

VAASAN YLIOPISTO
KAUPPATIETEELLINEN TIEDEKUNTA
LASKENTATOIMI JA RAHOITUS

Joni Lindström

VERTAILEVA TUTKIMUS KONKURSSIN
ENNUSTAMISMENETELMISTÄ

Laskentatoimen ja rahoituksen
pro-gradu tutkielma

Laskentatoimen ja tilintarkastuksen
maisteriohjelma

VAASA 2016

SISÄLLYSLUETTELO

SISÄLLYSLUETTELO	1
TIIVISTELMÄ	7
1. JOHDANTO	9
1.1. Tutkimusongelma	10
1.2. Tutkielman rakenne	12
2. AIEMMAT TUTKIMUKSET KONKURSSIN ENNUSTAMISESSA	14
2.1 Ensimmäiset tutkimukset konkurssin ennustamisessa	14
2.2. Myöhemmät konkurssinennustamistutkimukset	16
2.3. Maksukyvyttömyyden syihin perustuvat tutkimukset	18
2.4. Konkurssitutkimukset suomalaisella aineistolla	20
2.5. Ennustamismenetelmät	22
2.5.1. Tilastolliset mallit	23
2.5.2. Muut mallit	24
3. KONKURSSIN ENNUSTAMINEN TILINPÄÄTÖSMUUTTUIEN AVULLA	28
3.1. Maksukyvyttömyysprosessi	28
3.2. Tilinpäätösmuuttujien tulkinta	32
3.3. Ennustamismallin rakentaminen	34
3.4. Muuttujien valinta	35
3.5. Eri tasemuuttujamenetelmien välinen vertailu	37
3.6. Tasemuuttujaennustamisen ongelmat	40
3.7. Yhteenveto ja tutkimuksen hypoteesit	41

4. TUTKIMUKSEN AINEISTO JA MENETELMÄ	43
4.1. Tutkimusaineisto ja rajaukset	43
4.2. Ennustamiskyvyn mittarit	44
4.3. Tunnusluvut	45
4.4. Muuttujien esivalinta	48
4.5. Tutkimuksessa verrattavat menetelmät	48
5. EMPIIRINEN ANALYYSI JA TULOKSET	
ENNUSTAMISMENETELMISTÄ	54
5.1. Muuttujien esivalinta	54
5.2. Perinteisten mallien rakenne	56
5.3. Menetelmien luokittelukyky	57
5.4. Luokitteluerojen tilastollinen merkitsevyys	61
5.5. Johtopäätökset	64
5.6. Rajoitukset	65
6. YHTEENVETO	67
LÄHDELUETTELO	71
LIITTEET	75

KUVIOLUETTELO	sivu
Kuvio 1: Yrityksen terveyskolmio	29
Kuvio 2. Eri analyysimuodot kriisin ennustamisessa	33
Kuvio 3. Kolmikerroksinen neuroverkkomalli konkurssin ennustamisessa	51
Kuvio 4. Algoritmi bagging-menetelmän käytössä	52
Kuvio 5. Algoritmi Boosting-menetelmän käytössä	52
TAULUKKOLUETTELO	sivu
Taulukko 1. Tutkimukseen valitut tunnusluvut	45
Taulukko 2. Tutkimuksessa verratut menetelmät	49
Taulukko 3. Muuttujien esivalinnassa vertailuun valikoidut tunnusluvut	55
Taulukko 4. Lineaarisen regressioanalyysin mallin rakenne	56
Taulukko 5. Logistisen regressioanalyysin mallin rakenne	56
Taulukko 6. Mallien AUC-arvot vuosi ennen konkurssia	58
Taulukko 7. Mallien virheprosentit vuosi ennen konkurssia	58
Taulukko 8. Mallien AUC-arvot kaksi vuotta ennen konkurssia	58
Taulukko 9. Mallien virheprosentit kaksi vuotta ennen konkurssia	59
Taulukko 10. Mallien AUC-arvot kolme vuotta ennen konkurssia	59
Taulukko 11. Mallien virheprosentit kolme vuotta ennen konkurssia	59
Taulukko 12. AUC-arvojen erojen tilastollinen merkitsevyys vuosi ennen konkurssia	61
Taulukko 13. AUC-arvojen erojen tilastollinen merkitsevyys kaksi vuotta ennen konkurssia	61
Taulukko 14. AUC-arvojen erojen tilastollinen merkitsevyys kolme vuotta ennen konkurssia	61
Taulukko 15. Virheluokittelujen erojen tilastollinen merkitsevyys vuosi ennen konkurssia	62
Taulukko 16. Virheluokittelujen erojen tilastollinen merkitsevyys kaksi vuotta ennen konkurssia	62
Taulukko 17. Virheluokittelujen erojen tilastollinen merkitsevyys kolme vuotta ennen konkurssia	62

VAASAN YLIOPISTO**Kauppatieteellinen tiedekunta****Tekijä:**

Joni Lindström

Tutkielman nimi:Vertaileva tutkimus konkurssin
ennustamismenetelmistä**Ohjaaja:**

Tuukka Järvinen

Tutkinto:

Kauppatieteiden maisteri

Yksikkö:

Laskentatoimi ja rahoitus

Koulutusohjelma:Laskentatoimen ja tilintarkastuksen
maisteriohjelma**Aloitusvuosi:**

2007

Valmistumisvuosi:

2016

Sivumäärä: 77

TIIVISTELMÄ

Konkurssi on prosessina raskas ja se aiheuttaa mittavia menetyksiä yrityksen kaikille sidosryhmille. Konkurssin ennustaminen on ollut akateemisesti suosittu tutkimussaihe 1960-luvulta lähtien. Ensimmäiset tutkimukset olivat yksinkertaisia yhden tai useamman tunnusluvun analyyseja. Myöhemmin myös monimutkaisempia tilastollisia menetelmiä on otettu käyttöön. Tästä huolimatta ei ole löydetty laajasti hyväksytyä mallia, jonka ennustamiskyky olisi parempi kuin perinteiset monen muuttujan menetelmät.

Tutkimuksen tarkoituksena on selvittää, voidaanko eri ennustamismallien välillä löytää tilastollisesti merkitseviä eroja. Aineistona ovat kaikki vuosina 2009 – 2014 konkurssiin asetetut suomalaisyrityksiä. Tutkimuksessa on verrattu seitsemän eri mallin ennustamiskykyä kahdella eri ennustamiskyvyn arvioinnilla. Vertailu on suoritettu t-testillä. Peruste tutkimukselle on algoritmien parantuminen sekä tietokoneiden laskentatehon nopeutuminen. On mahdollista, että 1960-luvun rajoitteisiin pohjautuneet ennustamismenetelmät eivät enää nykyisin ole kaikista luotettavimpia.

Mallien välillä löytyi absoluuttisia eroja, jotka olivat monesti tilastollisesti merkitseviä. Parhaiten menestyivät uudet koneoppimista hyväksikäyttävät menetelmät sekä neuroverkot ja osittain päätöspuut. Perinteiset erotteluanalyysit ja regressioanalyysit menestyivät kautta linja heikommin. Tämä antaa viitteitä siitä, että uusien menetelmien käyttöönotto voisi olla perusteltua. Lisätutkimuksille on tarvetta, jotta voidaan varmistua, etteivät tulokset johdu monimutkaisempien menetelmien ylisovittamisesta käytössä olleeseen aineistoon.

AVAINSANAT: konkurssi, konkurssin ennustaminen, koneoppiminen, neuroverkot, logistinen regressioanalyysi.

1. JOHDANTO

Konkurssi on velallisen kaikkia velkoja koskeva maksukyvyttömyysmenettely, jossa velallisen koko varallisuus käytetään kerralla konkurssisaatavien maksuun. Konkurssin alkaessa velallinen menettää määräysvallan omaisuuteen. Tuomioistuin määrää omaisuutta ja konkurssipesän hallintoa hoitamaan pesänhoitajan. Omaisuus realisoidaan ja varat käytetään velkojen suoritukseksi. (Koulu 2009: 1)

Konkurssi on oikeudellisena ja taloudellisena ilmiönä vanha ja konkurssilainsäädännöllä on useimmissa maissa pitkä historia. Konkurssi kuuluu nykyisin kiinteänä osana markkinatalouteen. Se on välttämätön oikeudellinen menettely, jolla elinkelvottomien velallisyriyten maksukyvyttömyystilanteet voidaan järjestetysti hoitaa. Yleensä konkurssi on likvidaatiomenettely, joka tähtää velallisen omaisuuden rahaksimuuttoon ja varojen jakamiseen velkojille. (HE 26/2003: 6)

Nykyisen lain tavoitteena on säännellä konkurssista tehokkaasti ja selkeästi. Konkurssimenettelystä on pyritty tekemään mahdollisimman tehokas ja tuloksekas. Lisäksi menettelyn tulisi olla läpinäkyvää. (HE 26/2003: 17) Vuoden 2004 konkurssilaki edustaa tosiasiaassa kuitenkin vanhempaa aatesuuntausta kuin vuoden 1868 konkurssisääntö. Konkurssisäännössä lähtökohtana oli liiketoiminnan jatkuminen, mitä on yleisesti pidetty velallismyönteisenä merkinä. Nykyinen konkurssilaki on sitä vastoin erittäin velkojamyönteinen. Sen lähtökohtana on likvidaatio, eikä esimerkiksi työllisyysnäkökohtia tai muita yhteiskunnallisia seurannaisvaikutuksia oteta huomioon. (Koulu 2009: 29-30)

Tyypillinen konkurssi on tavalliselle velkojalle lähes täysin tulokseton, jakoosuus on enintään 10 prosenttia yli 85 prosentissa konkurseista. Ulosotossa päästään kuitenkin 20 prosentin perimistehokkuuteen ja yrityssaneerauksessa jopa 40 prosentin suoritustasoihin. Konkurssin tehottomuus voisi pitkässä juoksussa viedä pääasiassa yksityisiin velkasovintoihin. Konkurssimenettelyn tosiasialliseksi käyttöalaksi jäisivät sellaiset tilanteet, joissa sopimukseen ei jostakin syystä päästä. Vuoden 2004 konkurssilain arvioitiin etukäteen nostavan konkurssikynnystä. (Koulu 2009: 23-34, HE 26/2003: 15)

Nykyisessä laissa ainoa konkurssiin asettamisen peruste on velallisen *maksukyvyttömyys*. Aiemmassa lainsäädännössä perusteita oli huomattavasti enemmän. Lisäksi osakeyhtiö piti ennen vuoden 2006 osakeyhtiölakia asettaa selvitystilaan, jos sen oma pääoma tippui alle kolmasosaan osakepääomasta. Tätä vaatimusta ei enää uudessa laissa ole. Nykyisin selvitystilaa käytetään ainoastaan yhtiön vapaaehtoiseen purkamiseen. (Airaksinen & Pulkkinen & Rasinaho 2007: 494-495)

Maksukyvyttömyydellä tarkoitetaan sitä, että velallinen on muutoin kuin tilapäisesti kykenemätön suorittamaan velkojaan niiden erääntyessä (KonkL 2:1.2). Maksukyvyttömyyden arviointi on oikeudellisesti vaikeaa. Velallisen varsinaiset velat sekä varat ovat monesti epäselviä, sillä tulevien tuottojen arviointi on aina epävarmaa. Arvioinnin perustana oleva velallisen varallisuuspiiri ei siis ole arviointihetkellä tiedossa. Velallisen taloudellisesta tilanteesta ei yleensä saada tarkkaa ja selkeää kuvaa, eikä varsinkaan velkojilla ole mahdollisuutta saada siitä tietoja. Maksukyvyttömyyden tulisi myös olla pysyvää, sillä ohimenevä maksukyvyttömyys estää konkurssiin asettamisen. (Koulu 2009: 70-73)

Konkurssi ei aina johda täysimittaiseen konkurssimenettelyyn, vaan se voi myös raueta tai peruuntua. Täysimittaiseen prosessiin, jossa velallisen omaisuus realisoidaan ja jaetaan velkojille, johtaa vuosittain noin kolmasosa hakemuksista (HE 26/2003: 14) ja konkurssin peruuntumista on nykyisin rajoitettu merkittävästi. (Koulu 2009: 410). Raukeaminen varojen puutteeseen onkin yleisin syy konkurssimenettelyn keskeytymiselle. Koska pesänhoitajalle tulee maksaa palkkio joka tapauksessa, ei velkojien intressissä ole ylläpitää konkurssia, jos jako-osuuksia ei kerry. (Koulu 2009: 402-403, HE 26/2003: 19)

Koska konkurssi ei enää uuden lainsäädännön aikana peruunnu kuin rajoitetuissa tapauksissa, on konkurssin käyttäminen pysyvän maksukyvyttömyyden ehdottomana tunnusmerkkinä vielä perustellumpaa kuin aikaisemmin.

1.1. Tutkimusongelma

Yhtiön toiminnan päättyminen konkurssiin on huono lopputulos kaikkien yhtiön sidosryhmien kannalta. Se aiheuttaa raskaita tappioita niin omistajille,

rahoittajille, asiakkaille, työntekijöille kuin muulle yhteiskunnalle. Konkurssi merkitsee sijoitetun pääoman menettämistä lopullisesti, minkä lisäksi menetetään paljon aineetonta pääomaa. Nämä menetykset voitaisiin mahdollisesti välttää, jos yhtiön ajautuminen konkurssiin voitaisiin ennustaa etukäteen. Tällöin konkurssi voitaisiin parhaimmassa tapauksessa jopa välttää, jos yhtiön toiminta on tervehdytettävissä. (Dimitras, Zanakis & Zopounidis 1996: 487-488).

Konkurssien määrä Suomessa on ollut lievässä laskussa viime vuosina, jota ennen konkurssit lisääntyivät talouden taantumien alkaessa. Vuonna 2014 konkurssiin haettiin 2 954 yritystä, mikä oli 5,7 prosenttia vähemmän kuin vuonna 2013. Henkilökuntaa konkurssiin päätyneissä yrityksissä oli 14 126 henkeä. Konkurssit koskettavat siten merkittävää määrää ihmisiä työpaikan menettämisen muodossa vuosittain. (Tilastokeskus 2014: 1-2). Vuonna 2015 konkurssien määrä laski edellen ja konkurssseja haettiin 2 574 kappaletta. (Tilastokeskus 2016: 1-2)

Konkurssin onnistunut ennustaminen ehkäisisi merkittävästi hyvinvointitappioiden syntymistä, millä olisi laajaa yhteiskunnallista hyötyä. Konkurssin ennustaminen onkin ollut melko intensiivisen tutkimuksen kohteena viimeisten 40 vuoden aikana. (Balcaen & Ooghe: 64).

Konkurssin ennustamista on toteutettu monella eri menetelmällä. Kehitystyötä on tehty runsaasti, sillä tilaus ylivertaiselle menetelmälle on olemassa. Yksiselitteisesti parasta menetelmää ei kuitenkaan ole kyetty kehittämään, vaikka ennustamismenetelmät ovat vuosien varrella kehittyneet ja niiden ennustamiskyky on parantunut. Perinteisten tunnuslukuihin perustuvien menetelmien lisäksi on luotu myös muita menetelmiä.

Konkurssin ennustamista on myös kritisoitu siitä, että malleilla on huomattavia teoreettisia puutteita. Suurin osa tutkimuksista onkin puhtaasti empiirisiä, jossa ennustamiskyky on pääasiallinen väline mallien rakentamisessa. Tämä johtuu siitä, että yleisesti hyväksytyä teoreettista taustaa konkurssitapahtumalle ei ole pystytty löytämään.

Tämän tutkielman tarkoituksena on tarkastella konkurssin ennustamisessa käytettyjä eri menetelmiä sekä niiden kykyä käytännössä onnistua ennustamaan konkurssseja. Tämä toteutetaan vertaamalla seitsemän eri

menetelmän ennustamiskykyä samalla aineistolla. Menetelmissä on mukana sekä perinteisiä yleisesti käytettyjä menetelmiä että uudempia koneoppimisessa käytettyjä menetelmiä. Koneoppimismenetelmien tarkastelu on perusteltua, sillä konkurssin ennustaminen ei ongelmana eroa muista koneoppimisessa kohdatuista ongelmista. Lisäksi tietokoneiden laskentatehon kasvu ja algoritmien kehittäminen mahdollistavat tällaisen tutkimuksen toteuttamisen.

Ennustamisessa käytetään hyväksi ainoastaan taloudellisia tunnuslukuja, jotta tutkimus olisi toteuttamiskelpoinen. Aineistona käytetään viime vuosina konkurssiin menneitä suomalaisia yrityksiä sekä toimivia vertailuyrityksiä.

1.2. Tutkielman rakenne

Tutkielma koostuu teoreettisesta ja empiirisestä osiosta. Teoreettisessa osassa syvennytään aikaisempiin konkurssitutkimukseen ja tarkastellaan ennustamismallin rakentamisen eri osa-alueita. Empiirisessä osassa toteutetaan tutkimus vertailemalla seitsemän eri mallin ennustamiskykyä viimeaikaisilla suomalaisilla konkurssiyrityksillä.

Toisessa luvussa esitellään tutkimuksia, joissa on tutkittu pysyvän maksukyvyttömyyden ennustamista. Tarkoituksena on esittää tutkimussuunnan keskeinen sisältö ja tähänastiset löydökset. Luvussa syvennytään varsinkin tutkielman aiheen kannalta olennaisiin ennustusmenetelmiin ja niiden käytöstä saatuihin tuloksiin. Lisäksi tarkastellaan olennaisimpia taloudellisia tunnuslukuja konkurssin ennustamisessa.

Luvussa kolme käydään läpi yrityksen konkurssiprosessia ja sitä kautta teoriaan ennustamisessa käytettävän tilinpäätösmuuttujamallin rakentamisessa. Yleisesti hyväksyttyä teoriaa kaikkien konkurssiyritysten konkurssiprosessista ei ole vielä löytynyt, mutta eri teoriat sekä empiiriset tutkimukset ovat kuitenkin löytäneet jonkinlaisen konsensuksen pysyvään maksukyvyttömyyteen johtavista syistä. Tilinpäätöstietoihin perustuvan muuttujamallin rakentaminen on keskeisessä asemassa kun yrityksen pysyvää maksukyvyttömyyttä pyritään formaalisti ennustamaan etukäteen.

Luvussa neljä esitellään tutkimuksessa käytetty aineisto, vertailtavat menetelmät sekä vertailun pohjana olevat tunnusluvut.

Viidennessä luvussa esitellään tutkimuksen tulokset koskien muuttujien esivalintaa, perinteisten mallien rakennetta sekä mallien ennustamiskyvystä. Mallien luokittelukykyjen eroja arvioidaan tilastollisilla testeillä. Lopuksi esitetään yhteenveto.

2. AIEMMAT TUTKIMUKSET KONKURSSIN ENNUSTAMISESSA

Konkurssin ennustamisella on pitkä noin satavuotinen historia. Monet ensimmäisistä tutkimuksista olivat rajallisia, sillä tilastotietoja oli heikosti saatavilla, ja tietokoneiden laskentateho oli alhainen. Ensimmäisissä tutkimuksissa käytettiinkin ainoastaan current ratio -tunnuslukua. (Laitinen & Laitinen 2004: 72)

Konkurssinennustamismenetelmillä pyritään ennustamaan konkurssia mahdollisimman suurella todennäköisyydellä ja mahdollisimman aikaisessa vaiheessa. Mitä aikaisemmin lähestyvä kriisi havaitaan, sitä enemmän mahdollisuuksia yrityksellä on toimintansa oikaisemiseen. Kriisin havaitseminen ajoissa antaa myös mahdollisuuden lieventää sen vaikutuksia, vaikkei sitä pystyttäisikään kokonaan välttämään. (Ohlson 1980: 111)

2.1 Ensimmäiset tutkimukset konkurssin ennustamisessa

Nykyisin laajimmin käytössä olevat konkurssinennustamismenetelmät ovat joko yksittäisten tunnuslukujen analyyseja (*univariate analysis*) tai useamman tunnusluvun analyysejä (*multivariate analysis*). Molemmilla lähestymistavoilla on omat pioneerinsa, jotka 1960-luvun loppupuolella julkaisivat uraauurtavia tutkimuksia. Useimmat nykyisistä konkurssinennustamismenetelmistä perustuvat tunnuslukuanalyysiin, joskin muitakin menetelmiä on olemassa. (Laitinen 1990: 39; 155-158)

Beaver (1966) tutki 79 tervettä ja 79 konkurssiyhtiötä. Konkurssiyhtiöille luotiin vastinparit ja yritysryhmien taloudellista tilannetta tutkittiin 30 tunnusluvun osalta vuosittain viiden vuoden ajan ennen konkurssitapahtumaa. Tämä on nykyäänkin yleisesti käytössä oleva perusasetelma konkurssitutkimuksissa. Beaver havaitsi suuria eroja eri tunnuslukujen osalta. Merkittävimmät erot todettiin rahoitustuloksen suhteessa vieraaseen pääomaan (cash flow) ja nettotuloksen suhteessa koko pääomaan. Erot olivat huomattavia jo viisi vuotta ennen konkurssia.

Edward I. Altman (1968) käytti erotteluanalyysiä johtaakseen tieteellisesti yhdistelmäluvun, joka ennustaisi yhtiön konkurssia. Tämän jälkeen erotteluanalyysistä tuli yleinen tapa kehittää ennustamismalli rahoituskriisiä varten. Altmanin aineistossa oli 33 yritystä, joille valittiin vastinparit. Tunnukslukujen valintaa ei perusteltu tieteellisesti, vaan alustavaan analyysiin valittiin 20 suhdelukua, jotka olivat yleisiä alan kirjallisuudessa. Luvut jaettiin viiteen luokkaan, josta valittiin aina *yksi* tunnusluku, joka loi parhaimman mallin. Altman ei valinnut parasta tunnuslukua, vaan parhaan tunnuslukujoukon, jossa tunnuslukujen yhdistelmä antoi parhaimman ennustustuloksen. Mallista käytetään nimitystä Z-malli. Lopullinen erotteluanalyysi oli seuraavanlainen:

$$Z = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,999X_5$$

missä:

X_1 = nettokäyttöpääoma / koko pääoma (maksuvalmiuden tunnusluku)

X_2 = kertyneet voittovarot / koko pääoma (pitkän tähtäimen kannattavuuden tunnusluku)

X_3 = tulos ennen korkoja ja veroja / koko pääoma lyhyen tähtäimen kannattavuuden tunnusluku)

X_4 = oman pääoman markkina-arvo / vieraan pääoman kirjanpitoarvo (vakavaraisuuden tunnusluku)

X_5 = myynti / koko pääoma (tehokkuuden tunnusluku)

Tutkimuksen merkittävin seuraus oli, että sillä pystyttiin osoittamaan miten konkurssia ennakoivaa yhdistelmälukua voidaan kehittää tieteellisesti. Altman tutki myös kriittisen arvon merkitystä ja sai selville sen raja-arvot. Väliin jäi harmaa vyöhyke, joten Altman valitsi kriittisen arvon siten, että kokonaisluokitteluvirhe jäi mahdollisimman pieneksi.

Kun vertaa Altmanin ja Beaverin tutkimuksia, voidaan todeta, että yhdistelmäluvulla on parempi ennustamiskyky verrattuna yksittäiseen tunnuslukuun pari vuotta ennen konkurssia. Yhdistelmäluvun ennustamiskyky kuitenkin heikkenee olennaisesti kun aika konkurssiin on pidempi. Tämä tarkoittaa, että yhdistelmäluvun sisältämissä tunnusluvuissa on useita sellaisia lukuja, jotka pystyvät ennakoimaan konkurssia vasta juuri ennen konkurssitapahtumaa. Käytännön ennuste- ja hälytysjärjestelmässä kannattaa siten käyttää sekä yhdistelmälukuja että yksittäisiä tunnuslukuja. (Laitinen & Laitinen 2004: 89-90)

Suomessa Aatto Prihti (1975) on laajentanut konkurssin ennustamista ja sisällyttänyt ennustamismenetelmänsä puhtaan empirian lisäksi myös teorian konkurssista. Prihti loi väitöskirjassaan erottelufunktion Altmanin tapaan, mutta perusteli tunnuslukujen valintaansa teoreettisesti. Mallia käytettiin siten, että sen pohjalta tehtiin hypoteesit yritysten käyttäytymiselle, ja sen mukaisesti etsittiin sopivat tunnuslukuvastineet. Prihtin käyttämässä konkurssimallissa yritys on sarja perättäisiä investointeja, jotka rahoitetaan tulorahoituksella sekä omalla ja vieraalla pääomalla. (Prihti 1975: 35-37)

Prihtin käyttämät kolme hypoteesia ovat: 1) yritysten tulorahoitus kattaa yleensä maksuvaatimukset rahoituksesta, 2) yritys ajautuu konkurssiin silloin kun sen lisäluoton tarve ylittää sen saatavilla olevan enimmäisluottomäärän ja 3) yrityksen johto ottaa tarvittavan lisärahoituksen siltä sidosryhmältä, jonka oikeudellinen etuoikeusjärjestelmä on kaikista huonoin. Tämän nojalla valittiin mallissa käytettävät tunnusluvut, jotka olivat tulojäämä verojen jälkeen, negatiivinen quick sekä vieras pääoma. Kaikki nämä suhteutettiin taseen koko pääomaan. Prihti ei käyttänyt vastinparimenettelyä, mutta sai mallinsa pohjalta luotua oman Z-mallin Altmanin tapaan. (Prihti 1975: 58-59; 73-76) Altmanin ja Prihtin luomat mallit tuovat esille selkeän teoreettisen viitekehysten yhdistelmäluvun käytölle. Lisäksi ne luovat eräänlaisen perusmallin, jonka avulla voidaan verrata muiden mallien ennustamiskykyä käyttämällä samaa aineistoa. (esim. Dacovic, Czado & Berg 2010)

2.2. Myöhemmät konkurssinennustamistutkimukset

Myöhemmissä tutkimuksissa ei ole ainoastaan pyritty löytämään parempia tunnuslukuja kuin Beaverin ja Altmanin tutkimuksissa tai parantamaan Altmanin Z-lukuja. Tutkimuksissa on myös yritetty parantaa ennustamismallien tarkkuutta monin eri tavoin, joista käytetyimmät tavat ovat: (Laitinen & Laitinen: 116)

1. Tilastollisten ennustamismenetelmien kehittäminen
2. Tilastollisten olettamusten vaikutusten arviointi
3. Tilastollisen otoksen vaikutusten arviointi
4. Tunnuslukujen ja tilinpäätöstietojen oikaiseminen
5. Muiden muuttujien kuin tunnuslukujen käyttäminen

6. Toimialaerojen huomiointi
7. Konkurssiprosessia kuvaavien mallien kehittäminen
8. Rahoittajien käyttäytymisen tutkiminen

Tilastollisia menetelmiä on kehitetty siten, että erotteluanalyysiä on käytetty vertailukohtana ja mallilla saatuja tuloksia on yritetty parantaa muilla tilastollisilla menetelmillä. Tällaisia menetelmiä ovat esimerkiksi olleet logit tai probit-mallien käyttö ja rekursiivinen osittaminen. (Laitinen & Laitinen 2004: 116-117)

Tilastolliseen malliin valittavat tunnusluvut saattavat poiketa käytettävän menetelmän tilastollisista olettamuksista. Tällä on vaikutusta ennustustarkkuuteen. Tutkimuksissa on osoitettu, että esimerkiksi lineaarinen malli on herkkä sille, että tunnusluvut noudattavat normaalisuusjakaumaa. Lisäksi on arvioitu käytetyn otoksen vaikutusta mallien ennustuskykyyn. Malleissa syntyy harhaa esimerkiksi sen takia, että konkurssiyrityksiä otetaan mukaan estimointiaineistoon suhteessa suurempi osa kuin niiden tosiasiallinen määrä yrityskentässä ja koska otokseen voidaan valita vain sellaiset yritykset, joista on saatavilla täydelliset tiedot. (Laitinen & Laitinen 2004: 117)

Mark E. Zmijewski (1984) on tutkinut tätä ja osoittanut, että molemmat harhat ovat selkeästi havaittavissa. Harhat eivät kuitenkaan merkittävästi vaikuta mallien luokittelukykyyn tai ennustuskykyyn. Täten niiden merkitystä voitaneen pitää pienenä.

Tunnuslukujen inflaatiotarkistus tai leasingin oikaisu ei ole vaikuttanut mallien ennustamiskykyyn, vaikka teorioissa monesti esitetään että näillä oikaisuilla saattaa olla merkittävä vaikutus. Toimialakohtaisia eroja on kuitenkin todettu siten, että eri tunnusluvut ja tunnuslukujen painotukset sopivat paremmin tietyille toimialoille kuin toisille. Yrityksen iän merkitys taas ei ole vaikuttanut ennustuskykyyn. (Laitinen & Laitinen 2004: 118-121)

Ennustusmallien ennustuskyky paranee huomattavasti kun niihin sisällytetään muitakin muuttujia kuin taloudellisia tunnuslukuja (ns. taustamuuttujia). Nämä muuttujat eivät ole kovinkaan riippuvaisia taloudellisista tunnusluvuista, jolloin ne parantavat mallien selitysasteita merkittävästi

puhtaasti taloudellisiin mittareihin verrattuna. (Laitinen & Laitinen 2014: 175-177)

Tutkimalla rahoittajien tosiasiallista käyttäytymistä käytetään hyväksi työkseen konkurssiriskejä ennustavien ihmisten ammattitaitoa. Kun rahoittajat eivät enää myönnä lisäluottoa, on yrityksellä erittäin suuri riski joutua maksukyvyttömäksi. Rahoittajien käyttäytymisen tutkimisessa käytetään ns. HIP-menetelmää (Human Information Processing). Tällä menetelmällä ei kuitenkaan ole saatu aikaan merkittävästi parempia ennustamistuloksia kuin muilla, puhtaasti tilastollisilla malleilla. (Laitinen & Kankaanpää 1997: 49-50, Laitinen & Laitinen 2004: 123-124)

Tutkimuksissa on myös huomattu, että puhtaasti taloudellisiin tunnuslukuihin perustuvissa malleissa, mallien ennustamistarkkuus huononee merkittävästi kun konkurssiin on aikaa 4-5 vuotta. Mallit toimivat selkeästi paremmin 1-3 vuotta ennen konkurssia. Tämä johtunee siitä, että yrityksellä on vielä 4-5 vuotta ennen konkurssia mahdollisuuksia sopeuttaa toimintaansa konkurssin välttämiseksi. Jotkut yritykset onnistuvat ja toiset eivät. Puhdas tunnuslukuanalyysi ei pysty erottamaan nämä kaksi ryhmää toisistaan ex ante. (Laitinen & Laitinen 2014: 158-159)

2.3. Maksukyvyttömyyden syihin perustuvat tutkimukset

Empiirisissä tutkimuksissa on tutkittu myös maksukyvyttömyyden syitä. Laajempiin aineistoihin perustuvat tutkimukset alkoivat oikeastaan John Argentin (1976) tutkimuksesta. Tätä ennen tutkimukset olivat suppealla aineistolla tehtyjä case-tutkimuksia, joissa oli syvälinen analyysi, mutta joiden tuloksia ei ollut mahdollista yleistää. (Laitinen & Laitinen 2014: 55)

Konkurssia voidaan ilmiönä lähestyä joko maksukyvyyn tai vakavaraisuuden kriisinä. Näistä maksukykyyn perustuva lähestymistapa on yleisempi, sillä jo Beaver (1966:80) teoretisoi yrityksen epäonnistumista tämän mallin pohjalta. Beaverin mukaan yrityksellä voidaan katsoa olevan tietty määrä likvidejä varoja. Tämä toimii puskurina kassavirran epätasapainoja vastaan. Teoriassa on neljä tärkeätä osa-aluetta, jotka vaikuttavat yrityksen konkurssiriskiin: 1) puskurin suuruus, 2) liiketoiminnan nettokassavirta, 3) yrityksen velan suuruus

ja 4) liiketoiminnan vaatima kassavirta mm. investointeja varten. Beaver oletti, että jokainen osa-alue on tärkeä siten, että:

- 1) Mitä suurempi puskurirahasto, sen pienempi konkurssiriski
- 2) Mitä suurempi liiketoiminnan nettokassavirta, sen pienempi konkurssiriski
- 3) Mitä suurempi velka, sen suurempi konkurssiriski
- 4) Mitä suurempi liiketoiminnan vaatima kassavirta, sen suurempi konkurssiriski

Nämä neljä osa-aluetta voidaan jakaa staattiseen ja dynaamiseen maksukykyyn. Kun valitaan tunnuslukuja konkurssin ennustamismalliin, voidaan tätä teoriaa käyttää hyväksi. Staattisen maksukykyyn muuttujan jakajana toimii luontevimmin taseessa olevat rahoitusvarat. Dynaamisen muuttujan jakajana toimii luontevimmin liiketoiminnan tuotot. (Laitinen & Kankaanpää 1997: 11)

Yhtä yleisesti hyväksyttyä teoreettista mallia konkurssista ei ole. Tämä johtuu siitä, että teorioiden vahvistaminen empiirisesti ei ole onnistunut sekä siitä, että konkurssiin menneet yritykset ovat hyvinkin erilaisia. Ensimmäisiä tutkimuksia, missä laajennettiin katsantokantaa yksittäisten yritysten case-analyysistä laajempaan, empiiriseen katsaukseen oli Argenti (1976: 150), joka jakoi konkurssiin menneet yhtiöt kolmeen luokkaan:

1. käyntiinlähdössä epäonnistunut yritys,
2. onnistuneen käyntiinlähdön jälkeen epäonnistunut yritys ja
3. vanha, riutuva yritys.

Käyntiinlähdössä epäonnistunut yritys on määritelmänkin mukaan nuori ja pienehkö. Yritys perustuu virheellisiin oletuksiin, eikä se ole alun alkaenkaan ollut elinkelpoinen. Se kituu muutaman vuoden ja ajautuu konkurssiin kun sen rahoitus loppuu. Kaikki tunnusluvut ovat heikkoja koko toiminnan ajan. (Ooghe & de Prijcker 2008: 228)

Toisen tyyppin yhtiö on alun perin ensimmäistä tyyppiyritystä paljon elinvoimaisempi. Sillä on hyvä tuoteidea ja se kasvaa sen johdosta nopeasti. Johtamismenetelmät eivät kuitenkaan pysy kasvuvauhdin mukana, jolloin yritys romahtaa äkkiä kun hyödyt perustamisideasta on käytetty. Kriisi tällaisessa yhtiössä on äkillinen, eikä se ole ennustettavissa pelkkien tilinpäätöstietojen pohjalta. (Ooghe & de Prijcker 2008: 226)

Kolmas konkurssityyppiyritys on yleensä suurempi ja merkittävästi vanhempi. Yhtiöllä on takanaan kunniakas historia, mutta siihen on vuosikymmenten ajan kertynyt tehottomuutta. Kilpailutilanteen muuttuminen tai muu vastaava tapahtuma voi siten sysätä yhtiön huonompaan suuntaan. Heikko vaihe voi kestää vuosikausia, jolloin yhtiö syö kertynyttä varallisuuttaan. Lopullisesti yhtiö ajautuu konkurssiin kun sen taloudellinen tilanne romahtaa ja se ajautuu kriisiin. Tällaisen yhtiön konkurssiin ajautuminen tulisi olla ennustettavissa jo vuosia aikaisemmin. (Laitinen & Laitinen 2004: 105)

Tutkimuksia on tehty viime vuosikymmeninä erittäin paljon, joten niistä on mahdollista laatia yhteenvetoja. Suurin ongelma on, että tutkimukset ovat toisistaan melko irrallisia sillä ne eivät perustu mihinkään yleisesti hyväksytyyn teoriaan konkurssiprosessista. Laitinen & Laitinen (2014: 75-79) on tutkinut n. 40 erilaista konkurssin syihin perustuvaa tutkimusta ja todenneet, että suurin osa konkurseista johtuu yrityksen sisäisistä syistä. Sisäiset syyt ovat yksinomaan vastuussa n. 70 % konkurseista, vaikka näissäkin tapauksissa laukaisevana tekijänä on ollut jokin ulkoinen tapahtuma tai kriisi. Ulkoiset syyt ovat yksinomaan vastuussa vain n. 10 % konkurseista ja loppuissa tapauksissa syyt ovat melko tasapuolisesti sekä ulkoisia että sisäisiä.

2.4. Konkurssitutkimukset suomalaisella aineistolla

Suomessa konkurssitutkimusta on harjoittanut pääasiassa Erkki K. Laitinen ja Teija Laitinen. Suomalaisella aineistolla tehtyjä keskeisiä tutkimuksia ovat mm. Laitinen (1990), Laitinen & Kankaanpää (1997), Laitinen & Laitinen (2004) sekä Laitinen & Laitinen (2014). Näistä kaikki muut paitsi Laitinen & Kankaanpää (1997) käyttävät hyväkseen Z-mallia ja pyrkivät löytämään suomalaisia konkurssiyrityksiä hyvin ennustavan mallin.

Tutkimuksessa Laitinen (1990:216) aineistona käytettiin 40 häiriöllistä ja 40 häiriötöntä yritystä, joista oli saatavilla täydelliset tilinpäätöstiedot vuosilta 1986–1989. Paras erotteluanalyysi tällä aineistolla oli seuraavalla viiden muuttujan Z-malli:

$$Z = 1,88 * X1 + 10,13 * X2 - 0,13 * X3 + 0,51 * X4 - 0,32 * X5$$

missä:

X1 = rahoitustulosprosentti

X2 = quick ratio

X3 = ostovelkojen maksuaika

X4 = omavaraisuusaste

X5 = liikevaihdon kasvunopeus

Tutkimuksessa Laitinen & Laitinen (2004: 301) käytettiin mallin aineistona 1897 häiriöllistä ja 1897 häiriötöntä suomalaista yritystä, joista oli saatavilla täydelliset tilinpäätöstiedot vuosilta 1998–2001. Tutkimuksessa saatiin varsinaiseksi Z-malliksi:

$$Z = -0,634 + 0,026X_1 + 0,006X_2 + 0,024X_3$$

missä:

X1 = quick ratio (staattisen maksuvalmiuden tunnusluku)

X2 = rahoitustulosprosentti (dynaamisen maksuvalmiuden tunnusluku)

X3 = omavaraisuusaste (staattisen vakavaraisuuden tunnusluku)

Z-mallin kriittinen arvo oli mallissa 0, jolloin negatiivinen arvo tarkoitti häiriöllistä yritystä.

Tutkimuksessa Laitinen & Laitinen (2014: 229-230) käytettiin aineistona 640 konkurssiyritystä ja 41 600 toimivaa yritystä, joista oli saatavilla täydelliset tilinpäätöstiedot kolme vuotta ennen konkurssia vuosilta 2007-2011. Tutkimuksessa saatiin varsinaiseksi Z-malliksi seuraava logistinen regressiomalli (logit):

$$L = 0,212 - 0,0270 * X_1 - 0,0170 * X_2 - 0,0290 * X_3 - 0,0300 * X_4$$

missä:

X1 = rahoitustulosprosentti

X2 = kokonaispääoman tuottoprosentti

X3 = omavaraisuusaste

X4 = quick ratio

Tutkimukset on toteutettu kolmella eri vuosikymmenellä kerätyillä aineistoilla ja kaikissa tutkimuksissa on alustavaan estimointiin otettu mukaan hyvin monia eri tunnuslukuja aineistossa olevista yrityksistä. On kuitenkin merkillepantavaa, että kaikissa tutkimuksissa lopulliseen malliin ovat aina päätyneet tunnusluvut quick ratio, rahoitustulosprosentti sekä omavaraisuusaste. Mallien ennustamiskykyä voidaan vielä hiukan parantaa ottamalla mukaan muita tunnuslukuja. Selvempää parannuta ennustamiskykyyn syntyy, kun mukaan otetaan myös yritystä kuvaavia taustamuuttujia. (Laitinen & Laitinen 2014: 175-177)

On myös syytä huomata, että pelkällä omavaraisuusasteella pystytään luokittelemaan oikein merkittävä määrä konkurssiyrityksistä, joten tämän tunnusluvun arvo on täysin hallitseva malleissa. (Laitinen & Laitinen 2014: 229) Kuten suomalaisista konkurssitutkimuksista selviää, puhtaasti taloudellisiin tunnuslukuihin perustuvissa malleissa olennaisten tunnuslukujen määrä on hyvin suppea.

2.5. Ennustamismenetelmät

Konkurssinennustamismenetelmät voidaan jakaa kolmeen pääasialliseen ryhmään: (Aziz & Dar 2006: 19, Laitinen & Kankaanpää 1997: 1-2):

1. Perinteiset tilastolliset mallit, joissa keskitytään löytämään parhaat ennustavat *muuttujat*
2. Koneoppimista hyödyntävät mallit tai mallit, joissa keskitytään löytämään paras *menetelmä* konkurssin ennustamisessa
3. Teoreettiset mallit, joissa keskitytään muuttujien valinnan teoriaan

Tilastolliset mallit sisältävät sekä yhden tunnusluvun analyysit että analyysit, joissa käytetään useampaa tunnuslukua. Ne keskittyvät löytämään oireita yrityksen epäonnistumiselle, sillä ei ole mahdollista löytää syitä kun aineisto ja muuttujat ovat usein peräisin yrityksen itse tekemistä tilinpäätöksistä. Aineisto analysoidaan perinteisin tilastollisin menetelmin. (Aziz & Dar 2006: 19)

Koneoppiminen on tekoälyn osa-alue, jossa luodaan tietokoneavusteisia järjestelmiä, jotka pystyvät parantamaan ongelmanratkaisukykyään kokemuksen avulla. Nämäkin mallit keskittyvät löytämään epäonnistumisen oireita ja käyttävät hyväkseen yrityksen tuottamaa tilinpäätösaineistoa, joten niissä on sisäänrakennettuna tilastollisten mallien peruslähtökohdat. Mallin rakentamisessa ja muuttujien valinnassa mallit kuitenkin eroavat perinteisistä tilastollisista malleista. (Aziz & Dar 2006: 19-21)

Teoreettiset mallit keskittyvät muista malleista poiketen tarkastelemaan konkurssiin johtaneita syitä, joiden johtopäätöksiin pohjautuen kerätään aineistoa. Tätä aineistoa tutkitaan sitten tilastollisen päättelyn mukaisesti, useasti monen tunnusluvun analyysia hyväksi käyttäen. Tilastollisen

tutkimuksen ideana on varmistaa teoreettisen viitekehyyksen avulla löydetty hypoteesit. Eroavaisuutena perinteisiin malleihin on siis muuttujien ja aineiston valinnassa. (Aziz & Dar 2006: 19)

2.5.1. Tilastolliset mallit

Tilastollisia malleja on monta erilaista. Alla on selostettu pääasiallisessa käytössä olevat tilastolliset mallit.

Yhden muuttujan mallit, jotka käyttävät pääasiassa hyväkseen taloudellisia tunnuslukuja. Ideana on, että taloudellisten lukujen eroavaisuudet terveiden ja konkurssiin menneiden yritysten välillä voisivat toimia ennustavina muuttujina. (Aziz & Dar 2006: 20, Jackson & Wood 2013: 188-189)

Useamman tunnusluvun mallit, jotka yhdistävät lineaarisesti erilaiset tunnusluvut yhdeksi konkurssin ennustamisluvuksi. Tällä luvulla yhtiöt jaotellaan terveisiin ja konkurssiyrityksiin. (Aziz & Dar 2006: 20, Jackson & Wood 2013: 189-190)

Lineaarinen todennäköisyysmalli, joka ilmaisee epäonnistumisen todennäköisyyden kaksijakoisena riippuvana muuttujana, joka on lineaarinen funktio selittävän muuttujan vektorista. Mallin teoreettisia perusoletuksia kuitenkin rikotaan usein, mikä heikentää sen käyttökelpoisuutta. (Aziz & Dar 2006: 20)

Logistinen regressioanalyysi (ns. logit-malli) on samanlainen kuin lineaarinen todennäköisyysmalli, mutta riippuvainen muuttuja on todennäköisyys sille että epäonnistuminen tapahtuu. (Dimitras ym. 1996: 504). **Probit-malli** perustuu erilaiseen tilastolliseen lähestymistapaan, mutta on hyvin lähellä logit-mallia sekä lineaarista todennäköisyysmallia. (Aziz & Dar 2006: 20)

Kumulatiivinen summamenetelmä on aikasarja-analyysi, jossa yrityksen toimintaa arvioidaan VAR-mallin avulla. Tarkoituksena on huomata yrityksen siirtyminen terveiden yritysten joukosta konkurssiyritysten joukkoon. On todennäköistä, että malli ei ikinä tule laajaan käyttöön sillä se vaatii hyvin laajoja tietokantoja, joita ei käytännössä ole saatavilla konkurssiin menneistä yrityksistä. (Aziz & Dar 2006: 20)

2.5.2. Muut mallit

Koneoppimista hyödyntävät menetelmät ovat syntyneet koska tiedon määrä lisääntyy nykyisin eksponentiaalisesti. Valtavasta tietomassasta relevanttien yhteyksien ja ymmärryksen löytäminen on luonut uuden käsitteen – *tiedon louhinta*. Sillä tarkoitetaan prosessia, jolla pyritään löytämään laajasta datamäärästä mielekkäitä rakenteita ja sääntöjä. (Shmueli, Patel & Bruce 2010: 3)

Tiedon louhinta edellyttää käytännössä nykyisten tietokoneiden laskentatehon hyödyntämistä ja tehokkaiden algoritmien hyödyntämistä. Tähän tarkoitukseen on syntynyt *koneoppiminen*, jolla tarkoitetaan algoritmien oppimista tai kouluttamista. Kun algoritmeille esitetään tietomassoja, voidaan niiden avulla löytää mielekkäitä yhteyksiä. Näiden avulla voidaan tulevaisuudessa ennustaa saman ilmiön tapahtumia. (Witten & Frank 2006: 7-9)

Tiedon louhinnassa voidaan käyttää monia eri malleja. Jokaisella mallilla on omat heikkoutensa ja vahvuutensa, ja ratkaisevaa valinnassa on käsillä olevan ongelman luonne. (Shmueli ym. 2010: 6) Koneoppimista hyödyntäviä menetelmiä voidaan käyttää myös konkurssin ennustamisessa. Konkurssin ennustaminen ei ole ongelmana erityinen suhteessa muihin, joten menetelmien käytössä ei ole rajoituksia. Akateemisissa tutkimuksissa on kuitenkin käytetty pääasiassa lineaarista erotteluanalyysia ja logistista regressioanalyysia, muiden jäädessä vähemmälle huomiolle. (Aziz & Dar 2006: 21)

Rekursiivisen osittamisen tai **päätöspuun** perusidea on jakaa yritykset kaksiluokkaisen puun muotoon, niin että koko puun virheluokittelujen odotetut kustannukset minimoituvat. Luokat jaetaan eri tunnusluvuilla siten, että lopuksi jäljellä on vain kriisiyritysten luokka ja toimivien yritysten luokka. (Laitinen & Kankaanpää 1997: 26-27) Eloonjäämisanalyysissä pyritään hyödyntämään tiedot tilinpäätöstietojen syntyhetken ja kriisihetken välillä. Keskeisiä käsitteitä ovat riskijoukko (risk set) ja riskiluku (hazard rate). Riskijoukko tarkoittaa havaintojen joukkoa, joka on vaarassa joutua rahoituskriisiin tietynä ajanhetkenä. Riskiluku tarkoittaa taipumusta tai alttiutta, jolla yritys joutuu rahoituskriisiin tietyllä hetkellä. (Dimitras ym. 1996: 505-506)

Case-pohjaisessa päättelyssä käytetään hyväksi aiemmin ratkottuja yksittäisiä ongelmia (=case). Kun uusi ongelma löydetään, siihen käytetään aiemmin ratkaistuja ongelmia, jonka jälkeen uusi ongelma ratkaistaan ja lisätään ns. case-kirjastoon, josta voi selata ratkaistuja ongelmia. Näin pystytään ajan myötä löytämään toimivia malleja konkurssin ennustamisessa. (Aziz & Dar 2006: 21, Kumar & Ravi 2007: 17-18)

Neurolaskenta perustuu neuroverkkoon (neural network), joka on joukko toisistaan riippuvia laskennallisia elementtejä. Verkko ohjelmoidaan joko ohjatusti tai ei-ohjatusti. Verkon opittua ennustamaan tietyn aineiston perusteella kriisiyhtiöitä, voidaan se tallentaa ja käyttää sitä muiden aineistojen pohjalta konkurssin ennustamiseen. Ongelmana verkossa on kuitenkin sen itseoppivuus, jolloin laskenta-algoritmi on käyttäjälle tuntematon. Verkon ohjelmointi vaatii myös suuren aineiston. (Laitinen & Laitinen 2004: 151-153; Laitinen & Kankaanpää 1997: 37-39) Neuroverkkojen avulla luodulla mallinnuksella on ollut joissain tutkimuksissa selkeästi parempi ennustamiskyky verrattuna perinteiseen monen muuttujan logistiseen regressioanalyysiin. (Zhang, Hu, Patuwo & Indro 1999: 26-27)

Geneettiset algoritmit pyrkivät ratkaisemaan tunnuslukujen valintaongelman. Se on optimointimenetelmä, joka jäljittelee biologista evoluutiota. Perinnöllisyystieteessä genotyyppi on yksilön geneettinen perimä, jota edustaa joukko kromosomeja. Geneettisessä algoritmossa kokoluku vastaa geeniä ja kokonaislukuvektori kromosomia. Geneettisiä algoritmeja ei ole käytetty kovinkaan laajasti konkurssin ennustamisessa. (Laitinen & Laitinen 2004: 174-175, Kumar & Ravi 2007: 18)

Rough-set mallit käyttävät hyväkseen epätäydellistä informaatiota objektien luokittelussa. Mallissa tietoa objekteista esitellään taulukossa, joka käyttäytyy kuten päätöstaulukko, sisältäen tilanne ja päätösominaisuuksien joukot. Hyväksikäyttäen induktiivista oppimista pystytään päättelemään uusia päättelysääntöjä. Jokainen yritys voidaan siten luokitella ominaisuuksiensa mukaan mallista saatavien sääntöjen avulla. (Kumar & Ravi 2007: 19-20)

Täysin toisenlainen suhtautuminen ongelmaan ovat teoreettiset mallit. Koneoppimista hyödyntävät mallit ovat puhtaasti empiirisiä eli eivät käytä mitään konkurssiprosessiin liittyvää teoriaa hyödykseen mallien luomisessa.

Teoreettiset mallit taas pohjaavat teoriaan ja pyrkivät sitä kautta löytämään parhaat muuttujat ongelman ymmärtämiseen. (Aziz & Dar 2006: 21)

Taseen dekompositiomittareiden lähtökohtana on yritysten pyrkimys pitää taloudellinen tilanteensa tasapainossa. Yrityksen taloudellisen tilanteen muuttuminen näkyy sen varallisuuden ja velkojen rakenteessa, jolloin muutoksia havainnoimalla on mahdollista luokitella yritys konkurssiyritykseksi tai toimivaksi yritykseksi. (Aziz & Dar 2006: 22)

Uhkapelaajan vararikossa (gambler's ruin) yritys katsotaan uhkapelaajaksi, joka jatkaa pelaamista kunnes nettoarvo putoaa nolnaan. Teoria on ns. vakavaraisuuskonkurssin tausta-ajatuksena. (Laitinen & Kankaanpää 1997: 8)

Kassavirtaan perustuvien teorioiden lähtökohta on, että tarkastelemalla yrityksen kassavirtoja pystyttäisiin ennakoimaan konkurssiriskiä. Pysyvästi negatiivinen kassavirta johtaa ennen pitkää yrityksen konkurssiin. Teorioissa yrityksen käyttäytyminen tulkitaan rahan kysynnän kautta. Yrityksellä nähdään olevan tietty määrä rahoitusvarallisuutta, jota rasittavat kulut ja jota kasvattavat tulot. Tutkimuksissa tutkitaan konkurssiriskiä yrityksen kassavirtojen avulla. (Laitinen & Laitinen 1998: 894-895)

Taloudellisiin tunnuslukuihin perustuvat mallit ovat perinteisesti olleet kaikista käytetyimpiä ennustamismenetelmiä. Aziz & Dar (2006: 23) ovat todenneet, että noin 60 % tutkimuksista on käytetty pelkästään taloudellisia tunnuslukuja ennustamisessa. Kassavirtoja oli tarkasteltu 7 prosentissa tutkimuksissa.

On kuitenkin olemassa myös muita kuin puhtaasti taloudellisiin tunnuslukuihin perustuvia ennustamismalleja. Näistä käytetyimmät ovat mallit, jotka huomioivat yrityksen toimialan, koon tai iän. (ks. esim. Ooghe & De Prijker 2008, Argenti 1976, Li & Miu 2010). Niitä oli Aziz & Darin (2006: 23) selvityksessä käytetty yhdessä taloudellisten tunnuslukujen kanssa 33 prosentissa tutkimuksista.

HIP-menetelmä (Human Information Processing) perustuu ihmisten tosiasiallisiin päätöksentekoprosesseihin. Menetelmän lähtökohta konkurssin ennustamisessa käytettäessä on otos konkurssiyhtiöistä ja terveistä yhtiöistä. Näistä yhtiöistä johdettuja tunnuslukuja ja muita tietoja on sitten annettu koehenkilöille ja pyydetty heitä esimerkiksi päättämään myöntäisivätkö he yritykselle lainaa vai ei. Usein pääasiallinen kiinnostuksenkohde on

koehenkilöiden analyysin oikeellisuus verrattaessa oikeisiin lopputuloksiin. Tavoitteena on ymmärtää, kuvailla, arvioida sekä parantaa tehtyjä päätöksiä. Tämä on mahdollista ymmärtämällä miten päätökset tosiasiallisesti tehdään. Menetelmä liittyy siten varsinaiseen psykologiaan ja psykologian teorioihin. (Laitinen & Kankaanpää 1997: 43-44) HIP-menetelmässä on käytetty faktorianalyysiä, jotta perusulottuvuudet löydettäisiin, eikä koehenkilöiltä kysyttäisi päällekkäisiä tietoja. (Laitinen & Laitinen 2004: 174)

3. KONKURSSIN ENNUSTAMINEN TILINPÄÄTÖSMUUTTUJEN AVULLA

Tilinpäätösmuuttujien käyttö on yllä esitetyn valossa käytännössä ainoa tapa tehdä kvantitatiivista tutkimusta konkurssin ennustamisessa. Konkurssiin tulevaisuudessa ajautuvat yritykset erotellaan toimivista yrityksistä niillä tiedoilla, jotka ilmenevät yritysten tilinpäätöksistä. Käytettävät tilinpäätöstiedot ovat numeraalisia lukuja, joista lasketaan erilaisia tunnuslukuja. Tunnuslukujen arvojen oletetaan paljastavan tulevat konkurssiyritykset ennen konkurssitapahtumaa. Mallinnuksessa käytettävien tunnuslukujen valinta ja ennustamisessa käytettävän mallin käyttö edellyttävät kuitenkin ymmärrystä varsinaisesta konkurssiprosessista sekä eri tilastollisten mallien vahvuuksista ja heikkouksista. Tässä kappaleessa syvennytään seikkoihin, jotka tulee olla tiedossa kun rakennetaan konkurssinennustamismallia tilinpäätösmuuttujia hyväksi käyttäen.


3.1. Maksukyvyttömyysprosessi

Kun yrityksen toimintaympäristössä tapahtuu muutos, johon johto reagoi väärin tai pysyy passiivisena voi yritys ajautua pysyvästi maksukyvyttömäksi. Konkurssi näkyy ensin yrityksen sisäisessä toiminnassa ja vasta myöhemmin ulkopuolisille sidosryhmille, kun yrityksen taloudelliset tunnusluvut heikkenevät. (Laitinen & Laitinen 2014: 142-144) Yritysten tunnusluvut eivät siis kuitenkaan ilmennä konkurssin syitä, vaan oireita. Varsinaiset syyt löytyvät muualta, ja tunnusluvut ainoastaan tuovat nämä syyt ilmi - myös yrityksen ulkopuolisten tietoon. (Ooghe & de Prijcker 2008: 224-226)

Konkurssiin johtavat syyt voidaan jakaa kahteen eri kategoriaan. Ensinnäkin konkurssi voi johtua yrityksen *ulkopuolisista* syistä. Yrityksen omalla toiminnalla ei ole merkittävää osaa siinä, ajautuuko se konkurssiin. Edes strategisilla päätöksillä ei ole merkitystä, sillä yritys ei pysty vaikuttamaan omaan toimialaansa tai toimintaympäristöönsä merkittävässä määrin. Yritysjohdolla on vähäiset mahdollisuudet vaikuttaa konkurssiprosessiin, sillä ulkopuoliset syyt määräävät. (Mellahi & Wilkinson 2004: 23-27) Toinen kategoria käsittää teorian, joiden mukaan yritysjohto on merkittävin tekijä yrityksen konkurssiin ajautumisessa. *Sisäiset* syyt siis vaikuttavat eniten

konkurssiriskiin. Yritysjohto toimii tietyssä ympäristössä, jossa on rajoittavia tekijöitä, mutta olennaisinta on kuitenkin se miten johto näkee ympäristön ja millaisia päätöksiä he tämän näkemyksen perusteella tekevät. Suurin syy konkurssiin ajautumisessa ovat johdon tekemät virheelliset päätökset, eikä yrityksen toimintaympäristö sinänsä. (Mellahi ja Wilkinson 2004: 27-31)

Yleisesti käytössä oleva yrityksen terveyskolmio mittaa kriisin oireita taloudellisten toimintaedellytysten kautta. Nämä ovat: 1) kannattavuus, 2) maksuvalmius ja 3) vakavaraisuus sekä kasvu, joka vaikuttaa kannattavuuteen.



Kuvio 1: Yrityksen terveyskolmio. (Laitinen & Laitinen 2004: 243)

Kannattavuus on tärkeintä yrityksen toiminnan kannalta, sillä koko yrityksen toiminta on sen varassa. Mikäli kannattavuus pitkällä aikavälillä on heikko, ei yhtiö voi olla elinkelpoinen. Heikon kannattavuuden yritys tuottaa tappiota ja syö omia pääomiaan. (Laitinen & Laitinen 2004: 242-243)

Pelkkä kannattavuus ei kuitenkaan riitä toiminnan jatkumiseen, jos maksuvalmius tai vakavaraisuus ei ole kunnossa. On lukuisia esimerkkejä yrityksistä, jotka ovat toimineet kannattavasti mutta ajautuneet konkurssiin maksuvalmius- tai vakavaraisuusongelmien vuoksi. Taloudelliset toimintaedellytykset ovat siis yhtä hyvät kuin terveyskolmion heikoimman osatekijän vahvuus. Kun kriisiä ennustetaan, tärkeimpiä tavoitteita on löytää tämä yhteys. (Laitinen & Laitinen 2004: 243)

Rahoituskriisi voi yrityksessä ilmetä pääasiassa kahdella eri tavalla, joko maksuvalmiuteen tai vakavaraisuuteen liittyen. *Maksuvalmiuskriisissä* yritys on ainakin hetkellisesti maksukyvytön, vaikka sen kannattavuus ja vakavaraisuus ovat kunnossa. *Vakavaraisuuskriisi* on vakavampi, sillä yhtiö on hitaan kasvun vuoksi maksukyvytön. Lisäksi yhtiön kannattavuus on niin heikko, että se on menettänyt merkittävän määrän omasta pääomastaan. *Maksukyvyttömyyskriisi* taas johtuu tavallisesti siitä, että yritys on kasvanut ja kannattavuus ei ole ollut tarpeeksi suuri kasvun rahoittamiseksi. Varsinkin epätasainen kasvu tai kasvussa tapahtunut jyrkkä muutos ovat riskejä, jotka voivat johtaa rahoitusvaikeuksiin. (Laitinen & Laitinen 2004: 243-244)

Tarkastelussa tulee huomioida myös konkurssiin ajautuvien yritysten erilaisuus, jolloin myös oireet ilmenevät eri tavoin. Tuoreessa, suomalaisella aineistolla tehdyssä tutkimuksessa Laitinen & Laitinen (2014: 226-228) konkurssiyritykset pystyttiin jakamaan neljään ryhmään, jotka melko hyvin vastaavat Argentin alkuperäistä jaottelua. Ryhmistä kolme olivat lähes yhtä suuria ja käsittivät kukin noin kolmanneksen kaikista konkurssiyrityksistä. Ryhmät olivat:

1. *Krooniset konkurssiyritykset*. Näiden yritysten taloudellinen tilanne on heikko jo vuosia ennen konkurssia ja tilanne heikkenee voimakkaasti aina konkurssihetkeen asti. Maksukyvyttömyyden ennakoiminen ei tuota näiden yritysten osalta vaikeuksia.

2. *Akuutit konkurssiyritykset*. Näiden yritysten taloudellinen tilanne on siedettävä vielä kaksi vuotta ennen konkurssia, mutta vuotta ennen konkurssia yrityksen tila romahtaa. Konkurssin ennustaminen kaksi vuotta ennen tapahtumaa on haastavaa, mutta vuotta ennen konkurssia maksukyvyttömyydestä ei ole epäilystä.

3. *Asteittaiset konkurssiyritykset*. Näiden yritysten taloudellinen tilanne heikkenee vähitellen, mutta ei kuitenkaan kriittiseksi, ainakaan kaikilta osin. Olennaiset taloudelliset tunnusluvut eivät missään tilanteessa muutu negatiivisiksi. Yrityksen tila on heikko, mutta sen tunnistaminen ilmeisesti maksukyvyttömäksi on haastavaa.

Viimeinen konkurssiryhmä käsitti hyvin pienen määrän yrityksiä, joilla ei ollut juurikaan vierasta pääomaa ja joiden maksukykyä kuvaavat tunnusluvut

pysyivät hyvinä aivan konkurssihetkeen asti. Näitä yrityksiä voidaan kutsua *yllättäviksi konkurssiyrityksiksi*. Niiden konkurssia ei pysty ennustamaan puhtaasti taloudellisilla tunnusluvuilla, vaan kyse on poikkeavista havainnoista, joiden ennustaminen on mahdollista vain käyttämällä muuta tietoa.

Voidaan huomata, että yrityksen toimintaedellytykset ovat riippuvaisia sen taloudellisesta tilanteesta. Maksukyvyttömyys on prosessi, joka voi kestää pitkäänkin. Taloudellisia vaikeuksia ja uhkaavan maksukyvyttömyyden oireita ilmaisevat tunnusluvut heikkenevät usein systemaattisesti, jos yrityksen johto ei kykene kääntämään yrityksen suuntaa. Usein maksukyvyttömyys alkaa heikentyvästä kannattavuudesta, mikä suoraan vähentää tulorahoitusta. Tämä johtaa rahoitusrakenteen heikentymiseen ja rahoituspuskurin pienentymiseen. Jatkaessaan tällaista toimintaa yritys ylivelkaantuu, eikä toiminta voi jatkua muuten kuin yksipuolisella velanotolla. Tällöin menoja lykätään ja maksamattomat laskut kertyvät. Viimeisessä vaiheessa yritys saa maksuhäiriöitä, ennen kun se ajautuu pysyvästi maksukyvyttömäksi. (Laitinen & Laitinen 2014: 151)

Ymmärtämällä konkurssin syitä ja näiden syiden ilmenemistä yrityksessä oireina, voidaan ennakoitiin tarkoitettua mallia rakentaa toimivammaksi. Tyypillisessä tilanteessa maksukyvyttömyysprosessi on systemaattista taloudellisten tunnuslukujen heikkenemistä. Yritysjohdon pelivara pienenee prosessin edetessä ja mitä pienempi pelivara on, sen vähemmän mahdollisia toimintatapoja yrityksellä on. Tällöin myös maksukyvyttömyyden ennakointi on helpompaa, sillä kaikki yritykset noudattavat loppuvaiheessa samaa kaavaa.

Laitinen & Laitinen (2014: 157) on tilastojen perusteella ryhmitellyt kriisissä olevat yritykset kolmeen ryhmään sen mukaan, kuinka pitkällä ne ovat maksukyvyttömyysprosessissa. Ilman suhdannevaihteluita häiriöttömien yritysten tunnusluvuissa ei ole mitään yleistä suuntaa, toisin kun maksukyvyttömyysprosessissa olevilla yrityksillä, joiden tunnusluvut systemaattisesti heikkenevät. (Laitinen & Laitinen 2014: 151-152)

Uhkaavan maksukyvyttömyyden yrityksissä sijoitetun pääoman tuotto on alle 5 prosenttia, nettotulos on negatiivinen ja quick ratio on alle 0,6. Omavaraisuusaste on myös heikko ja on alle 10 prosenttia. *Todennäköisesti maksukyvyttömän* yritys toimii alle 5 prosentin omavaraisuusasteella ja

negatiivisella rahoitustuloksella sekä quick ratiolla, joka on alle 0,5. Yrityksellä on hyvin vähän pelivaraa. *Ilmeisesti maksukyvytön* yritys toimii negatiivisella oman pääoman tuottosuhteella ja omavaraisuusasteella sekä sille kertyy systemaattisesti maksamattomia laskuja. Yrityksellä ei ole lainkaan pelivaraa ja sen voidaan katsoa olevan konkurssikypsä. (Laitinen & Laitinen 2014: 157)

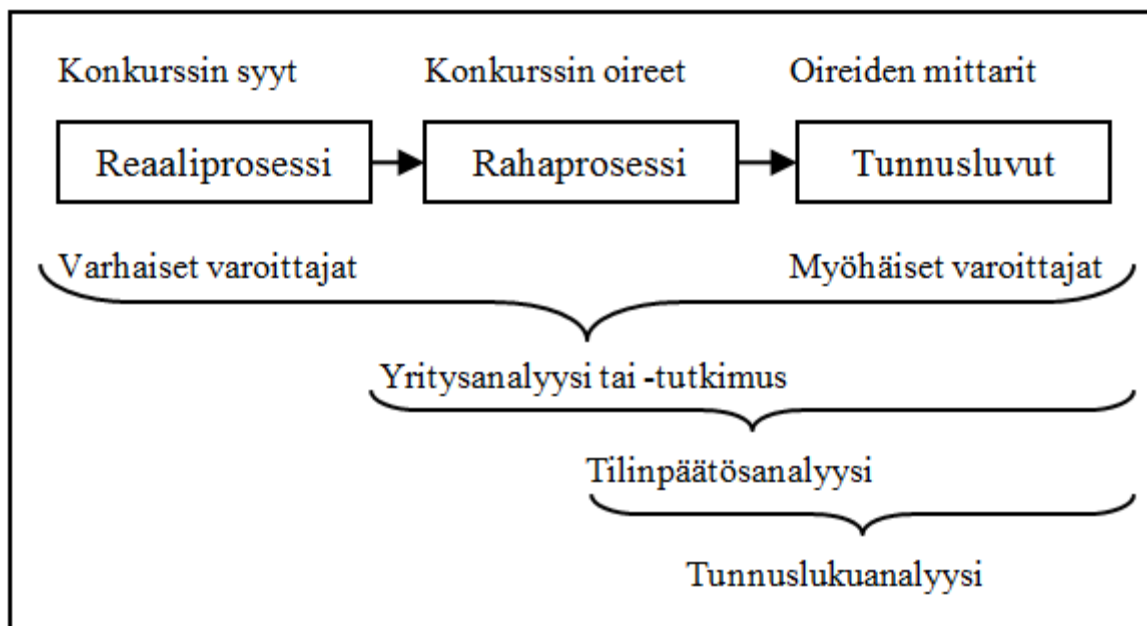
3.2. Tilinpäätösmuuttujien tulkinta

Pysyvän maksukyvyttömyyden (*Failure of the firm*) määrittelemisen laskentatoimen tutkimuksissa ei ole yksiselitteistä. Varsin usein käytetään hyväksi lainsäädännöllistä määritelmää. Edellytykset konkurssiin hakeutumiselle vaihtelevat kuitenkin maittain, mikä tarkoittaa tällä tavalla saatujen tutkimustulosten rajautumista koskemaan vain kyseistä maata. Lainsäädännöllisen konkurssimääritelmän käyttäminen helpottaa kuitenkin varsinaisen tutkimuksen tekemistä, sillä se jakaa yhtiöt selkeästi kahteen ryhmään: konkurssiyrityksiin ja ei-konkurssiyrityksiin. (Balcaen & Ooghe: 72)

Konkurssilla on aina jokin yrityksestä itsestään, yritysjohtosta tai toimintaympäristöstä johtuva syy. Näiden syiden aiheuttama kriisi näkyy yrityksen taloudessa, jos yritys ei pysty sopeutumaan siihen. Konkurssiin johtava kriisi syntyy siis yrityksen *reaaliprosessissa* ja yrityksen *raha-prosessi* ainoastaan heijastaa tätä. Yrityksen sisäiset tiedot osoittavat kriisin melko nopeasti, jolloin toimintaa on mahdollista myös oikaista nopeasti. Laskentatoimen tutkimuksessa joudutaan kuitenkin käytännössä turvautumaan ulkoisiin tietoihin, jotka ovat suppeampia kuin sisäiset. Olennaisempaa kuitenkin on, että ulkoiset tiedot julkaistaan vain vuosittain, jolloin viive syiden ilmaantumisesta oireiden havaitsemiseen voi olla niin pitkä, että korjaavia toimenpiteitä ei ole enää mahdollista toteuttaa. (Ooghe & de Prijcker 2008: 224-226)

Yrityksen kriisin arviointi voidaan jakaa *tilinpäätösanalyysiin* ja *yritysanalyysiin*. Tilinpäätösanalyysi perustuu ainoastaan yrityksen vuosittaisiin tilinpäätöstietoihin. Tällainen analyysi kohdistuu luonteensa mukaisesti kriisin oireisiin. Yritysanalyysissä käytettävissä on muitakin tietoja, jotka voivat koskea esimerkiksi yrityksen johtoa, strategiaa, markkinatilannetta, kilpailijoita yms. Tällöin voidaan puuttua myös kriisin syihin, jolloin toiminnan oikaiseminen on mahdollista. Tilinpäätösanalyysissä laaditaan usein

tunnuslukuja, joiden perustana on yrityksen tulos- ja taselaskelmat. (Laitinen & Laitinen 2004: 220-221)



Kuvio 2. Eri analyysimuodot kriisin ennustamisessa (Laitinen 1990: 157)

Viralliset tilinpäätöstiedot on oikaistava, jos tilinpäätösanalyysiä käytetään kriisin oireiden ja kriisin todennäköisyyden arvioimiseen. Positiivinen ilmiö on, että kotimaisessa kirjanpitolaissa on viime vuosina kavennettu mahdollisuuksia tehdä tilinpäätösjärjestelyitä. Tämä tarkoittaa, että viralliset tilinpäätöstiedot ovat luotettavampia kuin aikaisemmin. Heikossa taloudellisessa tilanteessa oleva yhtiö kuitenkin sortuu usein epänormaaleihin tilinpäätösjärjestelyihin, tilanteensa salaamiseksi. Nämä voivat olla joko lievästi hyvän kirjanpitotavan vastaisia tai jopa räikeitä kirjanpitorikoksia. (Laitinen & Laitinen 2004: 222-223)

Kaikkia epävarmuustekijöitä ja varsinkaan selkeitä väärinkäytöksiä ei ole mahdollista oikaista pelkästään virallisia tilinpäätöstietoja käyttämällä. Tilinpäätöksen normaalien järjestelyiden oikaiseminen on kuitenkin helpompaa. Lähtökohtana voidaan käyttää Yritystutkimusneuvottelulautakunnan (YTN) antamia ohjeita. (Laitinen & Laitinen 2004: 229) Tämä helpottaa laskentatoimen tutkimusten läpiviemistä, sillä otoksesta on mahdollista tehdä yhteismitallinen.

3.3. Ennustamismallin rakentaminen

Konkurssitutkimuksessa voi syntyä kahdenlaisia luokitteluvirheitä, kun yritysten elinkelpoisuutta arvioidaan *ex ante*. Konkurssiyritys voidaan virheellisesti luokitella elinkelpoiseksi (Tyypin I virhe) tai elinkelpoinen yritys voidaan luokitella konkurssiyritykseksi (Tyypin II virhe). (Prihti 1975:103)

Laskemalla yhteen virhetyypit saadaan selville kokonaisluokitteluvirhe. Virheiden suuruus riippuu tunnusluvulle annetusta kriittisestä arvosta. Esimerkiksi klassisessa tutkimuksessaan Beaver (1966) valitsi kriittisen arvon siten, että kokonaisluokitteluvirhe oli mahdollisimman pieni.

Eri virheiden haitat voidaan kuitenkin katsoa hyvin erilaiseksi. Vaikutusta on myös sillä, onko arvion tekijä rahoittaja vai sijoittaja. Rahoittajan näkökulmasta Tyypin I virhe on selkeästi kalliimpi kuin Tyypin II virhe, sillä lainalle saatava tuotto ei ole kuin murto-osan menetetyn pääoman arvosta. Toisaalta oman pääoman ehtoisen riskisijoittajan kannalta Tyypin II virhe voi olla kalliimpi, sillä riskisijoituksen onnistuessa saatava tuotto voi olla moninkertainen suhteessa menetetyn pääoman arvoon.

Monen tunnusluvun analyysissä tarkoituksena on sisällyttää samaan malliin useamman muuttujan informaatio yhdellä kertaa. Tällöin muodostetaan yhdistelmäluku valituista muuttujista. Tavoitteena on luoda malli, joka ennustaa yhtä muuttujaa paremmin yrityksen rahoituskriisin. Koska lopputuloksena on kuitenkin vain yksi muuttuja, voidaan sitä käyttää rahoituskriisin ennustamiseen samalla tavalla kuin yhden muuttujan mallia. (Laitinen & Laitinen 2004: 131)

Monen muuttujan mallissa ratkaisevaa on tunnuslukujen yhdistämistapa, tunnuslukujen painottaminen sekä tunnuslukujen valinta. Monen muuttujan malleja on useita erilaisia, joista selvästi käytetyin on lineaarinen erotteluanalyysi. Siinä muodostetaan erottelufunktio, joka mahdollisimman tehokkaasti erottelee kriisiyritykset ja toimivat yritykset toisistaan. Erottelufunktio muodostuu tunnuslukujen painotetusta summasta. Se tekee kuitenkin erinäisiä tilastollisia olettamuksia, jotka eivät aina pidä paikkaansa. Käytännössä lineaarinen erotteluanalyysi on joka tapauksessa osoittautunut melko hyväksi ennustusmenetelmäksi. Lisäksi se on yksinkertainen, mikä on selvä etu käytännön toiminnassa. (Ooghe & Balcaen 2007: 35-36)

Toinen vaihtoehto monen muuttujan mallin rakentamisessa on käyttää regressioanalyysiä. Tällöin lähtökohta on sama kuin lineaarisessa erotteluanalyysissä, kuitenkin siten, että toimivalle yritykselle merkitään status 1 ja kriisiyritykselle status 0. Statukselle pyritään sitten löytämään mahdollisimman hyvä selitysyhtälö, jolloin muodostuu monen muuttujan malli, jossa kertoimien painoarvot kiinnitetään eri vaiheessa kuin lineaarisessa erotteluanalyysissä. (Laitinen & Laitinen 2004: 137)

3.4. Muuttujien valinta

Ennustusmallit eivät voi toimia ilman muuttujia ja niiden valinta onkin tärkeimpiä asioita malleja rakennettaessa. Muuttujat voidaan valita joko teoreettisin tai empiirisin perustein. Teoreettisin perustein valitut muuttujat pohjautuvat käsitteelliseen tai matemaattiseen malliin konkurssiyrityksen käyttäytymisestä. Nämä muuttujat ovat otoksesta riippumattomia. Teoreettinen muuttujien valinta siis edellyttää kriisiteorian tai kriisimallin rakentamista. Muuttujat valitaan empiirisin perustein esikarsinnan jälkeen pelkästään sen perusteella kuinka tehokkaasti ne ennustavat konkurssia kyseisessä aineistossa. (Cybinski 2001: 26-27)

Beaver (1966) valitsi klassisessa tunnuslukuihin perustuvassa tutkimuksessaan muuttujat kolmella eri perusteella: a) yleisyys alan kirjallisuudessa, b) ennustamiskyky aiemmissa tutkimuksissa sekä c) kassavirtaisuus (tulomenopohjaisuus). Teoreettinen perustelu jäi kuitenkin melko vajaaksi, jolloin Beaverin voidaan katsoa käyttäneen empiiristä valitsemistapaa, tutkijoiden enemmistön tapaan.

Muuttujia valitessa suoritetaan ensin esivalinta, jossa rajataan tarkempaan tarkasteluun mukaan otettavien muuttujien määrää. Tämä tehdään yleensä aiempien tutkimusten nojalla sekä ottamalla mukaan muutama uusi, mielenkiintoiseksi koettu muuttuja. Lopullisessa valinnassa tulisi huomioida kolme seikkaa, jotta rakennettava malli olisi mahdollisimman toimiva. Ensinnäkin muuttujien tilastollisten ominaisuuksien tulee karkeasti vastata menetelmien olettamuksia. Voimakkaasti toisistaan riippuvaisia muuttujia ei kannata ottaa mukaan kuin yksi. Toiseksi useamman tunnusluvun mallissa tulee ottaa huomioon muuttujien yhteinen ennustamiskyky. Muuttujat valitaan siis osana kokonaisuutta, ei yksittäisinä. Yksin huonosti ennustava muuttuja voi

tuoda malliin kokonaisuutena merkittävän ennustuskyvyn parantumisen. Kolmas olennainen tekijä on ennustamiskyvyn aikajänne, sillä malliin otettavien muuttujien tulee kyetä ennustamaan konkurssi sekä kriisiprosessin alku- että loppuvaiheessa. Mallissa on otettava kantaa siihen, miten alku- ja loppuvaiheen ennustamiskykyä painotetaan. Tämä tehdään juuri muuttujien valinnan avulla. (Laitinen & Laitinen 2004: 169-171)

Lopullisessa valinnassa voidaan käyttää kahta tilastollista valintatapaa. *Askeltavassa menetelmässä* mallin muuttujat valitaan automaattisesti siten, että koko mallin suorituskyky paranee koko ajan. Tätä voidaan käyttää esimerkiksi regressioanalyysissä (sekä tavallisessa että logistisessa) sekä erotteluanalyysin yhteydessä. Toinen tapa valita muuttujat on käyttää hyväksi *faktorianalyysiiä*, jossa etsitään muuttujien taustalla olevia perusulottuvuuksia (ns. faktoreita). Tämä pienentää muuttujien määrää, sillä analyysi perustuu muuttujien väliseen korrelointiin, jolloin keskenään korreloivat muuttujat asetetaan samalla ulottuvuudelle. Etuna on, että valittujen muuttujien välillä ei ole voimakasta keskinäisriippuvuutta. (Laitinen & Laitinen 2004: 172-173)

Käytännössä eri tutkimuksissa on käytetty runsaasti eri muuttujia. Siten yleisesti hyväksyttyä teoreettista viitekehystä muuttujien valinnalle ei ole olemassa. Lisäksi eri yritystyypeille (koko, sijainti, toimiala) saattavat sopia paremmin toisenlaiset muuttujat kuin muille yhtiöille. Perusulottuvuuksia ei kuitenkaan ole montaa erilaista. Vaikka eri tutkimuksissa on käytetty eri muuttujia, ovat monet muuttujista kuitenkin läheistä sukua toisilleen. (Ohlson 1980: 110, Cybinski 2001: 39-40, Wu 2010: 2373)

Tunnuslukuista on tehty useita eri muunnelmia ja näiden muunnelmien merkitystä ennustamisessa on testattu. Esimerkkejä ovat suoriteperusteisten tunnuslukujen kassavirtaversiot sekä inflaatiolla ja leasingilla oikaistut tunnusluvut. (Grice & Dugan 2001: 153)

Tunnuslukujen lisäksi ennustusmalleissa voidaan käyttää myös muita muuttujia. Ne voivat olla sekä taloudellisia että ei-taloudellisia, esimerkiksi yrityksen koko ja kasvuvauhti, dekompositiomittarit (jotka kuvaavat muutoksia yrityksen taseen ja tuloslaskelman rakenteessa), toimialamuuttujat, johdon vaihtuminen ja makrotaloudelliset muuttujat. Käytännön riskien arvioinnissa hyödynnetään laajalti näitä muita tietoja, joten niiden painoarvo on suurempi

kuin puhtaasti akateemisesta tutkimuksesta ilmenee. (Laitinen & Laitinen 2004: 178-180)

3.5. Eri tasemuuttujamenetelmien välinen vertailu

Tutkimalla samaa aineistoa useammalla konkurssinennustamismenetelmällä voidaan tehdä päätelmiä mallien paremmuusjärjestyksestä. (ks. Laitinen & Kankaanpää 1997) On kuitenkin syytä muistaa, että tällöinkin aineiston ja otoksen merkitys voi olla suuri. Vertailtavassa tutkimuksessa samoja malleja tulisi siis verrata eri aineistoilla ja otoksilla, jolloin voitaisiin tehdä varmempia johtopäätöksiä mallien tosiasiallisesta ennustamiskyvystä. Voidaan perustellusti katsoa, että konkurssinennustamismallin perimmäinen hyödyllisyys punnitaan empiirisesti. Teoreettinen malli ei ole hyödyllinen, mikäli se ei pysty ennustamaan konkursseja. (Ooghe & Balcaen 2007: 62)

Konkurssin ennustamisessa on viime vuosina kiinnitetty entistä enemmän huomiota eri mallien tosiasialliseen kykyyn ennustaa konkursseja *ex ante*. Erityisesti useat empiiriset mallit ovat erittäin riippuvaisia omasta otoksestaan. Mallit siis ennustavat hyvin konkursseja siinä otoksessa, jolla malleja on testattu. Mallien ennustamiskyky ei kuitenkaan välttämättä ole kovin hyvä laajemmin, jolloin niiden hyödyllisyyskin on kyseenalainen. (Aziz & Dar 2006: 19-21)

Empiirisesti toteutettujen tutkimusten ennustuskyky paranee merkittävästi, jos otos jaetaan kahteen osaan siten, että yhdellä osalla estimoidaan mallin parametrit ja toisella osalla testataan näin viritetty yhdistelmäluke. Ainoastaan vajaassa puolessa tutkimuksissa oli kuitenkin toimittu näin. (Aziz & Dar 2006: 23) Mallin tosiasiallisen ennustamiskyvyn arviointi on mielekkäämpää tehdä optimoimalla se yhdellä aineistolla ja suorittamalla varsinainen testi täysin eri aineistolla. Näin vältetään otoksesta johtuvat yli- ja alipainotukset. (Grice & Dugan 2001: 153-154) Toinen merkittävä ongelma konkurssin ennustamisessa on käytettävissä olevien otosten suppeus. Tähän on käytännössä mahdotonta löytää ratkaisua, vaikka se heikentää ennustustulosten tilastollista luotettavuutta. (Aziz & Dar 2006: 23)

Aziz & Dar (2006) ovat tehneet laajan katsauksen eri ennustamismenetelmistä ja niiden historiallisesta ennustamistarkkuudesta eri tutkimuksissa

tarkastelemalla 89 eri konkurssinennustamistutkimuksen tuloksia. Selkeästi suosituimpia ovat olleet tilastolliset mallit. Erityisesti useamman tunnusluvun mallit sekä logit-mallit vastaavat merkittävästä osasta konkurssitutkimuksessa käytetyistä malleista. Seuraavaksi suosituimpia malleja ovat neuraaliverkot ja rekursiivinen osittaminen. Teoreettisia malleja on käytetty melko vähän, suosituin on taseen dekompositiomittareita hyväksi käyttävät mallit. (Aziz & Dar 2006: 23)

Aziz & Darin vertailututkimuksen mukaan eri mallien ennustamiskyky on melko samanlainen. Kaikki mallit onnistuvat myös ennustamaan tulevan konkurssin yli 80 prosentin ja melkein kaikki mallit yli 85 prosentin tarkkuudella. Mikään malli ei siis ole selkeästi ylivertainen tai alisuoriutuja vuoden aikaperspektiivillä. Mallien ennustustarkkuutta vertailtaessa huomataan, että koneoppimismallit ovat kaikista parhaimpia ja tilastolliset mallit huonoimpia ennustajia. Erot ovat kuitenkin erittäin pieniä. On kuitenkin syytä huomioida, että vuosi ennen konkurssia on hyvin lyhyt aika, ja kaikkien mallien suorituskky heikkenee merkittävästi pidemmän aikajakson ennustuksissa. (Aziz & Dar 2006: 26)

Ennustamistarkkuus ei ole ainoa tapa arvioida konkurssinennustamismallien suhteellista paremmuutta. Huomioitaessa mallien keskihajonta, näyttäytyvät suosituimmat mallit (useamman muuttujan mallit ja logit-mallit) parhaimpina. Niillä saadut tulokset ovat siis varmempia, vaikkakin ennustustarkkuus ei ole aivan yhtä hyvä kuin muissa malleissa. (Aziz & Dar 2006: 27)

Ennustamistarkkuuden arvioinnissa voidaan tarkastella myös eri virhetyyppien suhteellisia osuuksia. Konkurssin ennustamisella on suuri merkitys luotonannossa, jossa halutaan kaikista eniten painottaa tyypin I virheiden välttelyä eli konkurssiyrityksen luokittelua terveeksi. Parhaat mallit tässä mielessä ovat useamman muuttujan mallit, logit-mallit, neuraaliverkot sekä dekompositiomallit. (Aziz & Dar 2006: 27) Tyypin II virheluokituksilla katsottuna mallit erosivat toisistaan huomattavasti enemmän kuin mitattuna tyypin I virheillä. Parhaat mallit olivat neuraaliverkot ja lineaarinen todennäköisyysmalli. Myös useamman tunnusluvun mallit ja logit-mallit olivat tässä vertailussa melko tarkkoja. (Aziz & Dar 2006: 28)

Laitinen & Kankaanpää (1997) ovat tutkineet yleisimpien konkurssinennustamismenetelmien ennustamiskykyä yhtenäisellä aineistolla.

Aineisto koostui vuosina 1986–1989 konkurssiin menneistä suomalaisyrityksistä. Tutkittavia malleja olivat yhden muuttujan erotteluanalyysi (kolmella eri muuttujalla), logit-malli, rekursiivinen osittaminen, eloonjäämisanalyysi, neuraaliverkot sekä HIP-malli.

Puhtaassa ex post analyysissä neuraaliverkko sekä rekursiivinen osittaminen olivat selkeästi parhaat menetelmät sekä yksi, kaksi että kolme vuotta ennen konkurssia. Yhden muuttujan malli oli heikoin kaikkina vuosina. Erot olivat tilastollisesti merkittäviä. (Laitinen & Kankaanpää 1997: 48-49)

Ex ante-vertailussa malleja optimoitiin siten, että otos jaettiin kahtia ja mallit optimoitiin yhdellä osaotoksella. Tämän jälkeen ennustuskykyä testattiin toisella osaotoksella. Tässä vertailussa paras malli ei ollut yksiselitteinen. Paras malli vuosi ennen konkurssia oli logit-malli, mutta kaksi ja kolme vuotta ennen konkurssia eloonjäämisanalyysi oli paras malli. Logit-analyysin ennustustarkkuus tippui nopeasti kun konkurssiin oli aikaa kolme vuotta. Neuraaliverkot toimivat myös tässä vertailussa melko hyvin ja yhden muuttujan malli suhteellisen luotettavasti vuosi ja kaksi vuotta ennen konkurssia. (Laitinen & Kankaanpää 1997: 50-51)

Sekä ex ante että ex post vertailussa ei kuitenkaan löytynyt tilastollisesti merkitseviä (95 %:n merkitsevyystasolla) eroja kuin yhdessä vertailussa mallien välillä. (Laitinen & Kankaanpää 1997: 52-53) Tämä tarkoittaa käytännössä, että yllä esitetyt mallien väliset eroavaisuudet eivät ole selviä ja voivat johtua ainoastaan satunnaisvaihteluista. Tätä tulkintaa tukee myös Aziz & Darin (2006) saama tulos, jossa eri mallit ennustavat melko yhteneväisesti konkurssia vuoden horisontilla. Ei ole osoitettu, että tilanne olisi eri pidemmällä aikavälillä.

Yksinkertainen monen muuttujan malli pystyy yleensä ennustamaan konkurssia vähintäänkin 90 % niin hyvin kuin monimutkaisempi malli. (Dakovic ym. 2010: 1744; Balcaen & Ooghe 2006: 81). Voidaan siis kysyä, tulisiko pääsääntöisesti käyttää tällaisia malleja, sillä merkittävästi parempia malleja ei laajasta tutkimushistoriasta huolimatta ole edelleenkään löytynyt.

3.6. Tasemuuttujaennustamisen ongelmat

Ennustamisessa käytettävissä malleissa ilmenee myös ongelmia. Mallit toimivat joillakin otoksilla erittäin hyvin, mutta eivät pysty ennustamaan rahoituskriisiä toisilla otoksilla. Niiden arvo liiketoiminnan sijoitus- ja lainauspäätösten tukena on näin ollen kyseenalainen. Ennustamismenetelmillä on heikkoutensa ja nykyisen tietämyksen valossa niiden asettaminen paremmuusjärjestykseen ei ole mahdollista millään yleisesti hyväksytyllä ja yksiselitteisellä mittarilla.

Monille luottopäätösten kanssa työskenteleville nykyisten mallien n. 85 %:n ennustustarkkuus ei ole riittävä. (Wu 2010: 2371) Tarve tulevan rahoituskriisin ennustamiselle on kuitenkin jatkuva, eikä se tule tulevaisuudessa ainakaan vähenemään. Aikaisemmat epäselvät tulokset eivät siis tee tulevaa tutkimusta turhaksi, vaan kritiikistä tulisi ottaa oppia ja pyrkiä löytämään ennustamisen kannalta olennaiset tekijät.

Konkurssin ennustamisessa tulee ottaa huomioon myös se, että kaikkia menetelmiä ei todennäköisesti voida käyttää kaikilla aineistolla. Hyvä esimerkki on Altmanin Z-malli, joka kehitettiin suurten amerikkalaisten pörssiyhtiöiden rahoitusriskin ennustamiseen. Mallien käyttö eurooppalaisten pk-yritysten konkurssiriskin arvioimiseen onkin hyvin kyseenalaista. Mallit ovat periaatteessa yleismaailmallisia, mutta erityisesti empiiriset mallit on optimoitu sille aineistolle, johon ne perustuvat. (Balcaen & Ooghe 2006: 75-76; Dimitros ym. 1996: 495; Grice & Dugan 2001: 164)

Boritz, Kennedy & Sun (2007) ovat arvioineet Altmanin (1968) ja Ohlsonin (1980) mallien ennustamiskykyä kanadalaisissa yrityksissä. Arviointi tehtiin malleille tyyppin I ja tyyppin II virheiden sekä kokonaisluokittelutarkkuuden perusteella. Tutkimus arvioi siten kuinka hyvin mallit luokittelevat yritykset toimiviin ja konkurssiyrityksiin. Ennustamiskyvyn todettiin olevan selkeästi huonompi kuin alkuperäisissä tutkimuksissa. Tämä saattaa johtua siitä, että estimoinnissa ja luokittelussa käytetty aineisto on eri kuin aineisto, johon malleja tosiasiallisesti käytetään. Tutkimus antaa viitteitä siitä, että yleispätevän mallin kehittäminen voi olla hankalaa.

Tasemuuttujien avulla toteutettavassa konkurssinennustamisessa on muutamia perustavanlaatuisia ongelmia, jotka tulee ottaa huomioon malleja rakennettaessa sekä tuloksia tulkittaessa: (Balcaen & Ooghe 2006: 85):

1. Konkurssin määritelmän sattumanvaraisuus ja mielivaltaisuus
2. Tasetietojen epävarmuus sekä muuttujien välisten riippuvaisuuksien muuttuminen ajan myötä
3. Otoksen valinta. Otokseen valitaan yleensä liikaa konkurssiyrityksiä, jotta tutkittavaksi saataisiin tilastollisesti käyttökelpoinen määrä yrityksiä
4. Optimisaatiokriteerin sattumanvarainen valinta
5. Aikaulottuvuuden huomioimatta jättäminen
6. Alustavien muuttujien valinta on vaillinaista
7. Muuttujien oletetaan olevan täysin lineaarisia
8. Vuosittaisen tasetiedon käyttäminen
9. Yhden muuttujan mallissa ei pystytä huomaamaan kriisin moniulotteisuutta

Tutkimuksissa on kuitenkin pyritty parantamaan ennustamismallien tarkkuutta usein eri tavoin. Ensinnäkin mallien spesifikaatiota on parannettu. Muuttujiin on myös kiinnitetty huomiota tekemällä niihin oikaisuja. Lisäksi taloudellisten muuttujien rinnalle on otettu myös muita, kvalitatiivisia muuttujia. (Laitinen & Kankaanpää 1997: 57)

Ennustamismallien ennustuskyky heikkenee kun konkurssiin on pidempi aika kuin 3 vuotta ja 3-5 vuotta ennen maksukyvyttömyyttä ennustustarkkuus on ainoastaan 50–60 prosenttia, mitä voidaan pitää suhteellisen heikkona. Tämä johtuu siitä, että yritykset käyttävät tässä vaiheessa jäljellä olevan pelivaransa monella eri tavalla, siten että moni maksukyvyttömyysprosessin alussa oleva yritys pystyy vielä välttämään pysyvän maksukyvyttömyyden. Tämän takia ennustamismallien ennustamiskykyä kehitetään pitäen silmällä aikajaksoa 1-3 vuotta ennen konkurssia. (Laitinen & Laitinen 2014: 158-159)

3.7. Yhteenveto ja tutkimuksen hypoteesit

Tarve uusilla aineistoilla tehtäville empiricalähtöisille tutkimuksille on edellä mainitun mukaisesti jatkuva ja käytetyimpien mallien vertaaminen keskenään on aina ajankohtaista. Aiemmissa tutkimuksissa on käytetty melko vanhaa aineistoa, eivätkä esimerkiksi otoksen toimialajakaumat enää vastaa nykyisten yritysten toimialajakaumaa. Tästä syystä on perusteltua optimoida mallit

uudella aineistolla. (Boritz, Kennedy & Sun 2007: 157) Kun samaa aineistoa analysoidaan eri ennustamismenetelmillä, voidaan myös poistaa otannan vaikutus vertailutuloksiin. Lisäksi voidaan tarkastella pitävätkö aiemmin tutkimuksissa löydetty viitteet mallien ennustamiskyvystä paikkaansa.

Konkurssin ennustaminen on ollut akateemisesti suosittu tutkimussuunta jo 40 vuotta. Mitään yleisesti hyväksyttyä teoriaa konkurssista liiketaloudellisena prosessina ei kuitenkaan vielä ole löytynyt. Suurin osa tutkimuksesta onkin ollut puhtaasti empiiristä, eikä mallia, joka yksiselitteisesti pystyisi ennustamaan yritysten tulevaa rahoituskriisiä ole myöskään kyetty luomaan. (Laitinen & Kankaanpää 1997: 57, 60) Kaikki mallit ennustavat konkurssia melko hyvin, joten konsensuksen saavuttaminen ei välttämättä ole edes merkityksellistä. (Aziz & Dar 2006: 28)

Konkurssimenetelmien välisiä vertailuja samalla aineistolla on tehty aiemminkin (mm. Laitinen & Kankaanpää 1997). Suomalaiset tilinpäätöskäytännöt ovat kuitenkin yhdenmukaistuneet merkittävästi viimeisen kahdenkymmenen vuoden aikana ja varsinkin harkinnanvaraiset tilinpäätöskirjaukset ovat vähentyneet. Tämän takia voidaan perustellusti olettaa että aineistossa olevat eroavaisuudet yritysten välillä ilmentävät nykyisin aina todellisia eroja, eivätkä ainoastaan tilinpäätöskäytännöistä johtuvia eroja. Aineisto on siis nykyisin homogeenisempää, mikä puoltaa uuden vertailevan tutkimuksen tarvetta.

Aiemmissa tutkimuksissa (kts. mm. Aziz & Dar (2006) sekä Laitinen & Kankaanpää (1997)) on löydetty vain satunnaisesti tilastollisesti merkitseviä eroja eri mallien ennustuskäytännössä, joten tutkimuksen hypoteesiksi on johdettu seuraava:

H₁: Eri konkurssinennustamismenetelmien välillä ei ole tilastollisesti merkitsevää eroa

4. TUTKIMUKSEN AINEISTO JA MENETELMÄ

Tutkielman tarkoituksena on vertailla yleisimpien konkurssin ennustamisessa käytössä olevien menetelmien luokittelukykyä. Menetelmien suoriutumista verrataan samalla aineistolla. Aineistona tutkimuksessa ovat suomalaiset vuosina 2009 – 2014 konkurssiin menneet yritykset sekä vastaavana ajankohtana toiminnassa olleet vertailuyritykset, joista kummastakin on ollut saatavilla tarvittavat tilinpäätöstiedot.

4.1. Tutkimusaineisto ja rajaukset

Tutkimuksen alkuperäiseen otokseen on valittu kaikki vuosina 2009 – 2014 konkurssiin haetut suomalaiset osakeyhtiöt joita löytyi kaikkiaan 2112 kappaletta. Konkurssiin hakeminen on yleensä aina osoitus vakavasta maksuhäiriöstä, jolloin tapahtumaa voidaan pitää erottavana tekijänä maksukykyisten ja maksukyvyttömien yritysten välillä. Vuoden 2014 lopussa toimivia osakeyhtiömuotoisia vertailuyrityksiä on haettu satunnaisotoksella 3056 kappaletta. Vertailuyritysten lukumäärä on valikoitunut sillä perusteella, että tutkimuksessa halutaan hieman enemmän toimivia yrityksiä kuin konkurssiyrityksiä. Lisäksi toimivien yritysten tilinpäätösmuuttujista arvioitiin saatavan kattavammin tietoa, jolloin niitä karsiutuu myöhemmässä tutkimusvaiheessa vähemmän kuin konkurssiyrityksiä. Tutkimuksessa on pyritty mahdollisimman laajaan otokseen, jotta eri ennustamismenetelmien luokittelukykyvystä saataisiin tilastollisesti merkitsevää tietoa.

Yritysten haku on tehty Orbis Europe -tietokannasta. Tiedot otokseen valittujen yritysten tunnusluvuista on haettu Suomen Asiakastiedon hallinnoimasta Voitto+ – tietokannasta. Alkuperäisestä otoksesta on karsittu yritykset, joista ei ollut saatavilla tilinpäätöstietoja kolmen viimeisen vuoden ajalta. Lisäksi karsittiin ne yritykset, joiden tilinpäätöstiedot olivat vaillinaisia koska täydellisiä tietoja tutkimukseen valituista tunnusluvuista ei ollut saatavilla.

Tutkimuksen lopullisessa aineistossa on 4096 yritystä. Näistä 2534 on toimivia yrityksiä ja 1562 on konkurssiin haettuja yhtiöitä. Tutkimus on rajattu koskemaan ainoastaan osakeyhtiöitä, sillä niistä on saatavilla tilinpäätöstietoja selvästi henkilöyhtiöitä ja yksityisliikkeitä laajemmin. Osakeyhtiöitä haetaan

myös konkurssiin useammin kuin muita yhtiömuotoja. Varsinaiseen tutkimusaineistoon päätyi siis 74 % kaikista ajanjakson konkurssiyrityksistä.

4.2. Ennustamiskyvyn mittarit

Tutkielmassa selvitetään, miten yleisesti käytössä olevat konkurssinennustamismenetelmät suoriutuvat kun niiden ennustamiskykyä arvioidaan samalla aineistolla. Menetelmien ennustuskykyä verrataan kolmena vuonna ennen konkurssia siten, että jokainen menetelmä jaottelee estimointiaineiston yritykset joko toimiviksi tai konkurssiyrityksiksi yhtenä, kahtena sekä kolmena vuonna ennen konkurssia.

Menetelmien ennustamiskyvyn vertailussa käytetään kymmenkertaista ristiinvalidointia. Menetelmässä aineisto jaetaan kymmeneen tasasuuruiseen osaan. Jokainen osa sisältää oikean suhteellisen määrän konkurssiyrityksiä ja toimivia yrityksiä. Tämän jälkeen yhdeksän osaa käytetään mallin estimointiin ja yhtä osaa validointiin. Tämä toistetaan kymmenen kertaa ja jokainen osa toimii vuorotellen validointiaineistona. Näistä ajoista lasketaan sitten keskiarvot, jotka kuvaavat mallin ennustamiskykyä. Kymmenkertainen ristiinvalidointi toistetaan vielä kymmenen kertaa, jotta mallien ennustamiskyvyn keskihajonta pienenee. Tämä myös helpottaa tilastollisesti merkittävien erojen löytämistä. (Witten & Frank 2006: 150-151)

Menetelmien ennustamiskykyä arvioidaan sekä AUC-arvolla (Area Under the Curve) että luokitteluvirheiden perusteella. Näistä AUC-arvoa voidaan pitää parempana mittaajana mallin ennustamiskyvystä, sillä se ei perustu yhteen kynnysarvoon vaan ottaa huomioon kaikki mahdolliset kynnysarvot. (Forsström 1995) Tällöin satunnaisen poikkileikkauksen tuoma satunnainen hyöty tai haitta voidaan eliminoida.

AUC-arvo pohjautuu ROC-käyrään (Receiver Operating Characteristic). Käyrän vaaka-akseli kuvaa tunnusluvun arvon kasvaessa niiden maksuhäiriöttömien yritysten osuutta, joiden tunnusluvun arvo jää kyseisen arvon alle. Pystyakseli taas osoittaa tunnusluvun arvon kasvaessa niiden konkurssiyritysten osuutta, joiden tunnusluvun arvo jää arvon alle. Kun ROC-käyrä piirretään kokonaisuudessaan, mittaa sen alle jäävä alue luokittelun tarkkuutta. Täydellisessä mallissa AUC-arvo on yksi ja täysin satunnaisessa mallissa arvo

on 0,5. (Laitinen & Laitinen 2014: 170) Yli 0,7 arvoa voidaan pitää merkinä hyvästä erottelukyvystä. (Hosmer & Lemeshow 2000)

Eri menetelmien saamia AUC-arvoja ja luokitteluvirheitä verrataan kaksisuuntaisella kahden riippuvan otoksen t-testillä. Nollahypoteesina on, että AUC-arvojen ja luokitteluvirheiden keskiarvot ovat samansuuruiset ja vastahypoteesi, että keskiarvot eroavat toisistaan. Tilastollisesti merkitseviä eroja etsitään 1 %, 5 % ja 10 % merkitsevyysasteilla. Kahden riippuvan otoksen t-testiä voidaan käyttää sillä menetelmät ennakoivat konkurssia samalla aineistolla (Witten & Frank 2006: 154).

4.3. Tunnusluvut

Aineistoon on valittu seitsemän tunnuslukua, jotka kuvaavat yhtiön maksukykyä, vakavaraisuutta ja kannattavuutta. Tunnuksien valintaan on vaikuttanut Laitinen & Laitinen (2004) esittelemä terveyskolmio, jonka kustakin osa-alueesta on valittu 2-3 yleistä tunnuslukua. Tunnuksien valinnassa on otettu huomioon erityisesti tunnuksien erottelukyky aiempien tutkimusten perusteella. (Laitinen (1990), Laitinen & Kankaanpää (1997)) Aineistossa saatavilla olevat tunnusluvut ovat myös merkittävästi vaikuttaneet tunnuksien valintaan. Taulukossa 1 on esitetty tutkimukseen valitut tunnusluvut.

Taulukko 1. Tutkimukseen valitut tunnusluvut

Taloudellinen toimintaedellytys	Tunnusluku
Kannattavuus	Käyttökate-% Liikevoitto-% Sijoitetun pääoman tuotto-%
Maksuvalmius	Quick ratio Current ratio
Vakavaraisuus	Omavaraisuusaste Net gearing

Tutkimukseen valittujen tunnuslukujen laskentatapa perustuu Suomen Asiakastiedon Voitto+ -tietokannan laskentatapaan, jota esitellään alla.

Käyttökate kertoo yrityksen liiketoiminnastaan saaman tuloksen ennen poistoja ja rahoituseriä. Käyttökateprosentti suhteuttaa käyttökateen yrityksen liikevaihtoon. Käyttökateprosentti ei sisällä lainkaan tase-eriä, vaan ainoastaan tuloslaskelman eriä. Se ei siis ole vertailukelpoinen eri toimialojen välillä ja myös saman toimialan yritysten osalta vertailukelpoisuus kärsii sillä tunnusluku käsittelee yritykset eri tavalla riippuen siitä ovatko ne vuokranneet kalustonsa vai omistavatko ne sen itse. (Yritystutkimus 2011: 60-61)

$$(1) \quad \text{Käyttökate} - \% = \frac{\text{Käyttökate}}{\text{Liikevaihto}} \times 100$$

Toinen tuloslaskelmaan perustuva tunnusluku on liikevoitto, joka kertoo kuinka paljon liiketoiminnan tuotoista on jäljellä kattamaan rahoituskulut ja verot. Liikevoittoprosentti suhteuttaa liiketuloksen liikevaihtoon. Vertailukelpoisuus toimialan sisällä on hyvä, mutta eri toimialojen liikevoittoprosentit saattavat kuitenkin erota toisistaan. (Niskanen & Niskanen 2003: 112-113)

$$(2) \quad \text{Liikevoitto} - \% = \frac{\text{Liiketoiminnan tulos}}{\text{Liikevaihto}} \times 100$$

Sijoitetun pääoman tuotto on yksi käytetyimmistä tunnusluvuista. Siinä jakajana on liikevaihdon sijasta omistajien ja velkojien yritykseen sijoittama pääoma, jolle vaaditaan tuottoa. Vertailukelpoisuus toimialojen välillä on melko hyvä. Sijoitetun pääoman määrä lasketaan Yritystutkimuksen (2011) kaavan mukaisesti kuluvan ja edellisen vuoden keskiarvona. (Niskanen & Niskanen 2003: 115, Yritystutkimus 2011: 65)

$$(3) \quad \text{Sij. po. tuotto} - \% = \frac{\text{tulos ennen satunnaisia eriä + vieraan pääoman kulut (12 kk)}}{(\text{taseen loppusumma} - \text{korottomat velat}) / 2} \times 100$$

Maksuvalmiuden tunnusluvuista quick ratio mittaa lyhytaikaista maksukykyä, sillä yrityksen likvidiksi omaisuudeksi hyväksytään ainoastaan hyvin nopeasti realisoitavissa oleva rahoitusomaisuus. Tunnusluvun katsotaan olevan hyvällä tasolla jos se on yli yhden, jolloin rahoitusomaisuus riittää kattamaan lyhytaikaiset velat, joskin toimialakohtaisia eroja on. (Niskanen & Niskanen 2003: 120)

$$(4) \quad \text{Quick ratio} = \frac{\text{rahoitusomaisuus}}{\text{lyhytaikaiset velat} - \text{saadut ennakot}}$$

Current ration tarkasteluperspektiivi on pidempi kuin quick ratiassa, sillä yrityksen likvideihin varoihin hyväksytään myös vaihto-omaisuus. Sen ajatellaan olevan melko helposti realisoitavissa, joskin omaisuuden arvostamisessa piilee riskejä varsinkin maksukyvyttömyyden uhkaamissa yrityksissä. Molemmat tutkimuksessa käytetyt maksukykyä mittaavat tunnusluvut mittaavat ainoastaan staattista maksukykyä. (Yritystutkimus 2011: 70-71)

$$(5) \quad \textit{Current ratio} = \frac{\text{rahoitusomaisuus} + \text{vaihto-omaisuus}}{\text{lyhytaikaiset velat}}$$

Vakavaraisuuden mittarina omavaraisuusaste mittaa yrityksen kykyä selviytyä sitoumuksistaan pitkällä aikavälillä. Se mittaa yksinkertaisesti yrityksen oman pääoman osuutta koko taseen loppusummasta. (Yritystutkimus 2011: 66) Konkurssin ennakkoinnissa omavaraisuusaste on selkeästi käyttökelpoisin tunnusluku, joka selittää suuren osan yrityksen konkurssiuhasta. (Laitinen & Laitinen 2014: 172)

$$(6) \quad \textit{Omavaraisuusaste} = \frac{\text{oma pääoma} + \text{varaukset}}{\text{taseen loppusumma} - \text{saadut ennakot}} \times 100$$

Net gearing (nettovelkaantumisaste) mittaa korollisen vieraan pääoman osuutta koko pääomasta. Hyvänä arvona voidaan pitää alle yhtä. Tunnusluku kuvaa sellaista teoreettista tilannetta, jossa yritys käyttäisi kaiken likvidin omaisuutensa korollisten velkojensa lyhentämiseen. Hyvänä puolena tunnusluvussa on riippumattomuus toimialasta. (Niskanen & Niskanen 2003: 133, Suomen Asiakastieto)

$$(7) \quad \textit{Net gearing} = \frac{\text{korollinen vieras pääoma} - \text{rahat ja rahoitusarvopaperit}}{\text{oma pääoma}}$$

Tunnuslukujen laskentatavan takia nimittäjän pieni arvo saattaa johtaa tunnusluvun arvon äärimmäisyyteen, mikä saattaa heikentää joidenkin ennustamismenetelmien ennustamiskykyä. Tämän takia aineistoon on tehty poikkeavien havaintojen oikaisu (ns. Winsoring), jossa 2 % alittavat ja 98 % ylittävät havainnot trimmattiin vastaamaan 2 % ja 98 % havaintoa. Oikaisuutasoon 2 % päädyttiin koska pienemmällä trimmauksella poikkeavia havaintoja olisi jäänyt merkittävästi lopulliseen aineistoon.

Tunnuslukujen välisiä eroja arvioidaan niiden keskiarvoihin perustuen Mann-Whitneyn U-testillä (myöh. *U-testi*). Sillä voidaan selvittää tunnuslukujen keskiarvojen tilastollisesti merkitseviä eroja toimivien yritysten ja

konkurssiyritysten välillä. Testi sopii hyvin arvioimaan aineistoa, jossa muuttujat eivät ole normaalijakautuneita, sillä konkurssin ennustamisessa käytettävät tunnusluvut ovat harvoin normaalijakautuneita

4.4. Muuttujien esivalinta

Tutkimuksessa arvioidaan useampien mallien ennustamiskykyä samalla aineistolla. Eri muuttujien mukaanotto ja poisjättäminen haluttiin tehdä riippumattomasti arvioitavista malleista, sillä käytettäessä tiettyä menetelmää esivalinnassa saattaa se suosia samaista menetelmää myös lopullisessa arvioinnissa. Erityisesti koneoppimiseen perustuvat menetelmät ovat lisäksi herkkiä turhille sekä keskenään vahvasti korreloiville muuttujille. (Witten & Frank 2006: 287) Tämän takia muuttujien esivalinnassa käytettiin yksinkertaista korrelaatioon perustuvaa muuttujavalintaa, joka pyrkii löytämään ne muuttujat jotka korreloivat vahvasti konkurssiin ajautumisen kanssa mutta joiden keskinäinen korrelaatio on pientä. (Hall 1999: 69-73)

Muuttujien esivalinnassa käytettiin seuraavaa kaavaa:

$$(8) \quad M_S = \frac{krcf}{\sqrt{k+k(k-1)rff}}$$

missä M_S on tietyn muuttujajoukon S hyvyys kun se sisältää k muuttujaa, rcf on muuttujajoukon S :n korrelaation moodi suhteessa mitattavaan muuttujaan ja rff on muuttujajoukon S keskinäinen korrelaatio. (Hall 1999: 69-70). Kaikkien eri muuttujaryhmien kokoonpanot käydään läpi ja esivalinnan läpäiset se kokoonpano, joka saa suurimman testiarvon M_S .

4.5. Tutkimuksessa verrattavat menetelmät

Aikaisemmassa tutkimuksessa useimmin käytetyt ennustamismenetelmät otettiin mukaan tutkimukseen (kts jakso 2). Lisäksi haluttiin verrata suosittujen menetelmien suorituskykyä muutamiin yleisiin koneoppimismenetelmiin, joita ei ole aiemmin käytetty laajalti akateemisessa tutkimuksessa konkurssin ennustamiseen. Tutkimukseen valikoitujen koneoppimismenetelmien haluttiin kuitenkin olevan laajalti käytössä muissa yhteyksissä, jotta niiden vertailu perinteisiin malleihin olisi mielekästä. Valinta on tehty sen perusteella mitkä

koneoppimismallit ovat olleet laajassa käytössä tutkimuksessa käytetyn WEKA-ohjelman opetusmateriaaleissa. Taulukossa 2 on esitetty tutkimuksessa käytetyt menetelmät:

Taulukko 2. Tutkimuksessa verratut menetelmät

Yleiset ennustusmenetelmät	Uudet koneoppimismenetelmät
Lineaarinen erotteluanalyysi Logistinen regressio Päätöspuu (J48) Neuraaliverkko (Multilayer Perceptron)	Bagging Random Forest Boosting,

Lineaarinen erotteluanalyysi on monen muuttujan analyysi, jolla konkurssinennustaminen alkoi ja joka sittemmin on ollut yleisessä käytössä. Analyysissä muodostetaan erottelufunktio tunnuslukujen painotetusta summasta ja painotukset valitaan siten että erottelu toimivien ja konkurssiyritysten välillä on mahdollisimman hyvä. Funktio on seuraavanlainen: (Laitinen & Laitinen 2004: 133)

$$(9) \quad Z = a_1 * X_1 + a_2 * X_2 + \dots + a_n * X_n$$

missä Z on erottelufunktion arvo, X_i tunnusluvun i arvo ja a_i samaisen tunnusluvun painoarvo. Arvioitavalle yritykselle lasketaan siis Z-arvo, ja sitä verrataan kriittiseen arvoon jotta voidaan päättää kuuluuko yritys toimivien vai konkurssiyritysten joukkoon. (Laitinen & Laitinen 2004: 133)

Erotteluanalyysin käytön oletuksena on, että tunnuslukujen hajonnat ja kovarianssit ovat yhtä suuret ja että tunnusluvut ovat multinormaalisti jakautuneet. Nämä oletukset eivät usein pidä paikkaansa konkurssin ennustamisessa, mikä heikentää erotteluanalyysin käyttöarvoa. (Laitinen & Laitinen 2004: 135-136)

Logistinen regressioanalyysi soveltuu hyvin konkurssin ennustamiseen ja se onkin suosituimpia menetelmiä. Konkurssi mielletään binaariseksi tapahtumaksi eli se joko tapahtuu (=1) tai ei tapahdu (=0). Logistinen regressioanalyysi perustuu lineaarisen erotteluanalyysin teoreettiseen taustaan ja myös siinä käytetään hyväksi painotettua erottelufunktiota. Logistisessa analyysissä riippuvainen muuttuja on kuitenkin todennäköisyys

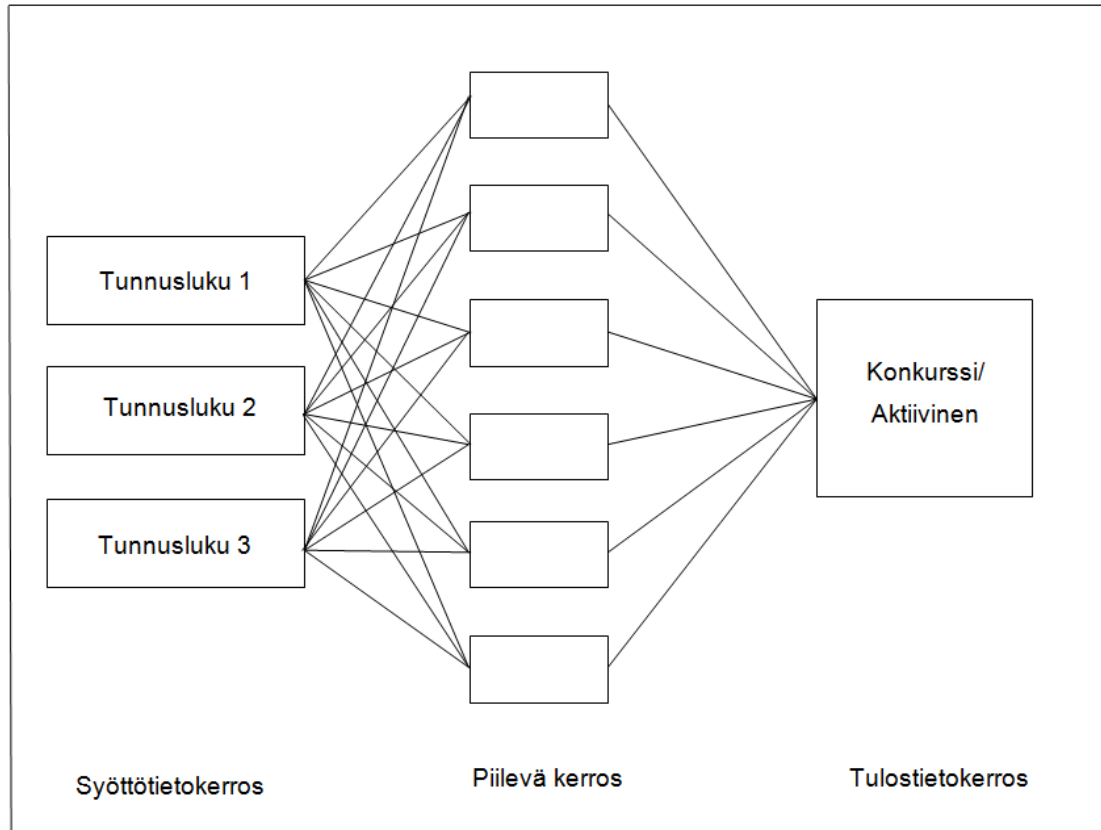
epäonnistumisen tapahtumiselle. Mallissa käytetään logistista jakaumaa, jolloin lineaarisen erotteluanalyysin muutoskaavaksi saadaan: (Laitinen & Laitinen 2004: 140-141)

$$(10) \quad P(T, i) = F(Z(i)) = \frac{1}{1 + \exp(-Z(i))}$$

missä $\exp(-Z(i))$ tarkoittaa Neperin lukua e , joka on korotettu potenssiin $-Z(i)$. (Laitinen & Laitinen 2004: 141)

Päätöspuu on rekursiivisesti ositettu puu, jonka idea on jakaa yritykset kaksiluokkaisen puun muotoon niin, että virheluokittelujen kustannukset minimoituvat koko puun osalta. Ensin valitaan parhaiten erotteleva tunnusluku, jonka mukaan yritykset jaetaan kahteen luokkaan. Seuraavaksi toiseksi parhaiten erottelevaa tunnuslukua käyttäen yritykset jaetaan taas kahtia kunnes päädytään luokkiin, joissa jakaminen ei enää kannata. Lopulliset luokat jaetaan kriisiyrityksiin ja toimiviin yrityksiin. (Laitinen & Laitinen 2004: 144) Tutkielmassa on käytetty päätöspuuna avoimen lähdekoodin algoritmia *J48*, joka perustuu Ross Quinlanin suosittuun *C4.5* päätöspuualgoritmiin. Aineistosta luodut päätöspuut on esitetty tutkielman liitteissä.

Neuroverkko on joukko toisistaan riippuvia neuroneja, ns. laskennallisia elementtejä. Perusrakenteessa verkossa on kolme kerrosta: syöttökerroksen neuronit, piilevän kerroksen neuronit ja tulostietokerroksen neuronit. Piilevän kerroksen rakenteesta johtuen tulostietojen ja syöttökerroksen keskinäiset riippuvuudet ovat yleensä hyvin monimutkaisia. Piilevä kerros määrittää neuroverkon laskennallisen tehokkuuden. Käytetyin neuroverkko konkurssin ennustamisessa on *monikerrosperceptron-verkko* (multilayer perceptron). (Laitinen & Laitinen 2004: 151-152), jota käytetään myös tässä tutkimuksessa.



Kuvio 3. Kolmikerroksinen neuroverkkomalli konkurssin ennustamisessa (Laitinen & Kankaanpää 1997: 38)

Tässä tutkimuksessa mukana olevat uudet koneoppimismenetelmät perustuvat kaikki ajatukseen yhden tavallisen ennustamismenetelmän (yleensä jonkinlainen päätöspuu) tehostamisesta. Tehostaminen tapahtuu yhdistelemällä eri menetelmiä tai hajauttamalla alkuperäinen aineisto. Vaikka menetelmien teoreettinen perusta on heikohko, niillä on kuitenkin saatu aikaan merkittäviä parannuksia suorituskykyyn. (Witten & Frank 2006: 315-316)

Bagging-menetelmä (tai bootstrap aggregating) on koneoppimisessa käytetty meta-algoritmi, jolla pyritään tietyn ennustamismenetelmän ennustamiskyvyn parantamiseen ja varianssin pienentämiseen. Se perustuu bootstrap menetelmän käyttöön, jossa estimointiaineiston osalta luodaan m kappaletta uusia samankokoisia estimointiaineistoja, ottamalla N kappaletta alkioita palauttaen. Näin osa alkuperäisessä aineistossa olevista havainnoista esiintyy lukuisia kertoja uudessa aineistossa m ja osa havainnoista ei esiinny ollenkaan. Bagging-menetelmä yhdistää nämä useat bootstrap-aineistot yhdeksi äänestämällä. (Breiman 1996: 123-124)

Äänestys on tarpeen, sillä päätöspuut saattavat olla hyvinkin erilaisia toisistaan vaikka ne pohjautuvat samaan aineistoon. Tämä johtuu niiden luontaisesta epävakauudesta. Äänestyksellä saadaan vähennettyä tätä varianssia ja myös suorituskyky yleensä paranee merkittävästi. (Witten & Frank 2006: 316)
Menetelmän käyttämä algoritmi on esitelty kuviossa 4:

Mallin luominen

Anna n olla estimointiaineistossa olevien havaintojen lukumäärä

Jokaiselle iteraatiolle t :

Ota n kpl havaintoja takaisinpanolla estimointiaineistolle

Sovella opetusalgoritmi tähän otantaan

Tallenna syntyvä malli

Klassifikaatio

Jokaiselle mallille t :

Ennusta tietyn havainnon luokka käyttäen hyväksi mallia

Palauta se luokka jota on ennustettu useimmiten

Kuvio 4. Algoritmi bagging-menetelmän käytössä (Witten & Frank 2006: 319)

Boosting perustuu saman bootstrap-menetelmän käyttöön kuin bagging, mutta äänestysprosessi on monimutkaisempi. Algoritmi on esitelty kuviossa 5:

Mallin luominen

Määritä sama paino jokaiselle havainnolle estimointiaineistossa

Jokaiselle iteraatiolle t :

Sovella opetusalgoritmia painotettuun havaintoaineistoon ja tallenna
syntynyt malli

Laske mallin virhe e painotetulle aineistolle ja tallenna virhe

Jos virhe = 0, tai suurempi tai yhtä suuri kuin 0,5:

Päätä mallin luominen

Jokaiselle aineiston havainnolle:

Jos havainto luokiteltu oikein:

Kerro kaikkien havaintojen paino $e / (1 - e)$

Normalisoi kaikkien havaintojen painoarvo

Klassifikaatio

Määritä paino 0 kaikille luokille

Lisää $-\log(e / (1 - e))$ mallin ennustamalle luokan painolle

Palauta se luokka jolla on suurin painoarvo

Kuvio 5. Algoritmi Boosting-menetelmän käytössä (Witten & Frank 2006: 322)

Myös **Random Forest** (satunnainen metsä) pohjautuu Bagging-menetelmän käyttämään bootstrap-menetelmään. Se yhdistää tähän lisäksi muuttujien satunnaisen valinnan. Menetelmä on Leo Breimanin (2001) kehittänyt ja se on

saavuttanut suuren suosion maailmanlaajuisesti. Kun aineistosta on bootstrap-menetelmällä saatu aikaan uusia estimointiaineistoja, niistä jokaiselle rakennetaan päätöspuu. Menetelmä eroaa Bagging-menetelmästä siinä, että puiden annetaan äänestää siitä mihin luokkaan havaintoaineisto kuuluu jokaisen puun haarautumisen kohdalla. Tämä vähentää puiden välistä korrelaatiota verrattuna Bagging-menetelmään. (Breiman 2001:5-6)

5. EMPIIRINEN ANALYYSI JA TULOKSET ENNUSTAMISMENETELMISTÄ

Tutkimuksessa tarkastellaan konkurssinennustamismenetelmien ennustamiskyvyn ja niiden erojen tilastollista merkittävyyttä. Ensin on valittava otokseen valituista tunnusluvuista ne tunnusluvut, jotka parhaiten pystyvät ennustamaan konkurssiin ajautumista. Tämä on tehtävä itsenäisesti varsinaisista menetelmistä, jotta menetelmien vertailukelpoisuus säilyisi. Valinta on tehty itsenäisesti jokaiselle vuodelle 1 – 3 ennen konkurssia. Tämän jälkeen jokaisella mallilla on ennustettu konkurssia 1 – 3 vuotta ennen konkurssia. Jokaisen mallin ennustamiskykyä on verrattu jokaiseen toiseen malliin kunakin vuotena t-testin avulla.

Koko aineiston kuvaus löytyy tutkimuksen liitetaulukoista. Voidaan kuitenkin huomata, että U-testin tulokset ovat tilastollisesti erittäin merkitseviä kaikille tunnusluvuille ja ajanjaksoille, paitsi net gearingille kolme vuotta ennen konkurssia. Konkurssiyritysten ja toimivien yritysten väliset erot ovat tunnuslukujen valossa todellisia.

Tutkimus on toteutettu laajasti käytetyllä avoimen lähdekoodin ohjelmalla Weka:lla (Waikato Environment for Knowledge Analysis), versiolla 3.6.12. Ohjelma on Java-ohjelmointikieleen pohjaava koneoppimisessa käytetty ilmainen ohjelma. SAS-ohjelman versiota 9.3. on käytetty U-testien tekemiseen sekä lineaarisen erotteluanalyysin ja logistisen regressioanalyysien mallien rakentamisessa.

5.1. Muuttujien esivalinta

Tunnuslukujen valinta tehtiin jokaiselle kolmelle vuodelle ennen konkurssia erikseen jaksossa 4.4. kuvatulla tavalla. Tutkimukseen valikoidut tunnusluvut jaoteltuna vuosien mukaan on esitelty alla:

Taulukko 3. Muuttujien esivalinnassa vertailuun valikoidut tunnusluvut

Yksi vuosi ennen konkurssia:
Quick ratio
Sijoitetun pääoman tuotto-%
Omavaraisuusaste
Kaksi vuotta ennen konkurssia:
Current ratio
Sijoitetun pääoman tuotto-%
Omavaraisuusaste
Kolme vuotta ennen konkurssia:
Käyttökate-%
Quick ratio
Current ratio
Sijoitetun pääoman tuotto-%
Omavaraisuusaste
Net gearing

Sijoitetun pääoman tuotto sekä omavaraisuusaste valikoituivat mukaan kaikkiin ennustamisjaksoihin. Lisäksi maksukykyä ennakoiva tunnusluku päätyi mukaan kuhunkin ennustamisjaksoon, siten että current ratio oli parempi tunnusluku kaksi vuotta ennen konkurssia ja quick ratio yksi vuosi ennen konkurssia.

Kolme vuotta ennen konkurssia tunnusluvuista valikoituivat mukaan kaikki paitsi liikevoittoprosentti. Muuttujavalinnasta voidaan huomata, että ennustaminen kolme vuotta ennen konkurssia on vaikeampaa. Muuttujien välistä keskinäisriippuvuutta on vähemmän, ja niiden korrelaatio myös konkurssiluokitteluun on pienempää.

Jokainen terveyskolmion osa-alue on itsenäisesti tärkeä ennustettaessa konkurssia, sillä vähintään yksi tunnusluku kustakin osa-alueesta päätyi mukaan kaikkiin ennustusjaksoihin. Toisaalta kahden samaa asiaa mittaavan tunnusluvun mukaan ottaminen ei paranna ennustamista, koska niiden keskinäinen korrelaatio on suurta.

5.2. Perinteisten mallien rakenne

Perinteisten menetelmien malleiksi on katsottu lineaarinen erotteluanalyysi, logistinen regressioanalyysi, päätöspuu sekä neuroverkot. Neuroverkon osalta malli ei ole tiedossa, mutta muiden mallien rakenne on esitelty alla tai tutkielman liitteissä.

Taulukko 4. Lineaarisen regressioanalyysin mallin rakenne

1. Vuosi ennen konkurssia

Muuttuja	Painotus	Keskivirhe
Vakio	0,403	
Quick ratio	-0,019	0,002
Sij. pääoman tuotto-%	-0,003	0,000
Omavaraisuusaste	-0,001	0,000

2. Vuosi ennen konkurssia

Muuttuja	Painotus	Keskivirhe
Vakio	0,450	
Omavaraisuusaste	-0,002	0,000
Sij. pääoman tuotto-%	-0,002	0,000
Current ratio	-0,016	0,002

3. Vuosi ennen konkurssia

Muuttuja	Painotus	Keskivirhe
Vakio	0,467	
Käyttökate%	-0,002	0,000
Quick ratio	-0,012	0,005
Current ratio	-0,004	0,004
Sij. pääoman tuotto-%	-0,001	0,000
Omavaraisuusaste	-0,002	0,000
Net gearing	0,003	0,001

Taulukko 5. Logistisen regressioanalyysin mallin rakenne

1. Vuosi ennen konkurssia

Muuttuja	Painotus	Keskivirhe
Vakio	0,192	
Quick ratio	0,300	0,033
Sij. pääoman tuotto-%	0,012	0,001
Omavaraisuusaste	0,007	0,001

2. Vuosi ennen konkurssia

Muuttuja	Painotus	Keskivirhe
Vakio	-0,001	
Current ratio	0,205	0,024
Omavaraisuusaste	0,010	0,001
Sij. pääoman tuotto-%	0,007	0,001

3. Vuosi ennen konkurssia

Muuttuja	Painotus	Keskivirhe
Vakio	-0,064	
Käyttökate%	0,010	0,002
Quick ratio	0,184	0,040
Current ratio	0,040	0,029
Sij. pääoman tuotto-%	0,003	0,001
Omavaraisuusaste	0,010	0,001
Net gearing	-0,015	0,004

Päätöspuun rakenne on esitelty tutkielman liitteissä. Kaikkina kolmena ennustamisjaksona ensimmäinen jakaja eli parhaiten ennustava tunnusluku oli omavaraisuusaste. Tämä ei ole yllättävää, sillä aiemmissa tutkimuksissa on todettu sen olevan ehdottomasti paras yksittäinen tunnusluku konkurssin ennustamisessa. Sijoitetun pääoman tuotto-% oli toinen jakaja toisena ja kolmantena vuonna ennen konkurssia. Vuosi ennen konkurssia toinen jakaja oli quick ratio, mikä on myös hyvin yhteneväinen konkurssiprosessin kanssa, sillä yhtiön maksukyky heikkenee äkillisesti konkurssihetken lähestyessä. Kauempana konkurssihetkestä kannattavuuden tunnusluvuilla on suurempi painoarvo.

5.3. Menetelmien luokittelukyky

Vuosi ennen konkurssia menetelmien ennustamiskyky AUC-arvolla sekä mallien virheprosentit olivat seuraavat, kun mallit on ryhmitelty paremmuusjärjestykseen:

Taulukko 6. Mallien AUC-arvot vuosi ennen konkurssia

Malli	AUC
Neuraaliverkko	0.87
Bagging	0.87
Boosting	0.86
Random Forest	0.85
Logistinen regressio	0.84
Päätöspuu	0.82
Lineaarinen erotteluanalyysi	0.76

Taulukko 7. Mallien virheprosentit vuosi ennen konkurssia

Malli	Virhe
Päätöspuu	19.30
Bagging	20.13
Boosting	20.44
Neuraaliverkko	20.72
Random Forest	21.17
Lineaarinen erotteluanalyysi	21.39
Logistinen regressio	22.88

Kaksi vuotta ennen konkurssia mallien ennustamiskyky AUC-arvolla sekä mallien virheprosentit olivat seuraavat, kun mallit on ryhmitelty paremmuusjärjestykseen:

Taulukko 8. Mallien AUC-arvot kaksi vuotta ennen konkurssia

Malli	AUC
Neuraaliverkko	0.81
Bagging	0.81
Boosting	0.81
Random Forest	0.80
Logistinen regressio	0.79
Päätöspuu	0.77
Lineaarinen erotteluanalyysi	0.68

Taulukko 9. Mallien virheprosentit kaksi vuotta ennen konkurssia

Malli	Virhe
Päätöspuu	24.99
Boosting	25.02
Neuraaliverkko	25.39
Bagging	25.51
Random Forest	26.61
Lineaarinen erotteluanalyysi	27.54
Logistinen regressio	28.38

Kolme vuotta ennen konkurssia mallien ennustamiskyky AUC-arvolla sekä mallien virheprosentit olivat seuraavat, kun mallit on ryhmitelty paremmuusjärjestykseen:

Taulukko 10. Mallien AUC-arvot kolme vuotta ennen konkurssia

Malli	AUC
Neuraaliverkko	0.79
Bagging	0.78
Random Forest	0.78
Logistinen regressio	0.77
Boosting	0.77
Päätöspuu	0.76
Lineaarinen erotteluanalyysi	0.64

Taulukko 11. Mallien virheprosentit kolme vuotta ennen konkurssia

Malli	Virhe
Neuraaliverkko	27.50
Päätöspuu	27.68
Random Forest	27.85
Bagging	28.07
Logistinen regressio	29.84
Lineaarinen erotteluanalyysi	30.18
Boosting	30.29

Edellä esitetystä tuloksista on huomattavissa, että neuraaliverkko oli selkeästi paras ennustusmenetelmä kaikkina vuosina kun ennustamiskykyä mitataan AUC-arvon mukaan. Toiseksi paras menetelmä oli jokaisena vuonna Bagging, joka oli hiukan epätarkempi kuin neuraaliverkko.

Koneoppimismenetelmät pärjäsivät vertailussa hyvin, sijoittuen AUC-arvoilla arvioituna 2 – 4 parhaimmaksi melkein jokaisena vuonna. Ne eivät myöskään koskaan olleet huonompia kuin lineaarinen erotteluanalyysi tai päätöspuu ja voittivat yhtä tapausta lukuun ottamatta myös logistisen regressioanalyysin.

Perinteisistä malleista lineaarinen erotteluanalyysi ei ollut kovin tarkka ennustuksissaan AUC-arvojen mukaan arvioituna, sillä se oli selkeästi huonoin menetelmä suurimmalla erolla toiseksi huonoimpaan. Logistinen regressio suoriutui siedettävästi AUC-arvoilla, mutta ei ikinä yltänyt parhaimpien menetelmien tarkkuuteen.

Virheluokittelujen mukaan arvioituna paras menetelmä oli päätöspuu, jolla oli pienin virheprosentti kaikkina vuosina paitsi kolmantena ennen konkurssia, jolloin se oli toiseksi paras. Lineaarinen erotteluanalyysi ja logistinen regressio eivät onnistuneet ennustuksissaan tälläkään tavalla mitattuna kovin hyvin, joskin lineaarinen erotteluanalyysi ei enää ollut selkeästi huonoin menetelmä kuten AUC-arvojen mukaan arvioituna.

Koneoppimismenetelmien suoriutumiskyky oli melko hyvä myös virheluokitteluilla arvioituna, joskin päätöspuun hyvä ennustuskky huononsi niiden suhteellista sijoitusta. Menetelmien väliset erot molemman arviointiperusteen mukaan ovat kuitenkin suhteellisen pieniä, eikä täysin yliverstaista menetelmää ole havaittavissa.

Kaikkien mallien ennustamiskyky myös luonnollisesti paranee kun konkurssiajankohta lähenee. Tässä ei voida havaita suuria eroja menetelmien välillä, sillä ennustuskky paranee hyvin tasaisesti kaikkien osalta. Tämä myös tukee sitä, että erot menetelmien välillä ovat todellisia, eivätkä perustu ainoastaan satunnaiseen varianssiin.

5.4. Luokitteluerojen tilastollinen merkitsevyys

Mallien välisten erojen tilastollista merkitsevyyttä on arvioitu vertailemalla niiden AUC-arvoja sekä virheluokitteluprosentteja. Erot ovat erilaisia eri vuosina sekä eri vertailuperustella, minkä takia kustakin vuodesta ja vertailuperusteesta on tehty oma taulukkonsa, jotta tuloksia voisi mielekkäästi tarkastella. Luokitteluerojen taulukot löytyvät alla:

Taulukko 12. AUC-arvojen erojen tilastollinen merkitsevyys vuosi ennen konkurssia

Malli	Log	PP	NN	Bag	RF	Boost
Logistinen regressio	X	**	vvv	vvv	vvv	vvv
Päätöspuu	vv	X	vvv	vvv	vvv	vvv
Neuraaliverkko	***	***	X	**	***	***
Bagging	***	***	vv	X	***	*
Random Forest	***	***	vvv	vvv	X	O

Taulukko 13. AUC-arvojen erojen tilastollinen merkitsevyys kaksi vuotta ennen konkurssia

Malli	Log	PP	NN	Bag	RF	Boost
Logistinen regressio	X	**	vvv	vvv	O	vvv
Päätöspuu	vv	X	vvv	vvv	vvv	vvv
Neuraaliverkko	***	***	X	O	*	O
Bagging	***	***	O	X	***	O
Random Forest	O	***	v	vvv	X	vv

Taulukko 14. AUC-arvojen erojen tilastollinen merkitsevyys kolme vuotta ennen konkurssia

Malli	Log	PP	NN	Bag	RF	Boost
Logistinen regressio	X	**	vvv	v	v	O
Päätöspuu	vv	X	vvv	vvv	vvv	O
Neuraaliverkko	***	***	X	O	O	***
Bagging	*	***	O	X	O	***
Random Forest	*	***	O	O	X	***

missä:

*** = suurempi arvo $p = 0,01$ merkitsevyytasolla,

** = suurempi arvo $p = 0,05$ merkitsevyystasolla,
 * = suurempi arvo $p = 0,10$ merkitsevyystasolla,
 vvv = pienempi arvo $p = 0,01$ merkitsevyystasolla,
 vv = pienempi arvo $p = 0,05$ merkitsevyystasolla,
 v = pienempi arvo $p = 0,10$ merkitsevyystasolla,
 O = ei tilastollisesti merkitsevää eroa
 kun verrataan pysty-akselia vaaka-akseliin

Mallien ennustamiskyky muuttuu melko merkittävästi, kun sitä verrataan virheluokittelujen mukaisesti:

Taulukko 15. Virheluokittelujen erojen tilastollinen merkitsevyys vuosi ennen konkurssia

Malli	Log	PP	NN	Bag	RF	Boost
Logistinen regressio	X	vvv	vvv	vvv	vv	vvv
Päätöspuu	***	X	***	*	***	***
Neuraaliverkko	***	vvv	X	O	O	O
Bagging	***	v	O	X	**	O
Random Forest	**	vvv	O	vv	X	O

Taulukko 16. Virheluokittelujen erojen tilastollinen merkitsevyys kaksi vuotta ennen konkurssia

Malli	Log	PP	NN	Bag	RF	Boost
Logistinen regressio	X	vvv	vvv	vvv	vv	vvv
Päätöspuu	***	X	O	O	***	O
Neuraaliverkko	***	O	X	O	O	O
Bagging	***	O	O	X	**	O
Random Forest	**	vvv	v	vv	X	vvv

Taulukko 17. Virheluokittelujen erojen tilastollinen merkitsevyys kolme vuotta ennen konkurssia

Malli	Log	PP	NN	Bag	RF	Boost
Logistinen regressio	X	vvv	vvv	vv	vvv	O
Päätöspuu	***	X	O	O	O	***
Neuraaliverkko	***	O	X	O	O	***
Bagging	**	O	O	X	O	***
Random Forest	***	O	O	O	X	***

missä:

*** = pienempi virheluokitteluprosentti $p = 0,01$ merkitsevyystasolla,
 ** = pienempi virheluokitteluprosentti $p = 0,05$ merkitsevyystasolla,
 * = pienempi virheluokitteluprosentti $p = 0,10$ merkitsevyystasolla,
 vvv = suurempi virheluokitteluprosentti $p = 0,01$ merkitsevyystasolla,
 vv = suurempi virheluokitteluprosentti $p = 0,05$ merkitsevyystasolla,
 v = suurempi virheluokitteluprosentti $p = 0,10$ merkitsevyystasolla,
 O = ei tilastollisesti merkitsevää eroa
 kun verrataan pysty-akselia vaaka-akseliin

Lineaarista erotteluanalyysia ei voitu ottaa mukaan ennustamiserojen tilastolliseen merkittävyysarviointiin teknisistä syistä. Menetelmä oli kuitenkin selkeästi huonoin kaikista malleista varsinkin AUC-arvojen osalta.

Tilastollisesti merkitseviä ja melkein merkitseviä eroja löydettiin melko runsaasti eri mallien välillä, mikä johtuu osaksi aineiston laajuudesta. Lisäksi ristiinvalidointi pienensi merkittävästi keskiarvojen keskihajontaa, ja lisäsi t-testin vapausastetta. Eniten tilastollisesti merkitseviä eroja voitiin havaita yksi vuosi ennen konkurssia, mutta kaikkina vuosina ja molemmilla arviointiperusteilla arvioituna erot olivat ainakin osittain tilastollisesti melkein merkitseviä.

Neuraaliverkon parempi ennustuskyky oli tilastollisesti melkein merkitsevä AUC-arvoilla mitattuna lähes kaikkiin muihin menetelmiin paitsi Bagging-menetelmään verrattuna. Siihen suhteutettuna eroja löytyi ainoastaan yksi vuosi ennen konkurssia. Myös muut koneoppimismenetelmät saivat tilastollisesti melkein merkitseviä parempia tuloksia verrattaessa niitä logistiseen regressioon ja päätöspuuhun AUC-arvoilla.

Päätöspuun parempi luokittelukyky muihin menetelmiin verrattuna kun ennustamiskykyä verrataan virheluokittelujen mukaisesti, oli myös useimmiten tilastollisesti merkitsevä. Kolmantena vuonna ennen konkurssia se koski kuitenkin vain logistista regressiota ja Boosting-menetelmää.

Logistisen regression huonompi suoriutuminen oli myös tilastollisesti merkitsevää tai melkein merkitsevää lähes kaikilla ennustamisjaksoilla ja suhteutettuna muihin menetelmiin sekä verrattaessa AUC-arvoilla ja varsinkin virheluokittelujen mukaan.

5.5. Johtopäätökset

Tutkimuksen lähestymistapa oli tutkia eri konkurssinennustamismenetelmien eroja sekä arvioida mahdollisia tilastollisesti merkitseviä eroja mallien välillä. Absoluuttiset erot mallien ennustamiskyvyssä olivat melko pieniä sekä AUC-arvoilla että virheluokittelujen mukaan arvioituna, poikkeuksena lineaarisen erotteluanalyysin heikko suorituminen kautta linjan. Mikään menetelmä ei siis ollut muita selkeästi parempi. Havaitut erot olivat kuitenkin suuresta analyysiaineistosta ja tilastollisen menetelmän valinnan johdosta melko usein tilastollisesti melkein merkitseviä ($p=0,05$) ja ajoittain myös tilastollisesti merkitseviä ($p=0,01$).

Rajoitteena on, että tutkimuksessa pystyttiin vertaamaan ainoastaan AUC-arvoja ja kokonaisvirheiden osuutta. Konkurssiyrityksen luokittelu toimivaksi on kuitenkin merkittävästi kalliimpi virhe kuin toimivan yrityksen luokittelu konkurssiyritykseksi. Mallien väliset erot voisivat pienentyä, suurentua tai hävitä kokonaan, jos mallien rakentamisessa sekä arvioinnissa otettaisiin huomioon virheiden kustannuserot.

Tutkimuksen tulosten perusteella voidaan todeta, että selkeitä eroja mallien välillä oli havaittavissa. Suurin osa malleista suoriutui kuitenkin verrattain hyvin ja sijoittui pienen hajonnan sisälle. Lisäksi eri mallit olivat parempia eri vuosina ennen konkurssia. Selkeästi paras menetelmä oli neuroverkot, kun tuloksia tarkastellaan AUC-arvojen mukaisesti. AUC-arvon voidaan katsoa mittaavan mallin kokonaisluokittelua paremmin kuin virheluokitusten suhteellisen osuuden, joka on ainoastaan poikkileikkausarvo.

Neuroverkkojen ja uusimpien koneoppimismenetelmien hyvä suoriutuminen on osoitus siitä, että käytännön luotonvalvonnassa tulisi hyödyntää myös muita menetelmiä kuin perinteisiä regressioanalyysijä. Uudemmat menetelmät ovat kuitenkin herkkiä ylisovittamiselle. Luottopäätöksiä ei voida suositella perusteltavan pelkästään niiden varaan. Menetelmien estimoinnissa voidaan kuitenkin nykyisin hyödyntää keinoja, jotka vähentävät ylisovittamisen vaaraa. (Witten & Frank 2006: 34-35) Laskentatehon merkittävä lisääntyminen on käytännössä poistanut monimutkaisempien mallien hitauden.

Mielenkiintoisena tuloksena voidaan pitää sitä, että mallien paremmuusjärjestys muuttuu selkeästi riippuen siitä otetaanko arvioinnin

pohjaksi AUC-arvo vai virheluokittelujen suhteellinen osuus. Aiemmissa tutkimuksissa on lähes yksinomaan käytetty virheluokitteluprosenttia mallin ennustamiskyvyn arvioinnissa. Tämän tutkimuksen valossa se saattaa kuitenkin yliarvioida erityisesti päätöspuun ennustamiskykyä ja mahdollisesti aliarvioida neuroverkkojen ennustamiskykyä.

Uudempien koneoppimismenetelmien suorituskky oli hyvää. Niiden käyttö akateemisessa konkurssin ennustamistutkimuksessa on kuitenkin ollut hyvin vähäistä. Muissa tiedon louhinnan ja koneoppimisen ongelmatehtävissä menetelmät ovat kuitenkin suoriutuneet hyvin. Niiden käyttöä konkurssin ennustamisessa voidaan tämän tutkimuksen perusteella pitää hyvinkin perusteltuna. Ne eivät kuitenkaan ole poikkeuksellisen ylivertaisia perinteisiin menetelmiin verrattuna. Aiemmin rajoitteena ollut laskentatehovaatimus on nykyisin kuitenkin väistynyt.

Tutkimuksen hypoteesina oli, että ennustamismallien välillä ei löydy tilastollisesti merkitseviä eroja. Käytännössä tutkittavia hypoteeseja oli kuitenkin 21 kappaletta, sillä jokaista mallia verrataan kaikkiin muihin malleihin. Vastahypoteesi sai vahvistusta, sillä monien mallien välillä löydettiin tilastollisesti merkitseviä eroja jopa 1 %:n merkitsevyystasolla. Ennustuskkyjen erot olivat myös melko suuria heikoimpien ja parhaimpien mallien välillä jokaisena ennustamisvuotena. Kaikkien mallien välillä ei kuitenkaan löydetty tilastollisesti merkitsevää eroa. Tämä koskee etenkin neuroverkkoa sekä uudempia koneoppimismenetelmiä. Toisaalta perinteisen lineaarisen regressioanalyysin ja logistisen regressioanalyysin suorituskky oli melko heikko, erityisesti AUC-arvoilla mitattuna. Tällä perusteella katson, että nollahypoteesi voidaan hylätä, sillä näiden yleisimpien ennustusmenetelmien ennustuskky oli selkeästi heikompi kuin tutkimuksen parhaiden menetelmien.

5.6. Rajoitukset

Tutkimus rajoittuu koskemaan kaikkia konkurssiin menneitä suomalaisia yhtiöitä, riippumatta niiden toimialasta, koosta, iästä tai maantieteellisestä sijainnista. Yrityksiä ei muutenkaan ole tyypitelty millään tavalla, vaikka konkurssiprosessi on erilainen eri konkurssiyrityksissä (vrt. Laitinen & Laitinen 2014: 225-227). Tämä on selkeä rajoite, sillä mallit ennustaisivat eri tavalla jos aineisto olisi tyypitelty erilaisten konkurssiprosessien mukaisesti.

Tutkimuksessa ei ole hyödynnetty kvalitatiivisia muuttujia vaan se perustuu puhtaasti tunnuslukujen analysointiin. Kvalitatiivisten muuttujien käyttö parantaisi todennäköisesti mallien ennustamiskykyä. (Laitinen & Laitinen 2014: 175-177)

Tutkimusta rajoittavat myös täydellisen aineiston vaatiminen yrityksiltä varsinaiseen tutkimusaineistoon mukaanpääsemiseksi. Tämä rajaa ulkopuolelle varsinkin konkurssiyrityksiä, jolloin otos ei enää välttämättä edusta koko populaatiota. Lisäksi nykyisen konkurssin ennustamisen paradigman kaikki ongelmat ja rajoitukset (Balcaen & Ooghe 2006: 85), joita käsiteltiin kappaleessa 3.7. koskevat myös tätä tutkimusta.

6. YHTEENVETO

Konkurssiin ajautuu vuosittain Suomessa noin 3000 yritystä, ja se koskettaa suoraan noin 15 000 työntekijää. Lisäksi konkurssiin ajautuminen aiheuttaa mittavat tappiot julkiselle vallalle sekä yrityksen rahoittajille. Kykenemällä ennustamaan yrityksen konkurssiuhka etukäteen voitaisiin näitä tappioita vähentää ja mahdollisesti myös estää yrityksen päätyminen konkurssiin kokonaisuudessaan.

Konkurssin ennustaminen on ollut akateemisesti erittäin suosittu tutkimussuunta jo 1960-luvusta lähtien. Ensimmäiset tutkimukset olivat Beaverin (1966) ja Altmanin (1968) tutkimukset yhden ja monen muuttujan erotteluanalyysillä. Pelkkiin taloudellisiin tunnuslukuihin perustuvan mallinnuksen perusidea ei ole muuttunut, mutta mallinnuksia on olennaisesti parannettu, ottamalla huomioon tarkkuuteen vaikuttavia tilastollisia seikkoja sekä taustamuuttujien merkitystä.

Myöhemmin mallinnoista on tehty tilastollisesti parempia menetelmiä, erityisesti logistisesta regressioanalyysistä on tullut ennustamistutkimuksen päämalli. Tietokoneiden laskentatehon lisääntyttyä ja aineiston saatavuuden parannuttua merkittävästi viime vuosikymmeninä, on ennustamisessa käytetty myös muita malleja. Suosituimpia näistä ovat olleet erilaiset neuroverkot sekä päätöspuut.

Laskentatehon merkittävä parantuminen on myös luonut mahdollisuuden analysoida akateemisesti suurempaa laskentatehoa vaativia aineistoja ja menetelmiä. Beaverin ja Altmanin tutkimukset olivat aineistoltaan hyvin suppeita ja matemaattisesti erittäin yksinkertaisia. Voidaankin olettaa, että monimutkaisuuden lisääntyminen johtaisi ainakin tiettyyn pisteeseen asti parempaan ennustustarkkuuteen.

Tietynlainen konvergenssi on kuitenkin havaittavissa mallinnoissa ja ennustuksessa yleensä. Puhtaasti taloudellisiin tunnuslukuihin perustuvat, tilastollisesti melko yksinkertaiset mallit ennustavat konkursseja hyvin, eivätkä monimutkaisempien menetelmien tai tietokoneiden laskentatehoa hyödyntävien menetelmien käyttöön otto ole muuttaneet konkurssin ennustamisen perusteita. Tunnuksien osalta konkurssia pystytään

ennustamaan melko pienilläkin määrällä muuttujia, eikä mallien monimutkaistaminen yleensä paranna niiden ennustustarkkuutta, jos mukaan ei oteta myös ei-taloudellisia muuttujia

Konkurssin ennustamisessa käytännössä merkitystä on myös konkurssiprosessilla. Ennustamismallin rakentamiselle ei kuitenkaan ole löydetty yleisesti hyväksyttyä teoreettista kehikkoa. Tämän takia suurin osa ennustamistutkimuksista – tämä mukaan lukien – perustuu pääasiassa empiiriseen optimointiin ja arviointiin käyttäen hyväksi tunnuslukuja. Konkurssiprosessia on kuitenkin yritetty ratkaista myös teorian avulla. Erityisesti Laitinen & Laitinen (2014) ovat laajan aineiston avulla löytäneet kolme pääasiallista konkurssiyrityksen tyyppiä, joka kattaa suurimman osan konkurssiyrityksistä.

Konkurssin ennustamisessa on mahdollista ja myös suotavaa käyttää hyväksi muita ei-määrällisiä taustamuuttujia, kuten yrityksen koko, ikä, toimiala. Tällä, ja konkurssiprosessin ymmärtämisellä, on selkeää käyttöarvoa käytännön luotonannossa ja maksukyvyyn arvioinnissa. Taloudelliset tunnusluvut ovat tällöinkin keskiössä, ja niiden merkitsevyyden analysointiin tarvitaan tilastollisia apuvälineitä.

Lähtökohtana tutkimukselle oli verrata perinteisen lineaarisen erotteluanalyysin ja logistisen regressioanalyysin ennustamiskykyä uudempiin ennustamismalleihin, jotka hyödyntävät koneoppimisessa ja tietokoneiden laskentatehossa tapahtunutta kehitystä. Päätöspuita ja neuraaliverkkoja on kuitenkin käytetty myös aiemmin konkurssin ennustamisessa, minkä vuoksi ne katsottiin tutkimuksessa kuuluvaksi perinteisiin malleihin. Mukaan valittiin kolme koneoppimismenetelmää, jotka ovat olleet laajassa käytössä viimeisen vuosikymmenen.

Aiemmissä tutkimuksissa ei ole löydetty pysyviä merkitseviä eroja ennustamismallien välillä. Tämän takia tutkimuksen päähypoteesina oli, ettei merkitseviä eroja ole löydettävissä vertailtavien menetelmien välillä. Malleja oli kaiken kaikkiaan seitsemän ja jokaista verrattiin toiseen malliin tilastollisella t-testillä. Tutkittavia hypoteeseja oli kaiken kaikkiaan 21 kappaletta. Vertailu tehtiin arvioimalla mallien ennustamiskykyä kahden eri suorituskykymittarin avulla, AUC-arvolla ja virheluokittelujen suhteellisen osuudella. Aineistona 4096 suomalaista osakeyhtiötä, joista 2534 oli toimivia yrityksiä ja 1562

konkurssiin haettuja. Vertailu suoritettiin kolmena vuotena ennen konkurssia, jokaisena vuotena erikseen.

Käytetyt tunnusluvut vaihtelivat vuosien välillä ja ne valittiin etukäteen laajasta joukosta tunnuslukuja, perustuen niiden keskinäiseen korrelaatioon sekä korrelaatioon konkurssimuuttujan kanssa. Syynä oli päällekkäisyyksien mahdollisimman suuri poistaminen sekä erityisesti koneoppimismenetelmien suorituskyvyn varmistaminen. Koneoppimismenetelmät kärsivät, mikäli mallinnukseen otetaan mukaan ylimääräisiä muuttujia, jotka eivät paranna ennustamiskykyä verrattuna yksinkertaisempaan malliin.

Mallien väliset erot olivat absoluuttisesti katsottuna melko pienet, joskin poikkeuksiakin oli. Erot olivat myös yhteneväiset vuosien välillä, sillä neuroverkko oli AUC-arvolla mitattuna paras ennustusmenetelmä kaikkina vuosina ennen konkurssia. Aineiston suuruudesta johtuen tilastollisesti merkitseviä eroja löydettiin kuitenkin melko paljon. Tästä kahdesta syystä johtuen nollahypoteesi päätettiin hylätä, pienin varauksin.

Mielenkiintoinen tutkimustulos oli mallien ennustuskvyn merkittävä vaihtelu riippuen siitä, arvioitiinko niitä AUC-arvojen vai virheluokittelujen suhteellisen osuuden mukaan. Neuroverkko menestyi molemmissa erittäin hyvin, samoin kolme arvioitavana ollutta koneoppimismenetelmää. Päätöspuu menestyi melko huonosti AUC-arvon mukaan arvioituna, mutta oli selkeästi paras menetelmä virheluokittelujen osuuden mukaan arvioituna. Molempia arviointikriteerejä on käytetty tutkimuksissa, mutta AUC-arvo on yleistynyt vasta viime vuosina kun taas aiemmat ja paljon viittauksia saaneet vanhemmat tutkimukset käyttävät ainoastaan virheluokittelujen suhteellista osuutta.

Tämä herättää kysymyksen siitä, kumpi arviointikriteeri on parempi ja mikä merkitys tällä on kun malleja optimoidaan käytettäväksi käytännön ennustamisessa. AUC-arvo on teoreettisesti perustellumpi tapa arvioida suorituskykyä, ja se onkin yleistynyt viime vuosina kun laskentateho on parantunut. Koska aiemmat tutkimukset ovat käyttäneet virheluokitteluja, olisi syytä pohtia tulisiko niitä toteuttaa uudestaan AUC-arvoilla arvioituna.

Tutkimuksen tulokset ovat melko luotettavat, joskin on syytä huomauttaa, että koneoppimismenetelmät sekä päätöspuu ja neuroverkko ovat menetelminä melko herkkiä ylisovittamiselle. Tässä tutkimuksessa aineistona on ollut

ainoastaan suomalaisia lähivuosina konkurssiin menneitä yrityksiä, joista on ollut saatavilla asianmukaiset taloudelliset taustatiedot. Tuloksia on pidettävä yhtenä osoituksena siitä, että perinteiset menetelmät lineaarinen erotteluanalyysi ja logistinen regressio eivät ole parhaita menetelmiä konkurssin ennustamisessa. Niitä ei kuitenkaan voida hylätä pelkästään tähän nojautuen, vaan lisätutkimukset ovat tarpeen.

Ottamalla huomioon väärästä luokittelusta aiheutuvien taloudellisten menetysten merkitys, voitaisiin myös saada parempia vertailutuloksia eri mallien välillä. Konkurssiyrityksen luokitseminen toimivaksi yritykseksi aiheuttaa huomattavan suuremman taloudellisen menetyksen kuin toimivan yrityksen luokitseminen konkurssiyritykseksi. On mahdollista käyttää hyväksi erilaisia painotuksia väärän luokittelun kustannuksesta sekä mallin optimoinnissa että sen suorituskyvyn arvioinnissa.

Jatkotutkimuksena olisi mielenkiintoista seurata luokittelevatko eri mallit eri yritykset väriin kategorioihin vai onko kaikilla malleilla vaikeuksia luokitella oikein samoja yrityksiä. Jos eroavaisuuksia löytyisi, tulisi myös selvittää sitä millä tavalla väärin luokitellut yritykset eroavat toisistaan.

LÄHDELUETTELO

- Airaksinen M. , Pulkkinen P. & Rasinaho V. (2007). *Osakeyhtiölaki II*. Karisto Oy. 649 s. ISBN: 978-952-14-1016-1.
- Altman E.I.(1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance* 23:4, 589-609.
- Argenti J. (1976). *Corporate Collapse: The Causes and Symptoms*. Mcgraw Hill Book Co Ltd. 193 s. ISBN: 978-0-07084-4698.
- Aziz M. A & H. A. Dar (2006). Predicting corporate bankruptcy: where we stand? *Corporate Governance* 6:1, 18–33.
- Balcaen S. & H. Ooghe (2006). 35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems. *The British Accounting Review* 38, 63–93.
- Beaver W. (1966). Financial Ratios as Predictors of Failure. Empirical Research in Accounting: Selected Studies. *Journal of Accounting Research*. 23:4, 71-111.
- Boritz J. E., D. B. Kennedy & J. Y. Sun (2007). Predicting Business Failures in Canada. *Accounting Perspectives* 6:2, 141-165.
- Breiman L. (1996). Bagging Predictors. *Machine Learning* 24:2, 123-140.
- Breiman L. (2001). Random Forests. *Machine Learning* 45:1, 5-32.
- Cybinski P. (2001). Description, explanation, prediction – the evolution of bankruptcy studies? *Managerial Finance* 27:4, 29-44.
- Dacovic R, Czado C. & D. Berg (2010). Bankruptcy prediction in Norway: a comparison study. *Applied Economic Letters* 17, 1739–1746.

- Dimitras, A. I., S. H. Zanakis & C. Zopounidis (1996). A survey of business Failures with an emphasis on prediction methods and industrial applications. *European Journal of Operational Research*, 90:3, 487-513.
- Forsström J. (1996). Testien diagnostisen arvon mittaaminen ROC-käyrän avulla. *Lääketieteellinen Aikakauskirja Duodecim* 3, 237-245.
- Grice J. & M. T. Dugan (2001). The limitations of bankruptcy prediction models: Some caution for the researcher. *Review of Quantitative Finance and Accounting* 17:2, 151-166.
- HE 26/2003 vp: Hallituksen esitys konkurssilainsäädännön uudistamiseksi.
- Hosmer D. & Lemeshow S. (2000). *Applied logistic regression*. New York: Wiley corporation. 373 s. ISBN: 0-471-35632-8.
- Jackson R. & Wood A. The performance of insolvency prediction and credit risk models in the UK: A comparative study. *The British Accounting Review*. 45, 182-202.
- Laitinen E. K. (1990). *Konkurssin ennustaminen*. Sundom: Vaasan Yritysinformaatio Oy. 302 s. ISBN: 952-90-2236-0.
- Laitinen E. K. & T. Laitinen (1998). Cash management behavior and failure prediction. *Journal of Business Finance & Accounting* 25:7-8, 893-919.
- Laitinen E. K. & T. Laitinen (2004). *Yrityksen rahoituskriisin ennustaminen*. Helsinki: Talentum. 405 s. ISBN: 952-14-0771-9.
- Laitinen E. K. & T. Laitinen (2014). *Yrityksen maksukyky. Arviointi ja ennakointi*. Helsinki: KHT Media Oy. 287 s. ISBN: 978-952-218-209-8.
- Laitinen T & M. Kankaanpää (1997). *Comparative Analysis of Failure Prediction Methods*. Vaasa: Vaasan yliopiston julkaisuja, Tutkimuksia 216. 78 s. ISBN: 951-638-678-X.

- Mellahi, Kamel & Wilkinson, Adrian. Organizational failure: a critique of recent research and a proposed integrative framework. *International Journal of Management Reviews*. 5/6:1, 21–41.
- Ohlson J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research* 18:1, 109-131.
- Ooghe H. & S. Balcaen (2007). Are Failure Prediction Models Widely Usable? An Empirical Study Using a Belgian Dataset. *Multinational Finance Journal* 11:½, 33–76.
- Ooghe H. & S. De Prijcker (2008). Failure processes and causes of company bankruptcy: a typology. *Management Decision* 46:2, 223-242.
- Prihti, A. (1975). *Konkurssin ennustaminen taseinformaation avulla*. Helsingi kauppakorkeakoulu. Helsinki: Painomies Oy. 138 s. ISBN: 951-699-071-1.
- Koulu, R (2009). *Konkurssioikeus*. Juva: WS Bookwell Oy. 449 s. ISBN: 978-951-0-35247-2.
- Kumar P & Ravi V. Bankruptcy prediction in banks and firms via statistical and intelligent techniques – A review. *European Journal of Operational Research* 180, 1-28.
- Shmueli G, Patel N. & Bruce P. (2010) *Data mining for business intelligence: concepts, techniques, and applications in Microsoft Office Excel with XLMiner* Hoboken, N.J.: Wiley, corporation. 404 s. ISBN: 978-04-7052-6828.
- Suomen Asiakastieto (2015). *Voitto+:-n tunnusluvut*. [online]. Saatavilla World Wide Webistä: <URL:<http://www.asiakastieto.fi/voitto/ohje/tunnusluvut.htm>>.
- Tilastokeskus (2014). *Konkurssit 2014. Konkurssien määrä väheni 5,7 prosenttia vuonna 2014*. [online]. Saatavana World Wide Webistä: <URL: http://www.stat.fi/til/konk/2014/12/konk_2014_12_2015-01-

28_fi.pdf>.

Tilastokeskus (2016). Konkurssit. 2015, joulukuu. *Konkurssien määrä väheni 13,8 prosenttia vuonna 2015*. [online]. Saaavilla World Wide Webistä.<URL: http://www.stat.fi/til/konk/2015/12/konk_2015_12_2015-01-27_fi.pdf>.

Wu Wei-Wen (2010). Beyond business failure prediction. *Expert Systems with Applications* 37, 2371-2376.

Zhang G., Hu M., Patuwo B. & Indro D. (1999) Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. *European Journal of Operational Research* 116:1, 16-32.

Zmijewski, Mark E.: Methodological Issues Related to the Estimation of Financial Distress Prediction Models. *Journal of Accounting Research*. Spring 1984, 59-86.

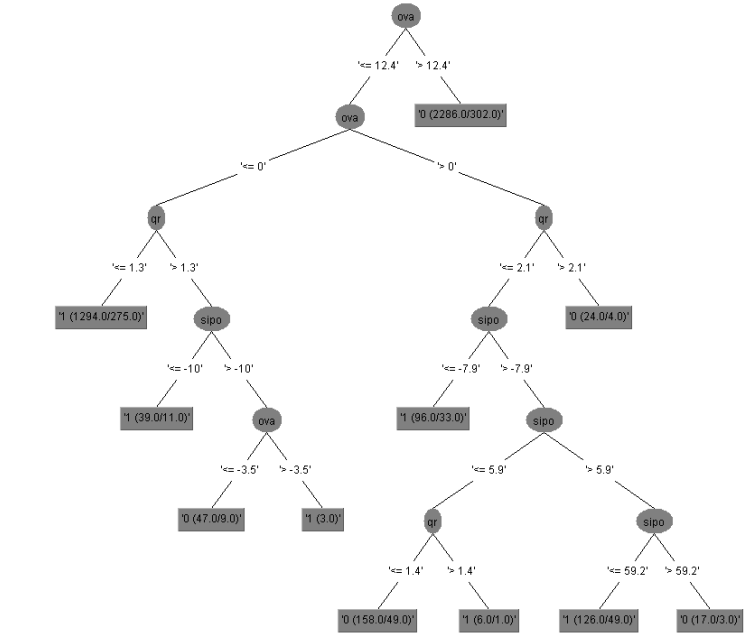
Witten I., Frank E. (2006) Data Mining. *Practical Machine Learning Tools and Techniques*. Second Edition. Morgan Kaufman Publishers. 560 s. ISBN: 978-0120884070.

LIITTEET


Liite 1. Koko aineiston kuvaus

1. Vuosi ennen konkurssia	Keskiarvo	Mediaani	Keskihajonta	U-testi
Käyttökate %	18,03	3,80	303,47	0,00
Liikevoitto %	-28,92	1,10	336,54	0,00
Quick ratio	3,26	0,80	18,76	0,00
Current ratio	4,32	1,10	29,28	0,00
Sij. pääoman tuotto %	3,57	2,40	71,41	0,00
Omavaraisuusaste %	45,14	20,30	471,05	0,00
Net gearing	1,00	-0,30	22,99	0,00
2. Vuosi ennen konkurssia	Keskiarvo	Mediaani	Keskihajonta	U-testi
Käyttökate %	-7,47	5,00	255,99	0,00
Liikevoitto %	17,22	2,20	313,82	0,00
Quick ratio	3,73	0,90	42,37	0,00
Current ratio	6,27	1,20	118,46	0,00
Sij. pääoman tuotto %	2,98	5,20	62,40	0,00
Omavaraisuusaste %	-4,03	23,10	263,68	0,00
Net gearing	2,82	-0,10	91,18	0,00
3. Vuosi ennen konkurssia	Keskiarvo	Mediaani	Keskihajonta	U-testi
Käyttökate %	-4,03	5,70	18,68	0,00
Liikevoitto %	-11,30	2,65	226,95	0,00
Quick ratio	3,03	1,00	14,23	0,00
Current ratio	4,08	1,30	24,78	0,00
Sij. pääoman tuotto %	6,32	5,90	81,53	0,00
Omavaraisuusaste %	6,21	24,20	215,53	0,00
Net gearing	7,12	0,00	233,28	0,29

Liite 2. Päättöpuun rakenne yksi vuosi ennen konkurssia



Liite 3. Päättöpuun rakenne kaksi vuotta ennen konkurssia



Liite 4. Päättöpuun rakenne kolme vuotta ennen konkurssia

