korrektselt hinnata oma firmaväärtust. Kaebuse kohaselt, pärast iga-aastast firmaväärtuse testi läbi viimist, eiras ettevõtte selget tõendit sellest, et firmaväärtus on langenud. Langust aruannetes ei kajastatud, seega esitas ettevõtte valeinfot. Aruannetes olid alahinnatud tegevuskulu, alahinnatud puhaskahjum, ülehinnatud firmaväärtus, ülehinnatud koguvara, ülehinnatud jaotamata kasum ja ülehinnatud omakapital.
- Magistritöös kasutatav tähis: SBG.

2) The Kraft Heinz Company

- AAER: AAER-4248.
- AAERi avaldamise aasta: 2021.
- Ettevõtte tegevusvaldkond: toiduainete tööstus.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte hankedivisjoni töötajad pidasid läbirääkimisi tarnijatega, soovides neilt saada tulevase koostöö eest sularahas ettemakseid ja allahindluseid. See ebaõige käitumine oli eesmärgiga vähendada müüdud kaupade omamaksumust ja saavutada kulude kokkuhoid. Kulude väärkajastamise tõttu oli ettevõtte esitatud aruannetes kasum ülehinnatud.
- Magistritöös kasutatav tähis: KHC.

3) Pareteum Corporation

- AAER: AAER-4247.
- AAERi avaldamise aasta: 2021.
- Ettevõtte tegevusvaldkond: arvutisüsteemide disain.
- Väärkajastamise olemus/juhtumi kirjeldus: Kaebuse kohaselt käskisid ettevõtte juhid kajastada tulu juba ostutellimuste alusel ning enne toote tarnimist, mis GAAPi järgi ei ole lubatud. Seetõttu oli ettevõtte tulu aruannetes ülehinnatud.
- Magistritöös kasutatav tähis: PAC.

4) Revolution Lighting Technologies, Inc.

- AAERid: AAER-4188, AAER-4187, AAER-4186, AAER-4170.
- AAERide avaldamise aasta: 2020.
- Ettevõtte tegevusvaldkond: elektrivalgustuse ja juhtseadmete tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte tegevjuht ja finantsjuhid avaldasid survet kajastada tulevast müüki lubatust varem (kasutati vääralt *bill and hold* tehinguid). Sellise käitumisega üritati korvata tulude puudujääki.
- Magistritöös kasutatav tähis: RLT.

5) Manitex International, Inc.

- AAERid: AAER-4180, AAER-4179, AAER-4178, AAER-4177.
- AAERide avaldamise aasta: 2020.
- Ettevõtte tegevusvaldkond: tööstuse erimasinate tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte võtmetöötajad kasutasid fiktiivseid *bill and hold* tehinguid seotud osapooltega, näitamaks suuremat tulu. Tehingute tulemusena oli ettevõtte aruannetes ülehinnatud tulu.
- Magistritöös kasutatav tähis: MAI.

6) Power Solutions International, Inc.

- AAER: AAER-4169.
- AAERi avaldamise aasta: 2020.
- Ettevõtte tegevusvaldkond: mootorite ja turbiinide tootmine.

- Väärkajastamise olemus/juhtumi kirjeldus: Analüütikute ootuste täitmiseks kasutasid kolm ettevõtte võtmetöötajad pettuslikke meetodeid, et suurendada tulu. Ettevõtte aruannetes kajastati tulu kaupade müügist, mida klient ei olnud veel aktsepteerinud. See hõlmas ka vääralt *bill and hold* tehingute kasutamist. Aruannetes esitati ülehinnatud tulu.
- Magistritöös kasutatav tähis: PSI.

7) Ironclad Performance Wear Corp.

- AAERid: AAER-4132, AAER-4121.
- AAERide avaldamise aasta: 2020.
- Ettevõtte tegevusvaldkond: töökinnaste tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Kolm ettevõtte juhti kasutasid pettuslikke vahendeid, et ettevõtte tulu suurendada. Tulu kajastati näiteks enne selle teenimist või kajastati tulu, mida kunagi ei olnud teenitud ehk kajastati fiktiivseid tehinguid.
- Magistritöös kasutatav tähis: IPW.

8) PPG Industries, Inc.

- AAER: AAER-4094.
- AAERi avaldamise aasta: 2019.
- Ettevõtte tegevusvaldkond: värvide, kattedkihtide ja erimaterjalide tarnimine.
- Väärkajastamise olemus/juhtumi kirjeldus: Analüütikute ootuste täitmiseks ehk tulu suurendamiseks, klassifitseeriti osa tulust vääralt ning kulude kajastamisega viivitati või ei kajastatud neid üldse.
- Magistritöös kasutatav tähis: PPG.

9) Comscore, Inc.

- AAERid: AAER-4092, AAER-4091.
- AAERide avaldamise aasta: 2019
- Ettevõtte tegevusvaldkond: turundusandmete ja -analüüsi pakkumine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte tegevjuhi soovil täita analüütikute ootused, ülehinnati vääralt ettevõtte tulu. Selleks sõlmiti ka rahalisi ning mitterahalisi lepinguid.

- Magistritöös kasutatav tähis: COM.

10) Marvell Technology Group, Ltd.

- AAER: AAER-4076.
- AAERi avaldamise aasta: 2019.
- Ettevõtte tegevusvaldkond: pooljuhtide ning nendega seotud tehnoloogia tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Nõudluse olulise languse varjamiseks kajastati tulevasi müüke lubatust varem ning seega oli tulu aruannetes ülehinnatud.
- Magistritöös kasutatav tähis: MTG.

11) DS Healthcare Group, Inc.

- AAERid: AAER-4071, AAER-4070.
- AAERide avaldamise aasta: 2019.
- Ettevõtte tegevusvaldkond: hügieenitoodete tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte juhtkonna käsul sisaldasid aruanded fiktiivset tulu, klientidele nõuete kajastamist rohkem, kui tegelikult alust oleks, kliendi krediteerimine hilisemas kvartalis, väärad *bill and hold* tehingud. Sellise tegevuse tõttu sisaldasid ettevõtte aruanded ülehinnatud tulusid.
- Magistritöös kasutatav tähis: DHG.

12) Barrett Business Services Inc.

- AAERid: AAER-3977, AAER-3986.
- AAERide avaldamise aasta: 2018.
- Ettevõtte tegevusvaldkond: ärijuhtimise lahenduste pakkumine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte finantsjuht manipuleeris raamatupidamisdokumentidega, et varjata töötajate hüvitiskulude suurenemist. Selleks klassifitseeriti valesti kulusid, kulusid kajastati valedes perioodides ning osaliselt ei kajastatud neid üldse. Seetõttu olid aruannetes ettevõtte kulud alahinnatud või valesti klassifitseeritud.
- Magistritöös kasutatav tähis: BBS.

13) Maxwell Technologies, Inc.

- AAER: AAER-3932.
- AAERi avaldamise aasta: 2018.
- Ettevõtte tegevusvaldkond: autotööstuse energiasalvestus- ja jõuvarustuslahenduste tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte aruannetes kajastati tulu vääralt liiga vara ning seetõttu sisaldasid aruanded ülehinnatud tulu.
- Magistritöös kasutatav tähis: MAT.

14) NCI, Inc.

- AAER: AAER-3909.
- AAERi avaldamise aasta: 2017.
- Ettevõtte tegevusvaldkond: IT ja AI teenuste pakkumine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte asepresident ja kontrolleri kasutas oma ametikohta selleks, et suunata põhjendamata alustel ettevõtte raha isiklikele pangakontodele. Selle varjamiseks esitas ta fiktiivseid dokumente, mis raamatupidamises kuludena kajastati.
- Magistritöös kasutatav tähis: NCI.

15) Osiris Therapeutics, Inc.

- AAER: AAER-3905.
- AAERi avaldamise aasta: 2017.
- Ettevõtte tegevusvaldkond: ravimite tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte aruanded sisaldasid ülehinnatud tulu. Selle saavutamiseks kasutati kunstlikult paisutatud hindu, kajastati tulu vääralt liiga vara või kajastati tulu tagasiulatuva kuupäevaga dokumentide alusel.
- Magistritöös kasutatav tähis: OST.

16) OCZ Technology Group Inc.

- AAER: AAER-3882.
- AAERi avaldamise aasta: 2017.
- Ettevõtte tegevusvaldkond: arvutikomponentide tootmine.

- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte tegevjuhi ja finantsjuhi tegevuse ning tegevusetuse tulemusena sisaldasid ettevõtte aruanded ülehinnatud tulu.
- Magistritöös kasutatav tähis: OTG.

17) UniTek Global Services, Inc.

- AAER: AAER-3874.
- AAERi avaldamise aasta: 2017.
- Ettevõtte tegevusvaldkond: inseneri-, ehitusjuhtimis- ja paigaldustööde pakkumine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte kajastas valesti tüarettevõtte tulu. Tulevaste perioodide tulusid kajastati vääralt liiga vara. Seetõttu sisaldasid aruanded ülehinnatud tulu.
- Magistritöös kasutatav tähis: UGS.

18) L3 Technologies, Inc.

- AAERid: AAER-3867, AAER-3868, AAER-3844, AAER-4023, AAER-4101.
- AAERide avaldamise aastad: 2017, 2019.
- Ettevõtte tegevusvaldkond: side- ja elektroonikaseadmete tarnimine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte aruanded sisaldasid ülehinnatud ning osaliselt ka fiktiivset tulu. Ettevõtte koostas aasta lõpus arveid, mis kajastati raamatupidamises, kuid kliendile ei saadetud. Osa arvetest saadeti järgmise aasta alguses, kuid osa neist ei jõudnudki saajani.
- Magistritöös kasutatav tähis: LTE.

19) Ixia

- AAERid: AAER-3858, AAER-3859.
- AAERide avaldamise aasta: 2017.
- Ettevõtte tegevusvaldkond: arvutivõrkudega seotud lahenduste pakkumine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte finantsjuhi ja raamatupidamisdirektorite algatusel kajastati ettevõtte aruannetes tulu vääralt enneaegselt. Seetõttu sisaldasid aruanded ülehinnatud tulu.
- Magistritöös kasutatav tähis: IXI.

20) MagnaChip Semiconductor Corp.

- AAER: AAER-3869.
- AAERi avaldamise aasta: 2017.
- Ettevõtte tegevusvaldkond: pooljuhtide ning nendega seotud tehnoloogia tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõttes kasutati mitmeid pettuslikke raamatupidamistavasid, mis suurendasid kunstlikult tulu, vähendasid või viivitasid kulu kajastamist ning varjasid viiviseid. Selline tegevus mõjutas nii tulu kui ka kulu kajastamist aruannetes.
- Magistritöös kasutatav tähis: MCS.

21) Blue Earth, Inc.

- AAERid: AAER-4055, AAER-4245.
- AAERide avaldamise aastad: 2019,2021.
- Ettevõtte tegevusvaldkond: taastuenergia tootmissüsteemide ehitus ja haldamine.
- Väärkajastamise olemus/juhtumi kirjeldus: Kaebuse kohaselt esitati finantsjuhi nii teadliku kui ka hoolimatu tegutsemise tõttu finantsaruannetes valeandmeid või jäeti osa infost avalikustamata. Aruannetes kajastati vara ülehinnatud väärtuses ehk kulu alahinnati.
- Magistritöös kasutatav tähis: BLE.

22) Hertz Global Holdings, Inc.

- AAERid: AAER-4012, AAER-4106, AAER-4160.
- AAERide avaldamise aastad: 2018, 2019, 2020.
- Ettevõtte tegevusvaldkond: autorendi pakkumine.
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte aruannetes oli kajastatud ülehinnatud tulu ning alahinnatud kulu. Raamatupidamises kasutati ebasobivaid hindamismeetodeid, mille tulemuseks olid ebapiisavad allahindlused (reserve moodustamised) ning mahakandmised. Väidetavalt oli ettevõttel surve ettevõtluskeskkonnast, mistõttu võiks väita, et meetodite valik oli tahtlikult tehtud.
- Magistritöös kasutatav tähis: HGH.

23) KIT Digital, Inc.

- AAERid: AAER-4050, AAER-4068.
- AAERide avaldamise aasta: 2019.
- Ettevõtte tegevusvaldkond: ringhäälingu- ja meediatööstuse professionaalsete teenuste ja tehnoloogia pakkumine.
- Väärkajastamise olemus/juhtumi kirjeldus: Analüütikute ootuste täitmiseks kajastati ettevõtte aruannetes ülehinnatud tulu. Tuluna kajastati tehingut, mida ei toimunud.
- Magistritöös kasutatav tähis: KIT.

24) Under Armour, Inc.

- AAER: AAER-4220.
- AAERi avaldamise aasta: 2021.
- Ettevõtte tegevusvaldkond: jalanõude, spordi- ja vabaajarõivaste tootmine.
- Väärkajastamise olemus/juhtumi kirjeldus: Analüütikute ootuste täitmiseks ning tulu languse varjamiseks, kajastati ettevõtte aruannetes vääralt enneaegselt tuleviku tulu.
- Magistritöös kasutatav tähis: UNA.

25) WageWorks, Inc.

- AAER: AAER-4220.
- AAERi avaldamise aasta: 2021.
- Ettevõtte tegevusvaldkond: *Consumer-Directed Benefits*'ide haldamine (aitavad töötajatel ja nende peredel raha säästa, kasutades maksueelseid dollareid teatud tervishoiu, ülalpeetava hoolduse ja pendelrände kulude katmiseks).
- Väärkajastamise olemus/juhtumi kirjeldus: Ettevõtte aruannetes kajastati ülehinnatud tulu. Ettevõtte juhid said heade finantstulemuste pealt kompensatsiooni.
- Magistritöös kasutatav tähis: WAW.

Lisa 2. Beneishi M-skoori tulemused

Ettevõtte	DSRI	GMI	AQI	SGI	DEPI	SGAI	TATA	LVGI	M (5)	M (8)
SBG	1,05	1,00	0,98	1,08	0,67	0,86	-0,19	1,28	-2,87	-3,37
KHC	0,43	0,87	1,01	1,44	0,57	0,76	-0,01	1,25	-3,23	-2,83
PAC	3,12	1,07	5,32	2,39	0,95	0,82	-0,03	0,39	2,44	2,56
RLT	1,03	0,94	0,95	1,69	0,85	0,75	0,08	1,11	-2,50	-1,53
MAI	1,05	2,54	1,02	0,90	0,67	1,04	-0,10	1,06	-1,57	-2,23
PSI	1,14	1,19	1,17	1,12	0,90	1,17	0,10	1,17	-2,45	-1,68
IPW	0,85	0,98	0,35	1,06	1,51	1,11	-0,12	1,36	-3,35	-3,46
PPG	1,06	1,04	1,05	1,03	0,99	0,96	0,00	0,95	-2,78	-2,33
COM	0,95	0,98	0,93	1,15	0,96	1,11	-0,17	1,14	-2,92	-3,29
MTG	1,04	1,11	1,09	0,74	0,95	1,91	-0,19	2,08	-2,92	-3,97
DHG	1,05	1,09	0,37	0,88	0,82	1,98	-0,77	0,70	-3,28	-6,44
BBS	1,07	0,83	0,89	1,28	1,05	0,95	-0,14	1,43	-2,87	-3,09
MAT	1,10	0,95	0,90	1,08	1,04	0,89	0,05	0,87	-2,88	-2,09
NCI	0,96	1,01	2,56	1,39	0,97	0,99	-0,03	0,94	-1,74	-1,65
OST	1,32	0,93	0,01	2,46	0,97	0,89	0,01	0,92	-2,25	-1,21
OTG	1,18	1,02	0,50	1,32	0,90	1,00	-0,04	0,86	-2,83	-2,37
UGS	0,97	1,10	0,88	1,25	0,77	0,82	-0,27	1,31	-2,77	-3,62
LTE	1,09	1,03	0,99	0,96	0,98	1,00	-0,03	0,98	-2,85	-2,57
IXI	1,19	0,99	1,10	1,33	1,05	1,09	-0,04	0,95	-2,47	-2,16
MCS	1,05	1,04	0,80	1,00	0,63	1,02	-0,14	0,96	-2,99	-3,16
BLE	2,91	1,11	1,29	1,22	1,06	1,82	-0,30	0,18	-0,91	-1,60
HGH	1,07	0,96	0,76	1,09	1,04	1,17	-0,11	1,02	-2,97	-2,98
KIT	1,25	0,77	1,81	2,02	1,08	1,14	-0,02	1,36	-1,70	-1,39
UNA	1,21	1,02	2,53	1,29	1,18	1,01	0,10	1,19	-1,60	-1,00
WAW	1,18	1,01	1,06	1,09	3,62	1,04	-0,18	1,13	-2,38	-2,80

Allikas: autori arvutused

Lisa 3. Altmani Z-skoori tulemused

Ettevõtte	A	B	C	D	E	Z
SBG	0,03	-0,21	-0,23	0,21	0,15	-0,73
KHC	-0,01	0,00	0,05	1,70	0,22	1,41
PAC	0,02	-1,94	-0,09	4,80	0,20	0,09
RLT	0,15	-0,42	-0,01	0,89	0,73	0,83
MAI	0,17	-0,06	-0,01	0,32	0,91	1,21
PSI	0,43	0,10	0,03	0,99	1,08	2,41
IPW	0,47	-0,61	-0,05	2,00	1,33	2,06
PPG	0,16	1,04	0,13	2,60	0,89	4,51
COM	0,08	-0,26	-0,04	6,78	0,93	4,58
MTG	0,31	0,20	-0,15	3,36	0,50	2,68
DHG	0,63	-1,96	-0,99	9,44	1,10	1,51
BBS	0,12	0,23	0,08	0,83	1,76	3,00
MAT	0,33	-0,90	0,05	3,48	0,90	2,31
NCI	0,22	0,12	0,12	1,11	1,70	3,21
OST	0,87	-2,07	0,02	37,86	0,61	21,52
OTG	0,11	-0,62	-0,19	0,35	2,13	0,97
UGS	0,05	-0,65	-0,08	0,12	1,34	0,31
LTE	0,15	0,41	0,09	0,96	0,90	2,53
IXI	0,28	0,14	0,03	1,38	0,50	1,96
MCS	0,40	0,16	0,05	0,49	1,28	2,44
BLE	0,17	-0,73	-0,29	8,49	0,12	3,43
HGH	-0,12	-0,03	0,05	0,16	0,39	0,46
KIT	0,13	-0,31	-0,06	2,30	0,43	1,35
UNA	0,36	0,38	0,14	12,52	1,38	10,32
WAW	0,08	0,01	0,06	2,26	0,27	1,94

Allikas: autori arvutused

Lisa 4. Dechow' F-skoori tulemused

Ettevõtte	RSST	AREC	AINV	SOFTASSETS	ΔCASHSALES	ΔROA	ISSUE	VALUE	TÕENÄOSUS	F
SBG	-0,15	0,01	0,00	0,97	0,11	-0,15	0,00	-5,92	0,0027	0,72
KHC	0,00	0,00	0,00	0,89	0,52	0,02	0,00	-6,06	0,0023	0,63
PAC	1,33	0,14	0,00	0,81	0,58	0,51	1,00	-4,22	0,0145	3,92
RLT	0,22	0,11	0,06	0,98	0,96	0,04	1,00	-4,27	0,0139	3,74
MAI	-0,38	-0,01	-0,02	0,82	-0,13	-0,08	1,00	-5,52	0,0040	1,08
PSI	0,04	0,07	0,12	0,87	0,19	-0,08	0,00	-5,71	0,0033	0,89
IPW	-0,45	-0,05	0,11	0,94	0,23	-0,14	1,00	-5,17	0,0057	1,53
PPG	0,07	0,02	0,01	0,51	0,01	0,05	1,00	-5,77	0,0031	0,84
COM	0,00	0,02	0,00	0,58	0,21	-0,02	1,00	-5,60	0,0037	1,00
MTG	-0,19	-0,02	-0,02	0,58	-0,25	-0,22	1,00	-5,77	0,0031	0,84
DHG	-0,06	-0,01	-0,01	0,54	-0,14	-0,92	1,00	-5,07	0,0062	1,69
BBS	-0,19	0,08	0,00	0,67	0,26	-0,01	1,00	-5,43	0,0044	1,18
MAT	0,15	0,03	0,05	0,31	0,05	0,05	1,00	-6,03	0,0024	0,65
NCI	0,19	0,16	0,00	0,90	0,42	-0,01	0,00	-5,48	0,0041	1,12
OST	0,06	0,18	0,09	0,52	1,18	-0,64	0,00	-5,45	0,0043	1,16
OTG	-0,14	0,16	0,19	0,73	0,21	-0,18	1,00	-4,68	0,0092	2,48
UGS	-0,21	0,05	0,01	0,78	0,26	-0,20	0,00	-6,14	0,0022	0,58
LTE	0,03	0,00	0,00	0,79	-0,05	0,00	1,00	-5,28	0,0051	1,37
IXI	0,12	0,05	0,01	0,82	0,20	0,02	1,00	-4,98	0,0069	1,85
MCS	0,02	0,01	-0,01	0,32	0,06	-0,10	1,00	-6,09	0,0023	0,61
BLE	1,25	0,08	0,00	0,88	-0,21	0,16	1,00	-4,10	0,0162	4,39
HGH	0,03	0,01	0,00	0,30	0,09	0,00	1,00	-6,20	0,0020	0,55
KIT	0,51	0,11	0,00	0,86	0,80	0,12	1,00	-4,45	0,0116	3,13
UNA	0,31	0,06	0,10	0,66	0,26	-0,02	1,00	-4,96	0,0070	1,88
WAW	-0,10	0,02	0,00	0,38	0,09	0,00	1,00	-6,12	0,0022	0,59

Allikas: Autori arvutused

Lisa 5. Beneishi M-skoori regressiooni- ja korrelatsioonanalüüs (M5)

Regression Statistics – M5	
Multiple R	0,999998
R Square	0,999996
Adjusted R Square	0,999994
Standard Error	0,002768
Observations	25

ANOVA	df	SS	MS	F	Significance F
Regression	5	32,78687	6,55737	855611,94743	0,00000
Residual	19	0,00015	0,00001		
Total	24	32,78702			

Results	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-6,06782	0,00347	-1748,54877	0,00000	-6,07508	-6,06056
DSRI	0,82203	0,00132	624,35976	0,00000	0,81928	0,82479
GMI	0,90856	0,00190	478,92982	0,00000	0,90459	0,91253
AQI	0,59222	0,00073	811,90097	0,00000	0,59069	0,59374
SGI	0,71941	0,00160	448,63178	0,00000	0,71605	0,72276
DEPI	0,10695	0,00101	105,59196	0,00000	0,10483	0,10907

KORRELATSIOONI- MAATRIKS	DSRI	GMI	AQI	SGI	DEPI	M (5)
DSRI	1					
GMI	0,0250	1				
AQI	0,6230	-0,0062	1			
SGI	0,4248	-0,2884	0,4468	1		
DEPI	0,0480	-0,1378	-0,0046	-0,0641	1	
M (5)	0,8450	0,1729	0,8860	0,5924	0,0175	1

Lisa 6. Beneishi M-skoori regressiooni- ja korrelatsioonanalüüs (M8)

Regression Statistics – M8	
Multiple R	0,999998
R Square	0,999996
Adjusted R Square	0,999994
Standard Error	0,002787
Observations	25

ANOVA	df	SS	MS	F	Significance F
Regression	8	32,78689	4,09836	527658,32353	0,00000
Residual	16	0,00012	0,00001		
Total	24	32,78702			

Results	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-6,06622	0,00559	-1085,64870	0,00000	-6,07807	-6,05437
DSRI	0,82121	0,00213	385,12087	0,00000	0,81669	0,82573
GMI	0,90844	0,00193	471,14775	0,00000	0,90435	0,91253
AQI	0,59218	0,00081	730,39439	0,00000	0,59046	0,59390
SGI	0,71910	0,00191	376,48083	0,00000	0,71505	0,72315
DEPI	0,10706	0,00103	103,73680	0,00000	0,10487	0,10925
SGAI	0,00243	0,00292	0,83179	0,41777	-0,00376	0,00863
TATA	0,00746	0,00465	1,60305	0,12848	-0,00241	0,01733
LVGI	-0,00193	0,00241	-0,80111	0,43480	-0,00703	0,00317

KORRELATSIOONI- MAATTRIKS	DSRI	GMI	AQI	SGI	DEPI	SGAI	TATA	LVGI	M (8)
DSRI	1								
GMI	0,0250	1							
AQI	0,6230	-0,0062	1						
SGI	0,4248	-0,2884	0,4468	1					
DEPI	0,0480	-0,1378	-0,0046	-0,0641	1				
SGAI	0,2108	0,0832	-0,1682	-0,4060	0,0231	1			
TATA	-0,0635	-0,0696	0,2428	0,3570	-0,0311	-0,6677	1		
LVGI	-0,6631	-0,0638	-0,2921	-0,2867	0,0440	-0,0156	0,1313	1	
M (8)	0,6285	0,0036	0,7512	0,7079	0,0053	-0,4573	0,6728	-0,3871	1

Lisa 7. Altmani Z-skoori regressiooni- ja korrelatsioonanalüüs

Regression Statistics - Z	
Multiple R	1
R Square	0,999999999
Adjusted R Square	0,999999999
Standard Error	0,000148974
Observations	25

ANOVA	df	SS	MS	F	Significance F
Regression	5	461,75686	92,35137	4161214519,94641	0,00000
Residual	19	0,00000	0,00000		
Total	24	461,75686			

Results	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-1,494E-06	6,231E-05	-0,0240	0,98112	-0,00013	0,00013
A	1,20024	0,00022	5340,9551	0,00000	1,19977	1,20071
B	1,39996	6,180E-05	22653,1396	0,00000	1,39983	1,40009
C	3,30010	0,00018	18067,1104	0,00000	3,29972	3,30049
D	0,59999	6,913E-06	86791,8882	0,00000	0,59998	0,60001
E	0,99997	6,255E-05	15987,8918	0,00000	0,99984	1,00010

KORRELATSIOONI- MAATRIKS	A	B	C	D	E	Z
A	1					
B	-0,4106	1				
C	-0,2660	0,5734	1			
D	0,6875	-0,5496	-0,1068	1		
E	0,2093	0,1373	0,0593	-0,1227	1	
Z	0,6669	-0,2483	0,1872	0,9304	0,0503	1

Lisa 8. Dechow' F-skoori regressiooni- ja korrelatsioonanalüüs

Regression Statistics - F	
Multiple R	0,98097
R Square	0,96231
Adjusted R Square	0,94679
Standard Error	0,26051
Observations	25

ANOVA	df	SS	MS	F	Significance F
Regression	7	29,45350	4,20764	62,00055	0,00000
Residual	17	1,15370	0,06786		
Total	24	30,60720			

Results	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	-2,11120	0,27618	-7,64430	0,00000	-2,69389	-1,52852
RSST	1,74943	0,19103	9,15810	0,00000	1,34640	2,15246
Δ REC	2,79455	1,45031	1,92687	0,07088	-0,26533	5,85443
Δ INV	1,61371	1,21010	1,33353	0,19995	-0,93938	4,16680
SOFTASSETS	2,85140	0,28154	10,12770	0,00000	2,25739	3,44541
Δ CASHSALES	0,34577	0,21104	1,63839	0,11972	-0,09949	0,79104
Δ ROA	-1,15144	0,25711	-4,47835	0,00033	-1,69390	-0,60898
ISSUE	1,48361	0,14763	10,04940	0,00000	1,17214	1,79509

KORRELATSIOONI- MAATRIKS	RSST	Δ REC	Δ INV	SOFTASSETS	Δ CASHSALES	Δ ROA	ISSUE	F
RSST	1							
Δ REC	0,4809	1						
Δ INV	-0,1176	0,4027	1					
SOFTASSETS	0,1544	0,2080	0,1235	1				
Δ CASHSALES	0,1914	0,6539	0,2984	0,2589	1			
Δ ROA	0,5359	0,1507	-0,1432	0,2232	0,0478	1		
ISSUE	0,1526	-0,2285	-0,1030	-0,3329	-0,3449	0,2282	1	
F	0,7552	0,5060	0,1414	0,4633	0,2848	0,3479	0,3481	1

Lisa 9. Kokkuvõttev tabel uuringu tulemustest

Ettevõtte	Manipulaator? (M5, -2,22)	Manipulaator? (M5, -1,78)	Manipulaator? (M8, -2,22)	Manipulaator? (M8, -1,78)	Liigitus Z- skoori järgi	Manipulaator? (F)	Mitmel korral õigesti liigitatud?
SBG	EI	EI	EI	EI	Pankroti tõenäosus on kõrge (<1,88)	EI	1
KHC	EI	EI	EI	EI	Pankroti tõenäosus on kõrge (<1,88)	EI	1
PAC	JAH	JAH	JAH	JAH	Pankroti tõenäosus on kõrge (<1,88)	JAH	6
RLT	EI	EI	JAH	JAH	Pankroti tõenäosus on kõrge (<1,88)	JAH	4
MAI	JAH	JAH	EI	EI	Pankroti tõenäosus on kõrge (<1,88)	JAH	4
PSI	EI	EI	JAH	JAH	Ettevaatus on vajalik (2,77– 2,99)	EI	3
IPW	EI	EI	EI	EI	Ettevaatus on vajalik (2,77– 2,99)	JAH	3
PPG	EI	EI	EI	EI	Rahaliselt stabiilne (>2,99)	EI	0

Lisa 9 järg

Ettevõtte	Manipulaator? (M5, -2,22)	Manipulaator? (M5, -1,78)	Manipulaator? (M8, -2,22)	Manipulaator? (M8, -1,78)	Liigitus Z- skoori järgi	Manipulaator? (F)	Mitmel korral õigesti liigitatud?
COM	EI	EI	EI	EI	Rahaliselt stabiilne (>2,99)	EI	0
MTG	EI	EI	EI	EI	Ettevaatus on vajalik (2,77- 2,99)	EI	1
DHG	EI	EI	EI	EI	Pankroti tõenäosus on kõrge (<1,88)	JAH	2
BBS	EI	EI	EI	EI	Rahaliselt stabiilne (>2,99)	JAH	1
MAT	EI	EI	JAH	EI	Ettevaatus on vajalik (2,77- 2,99)	EI	2
NCI	JAH	JAH	JAH	JAH	Rahaliselt stabiilne (>2,99)	JAH	5
OST	EI	EI	JAH	JAH	Rahaliselt stabiilne (>2,99)	JAH	3
OTG	EI	EI	EI	EI	Pankroti tõenäosus on kõrge (<1,88)	JAH	2

Lisa 9 järg

Ettevõtte	Manipulaator? (M5, -2,22)	Manipulaator? (M5, -1,78)	Manipulaator? (M8, -2,22)	Manipulaator? (M8, -1,78)	Liigitus Z- skoori järgi	Manipulaator? (F)	Mitmel korral õigesti liigitatud?
UGS	EI	EI	EI	EI	Pankroti tõenäosus on kõrge (<1,88)	EI	1
LTE	EI	EI	EI	EI	Ettevaatus on vajalik (2,77– 2,99)	JAH	2
IXI	EI	EI	JAH	EI	Ettevaatus on vajalik (2,77– 2,99)	JAH	3
MCS	EI	EI	EI	EI	Ettevaatus on vajalik (2,77– 2,99)	EI	1
BLE	JAH	JAH	JAH	JAH	Rahaliselt stabiilne (>2,99)	JAH	5
HGH	EI	EI	EI	EI	Pankroti tõenäosus on kõrge (<1,88)	EI	1
KIT	JAH	JAH	JAH	JAH	Pankroti tõenäosus on kõrge (<1,88)	JAH	6
UNA	JAH	JAH	JAH	JAH	Rahaliselt stabiilne (>2,99)	JAH	5

Lisa 9 järg

Ettevõte	Manipulaator? (M5, -2,22)	Manipulaator? (M5, -1,78)	Manipulaator? (M8, -2,22)	Manipulaator? (M8, -1,78)	Liigitus Z- skoori järgi	Manipulaator? (F)	Mitmel korral õigesti liigitatud?
WAW	EI	EI	EI	EI	Ettevaatus on vajalik (2,77–2,99)	EI	1

Allikas: autori koostatud lisade 2, 3 ja 4 põhjal

Lisa 10. Lihtlitsents

Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks¹

Mina, Kadi Vinglas,

1. Annan Tallinna Tehnikaülikoolile tasuta loa (lihtlitsentsi) enda loodud teose „Finantsaruannete pettuste tuvastamise meetodite kasutatavus“,

mille juhendaja on Paavo Siimann,

1.1 reprodutseerimiseks lõputöö säilitamise ja elektroonse avaldamise eesmärgil, sh Tallinna Tehnikaülikooli raamatukogu digikogusse lisamise eesmärgil kuni autoriõiguse kehtivuse tähtaja lõppemiseni;

1.2 üldsusele kättesaadavaks tegemiseks Tallinna Tehnikaülikooli veebikeskkonna kaudu, sealhulgas Tallinna Tehnikaülikooli raamatukogu digikogu kaudu kuni autoriõiguse kehtivuse tähtaja lõppemiseni.

2. Olen teadlik, et käesoleva lihtlitsentsi punktis 1 nimetatud õigused jäävad alles ka autorile.

3. Kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest ning muudest õigusaktidest tulenevaid õigusi.

07.05.2022

¹ Lihtlitsents ei kehti juurdepääsupiirangu kehtivuse ajal vastavalt üliõpilase taotlusele lõputööle juurdepääsupiirangu kehtestamiseks, mis on allkirjastatud teaduskonna dekaani poolt, välja arvatud ülikooli õigus lõputööd reprodutseerida üksnes säilitamise eesmärgil. Kui lõputöö on loonud kaks või enam isikut oma ühise loomingu tegevusega ning lõputöö kaas- või ühisautor(id) ei ole andnud lõputööd kaitsvale üliõpilasele kindlaksmääratud tähtajaks nõusolekut lõputöö reprodutseerimiseks ja avalikustamiseks vastavalt lihtlitsentsi punktidele 1.1. ja 1.2, siis lihtlitsents nimetatud tähtaja jooksul ei kehti.