

TAMPEREEN YLIOPISTO  
Taloustieteiden laitos

KÄYTETYIMPIEN TILINPÄÄTÖSPERUSTEISTEN KONKURSSIN  
ENNUSTAMISMENETELMIEN LAADULLINEN ARVIOINTI

Yrityksen taloustiede, laskentatoimi  
Pro gradu -tutkielma  
Joulukuu 2005  
Ohjaaja: Eeva-Mari Ihantola

Jussi Lahtinen

## TIIVISTELMÄ

Tampereen yliopisto	Taloustieteiden laitos; yrityksen taloustiede, laskentatoimi
Tekijä:	LAHTINEN, JUSSI
Tutkielman nimi:	Käytetyimpien tilinpäätösperusteisten konkurssin ennustamismenetelmien laadullinen arviointi
Pro gradu -tutkielma:	87 sivua, 3 liitesivua
Aika:	Joulukuu 2005
Avainsanat:	konkurssin ennustaminen, konkurssin ennustamismenetelmä, logit-analyysi, erotteluanalyysi, hermoverkot

---

Tutkielma käsittelee yritysten tilinpäätöstietojen perusteella suoritettavaa konkurssin ennustamista. Konkurssin ennustaminen tilinpäätösanalyysin avulla perustuu olettamukseen, jonka mukaan konkurssiyritysten ja toimintaansa jatkavien yritysten tunnusluvut eroavat toisistaan systemaattisesti. Tämä ero tulee esiin jo muutamia vuosia ennen konkurssia ja mahdollistaa konkurssin ennustamisen tilinpäätösaineistosta.

Tutkielman tavoitteena on arvioida laadullisesti käytetyimpiä konkurssin ennustamismenetelmiä. Menetelmien laadullisen arvioinnin perusteella annetaan suosituksia tiettyjen menetelmien käytöstä. Käytetyimpiä konkurssin ennustamismenetelmiä ovat yksittäiset tunnusluvut, erotteluanalyysi, regressioanalyysi, logit-analyysi, probit-analyysi, hermoverkot, rekursiivinen osittaminen, elonjäämisanalyysi sekä HIP-tutkimus. Nämä menetelmät arvioidaan tutkielmassa kehitettävällä konkurssin ennustamismenetelmien arviointikriteeristöllä. Kriteeristöön kuuluvat seuraavat kriteerit: käytön yleisyys, informaatioisältö, ymmärrettävyys, mallin rakentamisen ja käytön helppous, luokittelukyky, johdonmukaisuus, muutostensietokyky ja taustaoletusten todenmukaisuus.

Menetelmien kriteeristöön perustuvan laadullisen arvioinnin mukaan logit-analyysi osoittautui parhaaksi konkurssin ennustamismenetelmäksi. Logit-analyysi on tilastollinen, usean tunnusluvun painotettuun summaan ja logistiseen jakaumaan perustuva menetelmä. Se täytti arvioinnissa hyvin tai melko hyvin seitsemän kriteeriä kahdeksasta. Logit-analyysia on helppo käyttää, menetelmällä saa oikean ennusteen pääsääntöisesti kahdeksassa tai yhdeksässä tapauksessa kymmenestä sekä ennustustulos antaa myös tietoa ennusteen toteutumisen todennäköisyydestä. Vaihtoehtona logit-analyysille suositellaan erotteluanalyysia, joka täytti melko hyvin tai hyvin viisi kriteeriä. Logit-analyysin rinnalla suositellaan käytettävän neurolaskentaan perustuvia hermoverkkoja. Hermoverkkomenetelmä täytti erotteluanalyysin tapaan viisi kriteeriä. Osittain hermoverkkomenetelmä vaikutti erittäin lupaavalta, mutta paikoittaisten epäjohdonmukaisuuksien vuoksi menetelmää ei ole parasta käyttää ainoana ennustamismenetelmänä. Usein on hyödyllistä käyttää kahta hyväksi todettua menetelmää rinnakkain. Tutkielmassa suoritettun arvioinnin mukaan yksittäisten tunnuslukujen sekä HIP-tutkimuksen käyttöä konkurssin ennustamismenetelmänä ei suositella.

Tutkielman perusteella voidaan lausua, että useita vuosikymmeniä sitten kehitetyt selvästi yksinkertaisemmat tilastolliset konkurssin ennustamismenetelmät ovat edelleen kilpailukykyisiä uudempien, usein keinoälyä hyväksi käyttävien monimutkaisten menetelmien kanssa.

# SISÄLTÖ

1	JOHDANTO .....	4
1.1	Tutkielman tausta .....	4
1.2	Tutkielman tavoite ja tutkimusmenetelmät .....	7
1.3	Rajaukset .....	9
1.4	Keskeiset käsitteet .....	10
2	MENETELMIEN ARVIOINNISSA KÄYTETTÄVÄT KRITEERIT .....	12
2.1	Kriteerien esittely .....	12
2.2	Käytön yleisyys .....	13
2.3	Informaatioisisältö .....	13
2.4	Ymmärrettävyys .....	14
2.5	Mallin rakentamisen ja käytön helppous .....	15
2.6	Luokittelukyky .....	16
2.7	Johdonmukaisuus .....	17
2.8	Muutostensietokyky .....	17
2.9	Taustaoletusten todenmukaisuus .....	18
2.10	Kriteerien soveltaminen .....	19
3	KONKURSSIN ENNUSTAMINEN YKSITTÄISTEN TUNNUSLUKUIEN AVULLA .....	20
3.1	Periaatteet .....	20
3.2	William H. Beaverin malli .....	22
3.3	Arviointi .....	24
4	KONKURSSIN ENNUSTAMINEN TILASTOLLISILLA YHDISTELMÄLUKUMENETELMILLÄ .....	30
4.1	Periaatteet .....	30
4.2	Erotteluanalyysi .....	31
4.2.1	Edward I. Altmanin z-malli .....	32
4.2.2	Aatto Prihtin malli .....	35
4.3	Regressioanalyysi .....	38
4.4	Logit-analyysi .....	39
4.5	Probit-analyysi .....	41
4.6	Arviointi .....	42
5	KEINO- JA IHMISÄLYYN PERUSTUVAT KONKURSSIN ENNUSTAMISMENETELMÄT .....	51
5.1	Hermoverkot .....	51
5.2	Rekursiivinen osittaminen .....	55
5.3	Eloonjäämisanalyysi .....	58
5.4	HIP-tutkimus .....	60
5.5	Muita konkurssin ennustamisessa käytettyjä menetelmiä .....	63
5.6	Arviointi .....	65
6	YHTEENVETO JA PÄÄTELMÄT .....	78
	LÄHTEET .....	84
	Liite 1. ....	88
	Liite 2. ....	89
	Liite 3. ....	90

# 1 JOHDANTO

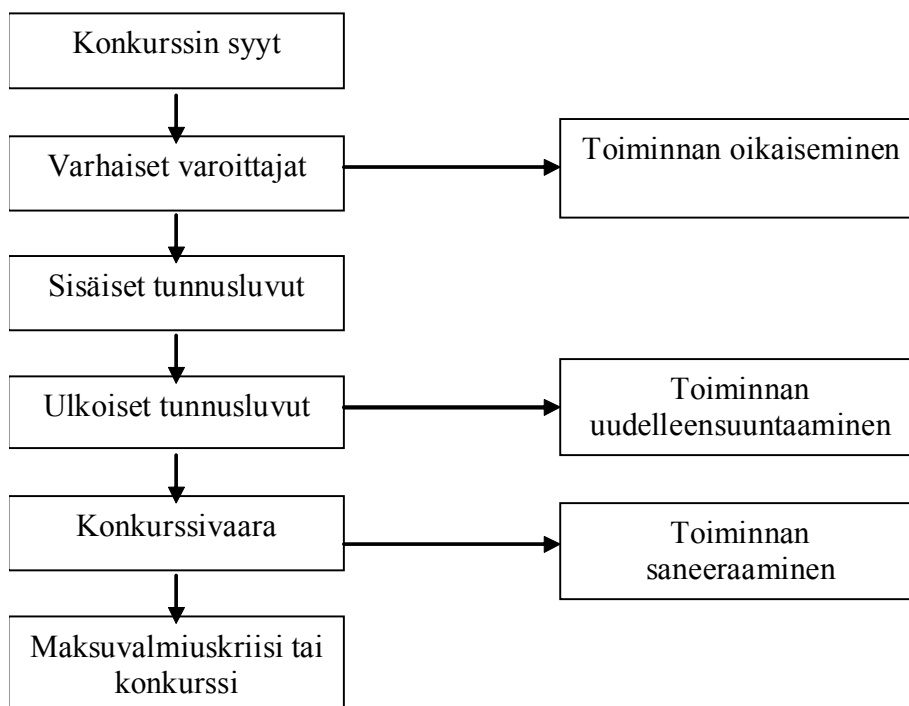
## 1.1 Tutkielman tausta

Tutkielma käsittelee yritysten konkurssien ennustamista. Yrityksen ajautuminen konkurssiin aiheuttaa tappioita yleensä kaikille sidosryhmille: velkojille, omistajille, toimittajille, asiakkaille, työntekijöille, yritysjohdolle ja niin edelleen. Myös kansantaloudellisesti ajateltuna konkurssiyrityksissä makaavat varat ovat tehottomassa käytössä. On tärkeää havaita konkurssiuhka mahdollisimman aikaisessa vaiheessa, jotta konkurssi voitaisiin vielä välttää. Välttäminen voi onnistua esimerkiksi suuntaamalla toimintaa kannattaviin tuotteisiin tai muuttamalla kustannusrakennetta. Jos tervettä pohjaa toiminnalle ei enää löydy, on parempi lopettaa toiminta silloin, kun yrityksellä on vielä pelastettavaa omaisuutta. Siksi konkurssin ennustamisen avulla pystytään vaikuttamaan myös konkurssin aiheuttamien tappioiden suuruuteen.

Konkurssiuhkaa mahdollisimman hyvin ennustavan tunnusluvun kehittäminen on erityisen tärkeää luotonantajille ja vakuuksien antajille. Myös oman pääoman ehtoisesti sijoittaville siitä on hyötyä. Kaikkien yrityksen toimintaan vaikuttavien asiakkaiden, hankkijoiden ja kilpailijoiden yksityiskohtainen seuranta olisi vaivalloista ja kallista ja sen takia usein mahdotonta toteuttaa käytännössä. Näin ollen päätettäessä sidosyrityksen seurannan suuntaamisesta konkurssia ennustavasta tunnusluvusta on erityistä hyötyä, vaikka tunnusluku ei kykenisikään täydellisesti erottamaan konkurssiuralla olevia yrityksiä terveistä. Yritys voi voimavarojensa mukaan valita sen riskitason, jonka se on valmis kantamaan suorittamansa seurannan laajuudesta ja syvyydestä päättäessään. (Leppiniemi & Leppiniemi 1997, 259–260)

Yrityksen konkurssikehitys etenee niin, että ensin ilmaantuvat konkurssin syyt. Niitä kutsutaan *varhaisiksi varoittajiksi*. Niiden havaitseminen vaatii yleensä yrityksen sisäisten rakenteiden tuntemusta ja on siten vaikeaa yrityksen henkilöstön ulkopuolisille. Lisäksi varhaisia varoittajia on usein hankalaa mitata numeerisesti. Esimerkkinä konkurssin syistä eli varhaisista varoittajista on yritysjohton virheellisiin arvioihin perustunut investointi. Konkurssin syyt alkavat vähitellen näkyä oireina yrityksen tilinpäätöstiedoissa. Tilinpäätöstietoja kutsutaan *myöhäisiksi varoittajiksi*. Tilinpäätöstietoja voidaan käyttää tehokkaan hälytysjärjestelmän rakentamiseen, vaikka sen antaman hälytyksen varhaisuus, tarkkuus ja luotettavuus eivät olekaan yhtä hyviä kuin sisäisiin

tietoihin perustuvissa vastaavissa järjestelmissä. Parhaimmillaan hälytys on kuitenkin saatavissa jo vuosia ennen mahdollisen konkurssin sattumista, jolloin toiminnan korjaamiseen ja uudelleen suuntaamiseen on vielä mahdollista vaikuttaa. Kuvio 1 havainnollistaa yritysten konkurssikehityksen eri vaiheita ja mahdollisia korjaustoimenpiteitä konkurssin välttämiseksi. Tilinpäätöstietojen helppo saatavuus ja ymmärrettävyys ovat tärkeitä syitä siihen, että suurin osa konkurssin ennustamista koskevasta tutkimuksesta perustuu tilinpäätöstietoihin muun muassa tunnuslukujen muodossa. (Laitinen & Laitinen 2004, 19–22)



Kuvio 1. Konkurssin ennustaminen (Laitinen 1990, 10)

Konkurssin ennustaminen tilinpäätösanalyysin avulla perustuu olettamukseen, jonka mukaan konkurssiyritysten ja toimintaansa jatkavien yritysten tunnusluvut eroavat toisistaan systemaattisesti. Tämä ero on havaittavissa muutamia vuosia ennen konkurssia ja se mahdollistaa konkurssin ennustamisen tilinpäätösaineistosta. (Laitinen & Laitinen 2004, 27) Tilinpäätösperusteisessa konkurssin ennustamisessa käytetään *yksittäisiä tunnuslukuja* tai eri tunnuslukujen informaatiota yhdistäen ja muokaten muodostettavaa *yhdistelmälukua*. Tätä konkurssitunnuslukuna toimivaa yhdistelmälukua kutsutaan usein *z-luvuksi*.

Konkurssin ennustamistutkimuksissa pyritään toimivien ja konkurssiin ajautuneiden yritysten tilinpäätöksiä sisältävän otoksen avulla kehittämään malli, jolla voidaan luokitella nykyajan yritykset kaksiluokkaisesti toimintaansa jatkaviin ja lähitulevaisuudessa konkurssiin ajautuviin. Mallien rakentamisessa on käytetty lukuisia toisistaan paljon poikkeavia menetelmiä. Azizin ja Darin (2004, 2) mukaan konkurssin ennustamiseen sovelletut menetelmät voidaan jakaa kolmeen ryhmään:

- tilastolliset menetelmät,
- keinoälyyn perustuvat tietokoneavusteiset menetelmät ja
- teoreettiset menetelmät.

Konkurssin ennustaminen ei ole ilmiönä mitenkään uusi, sillä yritysten kyky selviytyä rahoituksen vaatimista velvoitteista on ollut kiinnostuksen kohteena jo ainakin 1800-luvun loppupuolelta alkaen. Tällöin yrityskoon kasvaessa johtajuus irtautui omistajuudesta, mikä voimisti luottolaitosten roolia kasvun rahoittamisessa. Tutkimus ei kuitenkaan ollut vielä silloin tieteellistä. (Laitinen & Laitinen 2004, 71–74) Tilinpäätöstietoihin eli myöhäisiin varoittajiin perustuva konkurssitutkimus yleistyi 1930-luvun laman aikana. Silloin tyypillinen tapa kehittää ennustusmenetelmä oli verrata toisiinsa vaikeuksissa olevien ja menestyneiden yritysten tunnuslukuja. Samantyyppisiä tutkimuksia tehtiin myös seuraavina vuosikymmeninä. (Laitinen 1990, 39)

Vasta 1960-luvulla konkurssin ennustamistutkimus kehittyi merkittävästi. Beaver (1966) julkaisi *yksittäisiin tunnuslukuihin* perustuvan tutkimuksen konkurssin ennustamisesta. Hänestä tuli tämän lähestymistavan uranuurtaja, ja tutkimusta pidetään alan klassikkona (Laitinen 1990, 39–40). Altman (1968) jatkoi konkurssitutkimuksen klassikkosarjaa vielä samalla vuosikymmenellä. Altmanin konkurssin ennustamiseen kehittämässä mallissa käytettiin useaan tunnuslukuun perustuvaa yhdistelmälukua. Yhdistelmäluvun rakentamisessa menetelmänä oli *lineaarinen erotteluanalyysi* (Linear Discriminant Analysis, LDA), jossa erottelufunktio muodostuu tunnuslukujen painotetusta summasta (Laitinen & Laitinen 2004, 133). Konkurssia ennustavaa yhdistelmälukua alettiin kutsua z-luvuksi. Suomalaisen konkurssitutkimuksen uranuurtajana toimi Aatto Prihti, joka jatkoi yhdistelmäluvun kehittämistä (Laitinen 1990, 58). Uutta tässä tutkimuksessa oli se, että Prihti aiemmista tutkijoista poiketen perusteli teoreettisesti yhdistelmäluvussa käyttämiensä tunnuslukujen valinnan. Tunnuslukujen painottamisessa myös hän käytti lineaarista erotteluanalyysia. (Prihti 1975)

Mainittujen klassikkotutkimusten jälkeen tutkimus keskittyi pitkälti mallien ennustamistarkkuuden lisäämiseen. Malleja yritettiin kehittää muun muassa rakentamalla toimialakohtaisia malleja (esim. Platt & Platt 1990) ja tutkimalla mallien rakentamisessa käytettävän otoksen vaikutusta malleilla saataviin tuloksiin (esim. Platt & Platt 2002; Zmijewski 1984). Uusina menetelminä konkurssin ennustamiseen alettiin soveltaa *regressioanalyysia* (esim. Theodossiou 1991), *logit-analyysia* (esim. Ohlson 1980) ja *probit-analyysia* (esim. Skogsvik 1990). Laitisen (1990, 76) mukaan 70- ja 80-luvuilla tehtiin ylipäänsä paljon konkurssin ennustamista koskevia tutkimuksia. Tutkimuksissa käytettiin erilaisia lähestymistapoja, mutta suuria läpimurtoja ei Beaverin (1966) ja Altmanin (1968) tutkimusten jälkeen saavutettu.

Teknologian ja tietokoneiden kehityksen seurauksena konkurssin ennustamiseen alettiin 80- ja 90-luvuilla soveltaa uusia menetelmiä. Azizin ja Darin (2004, 12–13) mukaan yhteistä näille menetelmille on se, että ne yrittävät koneellisesti hyödyntää ihmisten kognitiivisia toimintoja esimerkiksi konkurssin ennustamisen kaltaisten ongelmien ratkaisemisessa. Näitä menetelmiä voidaan kutsua keinoälyllisiksi asiantuntijajärjestelmiksi (Artificially Intelligent Expert Systems, AIES). Tällaisia menetelmiä ovat muun muassa *rekursiivinen osittaminen*, *eloonjäämisanalyysi*, *neurolaskenta (hermoverkot)* ja *HIP (Human Information Processing)*-tutkimus (Laitinen & Laitinen 2004, 144–168). Näistä etenkin ihmisen aivotoimintoja jäljittelevien hermoverkkojen soveltuvuutta konkurssin ennustamiseen on tutkittu paljon (mm. Yang, Platt & Platt 1999; Altman, Marco & Varetto 1994; Tam & Kiang 1992).

## **1.2 Tutkielman tavoite ja tutkimusmenetelmät**

Konkurssin ennustamista käsittelevässä tutkimuskentässä on erityisen mielenkiintoista se, että vaikka ala on houkutelut hyvinkin erilaisia menetelmiä soveltavia tutkijoita monien vuosikymmenien ajan, edelleenkin ei ole onnistuttu kehittämään riittävän hyvää konkurssin ennustamismallia. Tämä voidaan päätellä siitä, että jokaiselle kehitetylle mallille on annettu kritiikkiä ja uusien menetelmien soveltaminen ja mallien kehittäminen jatkuu edelleen. Mielenkiintoista on myös se, että jo 30 vuotta sitten kehitetyillä täysin erilaisilla menetelmillä saatetaan saada vertailukelpoisia tuloksia viime vuosina kehitettyjen monimutkaisempien menetelmien kanssa.

Konkurssin ennustamismenetelmien laaja kirjo ja yksimielisesti parhaan menetelmän löytymättömyys aiheuttavat sen, että konkurssia ennustettaessa on vaikea valita, mitä menetelmää kannattaa käyttää. Tässä tutkielmassa pyritään helpottamaan käytettävän konkurssin ennustamismenetelmän valintaa. *Tutkielman tavoite on arvioida laadullisesti käytetyimpiä tilinpäätösperusteisia konkurssin ennustamismenetelmiä.* Arvioinnilla pyritään siihen, että tutkielman päätelmäosuudessa voidaan antaa suosituksia siitä, mitä konkurssin ennustamismenetelmää tai menetelmiä kannattaa yritysarvioita tehtäessä soveltaa. Tutkimusaihe on relevantti, sillä konkurssin ennustamismalleja käyttämällä voidaan saada helposti ja vaivattomasti tietoa yrityksen talouden lähitulevaisuudesta. Tällaiselle tiedolle on monenlaista käyttöä erilaisissa yritysanalyysitilanteissa. Toisaalta lukuisista konkurssin ennustamistutkimuksista huolimatta eri menetelmien käytettävyyden arviointia on vähän saatavilla. Etenkin kattavasti eri menetelmät sisältävää yhtenäistä teoreettista arviointia ei juuri ole tehty. Näin ollen perinteisten ja uudempien menetelmien arvioinnin yhdistävälle tutkielmalle on tarvetta.

Tutkielma toteutetaan teoreettisesti kvalitatiivisena tutkimuksena. Tutkielma ei sisällä itse koottua empiiristä yritysaineistoa. Suomalaisia liiketaloustieteen tutkimuksia luokiteltaessa on käytetty paljon Neilimon ja Näsin (1980) tutkimusoteluokittelua. Tämä tutkielma sisältää eniten päätöksentekometodologisen tutkimusotteen piirteitä. Päätöksentekometodologinen tutkimusote tähtää päätöstilanteiden ymmärtämiseen niitä mallintamalla ja ongelmanratkaisumetodien kehittämiseen. Tämän tutkielman taustalla on päätöstilanne siitä, mitä konkurssin ennustamismenetelmää käyttäjän tulisi soveltaa. Tätä ongelmaa mallinnetaan esittelemällä useita eri konkurssin ennustamismenetelmiä, jolloin valinnan vaikeus ilmenee. Ongelmanratkaisumetodiksi kehitetään seuraavassa pääluvussa konkurssin ennustamismenetelmien arviointikriteeristö. Päätöksentekometodologiselle tutkimusotteelle on tyypillistä normatiivinen luonne. Sekin tukee tämän tutkielman sijoittumista päätöksentekometodologiselle alueelle, sillä menetelmien laadullisen arvioinnin kautta pyritään antamaan suosituksia tai ohjeita tiettyjen menetelmien käytöstä.

Tutkimuksessa esitellään mahdollisimman kattavasti kaikki sellaiset konkurssin ennustamismenetelmät, jotka eivät kuulu seuraavassa luvussa tutkimuksen ulkopuolelle rajattaviin. Tutkielmassa käytettävä aineisto on kerätty pääosin eri kirjastoista ja tietokannoista. Perustellusti käytetyimpien menetelmien laadullinen arviointi suoritetaan yhtenevän kriteeristön avulla. Perustelu ilmenee etenkin siten, että menetelmien arvioinnissa käytön yleisyyden kriteerin kohdalla löytyy lähdeviittauksia tutkimuksiin, joissa kutakin menetelmää on sovellettu.



### 1.3 Rajaukset

Tutkimuksen ulkopuolelle rajataan konkurssin ennustamisessa käytetyt *varhaiset varoittajat* eli tiedot, jotka saadaan yrityksestä suoraan havainnoimalla ja päättelemällä toiminnan hyvän tuntemuksen seurauksena. Tämä rajaus johtuu siitä, että näitä usein vain sisäpiiriläisten laadullisia tietoja on vaikea saada käyttöönsä, ne voivat olla hankalasti tunnistettavissa ja etenkin niiden mittaaminen on usein vaikeaa. Luultavasti juuri nämä ovat syitä siihen, että konkurssin varhaisia varoittajia ei ole tutkittu läheskään niin paljon kuin myöhäisiä varoittajia eli tilinpäätöstietoja. Varhaisiin varoittajiin perustuvien menetelmien rajaaminen johtaa siihen, että tutkielma ei käsittele esimerkiksi Argentin (1976) kuuluisaa konkurssitutkimusta (ks. Laitinen & Laitinen 2004, 103–113). Tutkielman ulkopuolelle rajataan myös sellaiset konkurssin ennustamismenetelmät, jotka yhdistelevät tilinpäätösinformaatiota ja sen ulkopuolista informaatiota. Täten esimerkiksi Shumwayn (2001) tilinpäätösinformaatiota ja muun muassa osaketuottoja yhdessä käyttävä tutkimus jää käsittelyn ulkopuolelle. Tämä rajaus johtuu siitä, että tutkielmassa paneudutaan tilinpäätösperusteiseen konkurssin ennustamiseen.

Tutkielman tulokset ovat yleistettävissä paremmin isojen yritysten konkurssien ennustamiseen kuin pienten yritysten. Keaseyn ja Watsonin (1991, 96) mukaan pienten yritysten tilinpäätöksistä saatavien tunnuslukujen ennustuskyky on isoja yrityksiä heikompi. Siksi he suosittelevat pienten yritysten konkurssien ennustamiseen käytettävän tilinpäätösinformaation lisäksi tilinpäätöksen julkaisemisviiveen kaltaisia tekijöitä. Tässä tutkielmassahan paneudutaan vain tilinpäätösperusteiseen konkurssin ennustamiseen, joten tulokset ovat validimpia isojen yritysten kohdalla.

Tutkimus ei sisällä Beaverin (1966) yksittäisiä tunnuslukuja soveltavan tutkimuksen edeltäviä konkurssin ennustamismenetelmiä. Nämä aikaisemmat tutkimukset eivät olleet niin arvokkaita, että olisivat säilyneet vertailukelpoisina myöhempien vuosikymmenten tutkimusten kanssa. Beaverin tutkimus oli alalla ensimmäinen, joka sisälsi merkittävästi uutta. Ehkä siksi siitä muodostuikin ensimmäinen alan klassikotutkimus. (Laitinen 1990, 39)

## 1.4 Keskeiset käsitteet

Tutkimuksen keskeisin käsite on *konkurssi*. Yrityksen konkurssilla tarkoitetaan sen maksuvaateiden täytäntöönpanoa koskevaa menettelyä, jossa yrityksen koko ulosmittauskelpoinen omaisuus käytetään yhdellä kertaa velkojien saamisten maksamiseen. Konkurssin päämääränä on yrityksen varojen oikeudenmukainen ja tasapuolinen jakaminen velkojien kesken. Tasapuolisuus ei aina toteudu, koska velkojat ovat vakuusjärjestelyjen takia eri asemassa konkurssissa. Konkurssin seurauksena yrityksen toiminta luonnollisesti loppuu. Konkurssimenettely koskee kaikkia yhtiömuotoja. Epäselvyyksien välttämiseksi on hyvä huomata, että usein konkurssiin sekoitettava selvitystila koskee vain osakeyhtiöitä. Selvitystila perustuu havaittuun pääomavajaukseen, joka on vielä mahdollisesti korjattavissa. Täten selvitystila ei lopeta yrityksen toimintaa toisin kuin konkurssi. (Laitinen 1990, 36)

Tilinpäätösperusteisessa konkurssin ennustamisessa pyritään yritysten tilinpäätöksiä eri tavoin hyväksi käyttäen antamaan ennustus siitä, kuuluuko yritys toimintaansa jatkavien vai konkurssiin lähitulevaisuudessa ajautuvien joukkoon. Luokiteltaessa näin yrityksiä syntyy väkisin virheitä, joita on kahdentyyppisiä. Jos konkurssiyritys luokitellaan erehdyksessä toimivaksi, tehdään *tyypin I virhe*. Jos sen sijaan toimiva yritys luokitellaan konkurssiyritykseksi, tehdään *tyypin II virhe*. *Kokonaisluokitteluvirhe* saadaan selville laskemalla tyypin I ja II virheluokitusten yhteismäärä prosentteina kaikkien luokitusten (yritysten) lukumäärästä. Luokitteluvirheiden suuruus riippuu muuttujalle (yleensä konkurssitunnusluvulle) valitusta *kriittisestä arvosta*, jonka perusteella yritykset jaetaan kaksiluokkaisesti konkurssiyrityksiin ja toimiviin yrityksiin. Kriittisen arvon valinnalla voidaan painottaa eri virhetyyppien osuuksia, sillä monissa tilanteissa toinen virhetyyppi on epäedullisempi kuin toinen. Toisen virhetyypin osuus saatetaan haluta mahdollisimman pieneksi, vaikka samalla toisen virhetyypin esiintymistiheys kasvaakin. Usein kriittinen arvo valitaan kuitenkin siten, että kokonaisluokitteluvirhe jää mahdollisimman pieneksi. Tällöin virhetyyppien painotus on yhtä suuri. (Laitinen 1990, 40)

Tutkielmassa esiintyy sekä konkurssin *ennustamismenetelmiä* että konkurssin *ennustamismalleja*. *Ennustamismenetelmät* ovat keinoja, joilla rakennetaan yksittäisiä konkurssin *ennustamismalleja*. Rakentamiseen kuuluvat esimerkiksi muuttujien eli tunnuslukujen valinta ja niiden välisten suhteiden määrittäminen. Yhdellä *menetelmällä* voidaan siis rakentaa useita eri *malleja*. Esimerkiksi eri toimialoille voi olla syytä estimoida omat mallinsa, kuten myös eri ajanjaksoina suoritettaville

ennustuksille. Toisaalta samaan yritysarviointitilanteeseen voidaan soveltaa usealla eri menetelmällä rakennettuja useita malleja, jos halutaan vahvistusta yhden menetelmän tuottamalle arviolle. Konkurssin *ennustamismenetelmiä* ovat muun muassa erotteluanalyysi ja rekursiivinen osittaminen. Konkurssin *ennustamismalleja* sen sijaan ovat esimerkiksi Altmanin z-malli ja zeta-malli.

## 2 MENETELMIEN ARVIOINNISSA KÄYTETTÄVÄT KRITEERIT

### 2.1 Kriteerien esittely

Tutkielmassa arvioidaan kvalitatiivisesti käytetyimmät konkurssin ennustamismenetelmät. Jotta arviointiin saataisiin syvällisyyttä ja oikeudenmukaisuutta, se suoritetaan kaikkien arvioitavien menetelmien osalta yhdenmukaisesti. Tätä varten laaditaan kriteeristö, jonka sisältämien kriteerien perusteella voidaan antaa arvioita menetelmistä. Jokainen kriteeristöön valittu kriteeri täyttää seuraavat ehdot:

- kriteerin on mitattava menetelmän käytettävyyden kannalta olennaista seikkaa ja
- kriteerin on tehtävä eroja eri menetelmien välille.

Jos ensimmäinen ehto ei täytyisi, kriteeri olisi täysin hyödytön tutkielman tavoitteen kannalta, sillä tutkielmassa pyritään kvalitatiivisen arvioinnin avulla löytämään käyttökelpoisimmat menetelmät. Toinen ehto on perusteltavissa sillä, että olisi hyödytöntä arvioida menetelmiä sellaisen seikan kannalta, jonka kaikki menetelmät yhtä hyvin täyttävät. Sellainen kriteeri ei toisi lisäarvoa menetelmien arviointiin eikä täten auttaisi tutkimuksen tavoitteen saavuttamisessa. Taulukossa 1 on esitetty konkurssin ennustamismenetelmien arvioinnissa käytettävään kriteeristöön valitut kriteerit. Seuraavissa luvuissa esitellään kriteerit tarkemmin ja perustellaan kunkin kriteerin osalta, miksi se on sisällytetty kriteeristöön.

Taulukko 1. Konkurssin ennustamismenetelmien arvioinnissa käytettävät kriteerit

- 
1. Käytön yleisyys
  2. Informaatiosisältö
  3. Ymmärrettävyys
  4. Mallin rakentamisen ja käytön helppous
  5. Luokittelukyky
  6. Johdonmukaisuus
  7. Muutostensietokyky
  8. Taustaoletusten todenmukaisuus
-

## 2.2 Käytön yleisyys

*Käytön yleisyys* on tärkeä kriteeri, sillä se mittaa tutkijoiden kiinnostusta kutakin menetelmää kohtaan. Tietyn menetelmän soveltaminen useissa tutkimuksissa kertoo menetelmän käyttökelpoisuudesta, sillä muussa tapauksessa sitä tuskin olisi toistuvasti käytetty paljon tutkitulla konkurssin ennustamisalalla. Kriteerin etuna on siis se, että se yhdistää usean eri tutkijan mielipiteet. Käytetyimmille menetelmille on tyypillistä se, että niitä on sovellettu monissa tutkimuksissa yritettäessä rakentaa entistä toimivampia konkurssin ennustamismalleja. Menetelmä on siis usein pysynyt samana, mutta joitakin tekijöitä on saatettu muuttaa. Tällaisista tekijöistä on esimerkkinä toimialaerojen huomiointi mallien rakentamisessa (Platt & Platt 1990). Toisaalta eräät menetelmät ovat jo yhden tai kahden tutkimuksen perusteella osoittautuneet konkurssin ennustamiseen huonosti soveltuviksi.

Konkurssin ennustamistutkimuksille on tyypillistä se, että usein ensin esitellään tutkimuksessa käytettävä uusi menetelmä ja sitten verrataan sillä saatuja tuloksia jollakin aiemmin kehitetyllä menetelmällä saatuihin tuloksiin (esim. Min & Lee 2005; Tam & Kiang 1992). Se, mihin menetelmään uusia menetelmiä verrataan, antaa myös tietoa *käytön yleisyydestä*. *Käytön yleisyyden* kriteerin osalta hyvin menestyviä menetelmiä on käytetty konkurssin ennustamiseen tämän tutkielman lähdeaineiston perusteella vähintään kymmenessä tutkimuksessa. On mahdollista, että tämän tutkielman lähdeaineisto ei edusta parhaalla mahdollisella tavalla koko laajaa konkurssitutkimusjoukkoa, jolloin *käytön yleisyyden* arviointi joidenkin menetelmien kohdalla saattaa vääristyä. *Käytön yleisyyden* arvioinnille on tutkielmassa kuitenkin paljon perusteita, sillä lähdeaineisto sisältää muun muassa Azizin ja Darin (2004) sekä Dimitrasin, Zanakisin ja Zopounidisin (1996) tutkimukset, joissa listataan yhteensä 148 konkurssitutkimusta muun muassa käytetyn menetelmän osalta. Rajanveto kymmeneen *käytön yleisyyden* arvioinnissa perustellaan sillä, että kymmenessä tutkimuksessa esiintyminen kertoo vähintään melko suuresta kiinnostuksesta menetelmää kohtaan. Kymmeneen asetettu raja tekee kriteereille asetettujen vaatimusten mukaisesti myös eroja menetelmien välille.

## 2.3 Informaatioisältö

*Informaatioisältö* kertoo ensisijaisesti siitä, sisältääkö tietyllä menetelmällä rakennettu konkurssin ennustamismalli monipuolisesti informaatiota ennustettavan yrityksen taloudellisesta tilanteesta.

Malleissa käytettävät tunnusluvut mittaavat yrityksen talouden eri ulottuvuuksia, joita Niskasen ja Niskasen (2000) mukaan ovat kannattavuus, vakavaraisuus ja maksuvalmius. Kullakin eri ulottuvuudella saattaa olla paljon vaikutusta yrityksen konkurssiin ajautumisen todennäköisyyteen. Toisaalta yhden ulottuvuuden tunnusluvun huono arvo ei välttämättä ole kokonaistilanteen kannalta hälyttävää. Esimerkiksi hetkellisesti huono maksuvalmius saattaa lähitulevaisuudessa korjaantua, jos yrityksen kannattavuus on hyvä. Laitinen (1990, 227) on havainnut, että kaikki konkurssiyritykset eivät käytäydy samalla lailla ennen konkurssia. Hän on tunnistanut kolme eri konkurssityyppiä (Laitinen 1990, 227). Täten konkurssin ennustamismallinkin tulisi sisältää mahdollisimman paljon informaatiota, jotta se pystyisi ennustamaan erilaisia konkurssiprosesseja.

*Informaatioisältöä* arvioidaan toissijaisesti menetelmän antaman tuloksen informatiivisuuden kannalta. Joissakin menetelmissä tulos on vain luku, josta päätellään yrityksen sijoittuminen konkurssiyritysten tai toimintaansa jatkavien yritysten luokkaan. Toisten menetelmien tuloksista voidaan tehdä päätelmiä myös konkurssin tai toiminnan jatkumisen todennäköisyydestä, mikä parantaa niiden *informaatioisältöä*.

## 2.4 Ymmärrettävyys

*Ymmärrettävyydellä* halutaan mitata sitä, kykeneekö konkurssin ennustamismallin käyttäjä ymmärtämään tietyllä menetelmällä rakennetun mallin toimintaperiaatteen. Eri menetelmät eroavat siinä, miten niillä tuotetut mallit käsittelevät syötteinä toimivia tunnuslukuja. Käsittely voi olla esimerkiksi kerto- ja yhteenlaskua tai monimutkaista tiedon prosessointia. Kaikilla menetelmillä päädytään lopulta siihen, että yritys luokitellaan joko konkurssiyritykseksi tai toimintaansa jatkavaksi.

Hyvänä esimerkkinä mallien toimintaperiaatteiden *ymmärrettävyydestä* on erotteluanalyysin ja neurolaskennan tuottamien hermoverkkojen vertailu. Erotteluanalyysilla rakennetussa mallissa saattavat konkurssitunnusluvun muodostaa summamuotoisesti yhdistetyt kannattavuutta, maksuvalmiutta ja velkaantuneisuutta mittaavat tunnusluvut, joista kahdella ensimmäisellä on positiivinen kerroin ja viimeisellä negatiivinen kerroin. Tästä käyttäjä voi päätellä muun muassa sen, että yrityksen velkaantuneisuuden lisääntyessä konkurssitunnusluvun arvo pienenee, joten konkurssin todennäköisyys kasvaa. Ennustamismallin toimintaperiaatteen ymmärtäminen herättää luottamusta käyttäjässään. Neurolaskentamenetelmässä käyttäjä antaa verkkomallille tietyt

tunnuslukusyötteet, joista verkko laskee tietokoneavusteisesti lopputulokseksi konkurssitunnusluvun, josta päätelmät yrityksen kohtalosta tehdään (esim. Altman ym. 1994, 505–529). Käyttäjä ei voi havainnoida tietokonepohjaisen monimutkaisen mallin toimintaperiaatteita, joilla ratkaisuun on päästy. Tämän takia käyttäjän oman harkinnan ratkaistavaksi jää, onko ennustamistulos luotettava.

## 2.5 Mallin rakentamisen ja käytön helppous

*Mallin rakentamisen ja käytön helppous* on käyttäjien kannalta tärkeä kriteeri, joka nimensä mukaisesti mittaa menetelmän käytettävyyttä kahdesta ulottuvuudesta. *Mallin rakentamisen helppoutta* arvioidaan sen takia, että tutkimuksessa halutaan arvioida konkurssin ennustamismenetelmiä, joilla yksittäisiä ennustamismalleja voidaan rakentaa. Konkurssin ennustamistutkimuksille on tyypillistä, että jollakin menetelmällä aiemmin kehitetyt ja hyvänä pidetyt mallit on yleensä myöhemmissä tutkimuksissa todettu selvästi heikommiksi kuin alkuperäisessä mallin kehittämistutkimuksessa. Syitä tähän ovat muun muassa mallien sidonnaisuus siihen toimialaan, jonka yrityksistä malli on rakennettu (Grice & Dugan 2001; Grice & Ingram 2001; Platt & Platt 1990) sekä esimerkiksi makrotekijöiden aiheuttama mallin ajallinen sidonnaisuus rakennushetken aineistoon (Grice & Dugan 2001). Tämän takia yritysarvioita pitäisi tehdä sellaisilla konkurssin ennustamismalleilla, jotka on rakennettu arviointitilannetta vastaavissa olosuhteissa. Tämä johtaa siihen, että vaikka käyttäjä suosisikin tiettyä konkurssin ennustamismenetelmää, hänen tulisi kyetä rakentamaan menetelmänsä avulla uusi malli ajallisesti tai toimialallisesti poikkeavissa arviointitilanteissa. Siksi sillä, kuinka helposti malli on rakennettavissa, on merkitystä. Vertailuesimerkkeinä *mallien rakentamisen helppoudesta* eri menetelmien välillä mainittakoon yksittäiset tunnusluvut ja hermoverkot. Yksittäisten tunnuslukujen ennustuskykyä on helppo ja nopea testata uudessa yritysaineistossa, mutta verkkorakenteen opettaminen tarkaksi konkurssin ennustajaksi saattaa olla hyvin hidasta (esim. Pendharkar 2005, 2565).

Kriteerin toisena ulottuvuutena toimii *mallin käytön helppous*, jonka avulla arvioidaan sitä, kuinka paljon käyttäjän on nähtävä vaivaa tuloksen saamiseen. Olennaista on syötteiden antamisen vaiva ja mallin laskemiseen tarvittavat apuvälineet. *Käytön helppoudellakin* on merkitystä, sillä menetelmiin liittyvien epävarmuustekijöiden takia voidaan suositella usean eri menetelmän käyttöä samaan arviointitilanteeseen. Tällöin on hyödyllisempää saada kahden nopean menetelmän tulos käyttöönsä

yhtä nopeasti kuin yhden hidaskäyttöisen menetelmän. *Mallin rakentamisen ja käytön helppouden* arviointi on sisällytetty samaan kriteeriin, sillä ulottuvuudet ovat sisällöllisesti lähellä toisiaan. Lisäksi joidenkin menetelmien osalta voi olla vaikea arvioida pelkästään mallin käytön helppoutta, joten käytön helppoudella yksinään ei olisi muihin kriteereihin verrattavaa lisäarvoa tutkielman tulosten kannalta.

## 2.6 Luokittelukyky

*Luokittelukyky* eli menetelmän ennustustarkkuus on luonnollisesti erittäin tärkeä kriteeri menetelmien arvioinnissa. Mahdollisimman tarkasti yritykset konkurssiin ajautuviin ja toimintaansa jatkaviin luokitteleva menetelmä on käyttäjälle arvokkaampi kuin epätarkkoja ennusteita antava. *Luokittelukykyä* arvioidaan itse suoritettavan empiirisen testauksen sijaan mahdollisimman monen eri tutkimuksen tulosten perusteella. Tavallisesti kaikilla menetelmillä on niiden esittelytutkimuksissa saatu hyviä tuloksia. Myöhemmissä tutkimuksissa samoilla menetelmillä saadut tulokset ovat usein kuitenkin heikentyneet tai jollakin muulla menetelmällä on saatu vielä parempia tuloksia. Tämän takia *luokittelukykyä* on syytä arvioida usean eri tutkimuksen perusteella, jos vain se on mahdollista.

Eri menetelmien *luokittelukykyyn* arvioinnissa käytetään ensisijaisena kriteerinä luokittelun tarkkuutta vuotta ennen konkurssia. Toissijainen kriteeri on luokittelukykyyn säilyminen useiden vuosien päähän ennen konkurssia. Tämä menettely johtuu siitä, että kaikissa tutkimuksissa julkaistaan saadut luokittelutulokset ainakin vuotta ennen konkurssia. Useimmissa tutkimuksissa julkaistaan tulokset myös kahta tai kolmeakin vuotta ennen konkurssia, mutta vain joissakin tutkimuksissa viittä vuotta ennen konkurssia. Käyttämällä ensisijaisesti vuoden päähän ulottuvia arvioita saadaan eniten dataa kunkin menetelmän *luokittelukykyyn* arvioinnin pohjaksi. *Luokittelukykyä* arvioidaan ensisijaisesti tutkimuksissa käytettävien testiotosten tulosten perusteella. Estimointiotoksen tulokset ovat tutkimuksissa yleensä parempia, mikä johtuu siitä, että mallit luodaan estimointiotoksen perusteella. Tällöin mallit tehdään sellaiseksi, että ne luokittelevat estimointiotoksen yritykset mahdollisimman tarkasti. Mallit ovat kuitenkin usein riippuvaisia estimointiotoksesta, jolloin ne eivät toimi yhtä hyvin sen ulkopuolella. Tutkimuksissa käytetäänkin usein testiotoksia, jotta saadaan tietoa ennustuskykyyn yleispätevyydestä. Yleispätevän *luokittelukykyyn* selvittämiseksi tässä tutkielmassa pyritään käyttämään testiotostuloksia aina kun se on mahdollista.



*Luokittelukyky* on kiistämättä yksi tärkeimmistä kriteereistä. Konkurssin ennustaminen perustuu siihen olettamukseen, että on mahdollista kehittää malli, joka luokittelee yritykset mahdollisimman tarkasti konkurssiyrityksiksi ja toimintaansa jatkaviksi. Tämän takia sellaisilla menetelmillä, joilla ei kyetä rakentamaan edes kohtalaisen tarkasti ennustavaa mallia, ei ole arvoa konkurssin ennustamisen alalla. Tutkielmassa arviointiin sisällytetyt menetelmät ovat luokittelukyvyltään vähintään kohtalaisia, sillä muuten niitä ei kannattaisi muiden kriteerien osalta edes arvioida. Erot luokittelukyvyyn suhteen syntyvät siten siitä, onko menetelmä kohtalainen vai hyvä luokittelija. Hyvänä luokittelijana pidetään pääsääntöisesti yli 85 prosentin tarkkuuden saavuttavia menetelmiä. Siihen asetettu raja tekee kriteerien vaatimusten mukaisesti eroja menetelmien välille.

## **2.7 Johdonmukaisuus**

Konkurssin ennustamismallin *johdonmukainen* toiminta on edellytys käyttäjän kokeman luotettavuuden saavuttamiselle. Käyttäjä kokee varmasti tärkeäksi sen, että tunnusluvuiltaan tasavertaiset yritykset saavat myös samanlaisen ennusteen mahdollisesta konkurssista. Johdonmukaisuutta on myös se, että kaikki tulokset ovat tulkittavissa.

*Johdonmukaisuuden* kriteeri on sisällytetty kriteeristöön muun muassa siksi, että neuro-laskennalla tuotettujen hermoverkkojen monesti tarkoiksi todetuista ennustustuloksista huolimatta ne eivät aina toimi johdonmukaisesti (Altman ym. 1994, 526–527). Esimerkkinä hermoverkkojen epäjohdonmukaisuudesta on tilanne, jossa edelliseen yritysarviotilanteeseen verrattuna syötteet pidetään muuten samoina, mutta vakavaraisuutta mittaavaa tunnuslukua parannetaan hieman. Tällöin verkon tekemien laskutoimitusten lopputuloksena saatava konkurssitunnusluku saattaaakin järjenvastaisesti heikentyä. Tällainen epäjohdonmukainen toiminta herättää käyttäjässä luonnollisesti epäluottamusta menetelmää kohtaan.

## **2.8 Muutostensietokyky**

*Muutostensietokyvyllä* tarkoitetaan menetelmän muuntautumiskykyä uusiin olosuhteisiin, joita konkurssin ennustamismallit väistämättä kohtaavat. Esimerkiksi IFRS-standardit muuttavat monien tilinpäätöserien laskentaperusteita, jolloin aiempien säännösten mukaisesti estimoidut konkurssin ennustamismallit vanhenevat. Pelkästään ajan kulumisen aiheuttaa muutoksia yritysten

taloudellisessa toimintaympäristössä. Toiset mallit saattavat toimia hyvin myös eri toimialojen yrityksillä kuin mistä ne on rakennettu, jolloin niiden toimialallinen muutostensietokyky on hyvä. Eri menetelmillä rakennetut mallit sietävät muutoksia eri tavoilla. Siksi muutostensietokykyä on syytä arvioida kunkin menetelmän osalta. Esimerkiksi logit-analyysillä rakennettu yhdistelmäluke joudutaan todennäköisesti rakentamaan täysin uudestaan tunnuslukusyötteiden laskentaperusteiden muututtua. Tällöin pitää testata uusien säännösten perusteella laskettujen tunnuslukujen ennustuskyky yksinään ja yhdessä muiden tunnuslukujen kanssa sekä arvioida tunnuslukujen painotukset uudelleen.

Hermoverkot sen sijaan saattavat sopeutua uuteen tilanteeseen nopeasti, sillä niitä voidaan opettaa uusien säännösten perusteella laskettujen yritysten tunnuslukeaineistojen avulla. Oppimiskierrosten jälkeen verkko saattaa oppia kuvaamaan reaali maailman ilmiötä (tässä tapauksessa konkurssiprosessia) entisellä tasolla. Verkon toimittaman itseoppimisen ansiosta käyttäjän oma panos uuden verkkomallin kehittämisessä jää alhaiseksi, jolloin menetelmän *muutostensietokyky* voidaan pitää parempana kuin esimerkiksi logit-menetelmän. (Tam & Kiang 1992, 944)

## 2.9 Taustaoletusten todenmukaisuus

*Taustaoletusten todenmukaisuus* on sisällytetty kriteeristöön siksi, että joidenkin menetelmien käyttöön sisältyy tilastollisia oletuksia, jotka eivät aina toteudu reaali maailmassa. Taustaoletusten satunnainen toteutuminen saattaa heikentää menetelmällä saatavia ennustustuloksia. Esimerkiksi erotteluanalyysi perustuu kahteen tilastolliseen oletukseen:

- tunnuslukujen hajonnat ja riippuvuutta mittaavat kovarianssit ovat yhtä suuret sekä konkurssiyritysten että toimivien yritysten joukossa ja
- tunnusluvut ovat multinormaalisesti jakautuneet. (Laitinen & Laitinen 2004, 135)

Näiden oletuksien toteutumisessa on havaittu puutteita (esim. Ohlson 1980, 112).

Sen sijaan esimerkiksi hermoverkkomenetelmä ei sisällä oletuksia, joiden toteutumisesta olisi epävarmuutta, joten lähtökohdat tarkan konkurssin ennustamismallin luomiseen ovat siinä menetelmässä paremmat (Tam & Kiang 1992, 944). Täten voidaan todeta, että *taustaoletusten todenmukaisuuden* kriteeri on olennainen menetelmien käytettävyyden kannalta ja että se myös tekee eroja menetelmien välille. Kriteerin sisällyttäminen kriteeristöön on siis perusteltua.

## 2.10 Kriteerien soveltaminen

Kriteeristöön valittuja kriteereitä sovelletaan tutkielmassa siten, että arvioitaviksi valittavat menetelmät arvioidaan kriteeristön kaikkien kriteerien osalta. Arviointi suoritetaan kolmessa osassa. Pääluvun 3 lopuksi arvioidaan yksittäiset tunnusluvut konkurssin ennustajina, pääluvun 4 lopuksi tilastolliset yhdistelmäluvun rakentamismenetelmät ja pääluvun 5 lopuksi keino- ja ihmisälyyn perustuvat konkurssin ennustamismenetelmät. Pääluvuissa 3–5 menetelmien arvioinnin lopuksi esitetään taulukko, jossa osoitetaan rasteilla, mitkä kyseisessä luvussa arvioidut menetelmät täyttävät mitkään kriteerit. Rasti merkitsee sitä, että menetelmä täyttää kyseisen kriteerin hyvin tai melko hyvin. Rastittomuus taas tarkoittaa sitä, että menetelmä täyttää kyseisen kriteerin korkeintaan kohtalaisesti.

Tutkielman lopussa esitetään yhteenvetotaulukko kaikista arvioituista menetelmistä. Tämän havainnollistamisen avulla lukija saa nopeasti tietoa tutkimuksen kvalitatiivisista arviointituloksista. On kuitenkin syytä huomata, että kriteereitä ei ole arvoitettu mitenkään toisiinsa nähden. Täten ne eivät ole samanarvoisia keskenään. Sen takia taulukkoa ei tule käyttää siten, että rastien määrä kertoo yksioikoisesti menetelmän soveltuvuuden konkurssin ennustamiseen. Toki kriteeristö on pyritty laatimaan siten, että rastien määrä antaa suuntaa menetelmän soveltuvuudesta. Menetelmien arviointikappaleissa perustellaan sanallisesti arvio jokaisen kriteerin toteutumisesta kunkin arvioitavan menetelmän kohdalla. Tähän sanalliseen arviointiin on suositeltavaa tutustua, jotta väärinkäsityksiltä välttyttäisiin ja tuloksista saataisiin enemmän hyötyä. Toiset konkurssin ennustamismallien käyttäjät saattavat arvostaa eri ominaisuuksia kuin toiset. Siksi kriteereille on mahdotonta määrittää painotuksia tai arvojärjestystä.

# 3 KONKURSSIN ENNUSTAMINEN YKSITTÄISTEN TUNNUSLUKUJEN AVULLA

## 3.1 Periaatteet

Konkurssin ennustamistutkimuksissa käytettyjä tilastollisia menetelmiä ovat yhden tunnusluvun analyysit (univariate analysis) ja monen tunnusluvun analyysit (multivariate analysis). Näistä *yhden tunnusluvun analyysin* käyttäminen konkurssin ennustamiseen perustuu kahteen olettamukseen:

- käytetyn tunnusluvun jakaumat konkurssiyritysten ja toimivien yritysten joukossa eroavat toisistaan systemaattisesti ja
- näitä systemaattisia eroja voidaan hyödyntää konkurssin ennustamisessa. (Laitinen 1990, 85)

Keasey ja Watson (1991, 90) ovat lisänneet vielä, että yhden tunnusluvun analyysin perusolettamuksena on, että tunnusluvun osoittaja ja nimittäjä ovat verrannollisessa suhteessa.

Muuttujana yhden tunnusluvun analyyseissa käytetään yrityksen tilinpäätöksestä laskettavia tunnuslukuja. Tunnusluvut sopivat suoraan tilinpäätöksestä saatavia absoluuttisia lukuja paremmin yrityksen taloudellisen tilan mittaamiseen, koska niihin ei vaikuta yrityksen koko yhtä paljon kuin absoluuttisiin lukuihin. Tämä johtuu tunnuslukujen suhdelukumuotoisuudesta. Tunnuslukuja käytetään yhtä kerrallaan mahdollisen konkurssin ennustamiseen. Kunkin tunnusluvun ennustamiskykyyn perehdytään estimointiaineistossa. Estimointiotos muodostuu aiemmin konkurssin kohdanneista yrityksistä ja toimivista yrityksistä. Estimointiotoksen yritysten tunnuslukuja vertaamalla määritellään tunnusluville *kriittiset arvot*, jotka jakavat yritykset mahdollisimman tarkasti toimintaansa jatkaviin ja konkurssiyrityksiin. Kriittistä arvoa käytetään kunkin tunnusluvun kohdalla yksinkertaisesti siten, että jos yrityksen tunnusluvun arvo on kriittistä arvoa suurempi, yritys kuuluu toimintaansa jatkaviin. Jos tunnusluku saa kriittistä arvoa pienemmän arvon, yritys luokitellaan konkurssiin ajautuvaksi. Tosin velkaisuuden kaltaisia kielteisiä ominaisuuksia mitattaessa toimintaansa jatkaviksi luokitellut yritykset saavat kriittistä arvoa pienemmän arvon ja konkurssiyritykset suuremman arvon. (Lahti 2000, 12–15)

Estimointiotoksessa luotuja kriittisiä arvoja voidaan käyttää mihin tahansa estimointiotoksen ulkopuolisiin yrityksiin konkurssin ennustamistarkoituksessa vertaamalla ennustettavan yrityksen

tunnusluvun arvoa ja kriittistä arvoa. Kriittisen arvon toimivuutta testataan usein vielä testiaineistossa ennen varsinaista käyttöä. Testiotos muodostuu estimointiotoksen tapaan vanhoista konkurssiyrityksistä ja toimivista yrityksistä. Jos tunnusluku ja kriittinen arvo toimivat hyvin, ne luokittelevat tarkasti testiotoksen konkurssiyritykset konkurssiin ajautuviksi ja toimivat yritykset toimintaansa jatkaviksi. Testiotoksen käyttö antaa vahvistusta tunnusluvun ja kriittisen arvon yleispätevästä luokittelukyvyistä pienentäen sitä mahdollisuutta, että niiden luokittelukyky on sidonnainen vain estimointiaineistoon, jonka perusteella kriittinen arvo on määrätty. (Lahti 2000, 12–15)

Parhaaseen mahdolliseen luokitteluun yksittäisillä tunnusluvuilla päästään silloin, kun toimivien yritysten ja konkurssiyritysten tunnusluvun jakaumat ovat täysin erillään. Jos tunnusluvun arvot ovat korkeammat toimivilla yrityksillä, merkitsee tämä erillisyyttä sitä, että konkurssiin ajautuneiden yritysten tunnusluvun korkeinkin arvo jää pienemmäksi kuin heikoin toimivien yritysten arvo. Tässä tilanteessa yritykset luokitteleva kriittinen arvo voidaan valita näiden kahden arvon väliltä ja päästä virheettömään luokitteluun. (Laitinen 1990, 85–86)

Jos konkurssiyritysten ja toimivien yritysten tunnuslukujen jakaumat ovat päällekkäisiä, luokittelussa seuraa aina virheitä. Virheiden määrä riippuu siitä, miten kriittinen arvo valitaan. Valinta tapahtuu usein siten, että kriittinen arvo on keskiarvo konkurssiin menneiden ja toimivien yritysten tunnuslukujen keskiarvoista. Jos tunnusluku noudattaa normaalijakaumaa sekä konkurssiyritysten että toimivien yritysten joukossa, saadaan tällä tavalla pienin määrä *kokonaisluokitteluvirheitä*. Sen sijaan jos jakaumat ovat vinoja, luokitteluvirheiden määrä saattaa kasvaa huomattavan suureksi. Yleinen tapa kriittisen arvon valinnassa on kiinnittää se siten, että kokonaisluokitteluvirheitä tulee mahdollisimman vähän. Periaatteessa tämä tapa perustuu siihen, että molemmille virhetyypeille annetaan sama paino eli ne katsotaan samanarvoisiksi. Käytännössä kuitenkin *virhetyyppi I* eli konkurssiyrityksen luokittelu toimivaksi yritykseksi saattaa tulla selvästi kalliimmaksi kuin *virhetyyppi II*. Esimerkiksi luotonantajan tapauksessa virhetyypin I toteutuessa tämä rahoittaa konkurssiyritystä ja saattaa menettää koko sijoituksensa. Virhetyypissä II luotonantaja menettää asiakkaan ja korkokatteen antamatta jääneestä lainasta. Tällaisessa tilanteessa virhetyypin I kustannukset on arvioitu 7-46-kertaisiksi virhetyypin II kustannuksiin verrattuna. Virhetyyppien erilainen painotus voidaan halutessa ottaa huomioon esimerkiksi siten, että valitaan arvionvaraisesti kriittinen arvo, joka tuottaa vähemmän virhetyyppejä I. Kriittisen arvon täsmällisempi valinta on myös mahdollista luokitteluvirheiden todennäköisyyden ja luokitteluvirheiden aiheuttamien arvioitujen kustannusten avulla. (Laitinen 1990, 86–88)

### 3.2 William H. Beaverin malli

William H. Beaverin tutkimus (1966) on usein esille tuotu esimerkki tilinpäätösanalyysistä, jossa yhtä tunnuslukua kerrallaan analysoimalla ennustetaan konkurssia. Beaverin tutkimus sisälsi aivan uusia piirteitä verrattuna aikaisempiin tutkimuksiin, ja sen takia Beaveria pidetään yleisesti yksittäisiin tunnuslukuihin perustuvan lähestymistavan uranuurtajana. Tutkimuksesta onkin tullut klassikko konkurssin ennustamisen alalla. (Laitinen 1990, 39–40)

Tärkeimmäksi tavoitteekseen tutkimuksessaan Beaver (1966, 100) nimesi tilinpäätöksestä saatavien tunnuslukujen konkurssin ennustamiskyvyn tutkimisen. Toissijaisena tavoitteena oli löytää paras yksittäinen tunnusluku, jolla voidaan ennustaa yrityksen mahdollista konkurssia. Beaverin käyttämä aineisto muodostui 79 konkurssiyrityksestä ja 79 toimivasta yrityksestä. Toimivat yritykset valittiin vastinparimenettelyllä siten, että kutakin aineiston konkurssiyritystä vastasi samankokoinen toimiva yritys samalta toimialalta. Tällä tavalla Beaver eliminoi ennustamisesta toimialan ja yrityksen koon vaikutuksen. (Beaver 1966, 73–74) Vastinparimenettely oli Beaverin itsensä kehittämä ja sen ansiokkuutta kuvaa se, että menettelyä on käytetty useissa konkurssitutkimuksissa Beaverin jälkeen. Toisaalta menettely on saanut osakseen myös kritiikkiä, sillä todellisuudessa toimivia yrityksiä on enemmän kuin konkurssiyrityksiä. Otoksen pitäisi kuvata aina perusjoukkoa, josta se on muodostettu, jotta otoksen avulla saadut tulokset olisivat yleistettävissä koko perusjoukkoa koskeviksi. Kritisoiijat ovat puuttuneet juuri vastinparimenettelyn aiheuttamaan otoksen harhaisuuteen, mikä heikentää tulosten yleispätevyyttä. (esim. Keasey & Watson 1991)

Beaver analysoi yritysryhmien taloudellista tilannetta 30 tunnusluvun avulla viiden vuoden aikana ennen konkurssia. Toimivien yritysten osalta analysoitiin vastaavia kalenterivuotia. Hän valitsi tunnusluvut analyysiinsa seuraavilla perusteilla: yleisyys alan kirjallisuudessa, konkurssin ennustamiskyky aikaisemmissa tutkimuksissa ja kassavirtaisuus (tulo-menopohjaisuus). Beaver pyrki perustelemaan tunnuslukujen käyttökelpoisuutta myös yksinkertaisten olettamusten avulla. Nämä olettamukset perustuivat eräänlaiseen teoriaan siitä, että yritys on likvidien varojen muodostama varasto, johon tulee ja josta lähtee kassavirtoja. Jos tämä varasto tyhjenee, yritys joutuu konkurssiin. Hän jaotteli testaamansa 30 tunnuslukua kuuteen ryhmään:

- rahoitustulokseen perustuvat tunnusluvut,
- nettotulokseen perustuvat tunnusluvut,
- velkaisuuden ja kokonaisvarallisuuden suhteeseen perustuvat tunnusluvut,

- likvidien varojen ja kokonaisvarallisuuden suhteeseen perustuvat tunnusluvut,
- likvidien varojen ja velkaisuuden suhteeseen perustuvat tunnusluvut sekä
- liikevaihtoon perustuvat tunnusluvut.

Beaver vertasi keskenään konkurssiyritysten ja toimivien yritysten tunnuslukujen keskiarvoja eri vuosina. Tätä hän itse nimitti profiilianalyysiksi. (Beaver 1966, 78–79)

Beaver jakoi 158 yritystä sisältäneen otoksensa satunnaisesti kahteen osaryhmään, joista ensimmäinen ryhmä muodosti *estimointiryhmän* ja toinen *testiryhmän*. Tämän jälkeen hän arvioi tunnusluvuille kriittiset arvot siten, että estimointiryhmässä kokonaisluokitteluvirhe minimoitui. Täten hän antoi yhtä suuren painon molemmille virhetyypeille. Määrittelemäänsä kriittistä arvoa Beaver testasi testiryhmässä. (Beaver 1966, 84–85) Syy tämän menetelmän käyttöön oli se, että Laitisen (1990, 41) mukaan tulosten paljastuessa samansuuntaisiksi sekä estimointi- että testiryhmässä niitä voidaan pitää suhteellisen yleispätevinä. Näin ollen niitä voidaan käyttää aineiston ulkopuolella yritysten konkurssien ennustamiseen.

Laitisen (1990, 44) mukaan Beaverin teoreettiset perustelut tunnuslukujen valinnalle jäivät kuitenkin vähäisiksi ja tunnusluvut asetettiin paremmuusjärjestykseen niiden empiirisen ennustamiskyvyn perusteella. Parhaaksi konkurssin ennustajaksi yksittäisistä tunnusluvuista osoittautui *rahoitustuloksen suhde vieraaseen pääomaan*, joka mittaa vieraan pääoman takaisinmaksukykyä. Toiseksi paras luokittelija oli *nettotuloksen ja koko pääoman suhde*, joka mittaa kannattavuutta. Taulukossa 2 on esitetty viidelle tunnusluvulle Beaverin testiryhmässä saamat kokonaisvirheprosentit viideltä vuodelta ennen konkurssia. Kaikki taulukon tunnusluvut ovat eri tunnuslukuryhmistä.

Taulukko 2. Kokonaisluokitteluvirheiden prosentiosuudet Beaverin testiaineistossa (Beaver 1966, 87)

<i>Tunnusluku</i>	<i>Vuosia ennen konkurssia</i>				
	1	2	3	4	5
Rahoitustulos/Vieras pääoma	13	21	23	24	22
Nettotulos/Koko pääoma	13	20	23	29	28
Vieras pääoma/Koko pääoma	19	25	34	27	28
Käyttöpääoma/Koko pääoma	24	34	33	45	41
Current ratio	20	32	36	38	45

Käytettäessä yritysten luokitteluun rahoitustuloksen suhdetta vieraaseen pääomaan tehtiin vuotta ennen konkurssia virhe vain 13 tapauksessa sadasta. Vastaava virheluokitusten määrä viittä vuotta ennen konkurssia oli 22, joten tunnusluvun ennustamiskyky ulottui suhteellisen pitkälle. Lähes yhtä hyvät luokittelutulokset saatiin nettotuloksen ja koko pääoman suhteella.

Liitteessä 1 on esitetty parhaaksi ennustajaksi osoittautuneelle *rahoitustuloksen ja vieraan pääoman suhteelle* saadut luokitteluvirheet tyypeittäin. Siitä nähdään, että tunnusluku luokittelee erittäin harvoin toimivan yrityksen konkurssiyritykseksi eli tekee tyyppin II virheen. Tämä ominaisuus on tunnusluvulla voimassa aina viisi vuotta ennen konkurssia asti. Sen sijaan tunnusluku tekee melko usein tyyppin I virheen eli luokittelee konkurssiyrityksen toimivaksi yritykseksi. Tämän virheen osuus tehdyistä konkurssiyritysten luokitteluista on jo 4 vuotta ennen konkurssia 47 prosenttia. Jos tunnusluku tekee näin runsaasti luokitteluvirheitä, sillä ei ole mitään käyttöä, sillä esimerkiksi pelkällä kolikon heitolla päästään keskimäärin 50 prosentin luokitteluvirheeseen (Laitinen 1990, 43). Muutenkin virhetyypin I yleisyys virhetyyppiin II verrattuna saattaa heikentää tunnusluvun käytettävyyttä konkurssin ennustamiseen, sillä sen virhetyypin aiheuttamat kustannukset ovat monissa tilanteissa virhetyypin II suuremmat.

Beaver (1966, 83, 101–102) kertoo tutkimuksensa saavuttaneen sille asetetun tavoitteen, sillä hän sai varmistusta sille, että toimivien ja konkurssiin ajautuneiden yritysten tunnusluvuissa on eroa. Tämä ero on havaittavissa jo vähintään viisi vuotta ennen konkurssia ja se kasvaa konkurssin lähestyessä. Toki kaikkien tunnuslukujen ennustuskkyky ei ole yhtä hyvä. Ennustuskvyltään parhaaksi Beaver löysi siis rahoitustuloksen ja vieraan pääoman suhdetta mittaavan tunnusluvun, jonka erottelukvyytä hän piti erinomaisena koko mitatun konkurssia edeltävän viisivuotisjakson aikana.

### **3.3 Arviointi**

Yksittäisillä tunnusluvuilla konkurssin ennustamisessa on tunnettu asema. Beaverin (1966) ajankohtaansa nähden ansiokas tutkimus saavutti paljon huomiota ja herätti mielenkiintoa vielä parempien konkurssin ennustamismenetelmien kehittämiseen. Huomio suuntautuikin pääasiassa muihin menetelmiin, sillä yksittäisten tunnuslukujen käyttö on jäänyt melko vähäiseksi. Aziz ja Dar (2004, 32–34) ovat listanneet 89 konkurssitutkimusta muun muassa niissä käytetyn menetelmän ja saavutetun luokittelukvyyden osalta. Listauksen mukaan Beaverin lisäksi kolmessa muussa



tutkimuksessa on käytetty yksittäisiä tunnuslukuja konkurssin ennustajina. Näiden lisäksi Pompe ja Bilderbeek (2005) ovat käyttäneet yksittäisiä tunnuslukuja ennustaessaan pienten ja keskisuurten yritysten konkurseja teollisuuden alalla. Yksittäisille tunnusluvuille ei ole löydettävissä tutkielman lähdemateriaalista enempää käyttökohteita, joten käyttökohteet jäävät alle kymmeneen. Siksi menetelmä ei menesty hyvin *käytön yleisyyden* kriteerin osalta.

Yksittäisiä tunnuslukuja on kritisoitu voimakkaasti niiden yksipuolisuuden takia. Yrityksen taloustila perustuu useaan ulottuvuuteen, joita kaikkia ei pystytä mittaamaan yhdellä tunnusluvulla (Dimitras ym. 1996, 495). Altman (1968, 591) on havainnollistanut tätä yksipuolisuuden ongelmaa esimerkillä yrityksestä, jolla on huono kannattavuus ja vakavaraisuus. Tämän takia se luokiteltaisiin usean tunnusluvun perusteella konkurssiyritykseksi. Yrityksellä voi kuitenkin olla hyvä maksuvalmius, jonka avulla se voi ohittaa vaikeutensa ja pelastua. Tässä *informaatisällön* puutteellisuudessa piilee yksittäisten tunnuslukujen ehkä suurin heikkous konkurssin ennustajina. Jopa Beaver itse ansiokkaan tutkimuksensa (1966, 100) lopuksi toteaa, että useaan tunnuslukuun perustuvat menetelmät voisivat toimia yksittäisiä tunnuslukuja paremmin.

Yksittäisten tunnuslukujen *informatiivisuutta* heikentää myös se, että ne menettävät tietoa samalla kun suhdeluku muodostetaan. Esimerkiksi yrityksen oman pääoman tuotto prosentti saattaa olla 1000, mikä viittaa erittäin hyvään kannattavuuteen. Luku on kuitenkin saattanut syntyä siten, että osoittajana oleva voitto on 1000 euroa ja nimittäjä oleva oma pääoma kertyneiden tappioiden vuoksi vain yhden euron. Tunnusluvut poistavat siis kokoluokan vaikutuksen, jolloin luvut saattavat olla merkityksettömän pieniä ja antaa väärää informaatiota. (Laitinen & Laitinen 2004, 221)

*Informaatisällön* kriteerin toisen ulottuvuuden, tuloksen informatiivisuuden, osalta yksittäiset tunnusluvut eivät menesty paremmin. Tuloksen eli tunnusluvun arvon vertaaminen kriittiseen arvoon ilmaisee vain sen, luokitellaanko yritys toimintaansa jatkavaksi vai konkurssiyritykseksi. Tietysti joitakin lisäpäätelmiä voidaan tehdä, jos jonkin yrityksen tunnusluvun arvo on 0,1 yksikköä suurempi kuin kriittinen arvo ja toisen 3,6 yksikköä kriittistä arvoa suurempi. Ensimmäinen on silloin luonnollisesti suuremmassa vaarassa joutua toiseen yritysryhmään. Tällaisille päätelmille ei yksittäisten tunnuslukujen menetelmässä ole kuitenkaan teoreettisia perusteita, joten niille ei voi antaa suurta arvoa. Yhteenvedona voidaan todeta, että yksittäiset tunnusluvut eivät täytä *informaatisällön* kriteeriä.

*Ymmärrettävyys* on yksittäisillä tunnusluvuilla erinomainen. Tunnusluvut rakentuvat muutaman tilinpäätöserän summista, erotuksista ja suhteista. Tunnusluvun määräytymisen rakennetta tutkimalla on helppo päätellä, miksi toinen yritys luokitellaan konkurssiyritykseksi ja toinen toimintaansa jatkavaksi. Current ratio määräytyy vaihto- ja rahoitusomaisuuden summan suhteesta lyhytaikaiseen vieraaseen pääomaan (Yritystutkimusneuvottelukunta 1999, 64). Siksi esimerkiksi yritys, jolla on paljon lyhytaikaista velkaa ja vähän vaihto- ja rahoitusomaisuutta, saattaa saada konkurssiennusteen. Käyttäjän on helppo havaita ennusteen perusteet, jolloin tämä menetelmän *ymmärrettävyys* lisää käyttäjän luottamusta menetelmää kohtaan.

*Mallin rakentamisen ja käytön helppouden* kriteeri täyttyy myös hyvin yksittäisten tunnuslukujen kohdalla. Varsinaista mallia ei oikeastaan tarvitse edes rakentaa, sillä menetelmässä käytetään tunnuslukuja yksittäin. Käytännön ennustamistilanteita varten käyttäjän täytyy vain testata tunnuslukuja arviointitilannetta ajallisesti ja toimialallisesti vastaavissa olosuhteissa, jotta parhaiten konkurssia ennustavat tunnusluvut löytyisivät. Näille tunnusluvuille on empiirisen aineiston perusteella määrättävä kriittiset arvot, joiden mukaan yritykset jaotellaan. Näiden vaiheiden jälkeen tunnuslukuja on erittäin helppo käyttää, sillä monet tunnusluvut löytyvät sellaisenaan yritysten tilinpäätöksistä. Jos näin ei ole, tunnusluvun arvo on selvitettävissä muutamalla laskutoimituksella. Tunnusluvun arvoa verrataan kriittiseen arvoon ja voidaan siten tehdä päätelmät yrityksen lähitulevaisuudesta. Menetelmä on siis *mallin rakentamisen ja käytön* näkökulmasta helppo.

Yksittäisten tunnuslukujen *luokittelukyky* eli ennustustarkkuudesta on esitetty erilaisia mielipiteitä. Beaver (1966, 87) pääsi parhailla tunnusluvuilla 87 prosentin ennustustarkkuuteen vuotta ennen konkurssia. Beaver itse piti tulosta hyvänä, ja edelleenkin 87 prosentin tarkkuus on muihin menetelmiin nähden kilpailukykyinen. Azizin ja Darin (2004, 37) mukaan kolmessa muussa yksittäisiä tunnuslukuja soveltaneessa tutkimuksessa ennustustarkkuuden keskiarvo parhaalla tunnusluvulla oli 81 prosenttia. Samassa tutkimuksessa muilla menetelmillä saavutetut tarkkuudet olivat pääsääntöisesti muutamia prosenttiyksiköitä korkeampia. Pompe ja Bilderbeek (2005, 848) pääsivät siihen tulokseen, että yksittäiset tunnusluvut voivat parhaimmillaan olla lähes yhtä hyviä konkurssin ennustajia kuin moneen tunnuslukuun perustuvat mallit. Luottamusta tätä tulosta kohtaan kasvattaa se, että tutkijat käyttivät poikkeuksellisen suurta yritysaineistoa tunnuslukujen testaamiseen. Otos sisälsi peräti 1369 konkurssiyritystä.

Yksittäisten tunnuslukujen etuna on se, että niiden *luokittelukyky* säilyy pitemmälle ennen konkurssia kuin useaan tunnuslukuun perustuvilla menetelmillä. Tämä johtuu pääasiassa siitä, että

tunnuslukujen merkitsevyys konkurssin ennustamisessa muuttuu selvästi konkurssin lähestyessä. Jos useaan tunnuslukuun perustuva malli muodostetaan vuotta ennen konkurssia hyvin ennustavilla luvuilla, se ei välttämättä toimi hyvin pitemmällä aikavälillä, koska tunnuslukujen optimaalinen painotus muuttuu etäännyttäessä konkurssihetkestä. Sen sijaan valitsemalla yksittäinen tunnusluku, joka ei välttämättä ole paras ennustaja vuotta ennen konkurssia mutta jonka ennustuskyky säilyy pitkään, voidaan saavuttaa ennusteen kohtuullisen hyvä pysyvyys. (Laitinen 1990, 89)

Useassa eri tutkimuksessa on todettu, että konkurssin ennustamismenetelmien *luokittelukyvyissä* ei ole suuria eroja. Tämän takia on todettava, että koska yksittäiset tunnusluvut jäävät pääsääntöisesti vähän muita menetelmiä heikommaksi luokittelijaksi varsinkin vuotta ennen konkurssia, menetelmän kilpailukyky *luokittelukyvyyn* kriteerillä mitattuna ei ole hyvä. Ennustuskyvyn säilyvyys, joka toimii *luokittelukyvyyn* toissijaisena arviointikriteerinä, tosin puoltaa yksittäisten tunnuslukujen *luokittelukykyä*.

Yksittäisten tunnuslukujen *johdonmukaisuus* ei kuulu menetelmän vahvuuksiin. Yksittäisiä tunnuslukuja käytetään usein siten, että usealla eri tunnusluvulla haetaan vahvistusta arvioitavan yrityksen konkurssin todennäköisyydestä. Näin menetellään siksi, että tunnuslukujen käyttö on helppoa ja nopeaa. Lisäksi on syytä saada tietoa yrityksen talouden eri ulottuvuuksista, sillä yksi tunnusluku kuvaa vain yhtä ulottuvuutta. Useiden tunnuslukujen käyttö johtaa usein siihen ongelmatilanteeseen, että joku tunnusluku ennustaa yritykselle konkurssia ja toinen toiminnan jatkumista. Käyttäjän on itse harkittava, kumpaan ennustukseen on syytä luottaa. Jos toisaalta käytetään vain yhtä tunnuslukua ennusteen muodostamiseen, virhetulkinnan mahdollisuus on suuri (Aziz & Dar 2004, 22). Yksittäisten tunnuslukujen epäjohdonmukaisuus vähentää menetelmän käyttöarvoa.

*Johdonmukaisuuteen* liittyy vielä se, että tunnusluvun ennustuskyvyn tulisi lähtökohtaisesti heikentyä vuosi vuodelta etäännyttäessä konkurssihetkestä, sillä yrityksen konkurssikehityksessä vaikeudet lisääntyvät ja kasaantuvat vuosi vuodelta ennen lopullista alasajoa. Tunnuslukujen pitäisi loppua lähestyttäessä osoittaa vuosi vuodelta selvemmin yrityksen ongelmat. Esimerkiksi Beaverin (1966) tutkimuksessa ei kuitenkaan aina näin ole, mikä voidaan havaita taulukosta 2. Esimerkiksi vieraan pääoman ja koko pääoman suhde tekee luokitteluvirheen kolme vuotta ennen konkurssia 34 prosentissa tapauksista, mutta viisi vuotta ennen konkurssia vain 28 prosentissa tapauksista. Joissakin tilanteissa tämä epäjohdonmukaisuus saattaa olla selitettävissä yritysjohton tekemistä kuvion 1. mukaisista tervehdyttämistoimenpiteistä. Toisaalta se kuitenkin herättää pelkoa siitä,

perustuuko tunnusluvun ennustamiskyky jossakin määrin sattumaan ennustusten heitellessä vuodesta toiseen. Tämä epäjohdonmukaisuus aiheuttaa yksittäisten tunnuslukujen käyttäjälle ainakin sen ongelman, että suosiako mieluummin luokittelukyvyltään parasta tunnuslukua vai sitä tunnuslukua, joka on toiminut johdonmukaisimmin (Keasey & Watson 1991, 90).

*Muutostensietokyky* on yksittäisillä tunnusluvuilla heikko. Tilinpäätöserien laskentaperusteiden muuttuessa myös tunnuslukujen määräytymisperiaatteet muuttuvat. Tällöin aiemmin hyvin konkurssia ennustaneiden tunnuslukujen ennustuskky saattaa heikentyä ja toisaalta aiemmin huonosti ennustaneista tunnusluvuista saattaa muodostua hyviä konkurssin ennustajia. Vaikka näin ei tapahtuisi, ainakin tunnuslukujen vertailukohtena toimivat kriittiset arvot on estimoitava uudelleen. Yksittäisten tunnuslukujen eduksi tässä välttämättömässä menettelyssä voidaan kuitenkin mainita, että menettely ei vaadi yhtä paljon työtä kuin useita tunnuslukuja samanaikaisesti hyödyntävissä menetelmissä. Näissä menetelmissä on lisäksi testattava tunnuslukujen ennustuskky yhdessä sekä määrättävä tunnuslukujen yhdistämistapa ja keskinäiset painoarvot (Laitinen 1990, 90). *Muutostensietokyky* yli toimialarajojen on yksittäisillä tunnusluvuilla myös heikko, sillä eri toimialoilla taseet rakentuvat eri tavoilla. Esimerkiksi kiinteän omaisuuden määrä on hyvin erilainen teollisuus- ja palveluyrityksillä. Tällöin eri tunnusluvut ovat tärkeitä eri toimialoilla.

Olettamukseen siitä, että yksittäisten tunnuslukujen osoittajat ja nimittäjät ovat verrannollisessa suhteessa, liittyy ongelmia. Keaseyn ja Watsonin (1991, 90) mukaan mahdollisia ongelmatekijöitä käytännössä on kaksi:

- vakio-termi saattaa vaikuttaa osoittajan ja nimittäjän suhteeseen sekä
- osoittajan ja nimittäjän suhde saattaa olla epälineaarinen.

Ensimmäisestä ongelmasta he mainitsevat esimerkkinä liikevoiton ja liikevaihdon suhteen, jossa jokin liikevoiton elementeistä ei välttämättä ole suorassa suhteessa liikevaihtoon. Tällöin tunnusluku kuvaa riittämättömällä tavalla liikevoiton liikevaihdon suhdetta. Toista ongelmaa Keasey ja Watson (1991, 90) kuvaavat esimerkillä, jossa täydellisesti kilpailluilla markkinoilla toimiva yritys ei välttämättä saa jokaista liikevaihdon lisäystä kohden vakion suuruista lisäystä liikevoittoon. Tällöin liikevoiton ja liikevaihdon suhteesta saattaa muodostua epälineaarinen. Siksi teoriassa yksittäisten tunnuslukujen käyttöön liittyy verrannollisuuden mahdollisesti aiheuttama taustaoletuksen toteutumattomuus. McDonald ja Morris (1984) ovat kuitenkin osoittaneet, että empiirisessä testauksessa yksittäiset tunnusluvut ovat yleensä osoittautuneet verrannollisiksi (ks. Keasey & Watson 1991, 90). Mahdollisuus verrannollisuuden toteutumattomuuteen aiheuttaa kuitenkin sen, että yksittäiset tunnusluvut eivät täytä *taustaoletusten todenmukaisuuden* kriteeriä.

Taulukossa 3 esitetään yksinkertaistettuna yhteenvedona yksittäisten tunnuslukujen arviointi tutkielmassa yhtenäisesti käytettävän konkurssin ennustamismenetelmien arviointikriteeristön avulla. Rasti tarkoittaa sitä, että menetelmä osoittautui sanallisessa arvioinnissa hyväksi tai melko hyväksi kyseisen kriteerin osalta.

Taulukko 3. Yksittäisten tunnuslukujen arviointi konkurssin ennustamismenetelmien arviointikriteeristöllä

	Yksittäiset tunnusluvut (Univariate Analysis, UA)
Käytön yleisyys	
Informaatioisisältö	
Ymmärrettävyys	x
Mallin rakentamisen ja käytön helppous	x
Luokittelukyky	
Johdonmukaisuus	
Muutostensietokyky	
Taustaoletusten todenmukaisuus	

# 4 KONKURSSIN ENNUSTAMINEN TILASTOLLISILLA YHDISTELMÄLUKUMENETELMILLÄ

## 4.1 Periaatteet

Yhdistelmäluvun käyttö konkurssin ennustamisessa edustaa *monen muuttujan analyysia*. Monen muuttujan eli tunnusluvun analyysin perusideana on sisällyttää konkurssin ennustamismalliin usean tunnusluvun informaatio samalla kertaa. Yhdistelmäluvun syntyyn vaikutti yksittäisten tunnuslukujen käytön saama kritiikki. Kritiikkiä aiheutti muun muassa se, että yksittäiset tunnusluvut kykenevät kukin antamaan vain yksipuolisen kuvan yrityksen moniulotteisesta taloudesta. Monen muuttujan analyysin tavoitteena on, että yhdistämällä tunnuslukuja pystytään luomaan sellainen yksiulotteinen uusi muuttuja, joka toimii konkurssin ennustamisessa paremmin kuin yksikään yksittäinen muuttuja. (Laitinen 1990, 89)

Yhdistelmäluvun kehittämisen tarkoituksena on luoda uusi yhdistetty tunnusluku, jonka jakaumat konkurssiin ajautuneiden ja toimivien yritysten joukoissa poikkeavat toisistaan systemaattisesti. Tätä systemaattista eroa hyödynnetään yritysten luokittelemisessa. Yhdistelmäluvun rakentamisessa on ratkaistava kolme ongelmaa:

1. tunnuslukujen yhdistämistapa
2. tunnuslukujen painottaminen
3. tunnuslukujen valinta.

Ensimmäinen ratkaistava tekijä monen muuttujan mallia rakennettaessa on yhdistelyn matemaattinen muoto. Tällöin on päätettävä siitä, muodostetaanko yhdistelmäluku muuttujien painotetun summan avulla (lineaarinen muoto) vai jollakin muulla tavalla (ei-lineaarinen muoto). Toinen tekijä liittyy valittujen tunnuslukujen keskinäisiin suhteisiin. On ratkaistava, miten tunnuslukuja painotetaan, jotta yhdistelmäluvun erottelukyky olisi paras. Kolmas tekijä mallin rakentamisessa on se, miten mallin tunnusluvut valitaan. Lähtökohtana on usein se, että valittujen tunnuslukujen tulisi kuvata yrityksen taloutta monipuolisesti. (Laitinen & Laitinen 2004, 131–132)

Tunnuslukujen yhdistämisen lopputuloksena muodostuvaa yhdistelmälukua sovelletaan konkurssin ennustamiseen samalla tavalla kuin yksittäisiä tunnuslukuja. Yhdistelmäluvun saama arvo verrataan historiallisessa yritysaineistossa estimoituun kriittiseen arvoon. Tämän vertailun

seurauksena saadaan ennuste siitä, jatkaako yritys toimintaansa vai ajautuuko se lähivuosina konkurssiin. (Laitinen & Laitinen 2004, 131)

## 4.2 Erotteluanalyysi

*Erotteluanalyysia* käytetään Laitisen ja Kankaanpään (1999, 69) mukaan pääsääntöisesti sellaisiin luokitteluihin tai ennusteisiin, joissa riippuva muuttuja on kvalitatiivisessa muodossa. Konkurssin ennustamisessa on juuri näin, sillä yritys määritellään riippuvan muuttujan perusteella kvalitatiivisesti joko konkurssiyritykseksi tai toimintaansa jatkavaksi. Laitisen ja Laitisen (2004, 132–133) mukaan konkurssitutkimuksissa selvästi eniten käytetty monen muuttujan analyysi on juuri erotteluanalyysi. Erotteluanalyysissa muodostetaan sellainen tunnuslukujen yhdistelmä, joka erottelee toisistaan konkurssiyritykset ja toimivat yritykset mahdollisimman tehokkaasti. Tämä tapahtuu siten, että tunnusluvuille etsitään sellaiset painot, joilla yhdistelmäluku minimoi havaintojen (yleensä neliöön korotetun) etäisyyden siitä luokasta, johon ne kuuluvat. Yleisin erotteluanalyysin muoto on *lineaarinen erotteluanalyysi*, jossa ennustamismalli muodostuu tunnuslukujen painotetusta summasta. Lineaarisen erotteluanalyysin tuottama malli on seuraavan muotoinen (kaava 1):

$$(1) \quad Z = a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n .$$

Kaavassa 1  $Z$  on ennustamismallin eli yhdistelmäluvun arvo,  $X_i$  tunnusluvun  $i$  arvo,  $a_i$  tunnusluvun  $i$  saama painokerroin ja  $n$  tunnuslukujen määrä ennustamismallissa ( $i = 1, 2, \dots, n$ ). Erotteluanalyysin tuloksia sovelletaan käytännössä siten, että lasketaan arvioitavalle yritykselle yhdistelmäluvun eli ennustamismallin arvo  $Z$ . Tämän jälkeen verrataan arvoa valittuun kriittiseen arvoon. Vertailun perusteella voidaan päätellä, kuuluuko yritys toimivien vai konkurssiin ajautuvien yritysten joukkoon. (Laitinen & Laitinen 2004, 133)

Mallissa saattaa olla mukana tunnuslukuja, jotka mittaavat osittain samoja asioita. Tällöin tunnusluvut eivät ole toisistaan riippumattomia, joten mallissa esiintyy multikollineaarisuutta. Multikollineaarisuus tekee mallin kertoimien tulkinnan tunnuslukujen suorina merkityksinä virheelliseksi. Tällöin ei siis pystytä päättämään kertoimien arvosta suoraan sitä, mikä on kunkin yrityksen talouden ulottuvuuden painotus mallissa. Tunnuslukujen väliset riippuvuudet voivat kuitenkin parantaa mallin erottelukykyä. Sellaiset yksittäiset tunnusluvut, jotka eivät yksittäisinä

erottele konkurssiyrityksiä ja toimivia yrityksiä, saattavat olla hyvin tehokkaita tunnuslukujoukon osana. Tunnuslukujen keskinäiset riippuvuudet saattavat kuitenkin johtaa otoksesta riippuviin tuloksiin, jos sama riippuvuus ei vallitse yleisesti perusjoukossa. (Laitinen 1990, 91–93)

Lineaarinen erotteluanalyysi perustuu seuraaviin tilastollisiin olettamuksiin:

- tunnuslukujen hajonnat ja keskinäistä riippuvuutta mittaavat kovarianssit ovat yhtä suuret sekä konkurssiyritysten että toimivien yritysten joukossa ja
- tunnusluvut ovat multinormaalaisesti jakautuneet.

Nämä olettamukset eivät kuitenkaan pidä aina paikkaansa. Ensimmäisessä olettamuksessa ongelmana on se, että tunnuslukujen väliset riippuvuudet poikkeavat usein käytännössä toisistaan konkurssiyritysten ja toimivien yritysten joukoissa. Näissä tapauksissa pitäisi käyttää lineaarisen erottelumallin sijasta *kvadraattista erottelumallia*. Kvadraattinen eli neliömuotoinen malli ei oleta sitä, että tunnuslukujen kovarianssit ovat yhtä suuria eri yritysryhmien sisällä. Kvadraattinen malli sisältää tunnuslukujen keskinäisiä tuloja ja toisia potensseja. Kahden tunnusluvun tapauksessa kvadraattinen ennustamismalli on seuraava (kaava 2):

$$(2) \quad Z = a_1 \cdot X_1 + a_2 \cdot X_2 + a_3 \cdot X_1^2 + a_4 \cdot X_2^2 + a_5 X_1 \cdot X_2.$$

Toinenkaan lineaarisen erotteluanalyysin olettamuksista ei aina pidä paikkaansa. Tunnuslukujen multinormaalinen jakautuminen edellyttää jokaisen tunnusluvun normaalia jakautumista. Monet tunnusluvut ovat kuitenkin vinosti jakautuneita. Esimerkiksi quick ration minimiarvo 0 rajaa jakauman vain positiiviselle alueelle, jolloin jakaumasta muodostuu vino. Tällaisten tunnuslukujen sisällyttäminen malliin saattaa heikentää luokittelutuloksia. Ongelma voidaan yrittää välttää siten, että valitaan vain normaalisti jakautuneita tunnuslukuja tai tehdään vinosti jakautuneille tunnusluvuille muunnoksia normaalisuuden saavuttamiseksi. (Laitinen & Laitinen 2004, 135–136)

#### 4.2.1 Edward I. Altmanin z-malli

Monen muuttujan yhdistelmä-tunnusluvun tieteellisen käytön uranuurtajana pidetään Edward I. Altmania. Hänen tutkimuksensa (Altman 1968) on hyvä käytännön esimerkki erotteluanalyysin soveltamisesta konkurssin ennustamiseen. Altmanin tutkimus kuuluu konkurssitutkimuksen klassikoihin. Altmanin tutkimuksen jälkeen erotteluanalyysistä tuli konkurssin ennustamisessa käytetyin menetelmä. (Laitinen 1990, 49)



Altman lähti luomaan konkurssin ennustamismalliaan otoksesta, joka sisälsi 66 yritystä. Niistä 33 oli vuosina 1946–1965 konkurssiprosessin käynnistäneitä yrityksiä. Toiset 33 yritystä olivat toimivia yrityksiä ja ne valittiin vastinparimenettelyllä kuten Beaverinkin (1966) klassikkotutkimuksessa. Täten toimivat yritykset vastasivat konkurssiyrityksiä niin kooltaan kuin toimialaltaankin. Toimivista yrityksistä Altman tutki niiden vuosien tunnuslukuja, joita vastinparina olleilta konkurssiyrityksiltä tutkittiin. Kaikki otoksen yritykset olivat valmistustoiminnassa mukana olleita yrityksiä. Lisäksi yritykset olivat kooltaan keskisuuria. Tätä Altman perusteli sillä, että suuret yritykset tekevät melko harvoin konkurssin ja pieniltä konkurssiyrityksiltä on vaikea saada tietoja riittävässä laajuudessa. (Altman 1968, 593)

Alustavaan analyysiin Altman valitsi 22 tunnuslukua ilman teoreettisia perusteluita. Valintaperusteina olivat yleisyys alan kirjallisuudessa ja mahdollinen merkitys tutkimukselle. Nämä tunnusluvut Altman jakoi viiteen luokkaan:

- maksuvalmiutta mittaavat tunnusluvut,
- kannattavuutta mittaavat tunnusluvut,
- velkaantuneisuutta mittaavat tunnusluvut,
- vakavaraisuutta mittaavat tunnusluvut sekä
- toimintaa mittaavat tunnusluvut.

Lopulliseen erottelufunktioon Altman valitsi yhden tunnusluvun kustakin luokasta. Valinta tapahtui tutkimalla tunnuslukujen ennustamiskykyä erilaisissa malleissa, tutkimalla tunnuslukujen keskinäisiä riippuvuuksia sekä käyttämällä omaa harkintaa. Altman käytti tunnuslukujen yhdistelyyn lineaarista erotteluanalyysia. Tunnuslukujen painot hän estimoiti optimaalisiksi tietokoneavusteisen tilastollisen erotteluanalyysin avulla lukuisten iteraatiokertojen jälkeen. Altman painotti, että tunnusluvuiksi ei valittu yksittäin parhaiten erottelevia tunnuslukuja vaan valinnassa tarkasteltiin tunnuslukujen yhteiserottelukykyä. Täten hän valitsi tunnuslukujoukon, joka yhdessä antoi parhaan tuloksen. (Altman 1968, 594)

Altmanin (1968, 594) lopullinen ennustamismalli on seuraava painotettu summa, josta käytetään nimitystä *z-malli* (kaava 3):

$$(3) \quad Z = 0.012 \cdot X_1 + 0.014 \cdot X_2 + 0.033 \cdot X_3 + 0.006 \cdot X_4 + 0.999 \cdot X_5,$$

missä

$Z$  = konkurssiuhkaa mittaava painotettu summa, ”konkurssitunnusluku”

$X_1$  = Nettokäyttöpääoma/Koko pääoma

$X_2$  = Kertyneet voittovarot/Koko pääoma

$X_3$  = Tulos ennen korkoja ja veroja/Koko pääoma

$X_4$  = Oman pääoman markkina-arvo/Vieraan pääoman kirjanpitoarvo

$X_5$  = Myynti/Koko pääoma.

Nettokäyttöpääoman suhde koko pääomaan ( $X_1$ ) mittaa yrityksen maksuvalmiutta. Kertyneiden voittovarojen suhde koko pääomaan ( $X_2$ ) mittaa yrityksen pitkän aikavälin kannattavuutta. Altmanin mukaan se sisältää myös yrityksen iän vaikutuksen, sillä nuoremmille yrityksille ei ole ehtinyt kertyä voittovaroja yhtä paljon kuin vanhemmille. Tuloksen ja koko pääoman suhde ( $X_3$ ) kuvaa yrityksen pääoman todellista tuottavuutta (lyhyen aikavälin kannattavuutta). Altman korostaa sen tärkeyttä siksi, että yrityksen koko olemassaolo perustuu sen pääoman kykyyn tuottaa tulosta. Oman pääoman markkina-arvon ja vieraan pääoman suhde ( $X_4$ ) mittaa vakavaraisuutta. Myynnin suhde pääomaan ( $X_5$ ) mittaa pääoman kykyä tuottaa tuloja. Sen arvo riippuu liikkeenjohdon kyvystä menestyä kilpailussa. Tällä tunnusluvulla ei ollut yksittäisenä lukuna minkäänlaista erottelukykyyä, mutta painotetussa funktiossa se paljastui toiseksi merkittävimmäksi tunnusluvuksi. (Altman 1968, 594–596)

Liitteessä 2 on esitetty luokitteluvirheet Altmanin estimointiaineistossa viitenä vuonna ennen konkurssia ja testiaineistossa vuotta ennen konkurssia. Siitä nähdään, että erottelufunktio luokittelee vuotta ennen konkurssia väärin vain 5 % havainnoista estimointiotoksessa, mikä on selvästi paremmin kuin Beaverin (1966) parhaalla yksittäisellä tunnusluvulla. Tosin testiotos osoittaa, että tulos ei ole täysin yleistettävissä. Erottelukyky heikkenee estimointiotoksessa nopeasti, koska kokonaisvirheprosentti on kolme vuotta ennen konkurssia jo 52 %. Tällä ennustamiskyvyllä ei ole mitään käytännön arvoa, joten Altmanin mallilla on käyttöä konkurssin ennustajana vain kaksi vuotta ennen konkurssia. (Altman 1968, 599–604)

Altman tutki tarkasti myös erottelufunktion *kriittisen arvon* merkitystä luokittelussa. Hän havaitsi aineistostaan, että kaikki yritykset, joilla ennustamismallin arvo (z-luku) on yli 2.99, ovat toimivia. Vastaavasti kaikki yritykset, joilla z-luku on alle 1.81, ovat konkurssiyrityksiä. Jos kriittiseksi

arvoksi valitaan 2.99, erottelufunktio luokittelee oikein kaikki konkurssiyrietykset (virhetyyppi I = 0). Jos taas kriittiseksi arvoksi valitaan 1.81, malli luokittelee oikein kaikki toimivat yritykset (virhetyyppi II = 0). Näiden arvojen välisellä *harmaalla alueella* konkurssiyrietykset ja toimivat yritykset menevät ristiin ja tehdään väistämättä luokitteluvirheitä. Altman valitsi kriittiseksi arvoksi luvun 2.675, jonka avulla kokonaisluokitteluvirhe jäi pienimmäksi hänen aineistossaan. (Altman 1968, 606–607)

#### 4.2.2 Aatto Prihtin malli

Laitisen (1990, 58) mukaan suurin osa konkurssien ennustamista koskevista tutkimuksista on puhtaasti empiirisiä. Niissä ennustamismalli laaditaan valitusta yritysaineistosta ilman teoreettisia perusteluita. Tästä on kuitenkin myös poikkeuksia, joista suomalaisen Aatto Prihtin (1975) väitöskirjatutkimus on hyvä esimerkki. Tutkimus on ensimmäinen Suomessa tehty alan tieteellinen työ. Prihtin kehittämä konkurssin ennustamismalli osoittautui käyttökelpoiseksi ja sitä onkin käytetty yleisesti esimerkiksi erilaisissa yritysanalyysiohjelmistoissa. Siksi malli esitellään tässäkin tutkielmassa pääpiirteittäin.

Altmanin (1968) tapaan myös Prihti käytti yhdistelmäluvun rakentamiseen erotteluanalyysia. Prihti kuitenkin perusteli käyttämiensä tunnuslukujen valinnan teoreettisen konkurssimallin avulla, kun taas Altman perusteli valintansa empirian avulla. Prihtin ydinajatus oli mallintaa yritysten käyttäytymistä taloudellisessa ahdingossa. Hän johti hypoteesit yrityksen konkurssia edeltävästä käyttäytymisestä. Hypoteeseista tehtiin mitattavia etsimällä tunnusluvuista niille sopivat vastineet. (Prihti 1975, 35–76)

Prihtin ensimmäinen hypoteesi oli seuraava: *Toimivilla yrityksillä tulorahoitus yleensä kattaa rahoituksen maksuvaatimukset.* Prihti näki yrityksen sarjana perättäisiä investointeja. Investoinnit rahoitetaan tulorahoituksella sekä omalla ja vieraalla pääomalla, jolloin rahoitustarpeen aiheuttamista kustannuksista saadaan investoinneille minimituottovaatimus. Investointien täytyy tuottaa tulorahoitusta ainakin sen verran, että vieraan ja oman pääoman maksuvelvoitteet voidaan hoitaa. Tällöin yritys voi jatkaa toimintaansa suunnitellulla tavalla ilman lisäneuvotteluja rahoituksesta. Jos näin ei käy, yritys joutuu käymään uusia neuvotteluja investointiensä turvaamiseksi. Yrityksen lopettamispäätös tulee ajankohtaiseksi silloin, kun sidosryhmät eivät enää luota yrityksen investointien kykyyn tuottaa riittävästi tuloja. Tätä tulorahoitushypoteesia Prihti

mittasi kassavirtalaskelman mukaisella tulojäämällä verojen jälkeen ennen muuta voitonjakoa. Tämä tulojäämä jaettiin koko pääoman määrällä, josta rahoituksen maksuvaatimukset ovat peräisin, koska selvää vastinetta rahoituksen maksuvaatimuksille ei tilinpäätöstiedoista löytynyt. Näin ollen malliin saatiin seuraava:  $Tunnusluku_1 = \text{Tulojäämä verojen jälkeen} / \text{Taseen koko pääoma}$ . (Prihti 1975, 35–76)

Hypoteesi 2: *Konkurssiajankohta on ensimmäinen sellainen ajankohta, jossa syntyvä maksuvajaus (=lisäluoton tarve) ylittää saatavissa olevan enimmäislisäluoton määrän.* Toinen hypoteesi liittyy konkurssiajankohdan määrittelyyn. Yrityksen maksuvaatimusten ylittäessä tulorahoituksen määrän syntyy tarve saada lisäluottoa. Jos yritys ei sitä saa, se joutuu konkurssiin. Käytössä olevaa lisäluottoa Prihti mittasi käsitteellä negatiivinen quick, joka muodostuu vähentämällä rahoitusomaisuudesta lyhytaikainen vieras pääoma. Tämän lisäluoton enimmäismäärää ei voida suoraan laskea taseesta, vaan se selviää empiirisen tarkastelun yhteydessä. Lisäluoton määrään sisältyy virhemahdollisuuksia erityisesti pitkäaikaisen ja lyhytaikaisen vieraan pääoman rajanvedon kohdalla. Tämän takia Prihti mittasi velkaantumista quickin lisäksi velkaantumisasteella, joka kuvaa yrityksen velkaantumista kokonaisuutena. Prihti suhteutti quick-käsitteen taseen koko pääomaan, jolloin hän päätyi seuraaviin tunnuslukuihin:  $Tunnusluku_2 = \text{Quick} / \text{Taseen koko pääoma}$ ,  $Tunnusluku_3 = \text{Vieras pääoma} / \text{Taseen koko pääoma}$ . (Prihti 1975, 35–76)

Hypoteesi 3: *Yrityksen johto arvioi yksipuolisen lisäluoton sitä helpommin otettavaksi, mitä alemmaksi sidosryhmä on luokiteltu etuoikeusjärjestyksessä.* Tämä hypoteesi käsittelee siis sidosryhmiltä saatavien lisäluottojen käyttöjärjestystä. Neuvoteltavissa olevan lisäluoton kohdalla oletettiin, että käyttöjärjestys ratkeaa koron perusteella. Sen sijaan yksipuolisen lisäluoton käyttöjärjestys perustuu Prihtin hypoteesin mukaan sidosryhmien juridiseen etuoikeusjärjestykseen, jonka mukaisesti yrityksen omaisuus jaetaan konkurssimenettelyssä. Oletuksena oli, että alemmilla tasoilla olevat sidosryhmät hakevat yritystä harvoin konkurssimenettelyyn, koska saamisen takaisinsaannin todennäköisyys on pieni. Tätä hypoteesia Prihti ei kuitenkaan testannut eikä sisällyttänyt malliinsa. Tämä johtui siitä, että sidosryhmittäisiä lisäluottoja ei voitu laskea tilinpäätösaineistoista. (Prihti 1975, 51–58)

Prihtin yritysaineisto muodostui 49 konkurssiyrityksestä ja 87 toimivasta vertailuyrityksestä. Vertailuyritykset valittiin siten, että toimialajako vastasi konkurssiyritysten jakautumista. Prihti ei käyttänyt vastinparimenettelyä. Tätä hän perusteli sillä, että toimivia yrityksiä on paljon enemmän

kuin konkurssiyrityksiä. Lisäksi toimivien ja konkurssiyritysten keskimääräiset suuruusluokat saattavat poiketa toisistaan. Prihti jakoi yritykset kahteen ryhmään siten, että estimointiryhmään jäi 31 konkurssiyritystä ja 59 toimivaa yritystä sekä testiryhmään vastaavasti 18 ja 28 yritystä. (Prihti 1975, 79–83)

Prihti testasi valitsemiansa kolmea tunnuslukua aineistossaan ja huomasi, että konkurssiyritysten tulorahoitus, mahdollisuus lisäluottoon ja velkojen kokonaismäärä ovat jo vuosia ennen konkurssia heikkommat kuin toimivilla yrityksillä. Lisäksi tunnuslukujen arvot heikkenevät jatkuvasti konkurssihetken lähestyessä. Prihti muodosti ennustamismallin sekä vuotta että kahta vuotta ennen konkurssia. Tarkimmin erottelussa toimi malli, joka estimoitiin erottelemaan konkurssiyritykset ja toimivat yritykset vuotta ennen konkurssia. Tämä erottelufunktio (Prihtin konkurssin ennustamismalli) on seuraavanlainen (kaava 4):

$$(4) \quad Z = 0.049 \cdot \text{Tunnusluku}_1 + 0.021 \cdot \text{Tunnusluku}_2 - 0.048 \cdot \text{Tunnusluku}_3,$$

missä

$\text{Tunnusluku}_1 = 100 \cdot \text{Tulojäämä verojen jälkeen} / \text{Taseen koko pääoma}$

$\text{Tunnusluku}_2 = 100 \cdot (\text{Rahoitusomaisuus} - \text{Lyhytaikaiset velat}) / \text{Taseen loppusumma}$

$\text{Tunnusluku}_3 = 100 \cdot \text{Vieras pääoma} / \text{Taseen loppusumma}$ . (Prihti 1975, 102)

Erottelufunktiolle saatiin kriittiseksi arvoksi teoreettisin perustein  $Z = -4,55$  (Prihti 1975, 102). Tämän kriittisen arvon perusteella lasketut luokitteluvirheet Prihtin estimointi- ja testiaineistossa on esitetty liitteessä 3. Kokonaisluokitteluvirhe estimointiaineistossa on 20 % vuotta ennen konkurssia, jonka jälkeen se kasvaa melko hitaasti. Tulosten tulkinnassa on huomioitava se, että vertailuaineistona käytettyjen toimivien yritysten tiedot pysyvät vertailussa aina samoina, jolloin virhetyypin II osuus on ajassa vakio. Testiaineistossa virhetyypin I osuus on ensimmäisinä vuosina ennen konkurssia huomattavan pieni, mutta se kasvaa nopeasti. Virhetyypin II osuus on sen sijaan suuri koko ajan testiaineistossa. Virhetyypin I nopea kasvu johtaa siihen, että Prihtin malli ei ole käyttökelpoinen ennustettaessa konkurssia pidemmällä kuin kahden vuoden aikahorisontilla, mikä havaittiin myös Altmanin (1968) z-mallin kohdalla. Liitteistä 2 ja 3 nähdään, että Prihti ei päässyt yhtä hyvään luokittelutarkkuuteen estimointiaineistossa kuin Altman, mutta Prihtin mallin tarkkuus säilyi Altmanin z-mallia paremmin testiaineistossa. Yleistä ennustuskykyä ilmaisevan testiaineiston tuloksissa Prihtin ja Altmanin välillä ei enää ollut suurta eroa.

### 4.3 Regressioanalyysi

Konkurssia ennustavan yhdistelmäluvun rakentamismenetelmänä voidaan käyttää myös *regressioanalyysia*. Joissakin tutkimuksissa (Aziz & Dar 2004; Dimitras ym. 1996) samaa menetelmää kutsutaan *lineaarisen todennäköisyyden malliksi* (linear probability model, LPM). Regressioanalyysi on hyvin samankaltainen menetelmä kuin erotteluanalyysi. Regressioanalyysissa merkitään konkurssiyrityksen tilaa arvolla 0 ja toimivan yrityksen tilaa arvolla 1. Tavoitteena on löytää muuttujalle eli yrityksen tilalle mahdollisimman hyvä selitysyhtälö. *Lineaarisessa regressioanalyysissa* selitysyhtälönä toimii käytettyjen tunnuslukujen painotettu summa. Painotettu summa vastaa periaatteessa erotteluanalyysin tuottamaa mallia, mutta regressioanalyysissa tunnuslukujen kertoimien arvot on kiinnitetty samalla kun tilamuuttujalle on annettu arvot 0 ja 1. Erotteluanalyysissa kertoimet normeerataan eri periaatteilla. Näin kertoimien suhteet ovat sekä erottelu- että regressioanalyysissa samat, mutta niiden absoluuttiset arvot saattavat vaihdella tehdystä normeerauksesta riippuen. (Laitinen 1990, 94–95)

Regressioanalyysin (tai lineaarisen todennäköisyyden) tuottamaa mallia voidaan mallintaa matemaattisesti samoin kuin erotteluanalyysia (kaava 5):

$$(5) \quad Y = a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n.$$

Kaavassa  $a$ :t kuvaavat tunnuslukujen painokertoimia ja  $X$ :t tunnuslukuja.  $Y$  saa arvoja nolasta yhteen. Nollan ja yhden välille sijoittuvat  $Y$ :n arvot voidaan väljästi tulkita yrityksen konkurssin todennäköisyydeksi. Täten kaavan 5 voidaan tulkita kuvaavan yrityksen konkurssitodennäköisyyttä. Regressioanalyysia käytetään usein kuitenkin siten, että määritetään tilamuuttuja  $Y$ :lle erotteluanalyysin mukainen kriittinen arvo nollassa ja yhden väliltä, jonka perusteella yritykset luokitellaan konkurssiyrityksiksi tai toimintaansa jatkaviksi. Tämä voi olla edullista niille käyttäjille, jotka eivät halua käsitellä todennäköisyyksiä. (Aziz & Dar 2004, 7–8)

Regressioanalyysia voidaan käyttää konkurssin ennustamismallin estimoimiseen siten, että pyritään maksimoimaan regressiomallin selityssaste. Tällöin tunnuslukujen painokertoimia estimoitaessa pyritään minimoimaan luokkansa keskiarvosta poikkeavien yritysten poikkeamien neliöiden summa. Tätä menetelmää kutsutaan pns-menetelmäksi. Regressioanalyysi perustuu samoihin tilastollisiin oletuksiin kuin erotteluanalyysi. Pitkästi identtisten ominaisuuksien takia se johtaa

myös lähes samoihin tuloksiin erotteluanalyysin kanssa. (Laitinen & Laitinen 2004, 137–138) Tilastollisten oletusten toteutumattomuus ja tulosten samankaltaisuus erotteluanalyysin kanssa ovat vähentäneet konkurssitutkijoiden mielenkiintoa regressioanalyysia kohtaan (Dimitras ym. 1996, 503).

#### 4.4 Logit-analyysi

*Logit-analyysi* kuuluu ehdollisen todennäköisyyden menetelmien joukkoon. Logit-analyysissa lasketaan yritykselle konkurssin todennäköisyys, jota voidaan käyttää hyväksi päätöksenteossa. Menetelmässä on riippuvana muuttujana konkurssin todennäköisyyden logaritmi. Menetelmässä on siten kyse siitä, että mallinnetaan yrityksen konkurssin todennäköisyyttä logaritimuunnoksen avulla. Aiemmissa menetelmissä on mallinnettu yrityksen kuulumista joko konkurssiyrityksiin tai toimiviin yrityksiin ilman muunnoksia. Mallintaminen on siis mahdollista ilman logaritmeja, mutta logaritmien käytöllä todennäköisyyksien mallintamisessa saavutetaan tietty etu. Logaritimuunnos takaa nimittäin sen, että riippuva muuttuja voi saada mitä tahansa arvoja negatiivisen ja positiivisen äärettömän välillä. Riippuvasta muuttujasta tulee tällöin jatkuva, kun aiemmissa menetelmissä se on ollut diskreetti. Riippuvan muuttujan kumulatiivinen jatkuvuus takaa sen, että logit-menetelmässä ei tarvita tilastollisia taustaolettamuksia. (Aziz & Dar 2004, 8)

Perusideana ehdollisen todennäköisyyden menetelmissä on se, että konkurssin (tai ei-konkurssin) todennäköisyyden oletetaan noudattavan jotakin todennäköisyysjakaumaa erotteluanalyysin tai regressioanalyysin antaman tilaennusteen suhteen. Tällöin oletetaan, että konkurssin todennäköisyys voidaan laskea seuraavalla tavalla (kaava 6):

$$(6) \quad P(T, X_i) = F(a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n) = F(Z(X_i)).$$

Kaavassa 6  $X_i$  on tunnusluku,  $a$ :t ovat vakioita,  $P(T, X_i)$  on yrityksen  $i$  konkurssin todennäköisyys,  $Z(X_i)$  saman yrityksen regressioanalyysista saama tilamuuttujan ennuste ja  $F(Z(X_i))$  valitun todennäköisyysjakauman kertymäfunktion arvo pisteessä  $Z(X_i)$ . Todennäköisyys  $P(T, X_i)$  on voimassa sillä ehdolla, että yrityksen tunnusluvulla  $X_i$  on esitetty kaavassa arvo. Tämän vuoksi todennäköisyyden tuottavia menetelmiä nimitetään ehdollisen todennäköisyyden menetelmiksi. (Laitinen & Laitinen 2004, 140)

Ehdollisen todennäköisyyden menetelmistä logit-analyysi perustuu logistiseen jakaumaan. Tämän takia regressioperusteinen logit-malli voidaan yhden tunnusluvun tapauksessa kirjoittaa seuraavaan muotoon (kaava 7):

$$(7) \quad \ln(P/1-P) = a_0 + a_1 \cdot X_1.$$

Kaavassa  $P$  kuvaa konkurssin todennäköisyyttä,  $a$ :t ovat vakioita ja  $X$  on tunnusluku. Yhtälön oikea puoli kuvaa kokonaisuudessaan regressioanalyysin antamaa tilaennustusta. Kun ratkaistaan  $P$  kaavasta 6, voidaan yrityksen konkurssin todennäköisyys määrittää seuraavasti (kaava 8):

$$(8) \quad P(Z(X_i)) = \frac{1}{1 + e^{-(a_0 + a_1 \cdot X_1)}}.$$

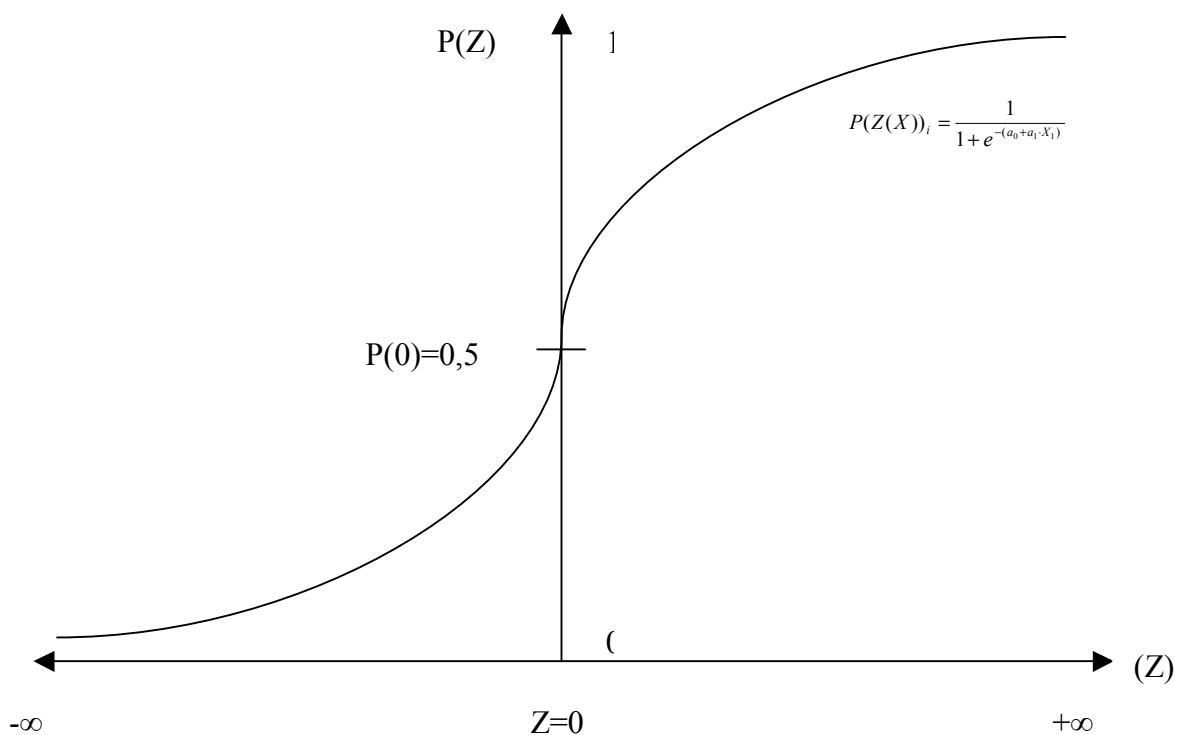
$P$  on siis konkurssin todennäköisyys  $Z$ :n funktiona,  $e$  on Neperin luku,  $a$ :t ovat vakioita ja  $X$  on tunnusluku. Usean tunnusluvun tapauksessa logit-mallin (kaavan 8)  $e$ :n eksponentin muodostaa erottelu- ja regressioanalyysistä tuttu tunnuslukujen painotettu summa. (Aziz & Dar 2004, 8)

Laitisen ja Kankaanpään (1999, 70–71) mukaan tunnuslukujen painot valitaan ehdollisen todennäköisyyden menetelmissä yleensä suurimman uskottavuuden menetelmällä. Regressioanalyysin soveltama pienimmän neliösumman menetelmä ei sovellu logit-analyysiin yhtä hyvin logit-analyysin epälineaarisuuden takia. Epälineaarisuus ilmenee siitä, että malli sisältää muitakin laskutoimituksia kuin tunnuslukujen painotetun summaamisen.

Logit-analyysin tuottamien tulosten tulkinta on helppoa. Tuloksena saatava konkurssitodennäköisyys on aina nollan ja yhden välillä, kuten voidaan havaita kuviosta 2. Menetelmällä saadaan siis konkurssin tai toiminnan jatkuvuuden ennusteen lisäksi tietoa ennusteen todennäköisyydestä. Jos ennusteiden virhetyypit painotetaan samanarvoiseksi, kriittiseksi arvoksi valitaan 0,5. Tällöin sekä 0,7 että 0,9 konkurssitodennäköisyydeksi saavat yritykset luokitellaan konkurssiin ajautuviksi. Ennusteeseen liittyy myös lisätieto siitä, että jälkimmäisen yrityksen konkurssi on selvästi todennäköisempi kuin ensimmäisen. Ehdollisen todennäköisyyden menetelmissä on helppo painottaa eri virhetyyppien osuuksia valitsemalla kriittinen arvo 0,5:stä poikkeavaksi. Esimerkiksi luotonantajalle saattaa olla hyödyllistä välttää ennusteissa enemmän



virhetyyppiä I kuin virhetyyppiä II. Konkurssiyrityksen luokitteluun toimivaksi saattaa tulla luotonantajalle kalliiksi. Kuvio 2 havainnollistaa logit-menetelmän jatkuvan jakauman etua tulosten tulkinnassa. Kuvioista nähdään myös se, että konkurssin todennäköisyyden vaihdellessa 0,5:n lähellä yritys on altis ennusteen muutoksille. Pieni muutos jossakin tunnusluvussa saattaa kääntää ennusteen toimivuudesta konkurssiksi tai päinvastoin. Sen sijaan lähellä ääripäitä yrityksen tilanteen ja sitä kautta tunnuslukujen on muututtava paljon, jotta myös ennustus yrityksen tulevaisuudesta muuttuisi.



Kuvio 2. Ehdollisen todennäköisyyden menetelmän kumulatiivinen todennäköisyyskäyrä (Laitinen & Kankaanpää 1999, 70)

#### 4.5 Probit-analyysi

*Probit-analyysi* kuuluu myös ehdollisen todennäköisyyden menetelmiin. Se on hyvin samankaltainen kuin logit-analyysi. Myös probit-analyysissä lasketaan yrityksen tilamuuttujan jatkuvan kumulatiivisen jakauman avulla yritykselle konkurssin todennäköisyys. Täten probit-analyysiakaan eivät rasita tilastolliset oletukset. Probit-analyysin matemaattisessa mallintamisessa lähtökohta on logit-analyysin tapaan se, että konkurssin (tai ei-konkurssin)

todennäköisyyden oletetaan noudattavan jotakin todennäköisyysjakaumaa erotteluanalyysin tai regressioanalyysin antaman tilaennusteen suhteen. Täten lähdetään liikkeelle samasta kaavasta 6. Probit-analyysi eroaa logit-analyysistä siinä, että probit-analyysissä käytetään logistisen jakauman sijaan normaalijakaumaa. Probit-analyysissä yhden tunnusluvun sisältämä regressiopohjainen konkurssitodennäköisyys määräytyy seuraavasti (kaava 9):

$$(9) \quad P(Z(X_i)) = \int_{-\infty}^{a_0 + a_1 \cdot X_i} \frac{1}{(2\pi)^{1/2}} e^{-z^2/2} dz.$$

Symbolit ovat kaavassa 9 samoja kuin logit-analyysin kohdalla. Kaavasta 9 voidaan havaita, että probit-analyysin ennuste konkurssin todennäköisyydestä perustuu normaalijakauman integroituun pinta-alaan. (Dimitras ym. 1996, 504–505)

Probit-analyysin tulosten tulkinta tehdään samalla tavalla kuin logit-analyysin kohdalla. Ainoana merkittävänä teoreettisena erona menetelmillä on siis sovellettava jakauma. Käytännössä logit-analyysia on sovellettu huomattavasti enemmän konkurssin ennustamiseen. (Dimitras ym. 1996, 504–505)

#### 4.6 Arviointi

Luvun 4 tilastolliset yhdistelmäluvun rakentamismenetelmät eroavat selvästi *käytön yleisyyden* osalta. Erotteluanalyysia on käytetty erittäin paljon. Dimitrasin ym. (1996, 494) mukaan erotteluanalyysi on käytetyin konkurssin ennustamisen menetelmä. Keaseyn ja Watsonin (1991, 90) mukaan erotteluanalyysia oli käytetty yli sadassa konkurssitutkimuksessa vuoteen 1991 mennessä. Regressioanalyysi sen sijaan menestyy erotteluanalyysia huonommin *käytön yleisyyden* näkökulmasta. Dimitrasin ym. (1996, 494) 59 konkurssitutkimusta sisältävän listauksen mukaan regressioanalyysia on käytetty viidessä tutkimuksessa. Azizin ja Darin (2004, 32–34) 89 konkurssitutkimusta sisältävä listaus lisää regressioanalyysin sovelluksia kahdella. Lisäksi Suuriniemi (1993) on soveltanut menetelmää pro gradu -tutkielmassaan. Täten regressioanalyysille tutkielman lähdemateriaalista löydetty sovellukset jäävät alle kymmeneen, minkä takia regressioanalyysi ei saa hyvää arvioita *käytön yleisyyden* osalta.

Logit-analyysin kohdalla *käytön yleisyyden* tilanne on toinen. Wilsonin ja Shardan (1994, 545–557) mukaan erotteluanalyysi ja logit-analyysi ovat käytetyimpiä menetelmiä konkurssin

ennustamisessa. Sekä Dimitrasin ym. (1996, 494) että Azizin ja Darin (2004, 32–34) listauksissa on logit-analyysille löydetty selvästi yli 10 käyttökohdetta, joten logit-analyysi täyttää *käytön yleisyyden* kriteerin. Probit-analyysia sen sijaan on käytetty selvästi harvemmin. Dimitrasin ym. (1996, 494) sekä Azizin ja Darin (2004, 32–34) listauksista on löydettävissä vain neljä tutkimusta, joissa probit-analyysia on käytetty. Lisäksi Zopounidis ja Doumpos (1999) käyttivät probit-analyysia yhtenä vertailumenetelmänä. Samojen tutkijoiden mukaan probit-analyysia on käytetty myös Casey, McGeen ja Stinkeyn (1986) tutkimuksessa. Probit-analyysille tutkielman lähdemateriaalista löydettyjen käyttökohteiden jäädessä kuuteen voidaan todeta, että menetelmä ei täytä *käytön yleisyyden* kriteeriä.

*Informaatisällön* kriteerin osalta kaikki luvussa 4 esitetyt yhdistelmäluvun rakentamismenetelmät täyttävät kriteerin ensimmäisen osa-alueen. Kaikilla menetelmillä rakennettaviin malleihin voidaan sisällyttää haluttu määrä tunnuslukuja. Täten mallit saadaan sisältämään informaatiota kaikista yrityksen talouden ulottuvuuksista. Valittavien tunnuslukujen määrässä kannattaa kuitenkin huomioida mallin rakentamisen helppous. Jos tunnuslukuja on toistakymmentä, mallin rakentaminen on hidasta, sillä jokaiselle tunnusluvulle on estimoitava optimaalinen painokerroin. Tunnuslukujen määrä on siis jokaisen käyttäjän itse ratkaistava, mutta yhdistelmäluvun menetelmät eivät kannusta kovin runsaan tunnuslukumäärän käyttöä. Siksi *informaatisällön* kriteerin ensimmäisen osa-alueen menestys on kaikilla kohtalaisen hyvä.

*Informaatisällön* toisella osa-alueella syntyy eroja. Erotteluanalyysin tulos voi olla mikä tahansa luku, jonka vertaaminen valittuun kriittiseen arvoon johtaa vain yrityksen dikotomiseen luokitteluun. Tuloksesta ei voida tehdä muita perusteltuja päätelmiä, sillä paljon kriittisestä arvosta poikkeavalle yhdistelmäluvun arvolle saattaa löytyä vielä enemmän poikkeava arvo, koska diskreetillä tulosjakaumalla ei ole ääripäitä. Regressioanalyysin tulokset ovat nollan ja yhden välillä, joten ne antavat lisätietoa ennusteen toteutumisen todennäköisyydestä. Sen takia regressioanalyysin tuloksia on väljästi tulkittu konkurssin todennäköisyyksiksi (Aziz & Dar 2004, 8). Regressioanalyysin tulokset ovat siten erotteluanalyysin tuloksia informatiivisempia.

Jatkuvaan kumulatiiviseen jakaumaan perustuvat logit- ja probit-analyysi antavat yrityksen tilaennusteen lisäksi perustellun tiedon ennusteen toteutumisen todennäköisyydestä. Jos kriittinen arvo on 0,5 ja yritys saa yhdistelmäluvulle arvon 0,9, sen konkurssi on selvästi todennäköisempi kuin 0,6 arvoksi saavan yrityksen. Tällä tavalla logit- ja probit-analyysi antavat lisätietoa konkurssin ennustamismallin käyttäjälle (kuvio 2). Lisätieto voi olla monessa tilanteessa arvokasta.

Sijoittaja saattaa haluta tehdä riskisijoituksen toiseen kahdesta yrityksestä, mutta ei osaa valita näiden väliltä. Erotteluanalyysi ei anna muuta tietoa kuin että molemmille yrityksille ennustetaan konkurssia. Regressio-, logit- ja probit-analyysit antavat tiedon myös konkurssien todennäköisyyksistä. Mainituilla lukuesimerkeillä rationaalinen sijoittaja valitsisi yrityksen, joka saa yhdistelmäluvun arvoksi 0,6. Hän tietää, että yhdistelmäluvun arvoksi 0,9 saava yritys on lähes konkurssikypsä, koska maksimiarvo menetelmissä on 1. Yhteenvetona *informaatioisällön* osalta voidaan todeta, että erotteluanalyysi menestyy kohtalaisesti, regressioanalyysi kohtalaisen hyvin ja logit- ja probit-analyysit hyvin.

*Ymmärrettävyyden* kohdalla arvioidaan menetelmien tuottamien konkurssin ennustamismallien toimintaperiaatteiden ymmärrettävyyttä. Lineaarinen erotteluanalyysi ja regressioanalyysi tuottavat erittäin ymmärrettävät mallit (kaavat 1 ja 5). Niissä yhdistelmäluvu muodostuu painokertoimilla varustettujen tunnuslukujen summasta. Käyttäjän on helppo havaita, miten valitut tunnusluvut ja muutokset niissä vaikuttavat tulokseksi saatavaan ennusteeseen. Kvadraattinen erotteluanalyysi ja regressioanalyysi ovat jo hieman monimutkaisempia (kaava 2). Niissä on mukana tunnuslukujen tuloja ja potensseja. Yhdistelmäluvu määräytyy kuitenkin edelleen muutamien tekijöiden summana, joten tunnuslukujen arvojen muuttumisen aiheuttamat muutokset ennusteissa ovat pääteltävissä. Mallin toimintaperiaate on kvadraattisissakin analyyseissa melko yksinkertainen.

Logit-analyysin tuottama konkurssin ennustamismalli on edellisiä monimutkaisempi (kaava 8). Se sisältää osamäärän ja Neperin luvun negatiivisen eksponentin. Käyttäjän matemaattisista valmiuksista riippuu, voidaanko mallia pitää ymmärrettävänä. Keasey ja Watson (1991, 92) ovat ymmärrettävyyden kannalla. Myös Ohlson (1980, 118) toteaa, että mallia on suhteellisen helppo tulkita. Aziz ja Dar (2004, 23) puolestaan korostavat, että ymmärrettävyys on selvästi heikompi kuin erotteluanalyysillä. Erotteluanalyysin verrattaessa ymmärrettävyys on kiistatta heikompi, mutta silti logit-analyysille voidaan antaa kohtalaisen hyvä arvio ymmärrettävyydestä. Kaava 8 ei kuitenkaan ole ylivoimainen tulkittavaksi. Muutamien käyttökertojen jälkeen käyttäjä pystyy varmasti tulkitsemaan mallin toimintaperiaatteita ja ymmärtää, miksi ennuste muuttuu tunnuslukujen muuttuessa tiettyyn suuntaan. Ymmärrys mallin toimintaperiaatteista herättää käyttäjässään luottamusta mallia kohtaan.

Probit-analyysia voidaan jo pitää monimutkaisena. Kaavasta 9 nähdään, että menetelmän tuottama malli sisältää osamääräisen integraalilausekkeen. Sen tulkinta vaatii korkeampaa matemaattista osaamista, jota ei kaikilla konkurssin ennustamismallin käyttäjillä varmastikaan ole. Siksi probit-

menetelmän käyttäjien on ratkaistava omalta kohdaltaan se, voiko epäselviin toimintaperiaatteisiin perustuviin ennusteisiin luottaa kaikissa tilanteissa. Probit-menetelmän tuottaman mallin monimutkaisuus saattaa olla yksi syy siihen, että monilta muilta osin hyvää menetelmää on käytetty vähän konkurssin ennustamisessa. *Ymmärrettävyyden* kriteeri täyttyy siis erottelu- ja regressioanalyysin kohdalla hyvin, logit-analyysin kohdalla melko hyvin ja probit-analyysin kohdalla huonosti.

Tarkastellaan *mallin rakentamisen ja käytön helppouden* kriteerin osalta ensin *rakentamisen helppoutta*. Kaikissa yhdistelmäluvun rakentamismenetelmissä on ratkaistava tunnuslukujen valinta, yhdistämistapa ja painottaminen (Laitinen 1990, 90). Tunnuslukujen valinta perustuu niiden ennustamiskyvyn testaamiseen ja ei eroa menetelmien välillä. Yhdistämiseen käytetään joko lineaarista tai kvadraattista summamuotoa, joten sekin on samankaltaista kaikilla menetelmillä. Tunnuslukujen painottamiseen sen sijaan käytetään eri tapoja, kuten pienimmän neliösumman menetelmää ja suurimman uskottavuuden menetelmää (Laitinen & Laitinen 2004, 137–141). Näiden menetelmien käytöstä ei kuitenkaan ole raportoitu ongelmakohtia, jotka tekisivät eroja tilastollisten konkurssin ennustamismenetelmien välille. Erotteluanalyysin toteutumattomien taustaoletuksien haittavaikutuksia voidaan lieventää sillä, että rakennetaan malli suuren yritysotoksen pohjalta (Laitinen & Laitinen 2004, 137). Azizin ja Darin (2004, 23) mukaan myös logit- ja probit-menetelmät toimivat parhaiten, kun niillä rakennettujen mallien perustana oleva otos on suuri. Käytännössä suurten toimivia ja konkurssiyrityksiä sisältävien otosten kerääminen on hankalaa, sillä konkurssiyrityksiä tilinpäätöstietoineen ei yleensä ole kovin paljon käytettävissä. Tämä heikentää hieman muuten hyvää *mallin rakentamisen helppoutta* erottelu-, logit- ja probit-analyysien osalta.

Mallin *käytön helppouden* osalta on olennaista, kuinka paljon käyttäjän on nähtävä vaivaa ennusteen saamiseen. Erotteluanalyysilla ja regressioanalyysilla rakennetun mallin käyttö on erittäin helppoa. Lineaarisen muodon malli on laskettavissa nopeasti vaikka taskulaskimella syöttämällä tunnusluvut kaavaan. Kvadraattisten mallienkin laskeminen onnistuu hyvillä taskulaskimilla. Tietokoneen taulukkolaskentaohjelmilla tulos on saatavissa silmänräpäyksessä. Logit-menetelmällä rakennettu malli on myös helppo käyttää. Neperin luvun eksponentin sisältävän osamäärän laskeminen onnistuu graafisilla laskimilla. Taulukkolaskentaohjelmilla logit-mallin laskeminen edellyttää vain tunnuslukusyötteiden antamista, minkä jälkeen tulos on heti käytettävissä. Ainoastaan probit-mallin laskeminen vaatii paneutumista. Monimutkaisen integraalin laskeminen onnistuu hyvin taulukkolaskennassa, mutta integraalin syöttäminen ohjelmaan ei varmastikaan ole

kaikilla entuudestaan tuttua. Niinpä probit-mallin käyttämiseksi saattaa joutua näkemään jonkin verran vaivaa. *Mallin rakentamisen ja käytön helppouden* kriteerin osalta voidaan todeta, että regressioanalyysi menestyy hyvin, erotteluanalyysi ja logit-analyysi melko hyvin ja probit-analyysi kohtalaisesti.

Menetelmien *luokittelukyvyssä* ei ole suuria eroja, sillä kaikki arvioitavat menetelmät ovat vähintään kohtalaisia luokittelemaan yritykset konkurssiin ajautuviksi tai toimintaansa jatkaviksi. Liitteestä 2 nähdään, että Altmanin erotteluanalyysillä rakentama z-luku luokitteli oikein testiaineiston yritykset 83 prosentin tarkkuudella. Prihtin vastaava luku oli 78 prosenttia (liite 3). Myöhemmin erotteluanalyysillä on päästy tarkempiin tuloksiin. Azizin ja Darin (2004, 32–37) listaus osoittaa, että lähes 30:ssä erotteluanalyysia soveltaneessa tutkimuksessa luokittelukyvyn keskiarvo vuotta ennen konkurssia oli 86 prosenttia. Kuutta eri konkurssin ennustamismenetelmää vertailevassa tutkimuksessaan Laitinen ja Kankaanpää (1999, 83) pääsivät erotteluanalyysillä 87 prosentin tarkkuuteen testiotoksessa vuotta ennen konkurssia.

Ennustuskyky ei säily erotteluanalyysissä pitkälle ennen konkurssia. Altmanin z-malli ennusti enää noin puolet tapauksista oikein kolme vuotta ennen konkurssia (liite 2). Tällaisilla ennusteilla ei ole mitään käyttöä, sillä kolikkoa heittämällä päästäisiin keskimäärin yhtä hyvään tulokseen. Prihtin mallilla päästiin sentään 72 prosentin tarkkuuteen kolmea vuotta ennen konkurssia (liite 3). Laitisen ja Kankaanpään (1999, 83) tutkimuksessa saman aikajänteen tarkkuus oli 68 prosenttia. Laitinen (1990, 54) esittää luonnollisen selityksen ennusteiden nopealle heikkenemiselle. Toiset tunnusluvut varoittavat konkurssista vasta viime hetkellä, kun taas toisilla (harvemmillä) tunnusluvuilla ennustuskyky säilyy pitkään. Yhdistelmäluke sisältää monia tunnuslukuja, joten mukaan tulee väkisinkin vain viime hetkellä varoittavia tunnuslukuja. Yksittäisillä tunnusluvuilla tätä ongelmaa ei ole, sillä niistä voidaan käyttää vain sellaista, jonka ennustuskyky säilyy pitkään. Erotteluanalyysin *luokittelukyvyssä* voidaan tehdä se johtopäätös, että menetelmän luokittelukyky on hyvä vuotta ennen konkurssia, mutta se ei säily kahta vuotta pitemmälle.

Regressioanalyysin *luokittelukyvyn* arviointi joudutaan tekemään vain muutaman tutkimuksen perusteella, sillä menetelmää on sovellettu harvoin. Toisaalta ennakko-oletuksena voidaan pitää sitä, että regressioanalyysin luokittelukyky ei ole hyvä, koska menetelmää ei ole käytetty paljon. Azizin ja Darin (2004, 37) kolmessa regressioanalyysia soveltaneessa konkurssitutkimuksessa luokittelukyvyn keskiarvo vuotta ennen konkurssia oli 81 prosenttia. Se antaa ennakko-oletukselle vahvistusta. Aziz ja Dar (2004, 23) toteavat myös, että regressioanalyysi tuottaa yleisesti liian

pessimistisiä ennusteita, mikä luonnollisesti heikentää luokittelukykyä. Toisaalta regressioanalyysin luokittelukyvyllä on myös puolestapuhujia. Laitinen ja Laitinen (2004, 137) sekä Dimitras ym. (1996, 503) toteavat, että regressioanalyysin ja erotteluanalyysin tulokset ovat samankaltaisia. Erotteluanalyysin luokittelukykyhän arvioitiin hyväksi. Regressioanalyysin käytön harvinaisuus saattaa kuitenkin muita menetelmiä huonomman luokittelukyvyn sijasta johtua siitä, että erotteluanalyysillä saadaan samat tai lähes samat tulokset, jolloin käyttäjät suosivat mieluummin erotteluanalyysia (Dimitras ym. 1996, 503). Regressioanalyysissä luokittelukyky ei säily pitkään samasta syystä kuin muiden yhdistelmäluvun rakentamismenetelmien kohdalla. Koska luokittelukyvyn arvion perustana olevissa tutkimuksissa ennustustarkkuus jää alle hyvän rajaksi asetetun 85 prosentin ja muut kannanotot ovat vaihtelevia, voidaan todeta, että regressioanalyysi menestyy vain kohtalaisesti *luokittelukyvyn* kriteerin osalta.

Ohlson (1980, 126) yhtenä varhaisimmista logit-analyysin soveltajista sai logit-mallinsa luokittelutarkkuudeksi 85 % vuotta ennen konkurssia. Hän ei käyttänyt testiotosta, joten tulos ei ole täysin vertailukelpoinen, sillä luokittelukyvyn arvioinnissa pyritään ensisijaisesti käyttämään testiotosten tuloksia. Azizin ja Darin (2004, 32–37) listauksessa on mukana lähes 20 logit-tutkimusta, joiden luokittelutarkkuuden keskiarvo vuotta ennen konkurssia oli 87 prosenttia. Laitisen ja Kankaanpään (1999, 83) logit-mallilla päästiin noin 90 prosentin tarkkuuteen. Dimitrasin ym. (1996, 504) mukaan logit-analyysia ja erotteluanalyysia vertaavissa tutkimuksissa on usein päädytty menetelmien yhtä hyvään luokittelukykyyn. Voidaan siis päätellä, että logit-analyysin *luokittelukyky* on hyvä.

Probit-analyysin harvojen sovellusten takia perusteita *luokittelukyvyn* arvioinnille on vähän. Skogsvik (1990, 153) sai probit-mallinsa tarkkuudeksi 84 prosenttia vuotta ennen konkurssia. Toisessa Azizin ja Darin (2004, 134) raportoimassa probit-tutkimuksessa päästiin 94 prosentin tarkkuuteen. Dimitrasin ym. (1996, 504) mukaan eräässä erotteluanalyysia ja probit-analyysia verranneessa tutkimuksessa tultiin siihen tulokseen, että probit-analyysin luokittelukyky on verrattavissa erotteluanalyysiin. Zavgren (1985, 28) sai yhtä hyvät tulokset probit-analyysille kuin logit-analyysille. Näiden perusteella voidaan päätellä, että probit-analyysin *luokittelukyky* on hyvä. Perusteena olevia tutkimuksia tämän päätelmän tekemiseen tosin on vähän, mutta sen voidaan olettaa johtuvan siitä, että tutkijat valitsevat mieluummin samankaltaisen mutta yksinkertaisemman logit-analyysin. Probit-analyysin harva käyttö ei siis todennäköisesti johdu menetelmän huonosta luokittelukyvästä. Myös logit-analyysin perustellusti hyvä luokittelukyky puoltaa probit-analyysin hyvää luokittelukykyä, sillä menetelmät ovat perusteiltaan hyvin samankaltaiset. Molempien

luokittelukykyä tosin hieman heikentää ennustuskyvyn lyhytjänteisyys samoin kuten erottelu- ja regressioanalyysin kohdalla.

*Johdonmukaisuuden* kriteerin osalta erotteluanalyysissa ei ole havaittu ongelmia. Menetelmän tuottamien mallien yksinkertainen rakenne puoltaa sitä, että tulokset ovat johdonmukaisia. Regressioanalyysissa sen sijaan on epäjohdonmukaisuutta. Vaikka menetelmässä normeerataan tunnuslukujen kertoimet siten, että yhdistelmäluku saa arvoja nollan ja yhden väliltä, joskus tulokseksi muodostuu nollaa pienempi tai yhtä suurempi luku (Dimitras ym. 1996, 503). Laitinen ja Laitinen (2004, 138–139) onnistuvat selittämään teoreettisesti tilanteen syntymisen, mutta siitä huolimatta skaalauksen ulkopuolelle osuvat arvot aiheuttavat tulkintaongelmia. Täten regressioanalyysi toimii toisinaan epäjohdonmukaisesti. Logit- ja probit analyysien käytössä ei ole havaittu vastaavia ongelmia, vaikka ne käyttävät samaa tulosskaalausta. Syynä tähän on menetelmien jakaumien jatkuvuus. Koska muitakaan epäjohdonmukaisuuksia ei menetelmistä ole raportoitu, voidaan logit- ja probit analyysien todeta menestyvän hyvin *johdonmukaisuuden* kriteerin osalta.

Mikään tilastollisista menetelmistä ei täytä *muutostensietokyvyn* kriteeriä. Laskentasaäntöjen muututtua tunnuslukujen määräytymisperiaatteet saattavat muuttua, jolloin mallit on estimoitava uudelleen. Muutostilanteissa täytyy vähintään painottaa tunnusluvut uudelleen, mutta jopa tunnuslukujen valintaa saattaa olla syytä muuttaa. Gricen ja Ingramin (2001, 11) tutkimus paljastaa hyvin Altmanin z-mallin ajallisen ja toimiallisen muutostensietokyvyttömyyden. Tutkijat testasivat Altmanin mallia lähes 30 vuotta myöhemmällä yritysotoksella. Z-mallin luokittelukyky oli pudonnut 58 prosenttiin, joka on onneton tulos. Altman loi mallinsa valmistustoiminnassa mukana olevilla yrityksillä, joten mallin oletettiin toimivan parhaiten valmistusyrityksissä. Tutkijat saivat myös tähän vahvistusta, sillä heidän valmistusyritysotoksessa luokittelutarkkuus oli 69 prosenttia ja kaikenlaisia yrityksiä sisältävässä otoksessa 58 prosenttia. Altmanin z-mallin toimivuuden huonontuminen niin ajallisissa kuin toimialallisissa muutoksissa on hyvä käytännön esimerkki erotteluanalyysin muutostensietokyvyttömyydestä. Tulos voidaan yleistää myös regressio-, logit- ja probit-analyyseihin, sillä näissä menetelmissä ei ole sellaisia eroavaisuuksia erotteluanalyysiin nähden, jotka parantaisivat *muutostensietokykyä*.

Erotteluanalyysia on kritisoitu paljon sen vaativista *taustaolettamuksista*, jotka eivät aina toteudu käytännössä (esim. Laitinen & Kankaanpää 1999, 69; Mossman, Bell, Swartz & Turtle 1998, 44; Keasey & Watson 1991, 91; Ohlson 1980, 112). Kvadraattisen erotteluanalyysin käyttö saattaa



parantaa olettamusten täyttymistä, mutta kvadraattisen muodon empiirinen soveltaminen on osoittanut, että kvadraattisuus ei välttämättä paranna ennustustarkkuutta (Laitinen & Kankaanpää 1999, 69). Kvadraattisen muodon käyttäminen saattaa jopa johtaa otoksesta riippuviin tuloksiin (Laitinen & Laitinen 2004, 136–137). Tämä vähentää kvadraattisen muodon käytön soveltuvuutta erotteluanalyysin ongelmien ratkaisemiseen, sillä mallien riippuvaisuus niiden luomisen pohjana olleista otoksista heikentää mallien yleistä ennustuskykyä huomattavasti. Ylipäänsä erotteluanalyysin usein toteutumattomat taustaoletukset altistavat menetelmän otoksista riippuville malleille (Keasey & Watson 1991, 91). *Taustaoletusten todenmukaisuuden* kriteerin huono täytyminen heikentää erotteluanalyysin soveltuvuutta konkurssin ennustamiseen. Regressioanalyysin kohdalla tilanne on sama, sillä regressioanalyysi yksinkertaistaen perustuu samoihin oletuksiin kuin erotteluanalyysi (Laitinen & Laitinen 2004, 137). Aziz ja Dar (2004, 23) täydentävät samaa havaintoa toteamalla, että regressioanalyysin taustaoletukset eivät tavallisesti toteudu.

Logit- ja probit-analyysien kohdalla *taustaoletusten todenmukaisuuden* tilanne on hyvä. Nämä menetelmät eivät vaadi erottelu- ja regressioanalyysin kaltaisia taustaolettamuksia toimiakseen moitteettomasti (Laitinen & Kankaanpää 1999, 76; Keasey & Watson 1991, 91). Dimitras ym. (1996, 504) toteavat, että logit-analyysista tuli 80-luvun alussa suosituin konkurssin ennustamismenetelmä pääasiassa juuri siksi, että menetelmässä vapaudutaan aiemmin suosituimman erotteluanalyysin vaativista taustaolettamuksista. Yhteenvetona *taustaoletusten todenmukaisuudesta* voidaan todeta, että erottelu- ja regressioanalyysi eivät täytä kriteeriä, mutta logit- ja probit-analyysit täyttävät.

Taulukossa 4 esitetään yksinkertaistettuna yhteenvetona yhdistelmäluvun tilastollisten rakentamismenetelmien arviointi tutkielmassa yhtenäisesti käytettävän konkurssin ennustamismenetelmien arviointikriteeristön avulla. Rastit osoittavat ne kriteerit, jotka kukin menetelmistä on sanallisessa arvioinnissa täyttänyt hyvin tai melko hyvin. On huomattava, että menetelmiä ei voi laittaa paremmuusjärjestykseen yksioikoisesti rastien määrän perusteella, sillä kriteereitä ei ole painotettu mitenkään. Kriteerit eivät siten ole samanarvoisia keskenään. Menetelmän saamien rastien eli sen täyttämien kriteereiden määrä kertoo menetelmän käytettävyydestä useasta näkökulmasta.

Taulukko 4. Yhdistelmäluvun tilastollisten rakentamismenetelmien arviointi konkurssin ennustamismenetelmien arviointikriteeristöllä

	DA	RA	LA	PA
Käytön yleisyys	x		x	
Informaatioisältö		x	x	x
Ymmärrettävyys	x	x	x	
Mallin rakentamisen ja käytön helppous	x	x	x	
Luokittelukyky	x		x	x
Johdonmukaisuus	x		x	x
Muutostensietokyky				
Taustaoletusten todenmukaisuus			x	x

DA=Erotteluanalyysi (Discriminant Analysis)

RA=Regressioanalyysi (Regression Analysis = Linear Probability Model (LPM))

LA=Logit-analyysi (Logit Analysis)

PA=Probit-analyysi (Probit Analysis)

# 5 KEINO- JA IHMISÄLYYN PERUSTUVAT KONKURSSIN ENNUSTAMISMENETELMÄT

## 5.1 Hermoverkot

Neurolaskennassa käytettävien *hermoverkkojen* (=neuroverkko, artificial neural networks, neural networks, connectionist networks, NN) tutkimusta on motivoinut alusta alkaen huomio, että ihmisäivot käsittelevät tietoa täysin eri tavalla kuin tavanomaiset tietokoneet. Ihmiset kykenevät sellaiseen massiiviseen rinnakkaisprosessointiin, josta tämänhetkisillä tietokoneilla voidaan vain haaveilla. Lisäksi ihmiset oppivat kokemuksesta ja kykenevät yleistämään ja käyttämään hyväkseen jo opittua tietoa uusissa asiayhteyksissä. Näiden ominaisuuksien takia ihmisäivot ja hermosto toimivat hermolaskentamallien innoittajina. Hermoverkkojen ydinidea on rakentaa tietokone tai tietokoneohjelma, joka toimii samoilla periaatteilla kuin ihmisäivot. (Järvelin 2003, 5)

Kohonen (1995, 51) mainitsee, että hermomallintamisen hyväksikäytössä on kaksi lähtökohtaa. Varsinkin varhaisimmissa sovelluksissa jo 1940-luvulla pyrittiin kuvaamaan mahdollisimman tarkasti sitä menetelmää, miten äivot prosessoivat informaatiota. Jäljittelemällä tarkasti tätä havaittua prosessointimenetelmää tai sen osaa saadaan tietoa aivojen toiminnasta ja lisäksi aivojen prosessointitapaa voidaan hyödyntää käytännön tilanteissa. Toinen lähtökohta hermomallintamisen hyväksikäyttöön on käytännönlähtöinen. Siinä on tarkoituksena luoda uusia malleja lähtökohtana olevien ihmisäivojen prosessointimallien pohjalta, minkä takia niitä kutsutaan keinotekoisiksi hermoverkoiksi. Luodut mallit muokkaantuvat kulloisenkin toimintatarkoituksen mukaan. Toimintatarkoituksia on paljon, sillä hermoverkkoja on käytetty muun muassa varaston kiertoajan optimointiin ja käsialan lukemiseen.

Ihmisäivojen perusyksikkö on *neuroni* eli hermosolu. Neuronit vastaanottavat viestejä muilta hermosoluilta ja tuottavat viesteihin vastauksia. Neuronin yleinen rakenne voidaan jakaa karkeasti neljään osaan: synapseihin, dendriitteihin, solukeskukseen ja aksoniin. Synapsit ovat kahden neuronin välisiä liitospisteitä, dendriitit toimivat hermosoluun sähköimpulssin muodossa saapuvan informaation välittäjinä ja aksoni taas välittää solukeskuksesta lähtevän informaation eteenpäin muille neuroneille. Aivoissa tietoa varastoituu neuronien välisiin liitospisteisiin. (Järvelin 2003, 5)

Myös hermoverkkojen peruslaskentayksikkönä on (yleensä keinotekoinen) neuroni. Hermoverkkojen neuroni koostuu *syötekanavasta*, *tuloskanavasta* ja *aktivaatiofunktioista*. Jokaiseen syötekanavaan liittyy paino, jolla esitetään syötekanavasta saapuvan syötteen voimakkuus. Aktivaatiofunktio laskee syötteiden perusteella neuronin tuloksen. Tuloskanavaa pitkin neuronin tulos lähtee eteenpäin. Lisäksi neuroniin liittyy *siirtotermi*, jolla säädellään neuronin aktivoitumistasoa, sekä *summain*, jolla summataan neuroniin saapuvat painollaan kerrotut syötteen. (Järvelin 2003, 5)

Matemaattisesti kuvattuna yksittäisen neuronin toimintaa voidaan mallintaa seuraavasti. Jokainen neuroniin saapuva reaalityyppinen syöte kerrotaan sitä vastaavan syötekanavan painolla. Näin saadut painotetut syötteen lasketaan yhteen, jolloin saadaan neuroniin saapuva kokonaissyöte  $u_i$  (kaava 10):

$$(10) \quad u_i = \sum_{j=1}^n w_{ij} x_j.$$

Kaavassa 10  $n$  on neuroniin kytkettyjen syötekanavien lukumäärä,  $w_{ij}$  syötekanavan  $j$  painoarvo ja  $x_j$  syötekanavaa  $j$  pitkin saapuva syöte. Kaava 10 vastaa siis esitetyistä peruskäsitteistä summainta. Olkoon neuronin aktivaatiofunktiona (reaali)funktio  $\varphi$ . Neuronin  $i$  tulos  $y_i$  saadaan laskemalla aktivaatiofunktion arvo syötteellä  $u_i - \theta$ , missä  $\theta$  on siirtotermi (kaava 11):

$$(11) \quad y_i = \varphi(u_i - \theta).$$

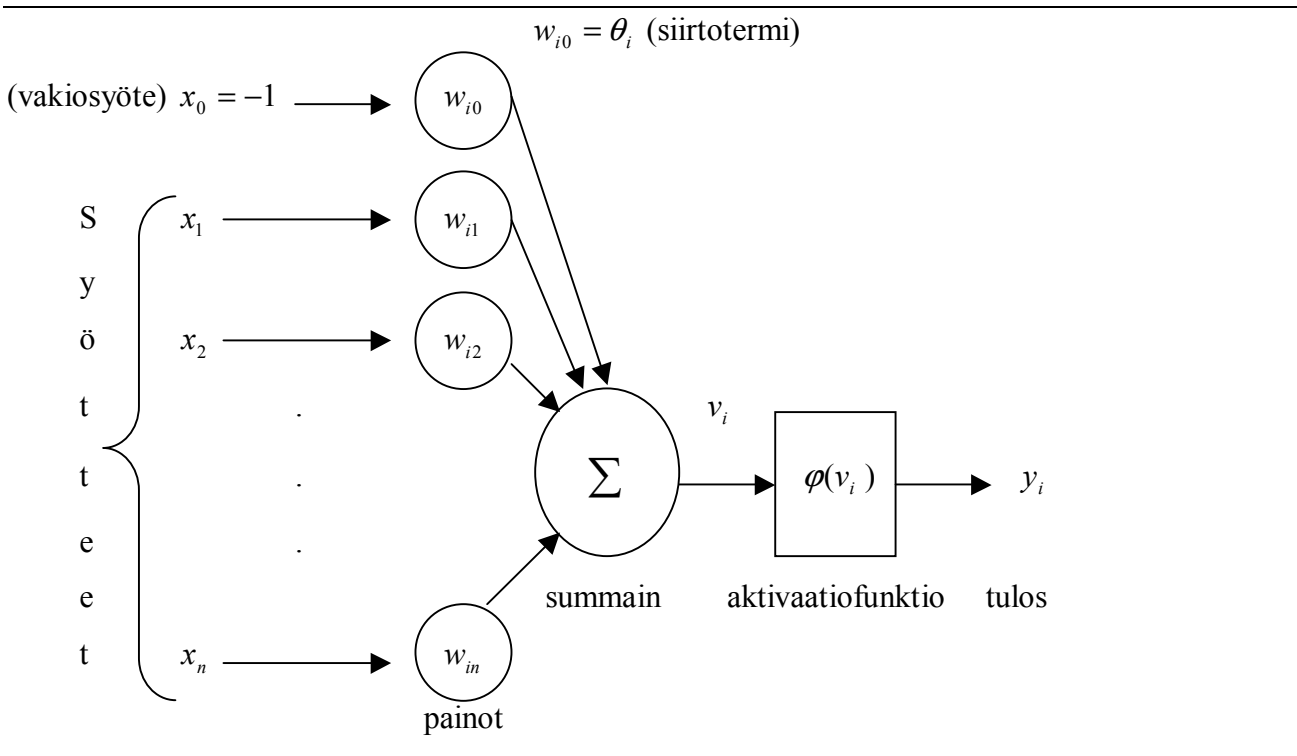
Aktivaatiofunktio  $\varphi$  voi olla mikä tahansa reaali-funktio, mutta käytännössä vain muutamia tyyppisiä käytetään. Siirtotermin  $\theta$  laskeminen voidaan yhdistää neuroniin saapuvan kokonaissyötteen laskemiseen lisäämällä neuroniin vakiosyöte  $x_0 = -1$  ja paino  $w_{i0} = \theta$ . Tällöin kaavat 10 ja 11 saadaan uusiin muotoihin (kaava 12 ja kaava 13):

$$(12) \quad v_i = \sum_{j=0}^n w_{ij} x_j$$

ja

$$(13) \quad y_i = \varphi(v_i). \quad (\text{Järvelin 2003, 6})$$


Kuvio 3 havainnollistaa yksittäisen neuronin  $i$  toimintaa kaavojen 12 ja 13 pohjalta.



Kuvio 3. Neuronin  $i$  toiminta (Järvelin 2003, 7)

*Hermoverkko* koostuu toisiinsa kytketyistä neuroneista. Hermoverkkoarkkitehtuureja on useita, mutta kaikkien perusrakennuspalikkoina ovat kuvatunkaltaiset neuronit. Verkon arkkitehtuurilla tarkoitetaan hermoverkon neuronien lukumäärää, niiden keskinäisiä kytkentöjä ja neuronien aktivaatiofunktioita. Arkkitehtuuriin vaikuttaa myös tiedon kulkusuunta, sillä monimutkaisimmissa rakenteissa tieto voi paikoin kulkea myös taaksepäin. Arkkitehtuuria tarkastellessa voidaan neuronit jakaa kerroksiin niiden tehtävien mukaan. Yksinkertaisimmissa kerroksellisissa hermoverkoissa on vain syötekerros ja tuloskerros. Syötekerroksen neuronit välittävät saamansa syötteen sellaisenaan eteenpäin seuraavalle kerrokselle. Tuloskerroksen neuronit taas toimivat esitetyllä tavalla. Monimutkaisemmissa arkkitehtuureissa voi olla lisäksi piilokerroksia, jotka välittävät aktivaatiota syöte- ja tuloskerroksen neuronien välillä. Piilokerrosten avulla hermoverkkojen laskentakapasiteettia voidaan parantaa. (Järvelin 2003, 10–11) Laitisen ja Laitisen (2004, 152) mukaan piilokerroksen sisältävät verkkorakenteet ovat käytetyimpiä konkurssin ennustamisessa. Kuviossa 4 havainnollistetaan konkurssin ennustamiseen soveltuvaa kolmikerroksista

hermoverkkoa. Tunnuslukusyötteiden ja piilokerrosten neuronien määrä voi vaihdella. Kuviossa esitetään yksi mahdollinen rakenne.



Kuvio 4. Kolmikerroksinen hermoverkko konkurssin ennustamisessa (Laitinen & Kankaanpää 1999, 74)


Konkurssin ennustamiseen sovellettavan hermoverkkomallin estimointi tapahtuu opettamalla verkkoa. Esimerkiksi niin sanotussa backpropagation-opetussäännössä verkkoa opetetaan etsimällä sellaiset parametrit, joilla verkon antaman tuloksen neliöllinen virhesumma minimoituu. Hermoverkon opettaminen voi olla ohjattua tai ei-ohjattua. Ohjatussa oppimisessa verkolle annetaan historiallisen yritysotoksen yritysten tunnuslukusyötteet ja tiedot konkurssista tai toiminnan jatkumisesta. Verkko mukauttaa rakennettaan löytääkseen yhteyden syötteiden ja tulosten välille. Prosessi lopetetaan ja verkkorakenne kiinnitetään siinä vaiheessa, kun haluttu tarkkuus on saavutettu. Ei-ohjatussa opettamisessa verkolla ei ole käytettävissä tulostietoja havainnoista. Tällöin verkko organisoii itse syöttötiedot ja havainnoi niiden perusominaisuudet. Sen jälkeen kun verkko on opetettu historiallisella yritysotoksella, verkko tallennetaan. Tallennettua verkkoa voidaan käyttää nykypäivän yritysten konkurssien ennustamiseen. Verkkorakenteen toimivuus on kuitenkin syytä varmistaa testitoksessa, jotta saataisiin varmistusta siitä, että verkon luokittelukyky on hyvä myös estimointiaineiston ulkopuolella. (Laitinen & Laitinen 2004, 152–153)

Hermoverkkoja on käytetty konkurssin ennustamiseen 90-luvun alusta lähtien (Tam & Kiang 1992, 927). Tutkimuksissa on tyypillisesti rakennettu useita hermoverkkomalleja ja verrattu niiden tuloksia tilastollisten menetelmien tuloksiin. Luokittelutulosten näkökulmasta hermoverkot ovat yleensä toimineet paremmin kuin tilastolliset menetelmät.

## 5.2 Rekursiivinen osittaminen

*Rekursiivinen osittaminen* (=recursive partitioning algorithm, RPA) on ei-parametrinen tietokoneavusteinen luokittelumenetelmä. Rekursiivista osittamista on käytetty muun muassa lääketieteelliseen päätöksentekoon sekä yritysten lainojen luokitteluun. Menetelmää sovelsivat konkurssin ennustamiseen ensimmäisinä Frydman, Altman ja Kao (1985). Rekursiivisen osittamisen perusideana on jakaa yritykset kaksiluokkaisen puun muotoon siten, että koko puun virheluokittelujen odotetut kustannukset minimoituvat. Konkurssin ennustamiseen käytettävä puumalli rakennetaan historiallisen yritysotoksen avulla. Malliin sisällytetään molempien virhetyyppien (konkurssiyritys luokitellaan toimivaksi ja päinvastoin) odotetut kustannukset, joten menetelmä soveltuu hyvin sellaisille käyttäjille, jotka haluavat ennustaessaan yrityksen tulevaisuutta välttää erityisesti toista virhetyyppiä. (Dimitras ym. 1996, 505; Frydman ym. 1985, 270)

Rekursiivinen osittaminen on menetelmänä tavallaan yhden ja usean muuttujan analyysien yhdistelmä. Tämä perustuu siihen, että menetelmässä käytetään useita tunnuslukuja yksi kerrallaan. Rakennettaessa päätöspuuta edetään siten, että ensin valitaan konkurssiyritykset ja toimivat yritykset parhaiten erotteleva tunnusluku, jonka perusteella yritykset jaetaan kahteen luokkaan. Jakamiseen käytetään valittua kriittistä arvoa. Tämän jälkeen jaetut luokat jaetaan edelleen kahtia seuraavaksi parhaiten erottelevan tunnusluvun avulla. Tätä jatketaan, kunnes luokkien jakaminen ei enää kannata. Tällöin lopulliset luokat jaetaan kokonaisina konkurssiyrityksiksi ja toimintaansa jatkaviksi yrityksiksi. (Laitinen & Laitinen 2004, 144–145) McKeen ja Greensteinin (2000, 222) mukaan optimaalisesti luokitellussa otoksessa kaikki konkurssiyritykset kuuluvat yhteen luokkaan ja toimivat yritykset toiseen luokkaan. Puumallin rakentamisessa on tavoitteena päästä mahdollisimman lähellä tätä optimaalista tilannetta. Rekursiivisen osittamisen tuottamaa puumallia on havainnollistettu kuviossa 5.



TL = tunnusluku  
 $a$  = tunnusluvun 1 kriittinen arvo  
 $b$  = tunnusluvun 2 kriittinen arvo  
 $c$  = tunnusluvun 3 kriittinen arvo  
 K = konkurssiyritys  
 T = toimiva yritys

---

Kuvio 5. Rekursiivisen osittamisen tuottama puumalli (mukaiillen Laitinen & Laitinen 2004, 145; Frydman ym. 1985, 272)

Kuvion 5 puumallin mukaan konkurssia ennustetaan sellaisille yrityksille, joiden tunnusluvun 1 arvo on pienempi tai yhtä suuri kuin  $a$  ja tunnusluvun 2 arvo on pienempi tai yhtä suuri kuin  $b$ . Konkurssiennusteen saavat myös sellaiset yritykset, joiden tunnusluvun 1 arvo on suurempi kuin  $a$  ja tunnusluvun 3 arvo on pienempi tai yhtä suuri kuin  $c$ . Toiminnan jatkumista ennustetaan yrityksille, joiden tunnusluvun 1 arvo on suurempi kuin  $a$  ja tunnusluvun 3 arvo on suurempi kuin  $c$ . Samoin toiminnan jatkumisen ennusteen saa yritys, jonka tunnusluvun 1 arvo on pienempi tai yhtä suuri kuin  $a$  ja tunnusluvun 2 arvo on suurempi kuin  $b$ .

Koska ennusteen konkurssista tai toimivuuden jatkuvuudesta voi saada puun eri haaroista, voidaan olettaa, että ennusteilla on erilaiset todennäköisyydet toteutua. Sellaisen yrityksen, jonka tunnusluvun 1 arvo on pienempi tai yhtä suuri kuin  $a$  ja tunnusluvun 2 arvo pienempi tai yhtä suuri kuin  $b$ , konkurssi näyttää todennäköiseltä. Yhtä selvänä ei voida pitää sellaisen yrityksen



konkurssia, joka saa konkurssiennusteen puun oikean haaran kautta. Tällaisella yrityksellä on parhaiten luokittelevan tunnusluvun 1 arvo suurempi kuin  $a$ , joten tilanne ei näytä yhtä huonolta kuin vasemmasta haarasta konkurssiennusteen saavalla yrityksellä. Frydmanin ym. (1985, 287) mukaan puumallin eri päätepisteille voidaan estimointiotoksen avulla määrittää todennäköisyys, jolla päätepisteen antama ennuste toteutuu. Tällöin eri päätepisteisiin sijoittuvia saman tilaennusteen yrityksiä voidaan vertailla. Sen sijaan samaan päätepisteeseen sijoittuvia yrityksiä ei voi asettaa järjestykseen, sillä rekursiivinen osittaminen ei mahdollista päätepisteiden sisäisiä vertailuja. Tällöin kaikille saman päätepisteen yrityksille saadaan sama ennuste, joka toteutuu samalla estimointiaineistossa määritetyllä todennäköisyydellä.

Rekursiivisen osittamisen tuottaman puumallin rakentaminen ei ole helppoa. Arkkitehtuuria valittaessa on ratkaistava, minkä tunnusluvun perusteella jaottelu missäkin vaiheessa tapahtuu ja kuinka pitkälle jaottelua jatketaan. Cielenin, Peetersin ja Vanhoofin (2004, 529) mukaan kulloinkin parhaiten jaottelevan tunnusluvun valinnassa voidaan käyttää informaation voittosuhteen kriteeriä. Kriteeri perustuu informaatioteoriaan, jonka mukaan tapahtuman informaatio on käänteisesti verrannollinen informaation todennäköisyyteen. Informaatiota voidaan mitata sen todennäköisyyden kaksikantaisen logaritmin negaationa. (Cielen ym. 2004, 529) sekä Frydman ym. (1985, 275) mainitsevat myös muita menetelmiä puumallin rakentamiseksi. Vaikka rekursiivisen osittamisen tuottama puumalli on yksinkertaisen näköinen ja helppo käyttää, sen rakentamiseen vaaditaan monimutkaisia tietokoneavusteisia laskelmia.

Konkurssin ennustamiseen käytettävän puumallin taustalla olevasta menetelmästä käytetään moninaista terminologiaa. Aziz ja Dar (2004, 13) sijoittavat kaikki puumallit induktiivisen oppimisen ryhmään. Puumallien yhteydessä rekursiivista osittamista on käytetty usein (Aziz & Dar 2004; Laitinen & Laitinen 2004; Laitinen & Kankaanpää 1999; Dimitras ym. 1996; Frydman ym. 1985). Myös ID3 (Interactive Dichotomizer 3)-nimi esiintyy tutkimuksissa. Tamin ja Kiangin (1992, 929) mukaan rekursiivinen osittaminen ja ID3 eroavat toisistaan luokkien jakamiskriteerien käytössä. McKee ja Greenstein (2000, 222) puolestaan toteavat, että eräs rekursiivisen osittamisen algoritmi tunnetaan nimellä ID3. He siis tulkitsevat ID3:n kuuluvan rekursiiviseen osittamiseen. Puumallien yhteydessä käytetään myös erilaisia C-yhdistelmiä, esimerkiksi C5.0 (Cielen ym. 2004). Pendharkar (2005, 2564) määrittelee C4.5:n ID3-algoritmin parannetuksi versioksi. Täten C-mallien yhteydessäkin liikutaan rekursiivisen osittamisen läheisyydessä. Koska kaikki puumalleja koskevat termit tarkoittavat hyvin toistensa kaltaisia menetelmiä, tämän luvun rekursiivisen osittamisen esittelyä ja luvun 5.6 arviointia voidaan soveltaa muidenkin puumallitermien yhteyteen.

McKee ja Greenstein (2000, 224) käyttivät tutkimuksessaan hyvin yksinkertaista puumallia, joka on siksi hyvä käytännön esimerkki puumallien käytöstä konkurssin ennustamiseen. Malli oli seuraavanlainen:

JOS current ratio on suurempi tai yhtä suuri kuin 0,64 JA

JOS kokonaistulos (=ROA) on suurempi tai yhtä suuri kuin 0

SILLOIN yritys on toimintaansa jatkava

MUULLLOIN yritys ajautuu konkurssiin.

Malli luokitteli toimivat yritykset erittäin tarkasti, mutta konkurssiyrietykset saivat usein väärän ennusteen. Malli siis teki paljon virhetyyppejä I:n virheitä. Kun current ration kriittistä arvoa nostettiin, saatiin virhetyyppejä I:n esiintymistiheys siedettäväksi. Current ration kriittisellä arvolla 1,94 saatiin molempien virhetyyppien osuus noin 15 prosenttiin, jolloin puumalli toimi noin 85 prosentin tarkkuudella. (McKee & Greenstein 2000, 224–227)

### 5.3 Eloojäämisanalyysi

Useimmissa konkurssin ennustamismenetelmissä yrityksiä tarkastellaan tietyssä hetkenä, kuten vuotta ennen mahdollista konkurssia. Yritysten tilinpäätös- ja konkurssihetket vaihtelevat kuitenkin siten, että tämä ”yksi vuosi” saattaa olla todellisuudessa vaikka 8 tai 20 kuukautta. Tämän seikan lisäksi konkurssin ennustamismalleja estimoitaessa on vaikea hyödyntää havaintoja, jotka ovat peräisin aikaisemmilta vuosilta ennen yrityksen vaikeuksiin joutumista. *Eloojäämisanalyysi* (survival analysis, SA) on menetelmä, joka pyrkii hyödyntämään tiedon tilinpäätöstietojen syntyhetken ja kriisihetken välillä. Eloojäämisanalyysia on monen muun menetelmän tapaan käytetty aikaisemmin muilla tieteenaloilla. Lane, Looney ja Wansley (1986) sovelsivat menetelmää ensimmäisen kerran konkurssin ennustamiseen. (Laitinen & Laitinen 2004, 147)

Eloojäämisanalyysimalli mittaa joko aikaa, joka kuluu tietyn tilan syntymiseen (konkurssitutkimuksissa konkurssihetki), tai havainnoimisjakson tietyn tapahtumien aikaväliä. Riippuvana muuttujana menetelmässä on joko aika tietyn tilan syntymiseen (survival time) tai riskiluku (hazard rate). Konkurssin ennustamisen yhteydessä eloojäämisanalyysin tavoite on kvantifioida suhde, joka vallitsee tarkasteluhetken ja konkurssihetken ajan (survival time) sekä

selittävinä muuttujina käytettävien tunnuslukujen välillä. Riskiluku tarkoittaa tällöin sitä taipumusta tai alttiutta, jolla yritys ajautuu konkurssiin tietyllä hetkellä. Eloönjäämisanalyysi pyrkii siis antamaan tietoa sekä yrityksen jäljellä olevasta elinajasta että konkurssin todennäköisyydestä. (Laitinen & Kankaanpää 1999, 71–72)

Eloönjäämisanalyysimalli eli riskiluvun kaava estimoidaan historiallisessa yritysotoksessa. Estimoinnissa käytetään tietoa siitä, kuinka paljon kullakin konkurssiyrityksellä on kulloinkin aikaa jäljellä konkurssihetken syntymiseen. Toimiville yrityksille ei luonnollisesti ole konkurssihetkeä. Ne käsitellään erikoistapauksina, joita kutsutaan sensuroiduiksi havainnoiksi. Tällöin niille määritellään ”riittävän pitkä” elinaika, joka on vähintään käytettävien tunnuslukujen pohjana olevasta tilinpäätöksestä tutkimuksen tekemisen hetkeen asti. Eloönjäämisanalyysimalleista on olemassa useita erilaisia versioita, jotka olettavat erilaisen riippuvuuden selittävien tekijöiden ja riskiluvun välille. Eräs käytetyimmistä versioista on Coxin suhteellisen riskin malli (proportional hazard model), joka on seuraavanlainen (kaava 14):

$$(14) \quad h(t, Z) = h_0(t) \cdot e^{a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n} = h_0(t) \cdot e^Z.$$

Kaavassa 14  $h(t, Z)$  on riskiluku eli taipumus ajautua konkurssiin ajanjaksona  $t$  ennen konkurssia,  $e$  on Neperin luku ja  $e$ :n eksponentti on erotteluanalyysistä tuttu selittävien tekijöiden eli tunnuslukujen painotettu summa  $Z$ . Tulon ensimmäinen tekijä  $h_0(t)$  on niin sanottu yrityksen tuntematon perusriski (baseline hazard) ajanjaksona  $t$ . Perusriskiä tarvitaan ainakin silloin, kun  $Z$  saa arvon 0 ja koko jälkimmäinen tulon termi siten arvon 1. Käytettäessä useita tunnuslukuja perusriskiä pidetään usein yhtenä, jolloin se ei vaikuta mallin tuottaman riskiluvun suuruuteen. (Laitinen & Laitinen 2004, 148–149; Laitinen & Kankaanpää 1999, 72–73)

Eloönjäämisanalyysimallissa esiintyy siis tunnuslukujen painotettu summa ja eksponenttimuunnos, joten se on muodoltaan samankaltainen kuin esimerkiksi logit-analyysin tuottama malli. Eloönjäämisanalyysin tuottama malli hyödyntää kuitenkin tarkasteluhetken ja konkurssihetken välisen ajan, jota muissa menetelmissä ei käytetä. Kaavan 14 parametreina toimivat  $a$ :t estimoidaan usein logit-analyysin tavoin suurimman uskottavuuden menetelmällä. Eloönjäämisanalyysia sanotaan semiparametriseksi menetelmäksi, koska kaavan 14 tulon ensimmäinen tekijä on ei-parametrinen ja toinen tekijä on parametrinen. (Laitinen & Laitinen 2004, 148–149; Laitinen & Kankaanpää 1999, 72–73)

Eloonjäämisanalyysin käyttöä voidaan havainnollistaa seuraavanlaiseksi estimoidulla painotetulla summalla (kaava 15):

$$(15) \quad Z = -1,5361 \cdot \text{pääoman tuotto} + 0,8073 \cdot \text{velkaisuusaste} - 1,0067 \cdot \text{quick ratio}.$$

Kaavan 15 painotettu summa voidaan sijoittaa kaavan 14 Coxin malliin konkurssivaaran laskemiseksi, kun ajasta riippuva perusriski  $h_0(t)$  tunnetaan. Oletetaan, että perusriski 36 kuukautta ennen konkurssia on yksi eli  $h_0(36) = 1$ . Oletetaan myös, että yrityksen pääoman tuotto on -0,103, velkaisuusaste on 1,1266 ja quick ratio on 4,5. Sijoitettaessa nämä luvut kaavoihin 14 ja 15 saadaan yrityksen riskiluvuksi eli vaaraksi tehdä konkurssi 0,03. Silloin voidaan merkitä, että  $h(36, Z) = 0,03$ . Tämä on erittäin pieni arvo, joka viestii vähäisestä konkurssiriskistä kolmen vuoden aikajaksolla. Sen sijaan jos quick ratio saa tavallisemman arvon 1,0, konkurssivaara nousee lukemaan 0,96. Se puolestaan ilmaisee suurta konkurssin uhkaa. (Laitinen & Laitinen 2004, 149)

Luoma ja Laitinen (1991) ovat tutkineet keskimääräisten suomalaisyritysten konkurssikehitystä (ks. Laitinen & Laitinen 2004, 149–150). Usein konkurssiyrityksen eloonjäämisfunktiossa konkurssivaara on kolme vuotta ennen konkurssia vielä pieni, mutta se nousee sen jälkeen nopeasti. Keskimäärin konkurssiprosessi alkaa noin 30 kuukautta ennen konkurssia ja on loppuvaiheessaan jo 10 kuukautta ennen konkurssin tapahtumista, jolloin riskiluku alkaa lähennellä yhtä. Mahdollinen saneeraus pitäisi siten aloittaa jo kolme vuotta ennen laskennallista konkurssihetkeä, sillä viimeisen vuoden aikana on enää vähän tehtävissä konkurssin välttämiseksi.

Laitinen ja Laitinen (2004, 147) sekä Dimitras ym. (1996, 495) toteavat, että aikahorisontin sisällyttäminen konkurssin ennustamismalliin tuo dynaamisuutta, joka tekee eloonjäämisanalyysistä luontevan valinnan konkurssin ennustamiseen. Eloonjäämisanalyysia on kuitenkin käytetty alalla harvoin. Menetelmällä saadut tulokset eivät ole rohkaisseet menetelmän suosimiseen.

## 5.4 HIP-tutkimus

*HIP (Human Information Processing)-tutkimuksessa* on erilainen lähtökohta muihin konkurssin ennustamismenetelmiin verrattuna. HIP-tutkimusten pääideana on tutkia päätöstentekijöiden käyttäytymistä, kun he arvioivat yrityksen konkurssin todennäköisyyttä erilaisissa päätöstilanteissa.

Päätöstentekijöiden käyttäytymisen perusteella voidaan myös rakentaa konkurssin ennustamismalli. HIP-tutkimukset tuottavat päätösproesseista perustietoa, jonka avulla ymmärrystä päätösten perusteista voidaan lisätä. Lisääntyneen ymmärryksen avulla pyritään nostamaan päätösten laatua, mistä on luonnollisesti myös konkurssin ennustamisessa hyötyä. (Laitinen & Laitinen 2004, 156)

Varhaisen HIP-tutkimuksen tehneen Libbyn (1975, 160) mukaan tilinpäätösinformaation hyöty määritellään informaation sisältämän ennustamispotentiaalin ja käyttäjien tulkitsemiskyvyn funktiona. Useissa tutkimuksissa on todistettu se, että tilinpäätösinformaatioon sisältyy ennustuskykyä tulevasta. HIP-tutkimuksissa hyödynnetään siten taitavien tilinpäätösten lukijoiden tulkintakykyä. HIP-tutkimukseen voidaan käyttää esimerkiksi luottopäätösten tekijöitä tai tilintarkastajia, sillä heidän tilinpäätösanalyysitaitonsa ovat työtehtävien takia korkeita.

Konkurssin ennustamista koskevat HIP-tutkimukset liittyvät useimmiten niin sanottuun linssimalliin. Linssimalliin perustuva tutkimus keskittyy analysoimaan informaation ja päätöksentekijän välistä vuorovaikutusta sekä informaation ja päätöksentekijän vaikutusta päätösten laatuun. Tavallisesti linssimalliin pohjautuvissa tutkimuksissa päätöksentekijän käyttäytymisen perusteella rakennetaan tilastollinen malli, jonka avulla tutkitaan päätöksenteossa käytettäviä informaation osatekijöitä sekä päätöksentekijän ja päätösten ominaisuuksia. Rakennettua mallia voidaan sen jälkeen käyttää muihin vastaaviin ennustamistilanteisiin. (Laitinen & Laitinen 2004, 156–157)

Tarvittavien tietojen hankkimiseksi HIP-tutkimuksissa käytetään yleensä koejärjestelyä, jossa päätöksentekijä asetetaan keinotekoiseen päätöstilanteeseen. Koejärjestelyssä päätöksentekijälle annetaan tietoja todellisista historiallisista yrityksistä ja pyydetään luokittelemaan yritykset toimintaansa jatkaneiksi ja konkurssiyrityksiksi. Joskus saatetaan käyttää myös keinotekoisia yritystapauksia, jos halutaan painottaa tiettyjä päätökseen vaikuttavia tekijöitä. Kun päätöksentekijöiden käyttäytymistä koskeva aineisto on kerätty, sitä voidaan analysoida erilaisilla tilastollisilla menetelmillä. Todellisten yritystapausten aineistoissa voidaan päätöstentekijöiden ennustamistarkkuutta arvioida luokitteluvirheiden määrän avulla. Tämä voidaan tehdä kunkin päätöksentekijän osalta erikseen ja kaikille yhdessä. Vertaamalla luokitteluvirheiden määriä muilla konkurssin ennustamismenetelmillä syntyviin luokitteluvirheisiin saadaan tietoa HIP-tutkimuksen konkurssin ennustamiskyvystä. Ennustamistarkkuuden lisäksi voidaan tutkia päätöksentekijöiden yksimielisyyttä laskemalla kuinka monesta yritystapauksesta he ovat samaa mieltä. Samojen

tunnuslukujen painottaminen eri päätöksentekijöiden päätösten perusteena viestii tunnuslukujen merkityksellisyydestä. (Laitinen & Laitinen 2004, 159–161)

Linssitutkimusten yksi keskeinen tutkimuskohde on päätöksentekijöiden käyttämät päätössäännöt. Niistä ilmenee, mitä tunnuslukuja päätöksenteossa käytetään ja miten niitä painotetaan. Yleisessä muodossa päätössääntö voidaan esittää seuraavasti (kaava 16):

$$(16) \quad Z = F(X_1, X_2, \dots, X_n).$$

Kaavassa 16  $Z$  ilmaisee tehdyn päätöksen konkurssista tai toiminnan jatkumisesta ja  $X_i$  ( $i = 1, 2, \dots, n$ ) päätöksenteossa käytetyt tiedot.  $F(\ )$  on päätössääntö, joka ilmoittaa sen, miten päätöksentekijä muuntaa tiedot valmiiksi päätökseksi. Monet HIP-tutkimukset ovat osoittaneet, että useimmat päätöksentekijät käyttävät lineaarista päätössääntöä. Lineaarinen päätössääntö voidaan esittää seuraavasti (kaava 17):

$$(17) \quad Z = a_1 \cdot X_1 + a_2 \cdot X_2 + \dots + a_n \cdot X_n.$$

Tämä päätössääntö tarkoittaa käytännössä sitä, että päätöksentekijät käsittelevät tietoja ( $X_i$ ) mielessään toisistaan riippumattomina ja antavat niille tietyn painon ( $a_i$ ) niiden merkityksen perusteella. (Laitinen & Laitinen 2004, 161–162)

Kaavasta 17 voidaan huomata, että se on sama kuin erotteluanalyysin tuottama kaava 1. Myös regressioanalyysi tuottaa samankaltaisen kaavan. Lähtökohta kaavan muodostamisessa on kuitenkin erilainen. Erottelu- ja regressioanalyysissä käytetään historiallisia yritysaineistoja, joista johdetaan tilastollisesti optimaalinen malli. HIP-tutkimuksessa käytetään sen sijaan lähtökohtana päätöksentekijöiden käyttäytymistä yrityksiä arvioitaessa. Erottelu- ja regressioanalyysia voidaan tosin käyttää HIP-tutkimuksessa päätöksentekijän päätössäännön matemaattiseen johtamiseen. Erotteluanalyysia voidaan käyttää estimoitaessa erottelufunktiota, joka erottelee tehokkaimmin päätöksentekijän eri luokkiin luokittelemat yritykset. Kaavan 17 erottelufunktio antaa silloin arvion päätöksentekijän subjektiivisesti käyttämästä päätössäännöstä. Vastaavasti käytettäessä  $Z$ :n skaalausta nolasta yhteen voidaan päätössääntö estimoida regressioanalyysin avulla. (Laitinen & Laitinen 2004, 162–163)

HIP-tutkimukseen voidaan soveltaa myös varianssianalyysia. Varianssianalyysin käyttö mahdollistaa päätössäännön epälineaarisen käsittelyn ja poistaa osan erottelu- ja regressioanalyysien tilastollisista ongelmista. Varianssianalyysi kuitenkin tekee päätössäännön ilmaisemisen melko monimutkaiseksi. Lisäksi on todettu, että epälineaarisuuden huomiointi päätössäännössä ei juuri paranna lineaarisen mallin antamia tuloksia. Moniulotteinen skaalaus on vielä yksi vaihtoehto HIP-tutkimuksissa. Moniulotteisessa skaalauksessa päätöksentekijät arvioivat yrityksiä pareittain. Tavoitteena on löytää arvioiden perusteena olevat tärkeimmät taloudelliset ulottuvuudet ja niitä parhaiten kuvaavat tunnusluvut. Etuna menettelyssä on se, että menettely pelkistää päätöksentekijöiden mielessään käyttämät tiedot muutamaankin perustekijään eli ulottuvuuteen. Heikkoutena puolestaan on se, että löydetty ulottuvuudet eivät aina ole selkeästi yksilöitävissä. Silloin niitä on vaikea kuvata tunnusluvuilla, mikä tekee konkurssin ennustamismallin rakentamisen hankalaksi. (Laitinen & Laitinen 2004, 162–165)

Laitisen ja Kankaanpään (1999, 82–83) tutkimuksessa esiintyy suomalainen esimerkki HIP-tutkimuksesta. Tutkijat lähettivät kyselylomakkeen 60 KHT-tilintarkastajalle. Näiden tehtävänä oli luokitella 76 yritystä kolmen tunnusluvun arvon perusteella. Tunnusluvut olivat yritysten tilinpäätöksistä vuotta ennen mahdollista konkurssia ja kuvasivat velkaantuneisuutta, maksuvalmiutta ja kannattavuutta. Lisätiedoksi vastaajille annettiin, että puolet 76 yrityksestä oli konkurssiyrityksiä. Tutkijat saivat 27 vastausta, joten vastausprosentiksi muodostui 45. Tilintarkastajat onnistuivat luokittelussa eli konkurssin ennustamisessa 83 prosentin tarkkuudella. Tarkkuutta saattoi parantaa se, että vastaajat tiesivät konkurssiyritysten ja toimivien yritysten osuuden aineistossa. Todellisissa nykypäivän ennustustilanteissa näin ei luonnollisesti ole. Laitisen ja Kankaanpään (1999) tutkimuksessa vertailtiin kuuden eri konkurssin ennustamismenetelmän luokittelukykyä. Siksi siinä tyydyttiin HIP-tutkimuksen osalta ennustamistarkkuuden selvittämiseen eikä rakennettu tilintarkastajien vastausten pohjalta konkurssin ennustamismallia.

## **5.5 Muita konkurssin ennustamisessa käytettyjä menetelmiä**

Tässä luvussa esitellään lyhyesti muita konkurssin ennustamisessa käytettyjä menetelmiä. Näitä menetelmiä ei arvioida kriteeristön avulla, sillä näiden menetelmien soveltaminen on ollut satunnaista. Laadulliselle arvioinnille ei siten välttämättä olisi riittävästi perusteita. Voidaan myös olettaa, että menetelmien harva käyttö viestii siitä, että ne eivät ole konkurssin ennustamisen alalle kovin hyvin soveltuvia. Myös Laitisen (1990), Laitisen ja Kankaanpään (1999) sekä Laitisen ja

Laitisen (2004) valinta jättää nämä menetelmät alan kokoelmatöidensä ulkopuolelle kertoo siitä, että menetelmät eivät ole ainakaan suomalaisista lähtökohdista tärkeimpiä. Tämänkään takia niiden arviointi ei ole välttämätöntä, jotta tutkielmassa voitaisiin tavoitteen mukaisesti antaa suosituksia parhaimpien menetelmien käytöstä.

Laitinen (1994) käytti *Markovin prosessia* konkurssin ennustamiseen tutkiessaan tunnuslukujen vaihteluita eri vuosina ennen konkurssia. Tunnuslukuvaihteluiden tai niiden stabiiliuden selvittämiseksi yritettiin saada lisäinformaatiota konkurssin ennustamiseen. Markovin prosessia vähän enemmän konkurssin ennustamisessa on käytetty *rough sets* -menetelmää (≈karkeat joukot, ei käytössä vakiintunutta suomenkielistä nimitystä). Dimitras, Slowinski, Susmaga ja Zopounidis (1999, 265) toteavat *rough sets* -tutkimuksessaan, että menetelmä pyrkii luokittelemaan yritykset niistä saatavien epätäydellisten tietojen perusteella mahdollisimman tarkasti konkurssiyrityksiin ja toimiviin yrityksiin. Saatavilla olevat tiedot kerätään informaatiotaulukkoon, josta luodaan *rough sets* -mallin luokittelut määräävät päätössäännöt. Päätössäännöt luodaan induktiivisen oppimisen periaatteella. Azizin ja Darin (2004, 25) mukaan *rough sets* -menetelmän käyttöön konkurssin ennustamisessa liittyy monia ongelmia. Menetelmä ei esimerkiksi toimi hyvin numeerisilla tiedoilla, joita yrityksistä pääasiassa on saatavilla. *Rough sets* -menetelmää on Dimitrasin ym. (1999) lisäksi käytetty kahdessa muussa tutkimuksessa (Aziz & Dar 2004, 32–34).

Myös *moniulotteista grafiikkaa* on käytetty konkurssin ennustamiseen. Varhaisin sovellus on lähes 30 vuoden takaa, sillä Moriarty (1979) ensimmäisenä käytti moniulotteisena grafiikkana Chernoff-kasvoja konkurssin ennustamiseen. Chernoff-kasvojen avulla yritykset luokitellaan konkurssiyrityksiksi ja toimiviksi yrityksiksi yritysten tilinpäätöksistä luotujen kasvokuvien perusteella. Menetelmässä on sekä tilastollisten menetelmien että HIP-tutkimuksen piirteitä, sillä kasvokuvien luomisessa käytetään painotettuja tunnuslukuja, mutta lopullisina luokittelijoina toimivat ihmiset. Penttilä (2004) pääsi Chernoff-kasvoilla noin 74 prosentin luokittelutarkkuuteen, joka jäi hieman vertailumenetelmänä käytetyn erotteluanalyysin tasosta. Moniulotteisen grafiikan kilpailukykyä muihin menetelmiin nähden ei ole yksimielisesti pystytty osoittamaan ja menetelmä onkin jäänyt eräänlaisen kuriositeetin asemaan. (Penttilä 2004, 2–6)

Azizin ja Darin (2004) tutkimuksessa esiintyy muutamia sellaisia tilinpäätösperusteisia konkurssin ennustamismenetelmiä, joita ei esiinny tämän tutkielman muussa lähdemateriaalissa. Näitä menetelmiä on käytetty vain yhdessä tai kahdessa konkurssin ennustamisalan tutkimuksessa. Tällaisia menetelmiä ovat *kumulatiivisten summien menetelmä* (Cumulative Sums Procedure,



CUSUM), *osittaissopeutus* (Partial Adjustment Process), *tapauserusteinen päättely* (Case-Based Reasoning, CBR), *geneettiset algoritmit* (Genetic Algorithms, GA) ja *taseen muutosten mittaaminen/entropiateoria* (Balance Sheet Decomposition Measure, BSDM/Entropy Theory).

*Matemaattista ohjelmointia* on myös sovellettu konkurssin ennustamiseen. Menetelmässä pyritään parantamaan yritysten luokittelun tarkkuutta vapautumalla erotteluanalyysin oletuksista ja vaatimuksista. Matemaattisella ohjelmoinnilla saavutetut tulokset verrattuna erotteluanalyysin tuloksiin ovat olleet vaihtelevia. Ehkä juuri siksi menetelmän soveltaminen on jäänyt satunnaiseksi. (Dimitras ym. 1996, 506–507)

Min ja Lee (2005, 603–614) esittelivät konkurssin ennustamisalalle uutena *SVM (Support Vector Machines)-menetelmän*. Se on hermoverkkojen tapaan monimutkainen keinoälyä soveltava menetelmä, joka on osoittautunut lupaavaksi monen eri alan sovelluksissa. SVM-menetelmä saattaa ratkaista ainakin osan hermoverkkojen ongelmista, sillä menetelmä ei ole altis liialliselle sopeuttamiselle ja tuottaa siten hermoverkkoja paremmin yleistettäviä tuloksia. SVM-menetelmässä yhdistyvät yksinkertaisempien tilastollisten menetelmien ja monimutkaisempien suurien datamääriä käsittelevien keinoälyllisten menetelmien edut. Minin ja Leen (2005) tutkimuksessa SVM-menetelmällä onnistuttiin luokittelemaan testiotoksen yritykset hieman tarkemmin kuin erotteluanalyysillä, logit-analyysillä ja hermoverkoilla. Tosin hyvän SVM-mallin rakentaminen saattaa olla vaikeaa, sillä osalla käytetyistä malleista luokittelukyky jäi alhaiseksi. Cielenin ym. (2004) tutkimuksessa toinen konkurssin ennustamisalalle uusi keinoälymenetelmä, DEA (Data Envelopment Analysis), osoittautui myös lupaavaksi konkurssin ennustajaksi. SVM- ja DEA-menetelmien uutuuden takia on vielä vaikea ennustaa, saavuttavatko menetelmät suosiota paljon tutkitulla konkurssin ennustamisalalla.

## 5.6 Arviointi

Hermoverkkoja on käytetty paljon konkurssin ennustamiseen. Azizin ja Darin (2004, 32–34) listauksesta löytyy kahdeksan hermoverkkotutkimusta. Listan tutkimusten lisäksi hermoverkkoja on käytetty ainakin Pendharkarin (2005), Pompen ja Bilderbeekin (2005), Laitisen ja Kankaanpään (1999) sekä Tamin ja Kiangin (1992) tutkimuksissa. Sovelluskohteita olisi löydettävissä tutkielman lähdemateriaalista lisääkin, mutta jo nämä yli kymmenen tutkimusta takaavat sen, että hermoverkot täyttävät *käytön yleisyyden* kriteerin. Myös rekursiivisen osittamisen kohdalla *käytön yleisyyden*

kriteeri täyttyy. Azizin ja Darin (2004, 32–34) sekä Dimitrasin ym. (1996, 494) listauksista löytyy yhteensä kuusi rekursiivisen osittamisen sovellusta konkurssin ennustamisalalla. Listojen ulkopuolisista tutkimuksista päätöspuita on sovellettu myös Pendharkarin (2005), Cielenin ym. (2004), McKeen ja Greensteinin (2000), Laitisen ja Kankaanpään (1999) sekä Tamin ja Kiangin (1992) tutkimuksissa. Täten rekursiivisen osittamisen käyttökohteet ylittävät kymmeneen asetetun rajan.

Eloonjäämisanalyysia ei ole käytetty usein konkurssin ennustamiseen (Dimitras ym. 1996, 498). Seuraavissa tutkimuksissa menetelmää on kuitenkin käytetty: Laitinen ja Kankaanpää (1999), Henebry (1997), Henebry (1996), Luoma ja Laitinen (1991) sekä Lane ym. (1986). Tutkielman lähdemateriaalista löytyneet sovellukset jäävät kuitenkin selvästi alle kymmeneen, joten eloonjäämisanalyysi ei täytä *käytön yleisyyden* kriteeriä. HIP-tutkimusta konkurssin ennustamisalalla ovat soveltaneet muun muassa Zopounidis ja Doumpos (1999), Laitinen ja Kankaanpää (1999), Casey (1980) ja Libby (1975). Lisäksi Laitinen ja Laitinen (2004, 167) sekä Laitinen ja Kankaanpää (1999, 89) ovat luetteloineet kahdeksan muuta konkurssin ennustamisalan HIP-sovellusta. HIP-tutkimukselle on siis löydettävissä yli kymmenen sovellusta, joten menetelmä täyttää *käytön yleisyyden* kriteerin.

Hermoverkot käyttävät usein lukuisia tunnuslukusyötteitä, koska menetelmä mahdollistaa suuren tietomäärän prosessoinnin. Monissa verkkoarkkitehtuureissa tunnuslukusyötteitä on yli kymmenen, kuten Tamin ja Kiangin (1992, 932) tutkimuksessa. Hyvän *informaatisällön* kautta yrityksen talouden eri osatekijät tulevat hyvin huomioituiksi. Hermoverkoilla tulokseksi saatava luku, jota päätelmiä tehtäessä verrataan kriittiseen arvoon, voidaan skaalata välille nolasta yhteen (Pendharkar 2005, 2562; Altman ym. 1994, 514). Tällä menettelyllä tulokseksi saatavan luokitteluennusteen toteutumisen todennäköisyydestä saadaan myös lisätietoa. Jos kriittinen arvo on 0,5 ja yritys saa arvoksi 0,52, ennustetta ei välttämättä kannata pitää kovin selvänä. Sen sijaan 0,97 arvoksi saavan yrityksen ennuste näyttää hyvin yksiselitteiseltä. Hermoverkot täyttävät siis *informaatisällön* kriteerin kauttaaltaan hyvin.

Rekursiivisessa osittamisessa voidaan myös käyttää tunnuslukusyötteitä laajasti ja monipuolisesti. Puumallin laajuus ratkaisee käytettävien tunnuslukujen määrän. Esteitä tunnuslukusyötteiden kautta muodostuvan riittävän *informaatisällön* saamiseksi menetelmässä ei ole. Puukuvioilla tulokseksi saatavasta toiminnan jatkumisen tai konkurssin ennusteesta on tehtävissä joitakin lisäpäätelmiä. Kuvion 5 yksinkertaisessa puumallissa on kaksi pääteipistettä, joihin päädyttäessä yritykselle

ennustetaan konkurssia. Vasemmanpuoleiseen päätepisteeseen päädyttäessä yrityksen konkurssi näyttää todennäköisemmältä kuin oikeanpuoleisessa, sillä silloin yrityksellä on sekä tunnusluvun 1 että tunnusluvun 2 arvo heikko. Oikeanpuoleiseen konkurssipäätepisteeseen päätyneellä yrityksellä sen sijaan on tunnusluvun 1 arvo hyvä, mutta tunnusluvun 3 arvo huono. Tunnusluvun 1 hyvän arvon takia konkurssi ei näytä yhtä selvältä kuin puun vasenta haaraa edenneellä yrityksellä. Eri pääteasteille voidaankin estimointiotoksessa laskea ennusteen toteutumisen todennäköisyys (Frydman ym. 1985, 287–289). Ennusteiden todennäköisyyden saaminen lisää menetelmän *informaatioisisältöä*. Huonona puolena on kuitenkin se, että menetelmä ei mahdollista samaan pääteasteeseen päätyneiden yritysten välistä vertailua (Dimitras ym. 1996, 506). Rekursiivinen osittaminen menestyy kaiken kaikkiaan *informaatioisisällön* näkökulmasta hyvin, mutta jää hieman hermoverkkojen tasosta.

Eloonjäämisanalyysissa voidaan hermoverkkojen ja rekursiivisen osittamisen tapaan käyttää haluttu määrä tunnuslukusyötteitä. Eloonjäämisanalyysilla voidaan tuottaa tietoa niin konkurssin todennäköisyydestä kuin ennustetusta ajasta konkurssin toteutumiseen (Henebry 1997, 1). Menetelmä täyttää siis *informaatioisisällön* kriteerin erinomaisesti. HIP-tutkimus voidaan toteuttaa monella tavalla. Siksi sen *informaatioisisällön* arvioiminen on hankalaa. Lähtökohtaisesti tunnuslukusyötteiden monipuolisuudelle ei ole rajoituksia, joten menetelmä voi sisältää riittävästi informaatiota. Laitinen ja Kankaanpää (1999, 77–78) kuitenkin toteavat, että inhimillinen päätöksentekijä kykenee prosessoimaan samanaikaisesti rajoitetun määrän informaatiota. Siksi he käyttivät kolmea tunnuslukua, jotka takaavat vain kohtalaisen *informaatioisisällön*. Myös Casey (1980, 46) havaitsi, että informaation lisääminen ei yleensä paranna ennusteiden tarkkuutta, mutta lisää kyllä ennusteiden tekemiseen käytettyä aikaa. Jos päätöksentekijöiden käyttäytymisen perusteella luodaan konkurssin ennustamismalli, *informaatioisisältö* riippuu mallin luomisen menetelmästä. Esimerkiksi erotteluanalyysilla saadut tulokset informoivat vain konkurssista tai toiminnan jatkumisesta. Regressioanalyysiä käytettäessä voidaan arvioida myös ennusteen toteutumista. HIP-tutkimuksen *informaatioisisällön* arvioiminen on siis moniselitteistä, mutta yleisarviona voidaan pitää kohtalaista *informaatioisisältöä*.

*Ymmärrettävyyden* kriteerillä arvioidaan menetelmien toimintaperiaatteiden selkeyttä. Yangin ym. (1999, 67) mukaan hermoverkkojen yksi heikkous on se, että niillä tehtyjä päätelmiä ei kyetä selittämään. Tam ja Kiang (1992, 944) lisäävät, että yksittäisten tunnuslukujen vaikutusta lopputulokseen ei voida selvittää, sillä vaikutuksia ei kyetä päättelemään eikä selvittämiseen ole kehitetty metodia. Altman ym. (1994, 515) mainitsevat, että ymmärtämättömyys aiheuttaa myös

sen, että mahdollisia virhetilanteita sekä kummallisia tuloksia ei voida tunnistaa. Laitinen ja Laitinen (2004, 153) jatkavat samalla linjalla todeten, että hermoverkkomenetelmän perusongelma on se, että mallin laskenta-algoritmi on käyttäjälle tuntematon. Hermoverkon matemaattinen muoto saattaa olla niin monimutkainen, ettei sitä voida rakenteellisesti kuvata selvien sääntöjen avulla. Azizin ja Darin (2004, 24) hermoverkoista käyttämä termi ”musta laatikko” vaikuttaakin sopivalta. Hermoverkkojen olematon *ymmärrettävyys* on epäilemättä menetelmän selkeä heikkous.

Rekursiivisen osittamisen käyttö on selkeää. Puumallissa kulloinkin käytettävää tunnuslukua verrataan kriittiseen arvoon, minkä jälkeen edetään seuraavaan vastaavaan tilanteeseen. Tätä yhden tunnusluvun käyttöä kerrallaan jatketaan, kunnes saavutaan puumallin päätepisteeseen. Päätepiste osoittaa, ennustetaanko yritykselle konkurssia vai toiminnan jatkumista. Mahdollisesti saadaan myös ennusteen toteutumisen todennäköisyydelle arvio. Cielen ym. (2004, 531) sekä Dimitras ym. (1996, 506) toteavatkin, että rekursiivisen osittamisen puumalli *ymmärrettävästi* selittää, miksi yritys saa tietyn ennusteen. Frydman ym. (1985, 287) ilmaisevat kuvaavasti, että rekursiiviselle osittamiselle on tyypillistä ”monimutkaisuuden puute”. Rekursiivisen osittamisen *ymmärrettävyyden* ainoana pienenä miinuksena on se, että yksittäisten tunnuslukujen vaikutusta lopputulokseen on vaikea arvioida, koska samat tunnusluvut saattavat toistua puukuvion eri vaiheissa (Frydman ym. 1985, 278). Kaiken kaikkiaan menetelmän *ymmärrettävyys* voidaan arvioida hyväksi.

Eloongjäämisanalyysi ei ole aivan yhtä selkeä kuin rekursiivinen osittaminen, mutta ei kuitenkaan ylivoimainen tulkittavaksi. Tyypillisesti eloonjäämisanalyysissa käytetty kaava 14 sisältää lineaarisesti määräytyvän ja siten helposti tulkittavan  $Z$ -luvun laskemisen. Neperin luku eli vakio  $e$  korotetaan  $Z$ -eksponenttiin. Perusriskiä  $h_0(t)$  ei yleensä tarvita. Matematiikan perusteet tuntevalle lausekkeen tulkitseminen ei siten ole kovin vaikeaa. Kaava 14 muistuttaa logit-analyysilla tuotettua mallia (kaava 8). Logit-analyysille annettiin kohtalaisen hyvä arvio *ymmärrettävyydestä*, joten eloonjäämisanalyysin osalta on syytä päätyä samaan arvioon.

HIP-tutkimus on menetelmänä hyvin *ymmärrettävä*. Koska menetelmässä käytetään ihmisten päättelyä, on luonnollista, että sillä syntyy myös ihmisten ymmärtämiä malleja. Usein käytetty lineaarinen päätössääntö (kaava 17) on helposti tulkittavissa, koska se sisältää vain tunnuslukujen painotettuja summia. HIP-tutkimuksen *ymmärrettävyydessä* on myös se etu, että jos käyttäjälle on

jokin epäselvää, hän voi yrittää selvittää tilannetta kysymällä päätöksentekijöinä käytetyiltä henkilöiltä. HIP-tutkimus menestyy siis *ymmärrettävyyden* kriteerin osalta erinomaisesti.

Seuraavaksi menetelmiä tarkastellaan *mallin rakentamisen ja käytön helppouden* näkökulmasta. Hyvin konkurssia ennustavan hermoverkon *rakentaminen* on vaikeaa, sillä hermoverkkoarkkitehtuureja on paljon olemassa. Rakentamisessa on ratkaistava neuronikerrosten määrä, neuronien määrä kerroksissa, käytettävä verkon opettamismenetelmä ja niin edelleen. Yangin ym. (1999, 67) mukaan hermoverkkoihin ei kuitenkaan liity muodollista teoriaa, joka helpottaisi soveltuvien hermoverkkorakenteiden löytämistä. Siksi hermoverkkomallin rakentaminen vaatii käyttäjältään erityisosaamista. Hyvin konkurssia ennustavan hermoverkon rakentamisessa tarvitaan myös suurta yritysotosta (Min & Lee 2005, 604; Laitinen & Laitinen 2004, 153). Suuren otoksen kerääminen vaikeuttaa hermoverkon rakentamista. Hermoverkon rakentaminen on myös hidasta, sillä hermoverkon opettamiseen tarvittava prosessointiaika on pitkä (Pendharkar 2005, 2565; Altman ym. 1994, 507). Tamin ja Kiangin (1992, 944) mukaan hermoverkon rakentaminen vaatii enemmän tietokonekäsittelyaikaa kuin muut menetelmät. Heidän tutkimuksessaan hermoverkon rakentamisen tietokonekäsittely vei muutamista minuuteista kolmeen tuntiin, kun tilastollisilla menetelmillä prosessointiaika oli korkeintaan puoli minuuttia (Tam & Kiang 1992, 944). On kuitenkin hyvä huomata, että tutkimuksen tekohetken jälkeen tietokoneet ovat kehittyneet huomattavasti, minkä seurauksena menetelmien prosessointiaikojen erot ovat varmasti kaventuneet. Hermoverkkojen tietokonekäsittelyn ongelmat eivät kuitenkaan ole kadonneet, sillä Pendharkarin (2005, 2577) tuoreessa tutkimuksessa mainitaan, että tietty verkkorakenne aiheutti muistiongelman, joka pakotti otoskoon pienentämiseen. Hermoverkkojen *käyttö* on käyttäjän kannalta yksinkertaista. Verkolle annetaan tunnuslukusyötteet, odotetaan ja saadaan tulos, jota mahdollisesti verrataan kriittiseen arvoon. Joissakin olosuhteissa käytön ongelmaksi voi muodostua se, että menetelmä vaatii tietokoneen, jossa on ainakin jonkin verran muistia. Hermoverkkojen kokonaisarvio *mallin rakentamisen ja käytön helppouden* osalta on heikko.

Puumallin *rakentaminen* rekursiivisella osittamisella on monivaiheista. Lopullisen muodon valintaan on useita menetelmiä, joista tulisi löytää kulloinkin soveltuvin. Ainakin tietyt menetelmät vaativat suuren yritysotoksen. Joskus on myös vaikea päättää, milloin yritysten jakaminen kannattaa lopettaa. Joudutaan siis ratkaisemaan, saavutetaanko puun jatkamisella ennustamiselle lisätarkkuutta vai onko jakamisen jatkamisella mahdollisesti saavutettava tarkkuuden pieni lisäys ominainen vain käytetylle yritysotokselle. Puumallit ovat alttiita liialliselle sopeutumiselle (overfitting). Liiallinen sopeutuminen tarkoittaa tilannetta, jossa rakentamisaineiston yritykset

jaetaan hyvin pikkutarkasti pieniin ryhmiin perusteilla, jotka heikentävät puumallin ennustuskkyä rakentamisaineiston ulkopuolella. Puumallin rakentajan tulisi siten kyetä ratkaisemaan, milloin yritysten jakaminen menee liiallisen sopeutumisen puolelle ja ei siten kannata enää. (Frydman ym. 1985, 273–275) Tamin ja Kiangin (1992, 944) tutkimuksessa puumallin tietokoneprosessointi kesti keskimäärin 8 minuuttia. Mallin estimoiminen oli siis selvästi hitaampaa kuin tilastollisilla menetelmillä, mutta kuitenkin nopeampaa kuin hermoverkkomenetelmällä. Dimitras ym. (1996, 506) kiteyttää puumallin *rakentamisen* arvioimisen toteamalla, että puumallin estimoiminen on vaikeaa. Puumallien *käyttö* sen sijaan on helppoa. Käytössä verrataan yhtä tunnuslukua kerrallaan sille määritettyyn kriittiseen arvoon, mitä jatketaan niin kauan kun päädytään kohtaan, jossa yrityksiä ei jaeta enää. Päätepisteeksi muodostunut sijainti puussa ratkaisee yrityksen ennusteen. Koska mallin rakentaminen on vaikeaa mutta käyttö helppoa, rekursiivinen osittaminen täyttää vain kohtalaisesti *mallin rakentamisen ja käytön helppouden* kriteerin.

Eloonjäämisanalyysimallin *rakentaminen* vaatii tietoa siitä, kuinka paljon yrityksillä on aikaa jäljellä konkurssihetkeen. Toimivien yritysten käsittely on hieman ongelmallista, koska niillä ei luonnollisesti ole konkurssihetkeä. Tutkijat ovat usein ratkaisseet ongelman määrittämällä toimiville yritykselle ”riittävän pitkän” keksityn elinajan. (Laitinen & Laitinen 2004, 148) Toimivien yritysten käsittelytapa saattaa olla merkityksellinen mallin toimivuuden kannalta, joten jokaisen tutkijan on ratkaistava se parhaaksi näkemällään tavalla. Muuten eloonjäämismallin rakentamisen ei pitäisi olla vaikeaa. Kertoimien estimoinnissa käytetään usein logit-analyysin tapaan suurimman uskottavuuden menetelmää (Laitinen & Laitinen 2004, 149; Dimitras ym. 1996, 495). Sen käytöstä ei ole raportoitu ongelmakohtia. Henebryn (1997, 10) mukaan eloonjäämisanalyysimalli on arbitraarinen, joten ennakkotyötä mallin rakentamisessa ei tarvitse tehdä. Eloonjäämisanalyysimallin *käyttö* on helppoa. Esimerkiksi kaavan 14 laskeminen onnistuu helposti laskimella tai taulukkolaskentaohjelmalla. Tulos on heti saatavissa. Eloonjäämisanalyysin osalta voidaan todeta, että menetelmä täyttää *mallin rakentamisen ja käytön helppouden* kriteerin melko hyvin.

HIP-tutkimuksen toteuttaminen on hankalaa. Mallin rakentamista varten tulisi kyetä aktivoimaan asiantuntevia päätöksentekijöitä yhteistyöhön. Yhteistyöstä ei välttämättä ole päätöksentekijöille hyötyä, joten heitä voi olla vaikea saada avukseen. Laitinen ja Kankaanpää (1999, 82) tekivät Suomessa melko ainutlaatuisen konkurssin ennustamisen HIP-tutkimuksen yliopistostatuksella, ja tutkimus vielä julkaistiin tieteislehdessä. Silti alle puolet kysytyistä KHT-tilintarkastajista osallistui tutkimukseen. Tästä huomataan, että asiantuntijoita voi olla vaikea saada innostumaan omiin yritysarviohankkeisiin. Mallin rakentamista HIP-menetelmällä vaikeuttaa myös se, että tutkijan on

valittava useista vaihtoehtoista sopivin. Koska HIP-tutkimuksessa pyritään jäljittelemään ihmisen tiedon prosessoinnissa käyttämiä päätössääntöjä, voi olla hankalaa muuttaa päätöksentekijöiden ajatukset matemaattiseen muotoon. Erottelu- ja regressioanalyysin soveltaminen tosin ei ole hankalaa. Mallin kertoimien estimointiin liittyy joka tapauksessa paljon valintoja, jotka vaativat kyvykkyyttä. HIP-tutkimuksella kehitetyt mallit sisältävät vain summia ja tuloja (Laitinen & Laitinen 2004, 161–165). Siksi niiden käyttö on erittäin helppoa. Koska HIP-tutkimuksessa *mallin rakentaminen* on vaikeaa ja *käyttö* helppoa, kokonaisarvio kriteerin osalta on kohtalainen rekursiivisen osittamisen tapaan.

Minin ja Leen (2005, 604) mukaan hermoverkkomenetelmää on viime aikoina käytetty eniten konkurssin ennustamiseen, koska sen *luokittelukykyä* pidetään muita menetelmiä parempana. Hermoverkkojen hyvälle luokittelukyvyllä onkin löydettävissä referenssiä. Azizin ja Darin (2004, 37) listaamassa kahdeksassa hermoverkkotutkimuksessa luokittelukyvyn keskiarvo vuotta ennen konkurssia oli 88 prosenttia. Minin ja Leen (2005, 612) tutkimuksessa hermoverkkojen tarkkuudeksi saatiin vuotta ennen konkurssia estimointiotoksessa 85 % ja testiotoksessa 83 %. Laitisen ja Kankaanpään (1999, 83) hermoverkko luokitteli testiotoksen yritykset vuotta ennen konkurssia 87 prosenttisesti, kahta vuotta ennen 66 prosenttisesti ja kolmea vuotta ennen 71 prosenttisesti. Luokittelukyky oli siis alkuun hyvä, mutta ei säilynyt vuotta pidemmälle. Tamilla ja Kiangilla (1992, 940) parhaan verkkorakenteen testiotostulokset olivat vuotta ennen konkurssia 85 prosenttia ja kahta vuotta ennen 89 prosenttia. Tarkkuus siis jopa kasvoi etäännyttäessä konkurssista aivan päinvastaisesti kuin Laitisen ja Kankaanpään (1999) tutkimuksessa. Hermoverkkojen luokittelukyky on pääsääntöisesti yli 85 % vuotta ennen konkurssia, joten *luokittelukyvyn* kriteeri täyttyy. Pientä epävarmuutta menetelmän ennustustarkkuudesta aiheuttaa kuitenkin se, että hermoverkot ovat rekursiivisen osittamisen tapaan alttiita liialliselle sopeutumiselle (overfitting). Altmanin ym. (1994, 521–522) mukaan hermoverkot saattavat hioutua opettamisvaiheessa erittäin tarkoiksi estimointiaineistojen luokittelijoiksi, mikä näkyy testiotoksissa tulosten yleistettävyyden heikentymisenä. Tämä yhdistettynä luokittelukyvyn säilymisen epävarmuuteen alentaa hermoverkkojen muuten hyvän *luokittelukyvyn* arvion melko hyväksi.

Laitinen ja Laitinen (2004, 145–146) esittävät perustellusti, miksi rekursiivinen osittaminen toimii teoriassa parempana luokittelijana kuin hyväksi luokittelijaksi arvioitu erotteluanalyysi. Frydmanin ym. (1985, 287) tutkimus puoltaa suurimmaksi osaksi tätä, sillä heidän tutkimuksessaan useimmissa tapauksissa rekursiivisen osittamisen mallit toimivat tarkemmin kuin erotteluanalyysimalli. Pendharkar (2005, 2570–2574) vertaili puolestaan C4.5 -puumallin luokittelukykyä erilaisiin

hermoverkkoihin. Puumalli osoittautui kilpailukykyiseksi hermoverkkojen kanssa. Azizin ja Darin (2004, 37) listauksessa on viisi rekursiivista osittamista soveltanutta tutkimusta. Niissä luokittelukyvyyn keskiarvo vuotta ennen konkurssia oli 87 prosenttia. McKeen ja Greensteinin (2000, 224–228) tutkimuksessa päästiin parhaimmillaan 85 prosentin tarkkuuteen, mutta paikoin tarkkuus oli hyvin alhainen. Tosin otos tutkimuksessa oli täysin erilainen kuin muissa tutkimuksissa vähäisten konkurssiyritysten takia, joten tuloksetkaan eivät ole täysin vertailukelpoisia.

Rekursiiviselle osittamiselle hermoverkkojen tapaan tyypillinen liiallisen sopeutumisen ongelma näkyy paikoin menetelmän *luokittelukyvyssä*. Tamin ja Kiangin (1992, 940) tutkimuksessa puumallin luokittelutarkkuus estimointiotoksessa vuotta ja kahta vuotta ennen konkurssia oli 92 ja 91 prosenttia, mutta testiotoksessa enää 80 ja 78 prosenttia. Laitisen ja Kankaanpään (1999, 79–83) vastaavat lukemat olivat estimointiaineistossa 95 ja 83 prosenttia ja testiaineistossa 83 ja 58 prosenttia. Molemmissa tutkimuksissa puumallin luokittelukyky putosi siis selvästi testattaessa mallia, mikä ilmentää liiallisen sopeutumisen aiheuttamaa sidonnaisuutta estimointiaineistoon. Tamin ja Kiangin (1992) tutkimuksessa luokittelukyky säilyi hyvin vielä kaksi vuotta ennen konkurssia, mutta Laitisen ja Kankaanpään (1999) tutkimuksessa tarkkuus putosi huomattavasti siirryttäessä vuotta pidemmälle aikajänteelle konkurssihetkestä. Rekursiivisen osittamisen *luokittelukyvyyn* kokonaisarviointissa osa tutkimuksista yli 85 prosentin tarkkuudellaan puoltaa hyvää arviota. Joissakin jäädyään kuitenkin selvästi alle hyvän luokittelukyvyyn 85 prosentin rajan. Myös havaitut liiallinen sopeutuminen ja ennusteen mahdollinen säilymättömyys yli vuoden aikajänteen aiheuttavat sen, että rekursiivisen osittamisen *luokittelukyky* on syytä arvioida kokonaisuudessaan kohtalaiseksi.

Eloonjäämisanalyysin *luokittelukykyä* arvioitaessa on huomioitava, että menetelmä antaa tietoa sekä konkurssin ajankohdasta että todennäköisyydestä. Toisaalta se on informatiivisuuden kannalta etu, mutta toisaalta se heikentää menetelmän luokittelutarkkuutta. Selviytymistaistelussaan konkurssia vastaan yrityksillä on yksilöllisiä keinoja, jotka eivät välttämättä näy tilinpäätöksessä samalla lailla. Tämä heikentää konkurssin ajankohdan ennustamismahdollisuutta. Lisäksi yritysten konkurssi voi aiheutua eri tekijöistä, sillä yrityksille on tunnistettu erilaisia konkurssiprosesseja. Sekin heikentää mahdollisuutta ennustaa yhdellä eloonjäämisanalyysimallilla kaikkien yritysten konkurssseja ja niiden ajankohtaa.

Käytännössä eloonjäämisanalyysin luokittelutulokset ovatkin jääneet vaatimattomiksi, mikä heijastuu jo sen harvasta käytöstä. Laitinen ja Kankaanpää (1999, 73) toteavat, että



eloonjäämisanalyysia alettiin soveltaa konkurssin ennustamiseen siksi, että sillä yritettiin saavuttaa logit-analyysia tarkemmat ennusteet. Muutamat tutkimukset todistivat sen kuitenkin mahdottomaksi. Lanen ym. (1986) tutkimuksessa päästiin testiotoksessa 80 prosentin tarkkuuteen sekä Luoman ja Laitisen (1991) tutkimuksessa estimointiotoksessa vain 62 prosentin tarkkuuteen vuotta ennen konkurssia (ks. Laitinen & Kankaanpää 1999, 89). Henebryn (1997, 7) tutkimuksessa tulokset olivat hyvin vaatimattomia. I-tyypin virheitä tehtiin sentään vähän, mutta toimivista yrityksistä yli puolet luokiteltiin väärin, joten II-tyypin virheitä syntyi todella paljon. Laitisen ja Kankaanpään (1999, 83) tutkimuksessa testiaineiston tarkkuudet olivat vuotta, kahta ja kolmea vuotta ennen konkurssia 76, 71 ja 74 prosenttia. Vaikka ainakin tämän perusteella vaikuttaisi siltä, että eloonjäämisanalyysin luokittelukyky säilyy hyvin, kokonaisarvio menetelmän *luokittelukyvyistä* on korkeintaan kohtalainen luokittelutulosten jäädessä säännöllisesti alle 85 prosentin.

HIP-tutkimuksen *luokittelukyky* riippuu mallin rakentajan kyvykkyyden lisäksi ennen kaikkea käytettyjen päätöksentekijöiden taidoista. Laitinen ja Laitinen (2004, 166) toteavat, että päätöksentekijöiden saavuttama ennustamistarkkuus on useiden tutkimusten perusteella likimain samaa luokkaa kuin tilastollisilla konkurssin ennustamismenetelmillä. HIP-menetelmällä on siis mahdollista rakentaa muiden menetelmien tasoinen malli. Käytännön HIP-tutkimuksissa ei ole kuitenkaan päästy parhaiden menetelmien tasolle. Libbyn (1975, 155–156) tutkimuksessa paras päätöksentekijä luokitteli 60 yritystä 83 prosentin tarkkuudella, kun keskiarvo kaikilla päätöksentekijöillä oli 73 prosenttia. Casey'n (1980, 45) tutkimuksessa ennustettavat yritysryhmät sisälsivät vain 10 yritystä. Päätöksentekijät onnistuivat luokittelemaan keskimäärin vain noin puolet yrityksistä oikein. Zopounidisin ja Doumposin (1999, 1144) rakentaman mallin testitulokset jäivät kaikkina konkurssia edeltävinä vuosina alle 70 prosentin. Laitisen ja Kankaanpään (1999, 83) käyttämät KHT-tilintarkastajat onnistuivat luokittelussa 83-prosenttisesti vuotta ennen konkurssia. Nämä käytännön tulokset osoittavat, että HIP-tutkimus ei täytä *luokittelukyvyyn* kriteeriä, koska tulokset jäävät selvästi alle 85 prosenttiin asetetun hyvän rajan.

Altmanin ym. (1994, 525) tutkimuksessa ilmeni, että hermoverkot saattavat toisinaan toimia järjenvastaisesti. Esimerkkinä tutkijat raportoivat tilanteesta, jossa hermoverkon konkurssiyritykseksi luokitteleman yrityksen maksuvalmiutta huononmetaan entuudestaan. Uusilla arvoilla laskettuna hermoverkko luokittelikin yrityksen toimintaansa jatkavaksi. Epäjohdonmukaisuuden pelkoa hermoverkoissa lisää myös se, että Tamin ja Kiangin (1992, 940) tutkimuksessa hermoverkkojen luokittelukyky parani testiotoksessa kahta vuotta ennen konkurssia 3,5 prosentilla verrattuna luokittelukykyyn vuotta ennen konkurssia. Yleensä luokittelukyky

heikkenee etäännyttäessä konkurssihetkestä. Paraneminen voi kuitenkin olla selitettävissä viime hetken elvytystoimenpiteillä tai erilaisilla tunnuslukupainotuksilla. Eri tunnusluvuilla on erilainen kyky ennustaa konkurssia eri hetkinä. Ennen kaikkea Altmanin ym. (1994) tärkeiden epäloogisuushavaintojen takia hermoverkkomenetelmä ei täytä *johdonmukaisuuden* kriteeriä.

Rekursiivisessa osittamisessa on myös ongelmia *johdonmukaisuuden* osalta. Frydmanin ym. (1985, 275) mukaan etenkin monimutkaisissa puukuvioissa on usein harhoja. Harhat saattavat johtua siitä, että menetelmässä suunnataan aina eteenpäin uusiin dikotomisiin luokitteluihin käyttämällä yhtä tunnuslukua kerrallaan. Aiempia luokitteluita ei siten huomioida millään tavalla. Tämä saattaa Dimitrasin ym. (1996, 506) mukaan johtaa siihen, että sama tunnusluku esiintyy puussa useassa vaiheessa, mutta eri kriittisellä arvolla. Vain yhden tunnusluvun käyttäminen kerrallaan aiheuttaa sen, että yritys saattaa ajautua sellaiseen haaraan, joka ei kuvaa parhaiten sen toiminnan kokonaisedellytyksiä. Rekursiivinen osittaminen sisältää siis selkeitä mahdollisuuksia epäjohdonmukaiseen toimintaan, joten se ei saa hyvää arviota *johdonmukaisuuden* kriteerin osalta.

Eloonjäämisanalyysitutkimuksissa ei ole raportoitu epäjohdonmukaisuuksista. Eloonjäämismallin rakentamisessa käytetään Laitisen ja Laitisen (2004, 149) mukaan usein suurimman uskottavuuden menetelmää, kuten logit-analyysin kohdalla. Muutenkin usein eloonjäämisanalyysimallina käytetty Coxin malli (kaava 14) muistuttaa logit-mallia. Logit-analyysinkaan kohdalla ei havaittu epäjohdonmukaisuuksia, joten eloonjäämisanalyysin voidaan todeta täyttävän *johdonmukaisuuden* kriteerin.

HIP-tutkimukseen sisältyy potentiaalisia epäjohdonmukaisuustekijöitä. Epäjohdonmukaisuutta voi syntyä siten, että päätöksentekijä tekee päätöksensä eri perusteilla eri yritysten kohdalla. Tällaisissa tilanteissa päätöksentekijän käyttäytymisen perusteella rakennettavasta mallista ei tule yleispätevä. Toinen epäjohdonmukaisuusmahdollisuus on se, että kun käytetään useita päätöksentekijöitä mallin rakentamisessa, eri päätöksentekijät perustavat päätöksensä täysin eri asioihin. Tällöinkin mallista tulee helposti epäjohdonmukainen. Libbyn (1975, 157–158) tutkimuksessa näitä epäjohdonmukaisuusmahdollisuuksia esiintyi, mutta ne eivät olleet tilastollisesti merkittäviä. Uhka on siis olemassa, mutta se ei välttämättä toteudu. HIP-menetelmällä rakennetun mallin käyttämiseen ei pitäisi liittyä epäjohdonmukaisuutta. Mallit ovat usein yksinkertaisia kaavan 17 tapaan. Tällaiset erotteluanalyysimallin kaltaiset mallit toimivat johdonmukaisesti. Kokonaisarviota HIP-tutkimuksen *johdonmukaisuudesta* on vaikea antaa, sillä johdonmukaisuus riippuu aina käytetyistä päätöksentekijöistä. Ihmisten käyttäytymiseen vaikuttavat lukemattomat tilannesidonaiset ja

yksilölliset seikat, joten mahdolliset epäjohdonmukaisuudet on otettava vakavasti. Siksi on syytä todeta, että HIP-tutkimus ei täytä aina *johdonmukaisuuden* kriteeriä.

Seuraava arvioitava kriteeri on *muutostensietokyky*. Hermoverkkojen selkeä vahvuus verrattuna muihin konkurssin ennustamismenetelmiin on menetelmän kyky mukautua uusiin olosuhteisiin (Altman ym. 1994, 515). Aiemmissä olosuhteissa hyvin toiminut hermoverkko ei välttämättä toimi sellaisenaan hyvin uudessa tilanteessa esimerkiksi kirjanpitosäännösten muututtua, mutta verkkoa voidaan opettaa. Opettamisessa verkolle syötetään uusien olosuhteiden yrityshavaintoja, jolloin verkko säätelee painotuksiaan siten, että verkko kuvaa mahdollisimman hyvin konkurssiprosessia uusissa olosuhteissa. Tällöin käyttäjän ei tarvitse rakentaa uutta verkkoarkkitehtuuria uusine tunnuslukuineen, vaan verkko opettelee itsenäisesti annettujen havaintojen perusteella kuvausta syötteiden ja tulosten välillä. (Aziz & Dar 2004, 15; Tam & Kiang 1992, 943) Hermoverkkojen hyvä *muutostensietokyky* mahdollistaa nopean sopeutumisen muuttuneisiin olosuhteisiin reaali maailmassa, mikä vähentää menetelmän käyttäjältä vaadittavaa panosta mallien päivittämisessä (Tam & Kiang 1992, 944).

Rekursiivisen osittamisen tuottamat päätöspuut ovat jäykkiä muutokselle. Cielenin ym. (2004, 531–532) mukaan eri olosuhteissa on rakennettava erilaiset puut, sillä menetelmää ei saa mukautettua uusiin olosuhteisiin. Laitinen ja Kankaanpää (1999, 71) jatkavat samalla linjalla toteamalla, että puumallit säilyttävät ennustuskykynsä vain silloin, kun konkurssiprosessi pysyy samanlaisena. Eloojäämisanalyysin kohdalla *muutostensietokyvyn* tilanne on samankaltainen. Henebryn (1997, 3–4) mukaan eloonjäämisanalyysimalleja ei tarvitse estimoida vuosittain uudelleen silloin, kun samat tunnusluvut pysyvät yhtä merkityksellisinä vuodesta toiseen. Käytännössä näin ei yleensä ole, sillä kirjanpitosäännökset, yritysten taloudelliset toimintaedellytykset ja yritysten toimintatavat muuttuvat. Nämä näkyvät luonnollisesti tunnuslukujen merkityksellisyyden vaihteluna. Henebry (1997, 3–4) havaitsi tutkimuksessaan eloonjäämisanalyysimallien muutostensietokyvyttömyyden, jota hän korvasi rakentamalla erilaisia malleja eri vuosille. HIP-tutkimuksessakaan ei ole sellaisia tekijöitä, jotka tekisivät siitä muutostensietokykyisen. HIP-mallit rakennetaan päätöksentekijöiden käyttäytymisen pohjalta tutkimuksen tekohetkellä vallitsevissa olosuhteissa. Jos olosuhteet muuttuvat, päätöksentekijät saattavat muuttaa päätössääntöjensä. Silloin on estimoitava uudet mallit. Näin ollen *muutostensietokyvyn* kriteerin osalta hermoverkot menestyvät hyvin ja rekursiivinen osittaminen, eloonjäämisanalyysi sekä HIP-tutkimus huonosti.

*Taustaoletusten todenmukaisuuden* osalta hermoverkkomenetelmä menestyy hyvin. Laitisen ja Laitisen (2004, 152) mukaan hermoverkon mallinnuksessa ei tarvita rajoittavia oletuksia esimerkiksi lopullisen riippuvuuden lineaarisuudesta tai logistisuudesta. Hermoverkkomenetelmä ei vaadi funktionaalisen muodon ennaltamääräämistä eikä rajoittavia oletuksia muuttujien ominaisuuksista, jakaumista tai hajonnoista (Altman ym. 1994, 515; Tam & Kiang 1992, 944). Menetelmä ei siten kärsi oletuksista, joiden mahdollisesti vajavainen toteutuminen heikentäisi ennustustuloksia. Täten *taustaoletusten todenmukaisuuden* kriteeri täyttyy hermoverkkomenetelmän kohdalla.

Rekursiivisessa osittamisessa ei tarvita oletuksia riippuvien tai riippumattomien tunnuslukujen jakaumista (Laitinen & Kankaanpää 1999, 76). Frydmanin ym. (1985, 276–277) mukaan rekursiivinen osittaminen ei vaadi samoja tilastollisia oletuksia kuin erotteluanalyysi, sillä rekursiivinen osittaminen olettaa ainoastaan, että konkurssiyritysten ja toimivien yritysten ryhmät ovat diskreettejä, ei-päällekkäisiä ja tunnistettavissa olevia. Tämä oletus ei sisällä suuria toteutumattomuusongelmia, joten myös rekursiivinen osittaminen täyttää *taustaoletusten todenmukaisuuden* kriteerin.

Eloonjäämisanalyysi on semiparametrinen menetelmä, sillä eloonjäämisanalyysimallissa (kaava 14) esiintyy ei-parametrinen perusriskitekijä sekä parametrinen  $e:n$  eksponentti (Laitinen & Kankaanpää 1999, 72–73). Dimitrasin ym. (1996, 495) mukaan eloonjäämisanalyysi välttää semiparametrisuuden takia osittain erotteluanalyysin kaltaisten parametrusten menetelmien kritiikin. Henebryn (1997, 10) mukaan eloonjäämisanalyysimalliin (kaavaan 14) ei sisälly oletuksia jakaumista. Eloonjäämisanalyysiin liittyy kuitenkin riski  $e:n$  eksponenttina toimivan  $Z$ -luvun taustaoletusten toteutumattomuudesta samoin kuin erottelu- ja regressioanalyyseissa, koska  $Z$ -lauseke on täysin samanlainen. Eloonjäämisanalyysin semiparametrisuus pelastaa taustaoletusvaatimukset vain osittain, joten eloonjäämisanalyysi ei täytä kokonaan *taustaoletusten todenmukaisuuden* kriteeriä.

HIP-tutkimuksessa on mahdollista johtaa konkurssin ennustamismalli eri menetelmillä päätöksentekijöiden päätössäännöistä. Siksi taustaoletuksetkin vaihtelevat valitun menetelmän mukaan. Jos käytetään erotteluanalyysia tai regressioanalyysia, kohdataan samat ongelmalliset taustaoletukset kuin näiden menetelmien arvioinnissa on esitetty (luku 4.6). Varianssianalyysin tai moniulotteisen skaalauksen käyttö saattaa auttaa taustaoletusongelmassa. (Laitinen & Laitinen 2004, 162–165) Joka tapauksessa HIP-tutkimukseen liittyy riski taustaoletusongelmasta, joten

eloonjäämisanalyysin tapaan HIP-tutkimus ei täytä kokonaan *taustaoletusten todenmukaisuuden* kriteeriä.

Taulukossa 5 esitetään yksinkertaistettuna yhteenvetona käytetyimpien keinoälyyn ja ihmisälyyn perustuvien menetelmien arviointi tutkielmassa yhtenäisesti käytettävän konkurssin ennustamismenetelmien arviointikriteeristön avulla. Rasti tarkoittaa sitä, että menetelmä täyttää kyseisen kriteerin hyvin tai melko hyvin, kuten luvuissa 3 ja 4 arvioitujen menetelmien kohdalla.

Taulukko 5. Keinoälyyn ja ihmisälyyn perustuvien menetelmien arviointi konkurssin ennustamismenetelmien arviointikriteeristöllä

	NN	RPA	SA	HIP
Käytön yleisyys	x	x		x
Informaatioisisältö	x	x	x	
Ymmärrettävyys		x	x	x
Mallin rakentamisen ja käytön helppous			x	
Luokittelukyky	x			
Johdonmukaisuus			x	
Muutostensietokyky	x			
Taustaoletusten todenmukaisuus	x	x		

NN=Hermoverkot (Neural Networks)

RPA=Rekursiivinen osittaminen (Recursive Partitioning Algorithm)

SA=Eloonjäämisanalyysi (Survival Analysis)

HIP=HIP (Human Information Processing)-tutkimus

## 6 YHTEENVETO JA PÄÄTELMÄT

Tutkielman tavoitteeksi asetettiin luvussa 1.2 käytetyimpien tilinpäätösperusteisten konkurssin ennustamismenetelmien laadullinen arviointi. Tavoitteeseen liittyvää ongelmaa mallinnettiin esittelemällä ja mainitsemalla luvuissa 3–5 lukuisia erilaisia konkurssin ennustamismenetelmiä, joiden paljous vaikeuttaa käytettävän menetelmän valintaa. Laadullisen arvioinnin avulla on mahdollista antaa suosituksia tiettyjen konkurssin ennustamismenetelmien käytöstä. Käytetyimpien menetelmien yksinkertaistettu arviointi on taulukoiden 3, 4 ja 5 perusteella yhdistetty taulukkoon 6.

Taulukko 6. Käytetyimpien konkurssin ennustamismenetelmien arviointi konkurssin ennustamismenetelmien arviointikriteeristöllä

	UA	DA	RA	LA	PA	NN	RPA	SA	HIP
Käytön yleisyys		x		x		x	x		x
Informaation sisältö			x	x	x	x	x	x	
Ymmärrettävyys	x	x	x	x			x	x	x
Mallin rakentamisen ja käytön helppous	x	x	x	x				x	
Luokittelukyky		x		x	x	x			
Johdonmukaisuus		x		x	x			x	
Muutostensietokyky						x			
Taustaoletusten todenmukaisuus				x	x	x	x		

UA=Yksittäiset tunnusluvut (Univariate Analysis)

DA=Erotteluanalyysi (Discriminant Analysis)

RA=Regressioanalyysi (Regression Analysis=Linear Probability Model (LPM))

LA=Logit-analyysi (Logit Analysis)

PA=Probit-analyysi (Probit Analysis)

NN=Hermoverkot (Neural Networks)

RPA=Rekursiivinen osittaminen (Recursive Partitioning Algorithm)

SA=Eloonjäämisanalyysi (Survival Analysis)

HIP=HIP (Human Information Processing)-tutkimus

Arviointikriteeristön kriteereitä ei ole painotettu mitenkään eivätkä kriteerit ole kaikille käyttäjille samanarvoisia. Näin ollen taulukkoa 6 ei ole syytä käyttää ilman perehtymistä siten, että menetelmät laitetaan paremmuusjärjestykseen vain rastien eli menetelmien täyttämien kriteereiden määrän perusteella. Kriteerit on kuitenkin laadittu siten, että ne pyrkivät kuvaamaan konkurssin ennustamismenetelmien laadullisia ominaisuuksia monipuolisesti. Eri käyttäjät saattavat arvostaa eri ominaisuuksia, joten taulukko 6 auttaa kunkin käyttäjän mieltymysten mukaisen menetelmän löytämisessä.

Taulukon 6 mukaan logit-analyysi täyttää seitsemän kriteeriä kahdeksasta. Se on selvästi eniten, sillä seuraavaksi parhaiten kriteerit täyttyvät erotteluanalyysin ja hermoverkkojen kohdalla. Molemmat menetelmät täyttävät viisi kriteeriä. Logit-analyysi vaikuttaa sen täyttämien kriteereiden perusteella laadullisilta ominaisuuksiltaan parhaalta. Logit-analyysin arvioinnin kohdalla todettiin, että menetelmä täyttää hyvin käytön yleisyyden, informaatioisisällön, luokittelukyvyyn, johdonmukaisuuden ja taustaoletusten todenmukaisuuden kriteerit. Melko hyvin täyttyvät ymmärrettävyys sekä mallin rakentamisen ja käytön helppous, mutta muutostensietokykyä menetelmällä ei ole. Logit-analyysilla on paljon selkeitä etuja, sillä menetelmää on helppo käyttää, sillä saa oikean ennusteen pääsääntöisesti kahdeksassa tai yhdeksässä tapauksessa kymmenestä sekä ennustustulos antaa myös tietoa ennusteen toteutumisen todennäköisyydestä. *Tämä tutkielma puoltaa logit-analyysin käyttöä ensisijaisena konkurssin ennustamismenetelmänä.*

Taulukon 6 perusteella logit-analyysin jälkeen käyttökelpoisimpia ovat erotteluanalyysi ja hermoverkot. Erotteluanalyysi täyttää hyvin käytön yleisyyden, ymmärrettävyyden, luokittelukyvyyn ja johdonmukaisuuden kriteerit. Melko hyvin täyttyy myös mallin rakentamisen ja käytön helppous, mutta informaatioisisällön kriteeri jää niukasti täyttymättä. Muutostensietokyky ja taustaoletusten todenmukaisuus sen sijaan ovat erotteluanalyysissa heikkoja. *Erotteluanalyysia suositellaan käytettäväksi lähinnä logit-analyysin korvikkeena, jos käyttäjä ei jostain syystä halua valita ominaisuuksiltaan vähän parempaa logit-analyysia. Sekä logit- että erotteluanalyysi tilastollisina yhdistelmäluvun rakentamisperiaatteina ovat melko samankaltaisia menetelmiä, joten niiden käyttö rinnakkain ei välttämättä tuo merkittävää lisäarvoa.*

Hermoverkkojen arvioinnissa päädyttiin siihen, että menetelmä täyttää hyvin käytön yleisyyden, informaatioisisällön, muutostensietokyvyyn ja taustaoletusten todenmukaisuuden kriteerit. Luokittelukyky todettiin paikoin erinomaiseksi, mutta paikoittaiset liiallisen sopeutumisen ongelmat alensivat luokittelukyvyyn arvion melko hyväksi. Ymmärrettävyys, mallin rakentamisen ja käytön helppous ja paikoittainen epäjohdonmukaisuus sen sijaan arvioitiin hermoverkkomenetelmän heikkouksiksi. Kaiken kaikkiaan hermoverkkomenetelmässä on useita hyviä puolia. Suurimmat ongelmat liittyvät siihen, että menetelmä tuottaa satunnaisesti absurdeja tuloksia, joita on menetelmän monimutkaisen rakenteen takia vaikea tunnistaa. Sen takia hermoverkkojen käyttöä ei välttämättä suositella ainoana käytettävänä menetelmänä. *Sen sijaan käytettynä täydentävänä menetelmänä samaan ennustustilanteeseen täysin erilaisen logit-analyysin kanssa hermoverkkomenetelmästä voi olla suurta hyötyä.* Kahden perusteiltaan täysin erilaisen menetelmän yhtenevä ennuste joko konkurssista tai toiminnan jatkumisesta lisää käyttäjän luottamusta ennusteen

toteutumisesta. Käyttäjä tosin voi kokea ongelmalliseksi tilanteen, jossa menetelmät antavat eriävät ennusteet. Toisaalta tämä voi olla hyväksikin siinä mielessä, että ennusteisiin ja muuhun yritysanalyysiin perehdytään silloin tarkasti eikä luoteta sokeasti yhden menetelmän mahdollisesti virheelliseen ennusteeseen.

Probit-analyysi, rekursiivinen osittaminen, eloonjäämisanalyysi ja regressioanalyysi näyttävät taulukon 6 perusteella keskitasoisilta konkurssin ennustamismenetelmiltä. Näitä menetelmiä valitsevien käyttäjien kannattaa kiinnittää huomiota varsinkin menetelmien luokittelukykyyn. Luokittelukyky on ehdottomasti yksi tärkeimmistä kriteeristön kriteereistä, sillä konkurssin ennustamisilmiö perustuu siihen olettamukseen, että yritysten tilinpäätösten perusteella voidaan ennustaa mahdollinen konkurssi. Jos menetelmä ei ole vakuuttanut ennustamiskyvyllään aiemmissa tutkimuksissa, sen käyttöä on syytä harkita tarkkaan. Keskitasoisista menetelmistä ainakin eloonjäämisanalyysin luokittelukyky on paikoin ollut vaatimaton.

Yksittäiset tunnusluvut ja HIP-tutkimus täyttävät taulukon 6 mukaan vain kaksi kriteeriä kahdeksasta. *Näiden menetelmien käyttöä konkurssin ennustamiseen ei siten suositella.* Yksittäisten tunnuslukujen merkitys konkurssin ennustamisalalla on lähinnä siinä, että niiden ennustamiskyvyn tultua ilmi tutkimus konkurssin ennustamisalalla sai uutta vauhtia. Yksittäiset tunnusluvut konkurssin ennustajina toimivat lähinnä tiennäyttäjinä myöhemmin kehitetyille niitä hyödyntäville menetelmille (Dimitras ym. 1996, 495). HIP-tutkimukseen liittyy monia heikkouksia. Menetelmällä saadut luokittelutuloksetkaan eivät puolla sen käyttöä.

Tämän tutkielman perusteella voidaan todeta, että useita vuosikymmeniä sitten kehitetyt selvästi yksinkertaisemmat tilastolliset konkurssin ennustamismenetelmät ovat edelleen kilpailukykyisiä uudempien, usein keinoälyä hyväksi käyttävien monimutkaisten menetelmien kanssa. Etenkin Ohlsonin (1980) alalle esittelemä ja jo 25 vuotta käytetty logit-analyysi vaikuttaa laadullisilta ominaisuuksiltaan jopa parhaalta. Altmaninkaan (1968) yli 35 vuotta sitten pohjustamaa erotteluanalyysia ei ole vielä syytä unohtaa. Nämä laadullisen arvioinnin perusteella tehdyt havainnot vahvistavat Laitisen ja Kankaanpään (1999) empiirisen testauksen perusteella tekemiä havaintoja. Laitinen ja Kankaanpää (1999) vertasivat empiirisen testauksen avulla erotteluanalyysin, logit-analyysin, rekursiivisen osittamisen, eloonjäämisanalyysin, hermoverkkojen sekä HIP-tutkimuksen tuloksia ja totesivat, että vuosikymmeniä vanhat tilastolliset menetelmät ovat yhtä toimivia kuin uudemmat menetelmät. Yksikään menetelmä ei noussut tutkimuksessa yli muiden.



Erilaisten konkurssin ennustamismenetelmien toimiminen vuosikymmenien ajan likimain yhtä hyvällä tarkkuudella kannustaa pohtimaan ilmiön syitä. Miksi mikään kehitetty menetelmä ei toimi niin tarkasti, että uusien menetelmien soveltamista ja vanhojen mallien kehittämistä ei tarvitsisi jatkaa vuodesta toiseen? Yksi syy on varmasti se, että kahta täysin samanlaista konkurssia ei ole. Historialtaan samanlaisten yritystenkin konkurssiprosessit voivat erota toisistaan inhimillisen toiminnan seurauksena (Penttilä 2004, 7). Asioista yrityksissä päättävät ihmiset, joiden toiminta erilaisissa tilanteissa on yksilöllistä. Toiminnan seuraukset näkyvät tilinpäätöksissä, joista konkurssia ennustetaan. Aina tilinpäätöksetkään eivät välitä oikeaa informaatiota, sillä heikossa taloudellisessa tilanteessa olevat yritykset pyrkivät usein salaamaan kriisin lähestymisen käyttämällä epänormaaleja tilinpäätösjärjestelyjä (Laitinen & Laitinen 2004, 223). Tällaisia ovat muun muassa vastuiden ilmoittamatta jättäminen, varaston arvon esittäminen todellista suurempana sekä laskentamenettelyiden muuttaminen siitä raportoimatta. Luovaksi laskentatoimeksi kutsuttuja epänormaaleja järjestelyitä on usein mahdotonta oikaista ilman yrityksen sisäisiä tietoja, mikä luonnollisesti vaikeuttaa konkurssin ennustamista tilinpäätöstietojen avulla.

Konkurssiprosessien eroaminen yritysten välillä voi johtua muistakin kuin inhimillisistä tekijöistä. Laitinen (1990, 227–231) on tunnistanut kolme erilaista konkurssiyritystyyppiä. *Krooninen konkurssiyritys* on helppo ennustettava, sillä sitä vaivaa useissa eri tunnusluvuissa ilmenevä pitkäaikainen sairaus, joka pikku hiljaa tappaa yrityksen. *Tulorahoituskonkurssiyritys* on selvästi vaikeampi tapaus, sillä se on tunnistettavissa vain kannattavuuden ja tulorahoituksen äkillisestä romahtamisesta suunnilleen kahta vuotta ennen konkurssia. Selvästi hankalin ennustettava on *akuutti konkurssiyritys*, sillä sen äkillinen kuolema näkyy vain kaikkien tunnuslukujen nopeana romahtamisena. Pompe ja Bilderbeek (2005, 864) ovat havainneet, että nuorten yritysten konkurssseja on vaikeampi ennustaa kuin vanhojen yritysten. Siksi he suosittelvat eri mallien rakentamista eri-ikäisille yrityksille. Useat konkurssityypit ja iän mahdollinen vaikutus osoittavat sen, että yhdellä erilaisista konkurssiyrityksistä ja toimivista yrityksistä yleistetyllä mallilla on mahdotonta ennustaa konkurssit varsinkin vuotta pitemmällä aikavälillä sataprosenttisesti.

Tilinpäätösperusteiseen konkurssin ennustamiskenttään suoritettua laajan katsauksen ja arvioinnin jälkeen on myös hyvä pohtia alan tulevaisuudennäkymiä. Entistä tarkempien konkurssin ennustamismenetelmien ja mallien etsiminen on jatkunut jo useita vuosikymmeniä. Selvästi muita parempaa menetelmää ei vielä ole löytynyt, joten on helppo ennustaa uusien menetelmien soveltamisen ja vanhojen mallien kehittämisen jatkuvan. Jatkuvasti kehittyvä teknologia

mahdollistaa entistä suurempien tietomäärien nopean prosessoinnin, joten keinoälymenetelmien kehittäminen konkurssin ennustamiseen jatkuu varmasti. Jos monimutkaisilla menetelmillä ei päästä merkittävästi parantuneeseen ennustamistarkkuuteen, yksinkertaiset tilastolliset menetelmät säilynevät myös käytössä. Kaikilla konkurssin ennustajilla ei välttämättä ole halua, teknisiä laitteita ja ehkä kykyjäkään keinoälymenetelmien käyttöön, joten logit- ja erotteluanalyysin kaltaisille yhdistelmäluokumenetelmille riittänee käyttäjiä jatkossakin.

Gilbert, Menon ja Schwartz (1990, 161–171) ovat havainneet, että konkurssin ennustamismallit erottelevat kyllä terveet ja sairaat yritykset, mutta eivät sitä, mitkä sairaista yrityksistä selviävät ja mitkä eivät. Platt ja Platt (2002, 194) onnistuivat lähes täydellisesti luokittelemaan logit-analyysillä yritykset terveisiin ja rahoitusvaikeuksissa oleviin. Grice ja Dugan (2001, 164) osoittivat, että eräät konkurssin ennustamismallit ennustavat paremmin rahoitusvaikeuksia kuin konkurssia. Vaikeuksissa olevalla yrityksellä voi olla monia vaihtoehtoja selviytyä ongelmistaan. Kaikki eivät valitse konkurssia. Esimerkiksi pienillä yrityksillä konkurssiin joutuminen riippuu siitä, onko omistajalla lisää pääomaa sijoitettavaksi yritykseen. Yritys voidaan myös laittaa myyntiin tai sulauttaa se toiseen yritykseen konkurssin välttämiseksi (Keasey & Watson 1991, 92–93). Sitä, minkä vaihtoehdon yrityksen johto ja omistajat kulloinkin valitsevat, ei voida päätellä tilinpäätösaineistosta.

Havainnoilla saattaa olla vaikutusta konkurssin ennustamisilmiöön. Altmanin ym. (1994, 526–527) mukaan hermoverkot mahdollistavat yritysten luokittelun useisiin homogeenisiin luokkiin. Kolmiportainen luokittelu esimerkiksi terveisiin, vaarantuneisiin ja parantumattomasti sairaisiin yrityksiin saattaa muodostua alalla yleisemmäksi kuin luokittelu toimiviin ja konkurssiin ajautuviin yrityksiin. Kolmiportaisella luokittelulla saatettaisiin onnistua vähentämään luokitteluvirheitä, sillä suurin osa luokitteluvirheistä kaksiluokkaisessa ennustamisessa tehdään varmastikin vaarantuneiden yritysten kohdalla. Toisaalta kehityssuuntaus yritysten jakamisesta kahta useampaan luokkaan ei vaikuta selvältä, sillä vaikka sen hyödyistä on kirjoitettu jo yli 10 vuotta sitten, ilmiö ei ole yleistynyt konkurssin ennustamisalalla. Syynä saattaa olla yhteisten sääntöjen puuttuminen siitä, milloin yritys arvioidaan vaikeuksissa olevaksi. Konkurssin ennustamista on helpompi tutkia, koska konkurssi on helposti havaittavissa ja konkurssikäsitettä ei tarvitse erikseen määritellä.

Jos kolmiluokkainen ennustaminen ei yleisty, on hyvin mahdollista, että aletaan yleisesti puhua konkurssin ennustamisen sijaan rahoituskriisin (financial distress) ennustamisesta. Tällöin välttyään esimerkiksi lisäpääoman sijoittamisen, yrityskauppojen ja fuusioiden aiheuttamilta

luokitteluongelmilta, sillä rahoituskriisiennuste niiden kohdalla on oikea, mutta konkurssiennuste ei huonosta tilanteesta riippumatta toteudukaan. Muun muassa Laitinen on vaihtanut termistöään konkurssin ennustamisesta (Laitinen 1990) rahoituskriisin ennustamiseen (Laitinen & Laitinen 2004). Gilbertin ym. (1990, 161–171), Gricen ja Duganin (2001, 164) sekä Plattin ja Plattin (2002, 194) mainitut havainnot menetelmien rahoituskriisin ennustamiskyvystä tukevat tätä kehityssuuntaa.

Yksi mahdollinen tulevaisuudennäkymä konkurssin ennustamisalalla on se, että yritystutkijoiden mielenkiinto kohdistuu entistä enemmän yritysten menestymisen ennustamiseen. Monen mielestä saattaa olla muodikkaampaa ennustaa yrityksen konkurssin sijaan yrityksen menestymistä. Erilaisia yrityksen taloudellista asemaa kuvaavia menestystekijämittaristoja on rakennettu vastapainona konkurssin ennustamismalleille. Menestystekijämittaristoilla huonosti sijoittuvat yritykset ovat konkurssivaarassa. Menestystekijämittaristoissa ja konkurssin ennustamismalleissa on lopulta kyse samasta asiasta, yritysanalyysistä. Näkökulma on vain erilainen. Epäselvää on, säilykö mielenkiinto konkurssin ennustamiseen edelleen suurena vai siirtyykö yritysanalyysitutkimus yhä enemmän menestystekijöiden puolelle. Kiinnostus yritysanalyysiin säilyy joka tapauksessa suurena, sillä niille on monenlaista tarvetta erilaisissa päätöksentekotilanteissa.

## LÄHTEET

- Altman, E. I. 1968. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, Vol. 23, No. 4, 589–609.
- Altman, E. I., Marco, G. & Varetto, F. 1994. Corporate Distress Diagnosis: Comparisons Using Linear Discriminant Analysis and Neural Networks (the Italian Experience). *Journal of Banking and Finance*, 18, 505–529.
- Argenti, J. 1976. *Corporate Collapse: The Causes and Symptoms*. New York: John Wiley & Sons.
- Aziz, M. A. & Dar, H. A. 2004. Predicting Corporate Bankruptcy: Whither do We Stand? Department of Economics, Loughborough University, UK. <[www.lboro.ac.uk/departments/ec/Researchpapers/2004/Departmental%20Paper%20\\_Aziz%20and%20Dar\\_.pdf](http://www.lboro.ac.uk/departments/ec/Researchpapers/2004/Departmental%20Paper%20_Aziz%20and%20Dar_.pdf)> 18.10.2005.
- Beaver, W. H. 1966. Financial Ratios as Predictors of Failure. *Journal of Accounting Research*, 4, 71–111.
- Casey, C. J., Jr. 1980. Variation in Accounting Information Load: The Effect on Loan Officers' Predictions of Bankruptcy. *The Accounting Review*, Vol. 55, No. 1, 36–49.
- Casey, M., McGee, V. & Stinkey, C. 1986. Discriminating Between Reorganized and Liquidated Firms in Bankruptcy. *The Accounting Review*, April, 249–262.
- Cielen, A., Peeters, L. & Vanhoof, K. 2004. Bankruptcy Prediction Using a Data Envelopment Analysis. *European Journal of Operational Research*, 154, 526–532.
- Dimitras, A. I., Slowinski, R., Susmaga, R. & Zopounidis, C. 1999. Business Failure Prediction Using Rough Sets. *European Journal of Operational Research*, 114, 263–280.
- Dimitras, A. I., Zanakis, S. H. & Zopounidis C. 1996. A Survey of Business Failures with an Emphasis on Prediction Methods and Industrial Applications. *European Journal of Operational Research*, 90, 487–513.
- Frydman, H., Altman, E. I. & Kao, D.-I. 1985. Introducing Recursive Partitioning for Financial Classification: The Case of Financial Distress. *The Journal of Finance*, Vol. 40, No. 1, 269–291.
- Gilbert, L. R., Menon, K. & Schwartz, K. B. 1990. Predicting Bankruptcy for Firms in Financial Distress. *Journal of Business Finance & Accounting*, 17, 161–171.
- Grice, J. S. & Dugan, M. T. 2001. The Limitations of Bankruptcy Prediction Models: Some Cautions for the Researcher. *Review of Quantitative Finance and Accounting*, 17, 151–166.
- Grice, J. S. & Ingram, R. W. 2001. Tests of the Generalizability of Altman's Bankruptcy Prediction Model. *Journal of Business Research*, Vol. 54, Issue 1, 53–61.

- Henebry, K. L. 1996. Do Cash Flow Variables Improve the Predictive Accuracy of a Cox Proportional Hazards Model for Bank Failure? *Quarterly Review of Economics and Finance*, 36:3.
- Henebry, K. L. 1997. A Test of the Temporal Stability of Proportional Hazards Models for Predicting Bank Failure. *Journal Of Financial And Strategic Decisions*, Vol. 10, No. 3, 1–11.
- Järvelin, A. 2003. *Neurolaskentamenetelmien soveltamisesta puheen tuoton häiriöiden mallintamiseen*. Tampereen yliopisto. Tietojenkäsittelytieteiden laitos. Pro gradu -tutkielma.
- Keasey, K. & Watson, R. 1991. Financial Distress Prediction Models: A Review of Their Usefulness. *British Journal of Management*, Vol. 2, 89–102.
- Kohonen, T. 1995. *Self-Organizing Maps*. Berliini: Springer.
- Lahti, S. 2000. *Konkurssin ennustaminen ja monitoimialaisuuden vaikutus ennustamistarkkuuteen*. Tampereen yliopisto. Yrityksen taloustieteen ja yksityisoikeuden laitos. Pro gradu -tutkielma.
- Laitinen, E. K. 1990. *Konkurssin ennustaminen*. Alajärvi: Vaasan Yritysinformaatio Oy.
- Laitinen, E. K. 1994. Markov Process in Business Failure Prediction. *The Finnish Journal of Business Economics*, 1, 3–19.
- Laitinen, E. K. & Laitinen T. 2004. *Yrityksen rahoituskriisin ennustaminen*. Helsinki: Talentum Media Oy.
- Laitinen, T. & Kankaanpää, M. 1999. Comparative Analysis of Failure Prediction Methods: The Finnish Case. *The European Accounting Review*, 8:1, 67–92.
- Lane, W., Looney, S. & Wansley, J. 1986. An Application of the Cox Proportional Hazards Model to Bank Failure. *Journal of Banking and Finance*, 10, 511–531.
- Leppiniemi, J. & Leppiniemi R. 1997. *Tilinpäätöksen tulkinta*. Porvoo: WSOY.
- Libby, R. 1975. Accounting Ratios and the Prediction of Failure: Some Behavioral Evidence. *Journal of Accounting Research*, Vol. 13, No. 1, 150–161.
- Luoma, M. & Laitinen, E. K. 1991. Survival Analysis as a Tool for Company Failure Prediction, *Omega*, 19 (6), 673–678.
- McDonald, B. & Morris, M. H. 1984. The Statistical Validity of the Ratio Method in Financial Analysis: An Empirical Examination. *Journal of Business, Finance and Accounting*, 33 (Spring), 89–97.
- McKee, T. E. & Greenstein, M. 2000. Predicting Bankruptcy Using Recursive Partitioning and a Realistically Proportioned Data Set. *Journal of Forecasting*, 19, 219–230.

- Min, J. H. & Lee, Y.-C. 2005. Bankruptcy Prediction Using Support Vector Machine with Optimal Choice of Kernel Function Parameters. *Expert Systems with Applications*, 28, 603–614.
- Moriarty, S. 1979. Communicating Financial Information through Multidimensional Graphics. *Journal of Accounting Research*, Vol. 17, No. 1, 205–224.
- Mossman, C. E., Bell, G. G., Swartz, L., M. & Turtle, H. 1998. An Empirical Comparison of Bankruptcy Models. *The Financial Review*, 33, 35–54.
- Neilimo, K. & Näsi, J. 1980. *Nomoteettinen tutkimusote ja suomalainen yrityksen taloustiede*. Yrityksen taloustieteen ja yksityisoikeuden laitoksen julkaisuja. Sarja A2: Tutkielmia ja raportteja 12. Tampereen yliopisto.
- Niskanen, J. & Niskanen, M. 2000. *Yritysrahoitus*. Helsinki: Oy Edita Ab.
- Ohlson, J. A. 1980. Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, Vol. 18, No. 1, 109–131.
- Pendharkar, P. C. 2005. A Threshold-varying Artificial Neural Network Approach for Classification and its Application to Bankruptcy Prediction Problem. *Computers & Operations Research*, 32, 2561–2582.
- Penttilä, A.-J. 2004. *Konkurssin ennustaminen moniulotteisen grafiikan avulla*. Tampereen yliopisto. Kauppätieteiden laitos. Pro gradu -tutkielma.
- Platt, H. D. & Platt, M. B. 1990. Development of a Class of Stable Predictive Variables: the Case of Bankruptcy Prediction. *Journal of Business, Finance & Accounting*, 17 (1), 31–51.
- Platt, H. D. & Platt, M. B. 2002. Predicting Corporate Financial Distress: Reflections on Choice-Based Sample Bias. *Journal of Economics and Finance*, Vol. 26, No. 2, 184–199.
- Pompe, P. P. M. & Bilderbeek, J. 2005. The Prediction of Bankruptcy of Small- and Medium-Sized Industrial Firms. *Journal of Business Venturing*, 20, 847–868.
- Prihti, A. 1975. *Konkurssin ennustaminen taseinformaation avulla*. Toinen painos. Helsinki: Painomies Oy.
- Shumway, T. 2001. Forecasting Bankruptcy More Accurately: A Simple Hazard Model. *The Journal of Business*, Vol. 74, No. 1, 101–124.
- Skogsvik, K. 1990. Current Cost Accounting Ratios as Predictors of Business Failure: The Swedish Case. *Journal of Business Finance & Accounting*, 17 (1), 137–160.
- Suuriniemi, T. 1993. *Konkurssin ennustaminen tilinpäätösanalyysillä*. Tampereen yliopisto. Yrityksen taloustieteen ja yksityisoikeuden laitos. Pro gradu -tutkielma.
- Tam, K. Y. & Kiang, M. Y. 1992. Managerial Applications of Neural Networks: The Case of Bank Failure Predictions. *Management Science*, Vol. 38, No. 7, 926–947.

- Theodossiou, P. T. 1991. Alternative Models for Assessing the Financial Condition of Business in Greece. *Journal of Business Finance and Accounting*, 18 (5), September, 697–720.
- Wilson, R. L. & Sharda, R. 1994. Bankruptcy Prediction Using Neural Networks. *Decision Support Systems*, 11, 545–557.
- Yang, Z. R., Platt, M. B. & Platt, H. D. 1999. Probabilistic Neural Networks in Bankruptcy Prediction. *Journal of Business Research*, 44, 67–74.
- Yritystutkimusneuvottelukunta 1999. *Yritystutkimuksen tilinpäätösanalyysi*. Helsinki: Gaudeamus.
- Zavgren, C. V. 1985. Assessing the Vulnerability to Failure of American Industrial Firms: A Logistic Analysis. *Journal of Business Finance & Accounting*, 12 (1), 19–45.
- Zmijewski, M. E. 1984. Methodological Issues Related to the Estimation of Financial Distress Prediction Models. *Journal of Accounting Research*, Vol. 22, 59–82.
- Zopounidis, C. & Doumpos, M. 1999. Business Failure Prediction Using the UTADIS MultiCriteria Analysis Method. *The Journal of the Operational Research Society*, Vol. 50, No. 11, 1138–1148.

## Liite 1.

Eri virhetyyppien suhteelliset osuudet Beaverin testitoksessa tunnusluvun rahoitustulos/vieras pääoma avulla (Beaver 1966, 90; Laitinen 1990, 43)

Vuosia ennen konkurssia	Virhetyyppi I (%)	Virhetyyppi II (%)	Kokonaisluokitteluvirhe (%)
1	22	5	13
2	34	8	21
3	37	8	23
4	47	3	24
5	43	5	22

Virhetyyppi I = konkurssiyritys luokitellaan toimivaksi

Virhetyyppi II = toimiva yritys luokitellaan konkurssiyritykseksi



## Liite 2.

Eri virhetyyppien suhteelliset osuudet Altmanin estimointi- ja testiaineistossa (Altman 1968, 599–600, 604; Laitinen 1990, 52)

Vuosia ennen konkurssia	Virhetyyppi I (%)	Virhetyyppi II (%)	Kokonaisluokitteluvirhe (%)
1	6 (4)	3 (21)	5 (17)
2	28	6	17
3	~	~	52
4	~	~	71
5	~	~	64

Virhetyyppi I = konkurssiyritys luokitellaan toimivaksi

Virhetyyppi II = toimiva yritys luokitellaan konkurssiyritykseksi

( ) = luokitteluvirhe testiaineistossa

### Liite 3.

Eri virhetyyppien suhteelliset osuudet Prihtin estimointi- ja testiaineistossa (Prihti 1975, 104, 110; Laitinen 1990, 64)

Vuosia ennen konkurssia	Virhetyyppi I (%)	Virhetyyppi II (%)	Kokonaisluokitteluvirhe (%)
1	19 (0)	20 (36)	20 (22)
2	32 (6)	20 (36)	24 (24)
3	42 (45)	20 (36)	28 (39)
4	48 (60)	20 (36)	30 (42)

Virhetyyppi I = konkurssiyritys luokitellaan toimivaksi

Virhetyyppi II = toimiva yritys luokitellaan konkurssiyritykseksi

( ) = luokitteluvirhe testiaineistossa