

Jesse Maijanen

KONEOPPIMINEN OSANA YRITYKSEN KONKURSSIN TODENNÄKÖISYYDEN ENNUSTAMISTA

Kandidaatintyö
Johtamisen ja talouden tiedekunta
Tarkastaja: Jarmo Uusikartano
Joulukuu 2025

TIIVISTELMÄ

Jesse Maijanen: Koneoppiminen osana yrityksen konkurssin todennäköisyyden ennustamista
(Predicting corporate bankruptcy probability using machine learning)

Kandidaatintyö

Tampereen yliopisto

Tuotantotalouden tutkinto-ohjelma

Joulukuu 2025

Yritysten konkurssien ennustaminen on taloudellisesti merkittävä ongelma, sillä konkurseilla on laajoja vaikutuksia niin luotonantajille, sidosryhmille kuin koko yhteiskunnalle. Virheelliset ennusteet, ja erityisesti konkurssiyrityksen luokittelu terveeksi, aiheuttavat huomattavia kustannuksia. Datamäärien kasvu ja laskentatehon kehittyminen ovat siirtäneet ennustusmenetelmien painopisteen yhä enemmän tekoäly- ja koneoppimispohjaisiin ratkaisuihin, jotka kykenevät mallintamaan talousdatan monimutkaisia epälineaarisia riippuvuuksia perinteisiä malleja tehokkaammin.

Tämän kandidaatintyön tavoitteena on selvittää, millaisia koneoppimisen sovelluksia alan tuoreessa kirjallisuudessa on tunnistettu yritysten konkurssin ja taloudellisen ahdingon ennustamiseen, sekä vertailla näiden menetelmien suorituskykyä. Työ toteutettiin systemaattisena kirjallisuuskatsauksena, jossa tarkasteltiin vuosina 2020–2025 julkaistuja vertaisarvioituja tutkimusartikkeleita ScienceDirect- ja Scopus-tietokannoista. Työ tarjoaa yleiskatsauksen kirjallisuudessa esiintyviin keskeisiin koneoppimismenetelmiin, niiden teoreettiseen taustaan sekä suorituskykyyn yrityksen konkurssin ennustamisen kontekstissa.

Katsauksessa havaittiin, että nykytutkimus keskittyy erityisesti kahteen pääsuuntaukseen: ensemble-menetelmiin sekä neuroverkko-pohjaisiin ratkaisuihin. Tulokset osoittivat, että ensemble-menetelmät, kuten boosting-algoritmit ja satunnaismetsät, saavuttivat aineistossa johdonmukaisesti korkeimman suorituskyvyn. Erityisen merkittävää oli näiden menetelmien kyky tunnistaa nimenomaan konkurssiin ajautuvat yritykset, mikä on riskienhallinnan kannalta kriittistä. Myös neuroverkko-pohjaiset menetelmät, mukaan lukien syväoppiminen, ylsivät korkeaan tarkkuuteen, mutta suoriutuivat ensemble-menetelmiä heikommin pidemmän aikavälin ennustamisessa. Perinteiset menetelmät, kuten logistinen regressio, toimivat nykytutkimuksissa pääasiassa vertailukohtina kehittyneemmille malleille.

Työn tulokset osoittavat, että erityisesti ensemble-menetelmiä soveltamalla voidaan saavuttaa merkittäviä hyötyjä konkurssin ja taloudellisen ahdingon ennustamisessa. Menetelmien laajempaan käyttöön liittyy kuitenkin vielä haasteita, jotka koskevat erityisesti mallien läpinäkyvyyttä ja tulosten tulkittavuutta päätöksenteon tukena.

Avainsanat: Koneoppiminen, tekoäly, konkurssin ennustaminen, taloudellinen ahdinko

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin Originality Check -ohjelmalla.

TEKOÄLYN KÄYTTÖ OPINNÄYTTEESSÄ

Opinnäytteessäni on käytetty tekoälysovelluksia:

- Ei
- Kyllä

Ilmoitukseni mukaan olen käyttänyt opinnäytteessäni tutkielmaprosessin aikana seuraavia tekoälysovelluksia:

Gemini, ChatGPT

Tekoälysovellusten nimet ja versiot: [Listaa tähän kaikki tekoälysovellukset ja niiden versiot, joita olet käyttänyt tutkielmaprosessin aikana.]

ChatGPT 5.1
Gemini 3 Pro

Käyttötarkoitus: [Kuvaa tähän yksityiskohtaisesti, mihin tarkoitukseen ja miten tekoälyä on sovellettu opinnäytteeseen tutkielmaprosessin aikana.]

Tekoälyä on käytetty kielentarkastukseen, termien suomentamiseen ja asioiden jäsentelyyn.

Osiot, joissa tekoälyä on käytetty: [Luettele tähän kaikki opinnäytteen vaiheet ja osiot, joissa tekoälyä on tutkielmaprosessin aikana käytetty.]

Luvut 1, 2, 3, 4 ja 5

Olen tietoinen siitä, että olen täysin vastuussa koko opinnäytteeni sisällöstä, mukaan lukien osat, joissa on hyödynnetty tekoälyä, ja hyväksyn vastuun mahdollisista eettisten ohjeiden rikkomuksista.

ALKUSANAT

Olin alkusyksystä koneoppimisen kurssilla, josta innostuneena halusin tutkia jotain sen sovelluskohdetta. Alun perin ideat liittyivät laajasti yrityksen talouden hallintaan, mutta prosessin edetessä löysin teoksia konkurssin ennustamisesta, joka herätti jostain nyt jo unohtuneesta syystä mielenkiintoni.

Erityisesti viimeisen kuukauden aikana olen ehtinyt moneen kertaan sekä innostua valitsemastani suunnasta että kyseenalaistaa sen. Muistelen niitä lukemattomia kertoja, kun olen löytänyt itseni lukemasta tekstiä, jota en ymmärrä alkuunkaan. Lopulta työ kuitenkin alkoi sujua, ja melko paljon matkalta tarttui myös oivalluksia ja oppeja aiheen tiimoilta. Nyt kun katselen taaksepäin, opin koneoppimismenetelmistä sen mitä en vielä itse kurssilla ymmärtänyt, mutta opin myös valtavasti koneoppimisen sovelluskohteista rahoituksen alalla.

Kiitän erityisesti työni ohjaajaa Jarmo Uusikartanoa neuvoista sekä avoimuudesta työn vaihtelevaa kurssia kohtaan. Kiitos myös seminaariryhmille ja Tuomas Korhoselle vinkeistä ja käydyistä keskusteluista seminaareissa. Ja ennen kaikkea kiitos kaikille, jotka ovat kandia nyt syksyllä kirjoittaneet ja toimineet vertaistukena.

Tampereella, 21.12.2025

Jesse Maijanen

SISÄLLYSLUETTELO

1.	JOHDANTO.....	1
1.1	Tavoite ja tutkimuskysymykset.....	2
1.2	Tutkimusmenetelmät.....	2
1.3	Työn rakenne	5
2.	KONEOPPIMINEN JA TEKOÄLY	6
2.1	Koneoppiminen käsitteenä	6
2.2	Koneoppimisen menetelmiä	7
2.2.1	Yksittäiset luokittelijat	7
2.2.2	Neuroverkot ja syväoppiminen	8
2.2.3	Ensemble-menetelmät	10
2.3	Koneoppiminen ennustamisessa	11
3.	YRITYKSEN KONKURSSI	12
3.1	Yrityksen konkurssi	12
3.2	Konkurssin todennäköisyyden ennustusmenetelmät	14
4.	KONEOPPIMINEN KONKURSSIN ENNUSTAMISESSA	16
4.1	Käytetyt koneoppimismenetelmät.....	16
4.2	Ennustustarkkuuden mittarit	20
4.3	Lyhyen aikavälin ennustaminen.....	22
4.4	Pidemmän aikavälin ennustaminen.....	24
5.	PÄÄTELMÄT.....	27
5.1	Työn keskeiset tulokset.....	27
5.2	Tulosten arviointi ja jatkotutkimusaiheet.....	29
	LÄHTEET	31

1. JOHDANTO

Konkurssien ennustaminen on kiinnostanut taloustieteilijöitä jo pitkään (Shumway 2001). Yrityksen konkurssi vaikuttaa laajasti eri sidosryhmiin, minkä vuoksi sen tarkasta ennustamisesta on tullut monille tahoille todellinen huolenaihe (Dasilas & Rigani 2024). Konkurssi ja taloudellinen ahdinko aiheuttavat lisäkustannuksia niin yritykselle itselleen kuin sen sidosryhmille (Altman & Hotchkiss 2019). Kirkos (2015) nimeää konkurssien ennustamisen yhdeksi liiketoiminnan tärkeimmistä päätöksenteko-ongelmista, sillä vakavimmissa tapauksissa konkurssi voi vaikuttaa kokonaisuudessaan taloudelliseen järjestelmään ja yhteiskuntaan. Mahdollisuus havaita ongelmia etukäteen antaa sidosryhmille tilaisuuden vähentää riskejä ja jopa estää konkurssia tapahtumasta (Dasilas & Rigani 2024).

Konkurssien ennustamisen menetelmät ovat kehittyneen huomattavasti viimeisten vuosikymmenten aikana. Alan varhaiset merkkiteokset, kuten Altmanin (1968) Z-luku ja Ohlsonin (1980) logistinen regressiomalli, loivat pohjan tilastolliselle ennustamiselle, mutta ne perustuivat usein oletuksiin datan lineaarisuudesta ja jakaumista. Laskentatehon ja datamäärien kasvaessa 1990-luvulla alettiin hyödyntää tekoälypohjaisia menetelmiä, kuten Odom ja Sharda (1990) osoittivat soveltaessaan neuroverkkoja konkurssien ennustamiseen. Nykyisin ala on siirtynyt kohti yhä kehittyneempiä koneoppimissovelluksia, kuten ensemble-menetelmiä ja syväoppimista, jotka kykenevät mallintamaan talousdatan epälineaarisia riippuvuussuhteita perinteisillä malleilla paremmin (Batz et al. 2025; Papík & Papíková 2025). Barboza et al. (2017) vertailivat perinteisiä menetelmiä kehittyneisiin ensemble-menetelmiin konkurssin ennustamisessa ja jopa alan pioneeri Altman totesi, että koneoppimismenetelmillä saavutettiin selvästi parempia tuloksia.

Erityisesti kyky havaita konkurssiin ajautuvat yritykset on kustannusten kannalta ratkaisevaa, sillä konkurssiyrityksen ennustaminen terveeksi on arvioitu 36 kertaa kalliimmaksi virheeksi kuin turha varoitus (Alam et al. 2021). Toisaalta yritykselle on tärkeää, ettei sitä luokitella turhaan riskiluokkaan.

Koneoppimisella (machine learning) viitataan tässä yhteydessä tietokonejärjestelmien kykyyn oppia historiallisesta datasta ja tunnistaa siinä esiintyviä säännönmukaisuuksia (Jordan & Mitchell, 2015). Käytännössä tämä tarkoittaa algoritmien kehittämistä, jotka

kykenevät tekemään tarkkoja luokitteluja ja ennusteita monimutkaisen ja moniulotteisen datan perusteella (Alpaydin 2020).

Koneoppimisen käyttöä konkurssin ennustamisessa on tutkittu jo paljon ja alueelta on tuotettu myös kirjallisuuskatsauksia. Useissa katsausartikkeleissa selvitetään mitä menetelmiä alalla on hyödynnetty, millaista dataa on käytetty ja miten dataan liittyviä ongelmia on ratkottu (mm. Shi & Li 2019; Le 2022; Dasilas & Rigani 2024). Alalta puuttuu kuitenkin nykyaikaista tutkimusrajojen ylittävää analyysiä erityisesti käytettyjen menetelmien suorituskyvystä, ja siitä löytyykö jotain tiettyä menetelmäryhmää, joka vaikuttaa vakiintuneen viimeaikaisessa tutkimuksessa käyttöön korkealla suorituskyvyllään. Tämä kirjallisuuskatsaus tarjoaa katsauksen yrityksen konkurssin ennustamiseen koneoppimismenetelmin ja vertailee alan tuoreessa kirjallisuudessa sovellettujen menetelmien suorituskykyä. Työ pyrkii tarjoamaan perusteltua suuntaa tahoille, jotka harkitsevat koneoppimisen implementointia osaksi taloudellisten riskien hallintaa.

1.1 Tavoite ja tutkimuskysymykset

Tämän kandidaatintyön tavoitteena on selvittää, millaisia koneoppimisen sovelluksia on tunnistettu alan kirjallisuudessa yritysten konkurssin ja taloudellisen ahdingon ennustamiseen. Tämän lisäksi tarkastellaan, miten eri menetelmien suorituskykyä on mitattu, ja erityisesti, miten eri menetelmät vertautuvat toisiinsa suorituskyvyltään artikkeleissa käytettyjen mittareiden mukaan.

Työssä vastataan tavoitteen mukaisesti seuraaviin tutkimuskysymyksiin:

- Millaisia koneoppimisen sovellutuksia alan kirjallisuudessa on tunnistettu yrityksen konkurssin ja taloudellisen ahdingon ennustamiseen?
- Miten eri konkurssin ja taloudellisen ahdingon ennustamismenetelmät vertautuvat toisiinsa suorituskyvyltään eri mittareilla ja ennustushorisonteilla?

1.2 Tutkimusmenetelmät

Työ toteutettiin systemaattisena kirjallisuuskatsauksena. Käytetyt hakusanat jakautuivat koneoppimisen alan teknisiin termeihin sekä yritystalouden terminologiaan. Hakuja tehtiin käyttäen samoja rajoituksia ScienceDirect- ja Scopus-tietokannoissa. Alan avainsanoista muodostettiin hakulauseke: (("bankruptcy" OR "financial distress") AND ("machine learning") AND ("business" OR "firm" OR "company") AND ("financial variable" OR "financial data" OR "financial ratio")), jolla pyrittiin löytämään artikkeleita, jotka käsittelivät sekä konkurssin että taloudellisen ahdingon ennustamista ja käyttivät

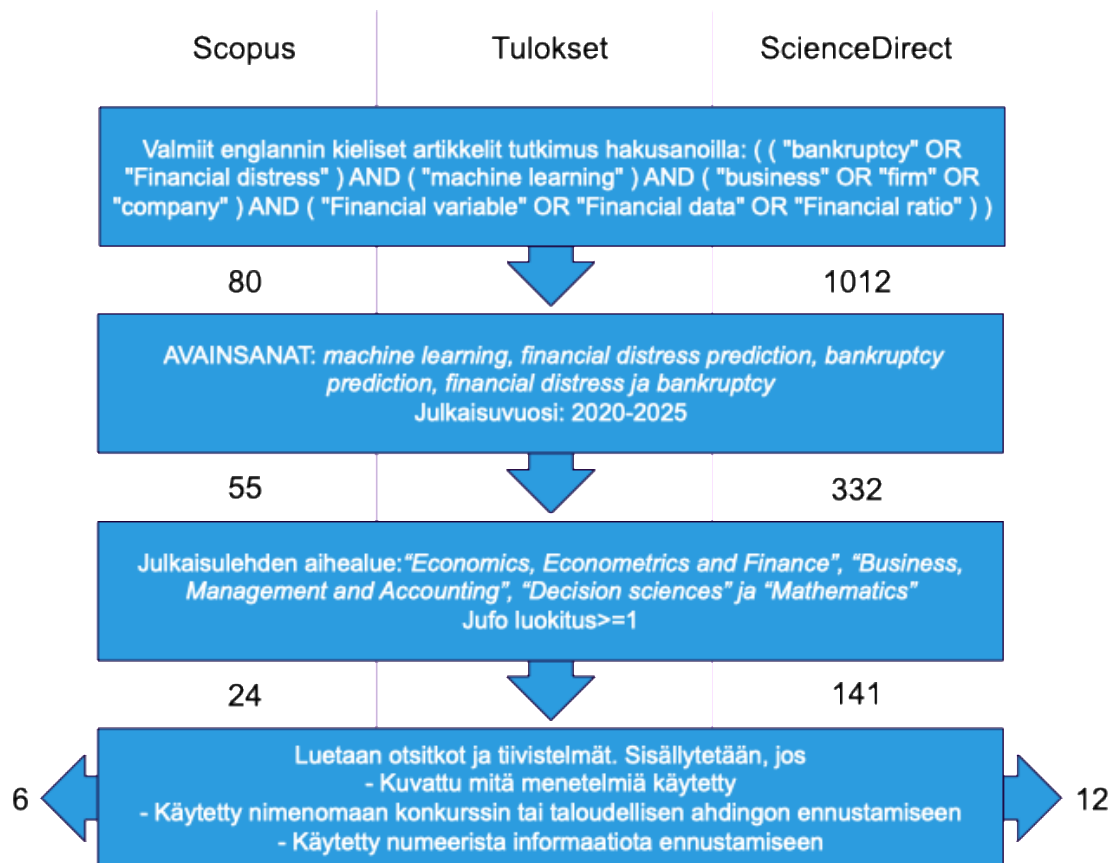
ennustukseen yrityksen taloustietoja ja tunnuslukuja. Artikkelit rajattiin englanninkielisiin tutkimusartikkeleihin. Tällä hakulausekkeella ja alustavilla rajauksilla saatiin ScienceDirect-tietokannasta 1011 tulosta ja Scopus-tietokannasta 80 tulosta.

Seuraavaksi artikkeleita rajattiin avainsanoilla *machine learning*, *financial distress prediction*, *bankruptcy prediction*, *financial distress* ja *bankruptcy*. Artikkelit rajattiin julkaisuvuodeltaan 2020–2025 julkaistuihin, jotta alasta muodostetaan nykytilaa kuvaava käsitys. Tämän jälkeen jäljelle jäi 332 ja 55 artikkelia.

Lopuksi artikkelit rajattiin julkaisulehtien aihealueisiin *economics*, *econometrics and finance*, *business, management and accounting*, *decision sciences* ja *mathematics*, minkä lisäksi rajattiin vielä lehtiin, joiden JUF0-luokitus on suurempaa kuin 0. Tämän jälkeen aineisto oli rajattu 141:n ja 24:n artikkeliin. Viimeisenä artikkeleiden otsikot ja tiivistelmät luettiin läpi ja huomiota kiinnitettiin erityisesti alla listattuihin asioihin.

Artikkeli sisällytettiin katsaukseen, jos siinä: 1) kuvataan käytetyt menetelmät, 2) sovelletaan menetelmää nimenomaan konkurssin tai taloudellisen ahdingon ennustamiseen ja 3) hyödynnetään vähintään osittain numeerista informaatiota.

Kuvassa 1 on kuvattu kokonaisuudessaan aineiston rajauksen prosessi. Lopulta aineistoon jäi 20 koneoppimisen hyödyntämistä konkurssin tai taloudellisen ahdingon ennustamisessa tutkivaa artikkelia, jotka esitellään myöhemmin tulososiossa. Artikkelien käsittelyvaiheessa huomattiin, että kaksi artikkelia eivät olleet enää saatavilla, minkä takia lopullinen aineisto kutistui 18 artikkeliin.



Kuva 1: Systemaattisen kirjallisuuskatsauksen rajausprosessi.

Artikkelit luettiin, jonka pohjalta taulukoitiin jokaisesta artikkelista käytetty pääasiallinen koneoppimismenetelmä, jos sellainen on, muut käytetyt menetelmät, datan jakauma ja maantieteellinen alue, ennustusintervalli, suorituskykyä kuvaavat mittarit, artikkelin mahdollinen tulokulma tai sovelluskohde ja lyhyt kuvaus artikkelista. Esimerkiksi Papíková ja Papík (2024) tutkivat artikkelissaan yrityksen henkistä pääomaa kuvaavien ominaisuuksien yhdistämistä tunnuslukuihin ennustettaessa PK-yritysten konkurssia 1-5 vuoden päähän käyttäen erityisesti XGBoost- ja CatBoost-menetelmiä, joiden suorituskykyä verrataan muun muassa AUC-luvulla.

Tämän lisäksi 2. tutkimuskysymystä varten jokaisen artikkelin jokaisesta käytetystä menetelmästä kerättiin artikkelissa käytetyillä metriikoilla tiedot menetelmien suorituskyvyistä. Liitteestä A voidaan havaita eri artikkeleissa käytetyt mittarit. Myöhemmin esiteltyjen perustelujen mukaisesti valikoituneilla metriikoilla on kerätty tiedot eri menetelmien suorituskyvyistä 1 ja 1–5 vuoden ennustushorisonteilla. Kyseiset tiedot löytyvät liitteistä B ja C. Esimerkiksi Deng et al. (2025) saavuttavat kiinalaisessa tasapainoisessa (515/ 515) datassa XGBoost-menetelmällä 85,8 % tarkkuuden ennustettaessa yhden vuoden päähän.

1.3 Työn rakenne

Työn teoriaosassa, eli luvuissa 2 ja 3, avataan työn kannalta oleellista käsitteistöä. Luvussa 2 käsitellään koneoppimisen käsitteistöä, perinteisiä menetelmiä sekä yleisesti koneoppimisen käyttöä ennustamisessa. Samassa luvussa tarkastellaan myös työn kannalta keskeisiä kehittyneempiä koneoppimisen menetelmiä siinä määrin kuin se on työn ymmärtämisen kannalta tarpeellista. Luvussa 3 avataan konkurssin käsitettä, sen lakiteknistä näkökulmaa sekä perinteisiä menetelmiä, joita on käytetty konkurssin ennustamiseen.

Työn varsinaisessa tulososiossa keskitytään koneoppimisen käyttöön yrityksen konkurssin ennustamisen välineenä. Tulososiossa pyritään tutkimuksen tavoitteiden ja tutkimuskysymysten mukaisesti selvittämään, millaisia koneoppimismenetelmiä alan kirjallisuudessa on tunnistettu konkurssien ennustamiseen ja miten löydetyt menetelmät vertautuvat suorituskyvyltään toisiinsa.

Viimeisessä, päätelmiä käsittelevässä osiossa, tunnistetaan työn keskeiset löydökset suhteessa työn tavoitteisiin ja tutkimuskysymyksiin sekä pohditaan mahdollisia jatkotutkimusaiheita.

2. KONEOPPIMINEN JA TEKOÄLY

Tässä osiossa avataan tämän työn kannalta keskeistä koneoppimisen käsitteistöä siinä määrin kuin se on työn ja alan kirjallisuuden ymmärtämisen kannalta olennaista. Aluksi tarkastellaan koneoppimisen taustaa, minkä jälkeen esitellään tulososiossa esiintyviä menetelmiä. Lopuksi käsitellään yleisellä tasolla, miten koneoppimista on hyödynnetty ja hyödynnetään nykyään erityisesti ennustamiseen.

2.1 Koneoppiminen käsitteenä

Koneoppiminen on edistynyt merkittävästi viimeisten parin vuosikymmenen aikana. Siinä missä aiemmin sitä tutkittiin lähinnä uteliaisuudesta, nykyään se on käytännöllinen teknologia, jolla on merkittäviä kaupallisia sovelluksia niin tuotannon kuin rahoituksen alalla (Jordan & Mitchell 2015). Kämäräisen (2023) mukaan vasta 2010-luvulla käyttöön tulleet uudet menetelmät ja tarvittava laskentateho mahdollistivat kehityksen, joka näkyy 2020-luvun tekoälysovelluksissa.

Koneoppiminen on keskeisesti osa tekoälyä ja sillä tarkoitetaan pohjimmiltaan tietokoneissa ja järjestelmissä tapahtuvaa automaattista oppimista (Jordan & Mitchell 2015). Jordanin ja Mitchellin (2015) mukaan monet tekoälyjärjestelmien kehittäjät ovat ymmärtäneet, että useissa sovelluksissa on tehokkaampaa kouluttaa järjestelmää näyttämällä sille esimerkkejä halutuista tuloksista sen sijaan, että yritettäisiin manuaalisesti ohjelmoida säännöt kaikille mahdollisille syönteille. Koneoppiminen mahdollistaa algoritmien kehittämisen, jotka kykenevät tunnistamaan kaavoja ja tekemään ennustuksia datan perusteella (Alpaydın, 2020, s.21-24). Koneoppimismenetelmillä voidaan arvioida samaan luokkaan kuuluvien havaintojen toistuvia kaavoja ja etsiä niitä piirteitä, jotka erottelevat eri ryhmiin kuuluvat havainnot mahdollisimman hyvin (Barboza et al. 2017).

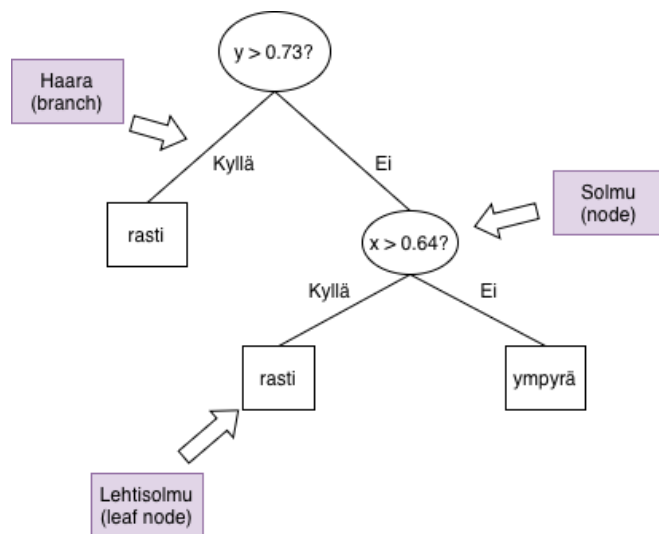
Koneoppiminen menetelmänä soveltuukin erityisen hyvin tehtäviin, joihin liittyy moniulotteista dataa, kuten luokitteluun (Janiesch et al. 2021). Tällöin puhutaan usein ohjatusta oppimisesta (supervised learning), jossa mallille syötetään opetusvaiheessa sekä syöttödata että tunnetut oikeat vastaukset, joiden perusteella se pyrkii myöhemmin ennustamaan tavoitearvoja entuudestaan tuntemattomalle datalle (Zhou 2025, luku 1.1). Yrityksen konkurssin ennustaminen on myös luokitteluongelma, jossa taloudellisesti terve yritys tulee erottaa vaikeuksissa olevasta.

2.2 Koneoppimisen menetelmiä

Tässä luvussa esitellään työn ymmärtämisen kannalta tärkeimmät koneoppimismenetelmät kahdessa alaluvussa, jotta muodostetaan peruskäsitys menetelmistä ja niiden logiikasta. Menetelmät on käsittelyn selkeyttämiseksi jaettu yksittäisiin luokittelijoihin, neuroverkkoihin ja ensemble-menetelmiin.

2.2.1 Yksittäiset luokittelijat

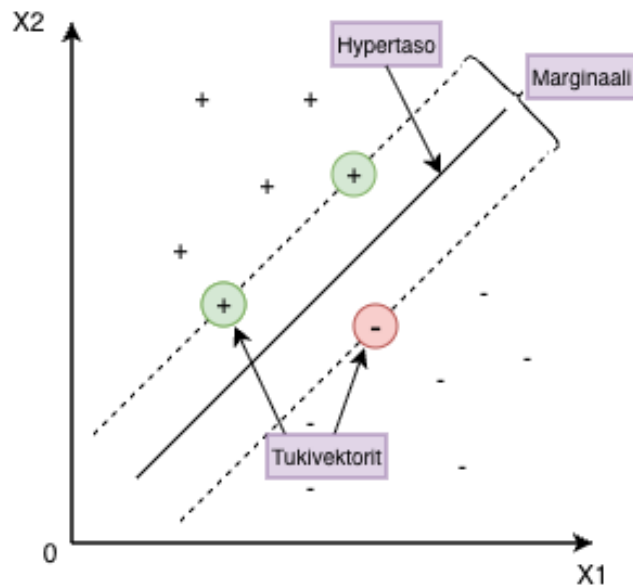
Päätöspuu on nimensä mukaisesti puumainen rakenne, joka koostuu erilaisista päätöksistä hyödyntäen *divide-and-conquer*-strategiaa (Alpaydin 2020, s.164-180; Zhou 2025, luku 1.2). Kuvassa 2 on kuvattu esimerkkiä yksinkertaisesta päätöspuusta. Päätöspuun kaksi tärkeää elementtiä ovat solmu (node) ja haara (branch). Solmut vastaavat testattavia attribuutteja ja solmusta lähtevät haarat taas vastaavat attribuutin mahdollisia arvoja. (Kämäräinen 2023, s.130–151) Syötteen mukaan jokaisessa solmussa tehdään testi ja jokin haaroista valitaan tuloksen perusteella. Tätä prosessia toistetaan, kunnes päästään lehtisolmuun (leaf node). (Alpaydin 2020, s.164–180; Zhou 2025, luku 1.2)



Kuva 2: Yksinkertainen päätöspuu, mukailen Zhou (2025).

Tukivektorikone (support vector machine, SVM) on alun perin binäärisiin luokitteluongelmiin kehitetty menetelmä, joka pyrkii erottelemaan luokat mahdollisimman hyvin toisistaan (Zhou 2025, luku 1.2). Menetelmän ydinajatuksena on löytää ns. maksimaalisen marginaalin hypertaso (maximal margin hyperplane), joka erottelee esimerkiksi positiiviset tapaukset negatiivisista mahdollisimman tehokkaasti (Alpaydin 2020, s.280-287; Zhou 2025, luku 1.2). Tämä optimaalinen erottelupinta määräytyy vain

lähimpänä rajaa sijaitsevien havaintojen perusteella, joita kutsutaan tukivektoreiksi (support vectors); kauempana sijaitsevat havainnot eivät vaikuta mallin muodostumiseen (Alpaydın 2020, s. 280–287). Kuvassa 3 on kuvattu lineaarista tukivektorikonetta, jossa yhtenäinen viiva kuvaa luokittelevaa hypertasoa, katkoviivat osoittavat marginaalin rajat, ja ympyröidyt havainnot ovat tukivektoreita, jotka määrittävät marginaalin leveyden ja tason sijainnin.

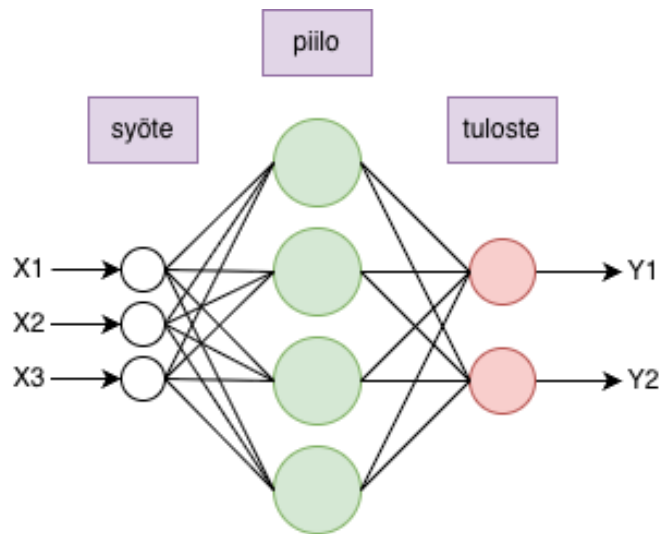


Kuva 3: Lineaarinen tukivektorikone (SVM), mukailen Hastie et al. (2009); Zhou (2025).

2.2.2 Neuroverkot ja syväoppiminen

Neuroverkot (neural networks, NN) ovat rinnakkaisesti toimivista, toisiinsa kytkeytyneistä mukautuvien solmujen eli neuronien verkostoja (Zhou 2025, luku 1.2). Neuronit ovat pienin päätöksiä tekevä elementti, josta voidaan käyttää myös nimeä päättelin (perceptron) (Alpaydın 2020, s.198-225; Kämäräinen 2023, s.116–127). Neuronit ovat liitettyinä toisiinsa painotettujen yhteyksien avulla. Erilaisia verkkorakenteita on useita, mutta yleisin niistä on monikerroksinen syöttöverkko (multi-layer feed-forward network), jossa neuronit ovat yhdistettyinä kerros kerrokselta, eikä rakenteessa ole kerroksen sisäisiä tai kerroksittain ristiin meneviä yhteyksiä (Zhou 2025, luku 1.2). Kuvassa 4 on esitetty kuvaus yksinkertaisesta neuroverkosta. Monikerroksinen neuroverkko koostuu syötekerroksesta, piilokerroksista ja tulostekerroksesta. Syötekerros vastaanottaa syötevektorin, jonka jokainen neuroni vastaa yhtä ominaisuutta. Piilokerrokset

suorittavat datan sisäisen käsittelyn, ja tulostekerros tuottaa lopullisen ennusteen, jossa jokainen neuroni edustaa tiettyä luokkaa tai arvoa. (Kämäräinen 2023, s.116–127; Zhou 2025, luku 1.2)



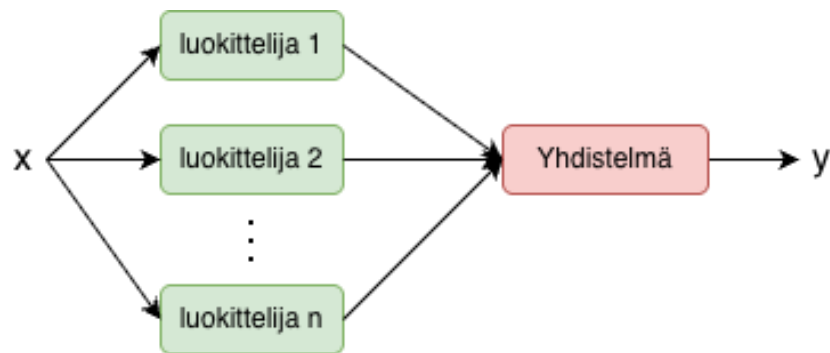
Kuva 4: Yksinkertainen neuroverkko, mukailten Kämäräinen (2023); Zhou (2025).

Syväoppiminen (deep learning) on koneoppimisen osa-alue, joka perustuu neuroverkkoihin. Menetelmä päihittää useissa käyttökohteissa kevyemmät koneoppimismenetelmät ja perinteiset data-analyysiin pohjautuvat menetelmät. (Janiesch et al. 2021) Syväoppiminen ei kuitenkaan varsinaisesti ole yksittäinen menetelmä, vaan siitä on suorastaan muodostunut oma lähestymistapansa koneoppimiseen (Kämäräinen 2023, s. 183–185). Yksinkertaistettuna Kämäräisen (2023, s. 183-185) mukaan syväoppiminen on käytännössä monikerrospäättelimen (multi-layer perceptron, MLP) eli siis neuroverkkojen perusarkkitehtuurin laajennus.

Myöhemmin vastaan tulee konvoluutioneuroverkko (convolutional neural network, CNN). Konvoluutioneuroverkko (CNN) eroaa perinteisistä neuroverkoista siinä, miten se havainnoi syötedataa. Sen sijaan, että jokainen neuroni olisi kytketty kaikkiin syötteen datapisteisiin kerralla, CNN tarkastelee dataa pienten, liukuvien 'ikkunoiden' (konvoluutiot) läpi. Nämä ikkunat skannaavat syötettä nähden siitä vain rajatun osan kerrallaan. (Kämäräinen 2023, s. 183–185) Verkon edetessä syvemmille tasoille nämä yksittäiset havainnot, jotka aluksi tunnistavat vain yksinkertaisia piirteitä, yhdistyvät, jolloin verkko hahmottaa yhä laajempia ja monimutkaisempia kokonaisuuksia (Alpaydin 2020, s.238–244).

2.2.3 Ensemble-menetelmät

Joukkio-oppimisen (ensemble learning) perusidea on kouluttaa joukkio luokittelijoita yhden sijaan (Kämäräinen 2023, s. 149–150). Viitataan joukkioihin jatkossa englanninkielisellä termillä ensemble. Kuvassa 5 on esitetty yksinkertaistettu kuvaus ensiblen arkkitehtuurista. Ensemble koostetaan luomalla mahdollisimman tarkkoja, mutta monipuolisia yksittäisiä luokittelijoita, jotka sitten yhdistetään eri tavoin (Zhou 2025, luku 1.4; Hastie et al. 2009, s. 605)



Kuva 5: Yksinkertainen kuvaus ensemblestä, mukailen Zhou (2025).

Boosting viittaa menetelmien joukkoon, jossa muutetaan heikoista luokittelijoista vahvoja luokittelijoita. Idea boostingin takana on kouluttaa joukko luokittelijoita peräkkäin jonossa, jossa seuraava luokittelija pyrkii oppimaan edellisten virheistä. (Zhou 2025, luku 2.1) Tunnetuimpiin boosting-menetelmiin kuuluu Freundin ja Schapiren (1997) kehittämä AdaBoost-algoritmi, jonka jälkeen myöhemmin Friedman (2001) esitti gradienttitehostusmenetelmän (gradient boosting machine, GBM), joka pääosin hyödyntää nimenomaan yksittäisiä päätöspuita. Useissa boosting-menetelmissä käytetään päätöspuita, johon viittaa myös termi *tree boosting* (Chen & Guestrin 2016). GBM:n perustuva nykyaikaisempi, myös konkurssin ennustuksessa usein esiintyvä, menetelmä on Chenin ja Guestrinin (2016) kehittämä extreme gradient boosting (XGBoost).

Boostingissa luokittelijat muodostetaan peräkkäin. Toisaalta mallit voidaan muodostaa myös rinnakkain, josta esimerkkinä toimii bagging. Yksinkertaistettuna bagging-menetelmässä koulutetaan rinnakkain useita samantyyppisiä luokittelijoita käyttäen alkuperäisestä datasta takaisinpanolla arvottuja satunnaisosajoukkoja. (Zhou 2025, luku 3.2) Tämän jälkeen koulutetut luokittelijat joko äänestävät vastauksesta tai luokittelijoiden ennusteet keskiarvoistetaan (Hastie et al. 2009, s. 182-185; Zhou 2025, luku 3.2). Tunnettu esimerkki bagging-menetelmän käytöstä on Breimanin (2001)

kehittämä satunnaismetsät (random forest), jossa satunnaisesti rakennetut päätöspuut äänestävät todennäköisintä luokkaa syötteen perusteella.

Boostingin ja baggingin lisäksi on myös kolmas suhteellisen vakiintunut tapa rakentaa ensemble malleja – stacking. Siinä missä boosting ja bagging usein hyödyntävät samantyyppisiä luokittelijoita, Wolpertin (1992) esittelemä stacking hyötyy mallien erilaisuudesta. Stacking-menetelmässä äänestämisen tai keskiarvoistamisen sijaan lopullisen ennusteen muodostaa uusi luokittelija, joka yrittää oppia perusluokittelijoiden syötteiden perusteella oikean vastauksen. (Alpaydin 2020, s.363–385)

2.3 Koneoppiminen ennustamisessa

Big datan kehityksen myötä tieteilijät ja insinöörit, jotka keräävät kyseistä dataa, ovat kääntyneet koneoppimisen puoleen tuottaakseen datasta oivalluksia ja ennustuksia. Merkittävimpiä koneoppimisen sovelluskohteita ovat nimenomaan ohjatun oppimisen (supervised learning) ongelmat, jotka liittyvät keskeisesti myös ennustamiseen (Jordan & Mitchell 2015). Ohjatun oppimisen ongelmissa on usein kyse juuri siitä, että annettujen tietojen perusteella ennustetaan jonkun asian todennäköisyyttä (Zhou et al. 2025). Koneoppiminen sopiikin monenlaiseen ennustamiseen. Voidaan ennustaa valuuttojen hintaa, erilaisten sairauksien todennäköisyyttä tai liikenneuhkaa (Hastie et al. 2009; Nazareth & Ramana Reddy, 2023). Koneoppimismenetelmien etu ennustamisessa on niiden kyky havaita epälineaarisia ja komplekseja suhteita, jotka voisivat muuten jäädä huomiotta (Barboza et al. 2017).

Koneoppimismenetelmiä hyödynnetään myös laajasti erilaisiin rahoitusalan ongelmiin (Nazareth & Ramana Reddy 2023). Katsausartikkelissaan Nazareth ja Ramana Reddy (2023) tutkivat kirjallisuudessa esiintyviä koneoppimissovellutuksia osakemarkkinoilla, portfolion hallinnassa, kryptovaluutoissa, valuuttamarkkinoilla, finanssikriiseissä ja konkurssin ennustamisessa. Koneoppimisen keinoin ennustetaan muun muassa osakkeen hintaa ja tuottoa, kryptovaluuttojen hintakehitystä ja volatiliteettia ja finanssikriisejä (Nazareth & Ramana Reddy 2023).

Rahoitusmarkkinoiden lisäksi yritykset hyödyntävät koneoppimista yhä enemmän oman liiketoimintansa operatiivisessa ennustamisessa. Koneoppimista voidaan esimerkiksi hyödyntää kysynnän ennustamisessa. (Carbonneau et al. 2008) Puolestaan erityisesti telekommunikaatioalan yritykset voivat hyödyntää koneoppimista asiakaspoistuman ennustamiseen (Vafeiadis et al. 2015).

3. YRITYKSEN KONKURSSI

Tässä osiossa käsitellään konkurssia käsitteenä. Ensimmäisessä alakohdassa tarkastellaan, miten käsite yleisesti määritellään kirjallisuudessa, mitä se tarkoittaa lakiteknisestä näkökulmasta, millaisia seurauksia sillä on ja miksi sen ennustaminen on tärkeää. Toisessa alakohdassa käsitellään klassisia konkurssin ennustamisen menetelmiä, joista siteeratuimpiin kuuluu Altmanin (1968) Z-score-malli, joka kehitettiin jo 1960-luvulla.

Myöhemmin tulososion aineistossa ennustetaan niin taloudellista ahdinkoa kuin konkurssia, joista molemmat myös määritellään aineiston artikkeleissa eri tavoilla. Tässä työssä ei kuitenkaan oteta varsinaisesti kantaa siihen, onko kyseessä taloudellinen ahdinko vai virallinen konkurssi. Se, miten näiden määritelmien ero vaikuttaa ennustamisen tarkkuuteen, on tutkimusaihe itsessään.

3.1 Yrityksen konkurssi

Suomen laki määrittelee, että konkurssiin voidaan asettaa velallinen, joka ei kykene vastaamaan veloistaan. Konkurssia haetaan joko velallisen tai velkojan toimesta, minkä perusteella tuomioistuin päättää velallisen asettamisesta konkurssiin. (Konkurssilaki 120/2004, 1 § 1) Konkurssilain (120/2004, 1 § 1) mukaan konkurssi on velallisen velkoja käsittelevä maksukyvyttömyysmenettely, jossa velallisen omaisuus siirtyy velkojien määräysvaltaan, minkä avulla velallisen omaisuus käytetään konkurssisaatavien maksuun. Kyseessä on siis nimenomaan lakitekninen menettely.

Konkurssi liittyy olennaisesti oikeushenkilön maksukyvyttömyyteen. Konkurssilain (120/2004, 2 § 1) mukaan konkurssiin voidaan asettaa velallinen, joka on maksukyvytön, mikä mainitussa laissa tarkoittaa velallisen kyvyttömyyttä muuten kuin tilapäisesti maksaa velkojaan niiden erääntyessä.

On hyvä tiedostaa, että konkurssimenettelyt eroavat toisistaan eri maiden välillä. Esimerkiksi Yhdysvalloissa suositaan yrityksen toiminnan jatkumista toimivana kokonaisuutena, kun taas Ruotsissa luotetaan markkinoiden mekanismeihin epäonnistuneen yrityksen varojen uudelleenallokoinnissa (Hotchkiss et al. 2008). Myös Suomessa velallisen omaisuus siirtyy velkojien määräysvaltaan (Konkurssilaki 120/2004, luku 1 § 1). Yhdysvalloissa konkurssimenettelyssä voidaan pyrkiä joko yrityksen uudelleenjärjestelyyn tai likvidointiin, mikäli uudelleenjärjestelylle ei ole edellytyksiä (Altman & Hotchkiss, 2006). Altmanin et al. (2019) mukaan

uudelleenjärjestelyyn perustuvan systeemin ensisijainen hyöty on työpaikkojen ja tulojen turvaamisen lisäksi se, että taloudellisesti tuottavat varat voivat jatkaa toimintaansa.

Huomioitavaa on, että Suomessakaan maksuvaikeuksissa olevalle yritykselle konkurssin hakeminen ei ole ainoa vaihtoehto. Suomessa Yhdysvaltojen uudelleenjärjestelyä vastaava toimenpide on yrityssaneeraus, jossa velallisen jatkamiskelpoisen yritystoiminnan tervehdyttämiseksi, edellytysten turvaamiseksi tai velkajärjestelyjen aikaansaamiseksi voidaan ryhtyä varhaiseen tai perusmuotoiseen saneerausmenettelyyn (Yrityssaneerauslaki 47/1993, 1 § 1). Menettelyssä velallisen toimintaa voidaan ohjata tuomioistuimen vahvistaman saneerausohjelman mukaisesti (Yrityssaneerauslaki 47/1993, 1 § 1).

Yrityksen taloudelliseen ahdinkoon tai konkurssiin on monia syitä. Altmanin ja Hotchkissin (2019) mukaan yleisimpiä syitä yrityksen epäonnistumiseen ovat:

1. heikko operatiivinen suoriutuminen
2. teknologisten innovaatioiden puuttuminen
3. likviditeetti- ja rahoitushäiriö
4. korkea yritysten perustamisaste tiettyä ajanjaksona
5. sääntelyn purkautuminen
6. odottamattomat velvoitteet.

Heikko operatiivinen suoriutuminen yhdistyy yleensä korkeaan velkaantuneisuusasteeseen, sillä korkea velkavipu vahvistaa vaikutusta ja kasvattaa konkurssin todennäköisyyttä. Operatiiviset vaikeudet kumpuavat esimerkiksi epäonnistuneista yrityskaupoista tai kiristyneestä kansainvälisestä kilpailusta. Samanaikaisesti yrityksen tulisi kyetä vastaamaan teknologiseen kehitykseen, jossa uudet innovaatiot syrjäyttävät vanhentuneita toimintamalleja. (Altman & Hotchkiss 2019) Yrityksen tulisi siis aina kestää mukana kilpailussa niin operatiivisesti kuin innovaatiotoiminnaltaan.

Sisäisten tekijöiden lisäksi myös rahoitusmarkkinoiden tila ja toimintaympäristö vaikuttavat yritykseen. Rahoituskriisien aikana ilmenevät likviditeettishokit voivat estää velkojen maksua. Toisaalta jo pelkästään korkea yritysten perustamisaste ja toimialojen sääntelyn purkautuminen, jotka kiristävät kilpailua ja tuovat uusia haavoittuvaisia toimijoita markkinoille, lisäävät konkursseja. (Altman & Hotchkiss (2019) Lisääntynyt kilpailu siis usein vaikuttaa suoraan myös konkurssien määrään. Joskus yritys voi myös kohdata odottamattomia velvoitteita, joita aiheutuu esimerkiksi oikeudenkäynneistä tai

yrittäjäkauppojen myötä periytyvistä velvoitteista, jotka realisoituessaan voivat aiheuttaa välittömän uhan liiketoiminnan jatkuvuudelle (Altman & Hotchkiss 2019).

Kumar ja Ravi (2007) mukaan yrityksen taloudellinen tila kilpailullisessa toimintaympäristössä riippuu sen maksukykyisyydestä, kyvystä tuottaa kassavirtaa operaatioistaan, mahdollisuudesta päästä pääomamarkkinoille ja taloudellisesta kestävydestä kohdattaessa yllättäviä kassavajeita.

3.2 Konkurssin todennäköisyyden ennustusmenetelmät

Seuraavaksi esitellään muutamia perinteisiä konkurssin ennustamismenetelmiä, joita kirjallisuudessa esiintyy. Yleisin käytetty perinteinen tilastollinen menetelmä konkurssin ennustamiseen on monimuuttujainen diskriminanttianalyysi (multiple discriminant analysis, MDA), jota ensimmäisenä käytti Altman (1968) kehittäessään Z-mallin (Alaka *et al.* 2018). Z-malli on edelleen, 50 vuotta kehittämisensä jälkeen, laajasti akateemikkojen ja ammattilaisten käyttämä luottoluokitusmalli arvioitaessa maksukyvyttömyyden todennäköisyyttä (Altman & Hotchkiss 2019). MDA on tilastollinen menetelmä, jonka tavoitteena on löytää lineaarinen yhdistelmä useista muuttujista, joka parhaiten erottaa ennalta määrätyt ryhmät toisistaan, esimerkiksi konkurssiin ajautuneet toimintaansa jatkaneista yrityksistä (Altman 1968).

Kaavassa 1 esitetty diskriminanttifunktio muuntaa yksittäiset muuttujat Z-arvoksi, jota käytetään yritysten jakamiseen eri riskiluokkiin (Altman 1968).

$$Z = v_1x_1 + v_2x_2 + \dots + v_nx_n \quad (1)$$

, jossa $v_1, v_2 \dots v_n$ ovat diskriminanttikertoimia (discriminant coefficients), jotka määräävät, kuinka paljon yksittäiset selittävät muuttujat (independent variables) $x_1, x_2 \dots x_n$ vaikuttavat lopulliseen Z-arvoon. MDA siis laskee diskriminanttikertoimet siten, että Z-arvon perusteella voidaan mahdollisimman tarkasti erotella konkurssiyritykset terveistä. (Altman, 1968) Taulukossa 1 on esiteltynä Altmanin (1968) käyttämät tunnusluvut ja niiden painokertoimet.

Taulukko 1: Alkuperäinen Z-malli, mukailen (Altman & Hotchkiss, 2019).

Muuttuja	Kuvaus	Painokerroin ($v_1, v_2 \dots v_n$)
X_1	$\frac{\text{Käyttöpääoma}}{\text{Taseen loppusumma}}$	1.200

X_2	$\frac{\text{Kertyneet voittovarot}}{\text{Taseen loppusumma}}$	1.400
X_3	$\frac{\text{Liikevoitto}}{\text{Taseen loppusumma}}$	3.300
X_4	$\frac{\text{Oman pääoman markkina – arvo}}{\text{Velkojen kirjanpitoarvo}}$	0.600
X_5	$\frac{\text{Liikevaihto}}{\text{Taseen loppusumma}}$	0.999

Koska MDA:han perustuvia menetelmiä on kritisoitu niiden taustalla olevien tilastollisten oletusten rikkomisesta, 1980-luvun tutkimuksessa huomio siirtyi ehdollisiin todennäköisyysmalleihin. Näistä tunnetuin ja laajimmin käytetty oli logistinen regressiomalli (logit). (Ohlson, 1980; Jackson & Wood, 2013) Logit-malli on ehdollinen todennäköisyysmalli, joka käyttää epälineaarista suurimman uskottavuuden (maximum log-likelihood) menetelmää yrityksen epäonnistumisen todennäköisyyden estimoimiseksi, olettaen, että havaintojen jakauma noudattaa logistista jakaumaa (Jackson & Wood, 2013). Logistinen funktio muuntaa mallin syötearvot todennäköisyyksiksi välillä 0–1, mikä tekee siitä sopivan menetelmän binääristen luokitteluongelmien ratkaisemiseen (Barboza & Altman 2024). Logistisen regression funktion voidaan muuttujien valinnan jälkeen esittää seuraavasti;

$$P_i = \left(\frac{1}{1 + e^{-(\beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_n X_{in})}} \right), \quad (2)$$

jossa P_i kuvaa yrityksen i konkurssitodennäköisyyttä ominaisuusvektorin X_{ij} (esim. tunnusluvut tai muut selittävät muuttujat) perusteella, ja β_j edustavat mallin parametrien arvioita (Ohlson 1980; Jackson & Wood 2013; Alaka et al. 2018).

(Shumway 2001) kritisoi staattisten mallien (esim. MDA ja logit) kyvyttömyyttä ottaa huomioon taloudellisten tunnuslukujen ajallista vaihtelua ja konkurssiriskin kestoa. Hazard-malli pyrkii vastaamaan ongelmiin hyödyntämällä kaikkea aikasarjadataa yrityksen elinkaaren ajalta pelkän konkurssia edeltävän havainnon sijaan (Shumway 2001). Siis hazard-malli käsittelee kaikkia yrityksen toimintavuosia erillisinä havaintoina, eli huomioi ajan kulumisen (Alam et al. 2021). Vaikkakin hazard-mallit ovat osoittaneet hyvää ennustustarkkuutta verrattuna staattisiin malleihin, niiden epävarmuus kasvaa merkittävästi, kun ennustavien parametrien määrä kasvaa (Alam et al. 2021).

4. KONEOPPIMINEN KONKURSSIN ENNUSTAMISESSA

Tässä osiossa tarkastellaan konkurssin ennustamista erityisesti koneoppimisen keinoin. Kirjallisuuskatsauksen aineiston perusteella tarkastellaan, mitä menetelmiä kirjallisuudessa on yleisesti tunnistettu välineenä konkurssin ja taloudellisen ahdingon todennäköisyyden ennustamiseen. Tämän jälkeen tarkastellaan, millä metrikoilla aineistot vertaavat ja tarkastelevat käsiteltyjen menetelmien tarkkuutta ja toimivuutta sekä miten eri menetelmät vertautuvat toisiinsa suorituskyvyltään. Käsittely koskee pääasiassa koneoppimismenetelmiä, mutta useassa artikkelissa on vertailukohtana käytetty myös logistista regressiota ja diskriminanttianalyysiä (esim. Jabeur et al. 2021; Liu et al. 2023; Ben Jabeur & Serret 2024). Täten myös aineistossa käsitellyt tilastolliset menetelmät otetaan mukaan tarkasteluun.

4.1 Käytetyt koneoppimismenetelmät

Aineistossa havaitaan päätyypiltään kahdenlaisia tutkimuksia. Osassa artikkeleista käsitellään selvästi jotain tiettyä kehitettyä menetelmää ja verrataan sitä muihin alalla noteerattuihin menetelmiin (mm. Jabeur et al. 2021; Wu et al. 2022; Ben Jabeur & Serret 2023). Kutsutaan näitä tutkimuksia *menetelmäkeskeisiksi*. Toisaalta osa artikkeleista pyrkii löytämään parhaan menetelmän, jonka jälkeen sitä on tarkoitus soveltaa johonkin tiettyyn kohteeseen. Sehgal et al. (2021) pyrkivät kehittämään mallin nimenomaan Intian kaltaisille kehittyville markkinoille. Puolestaan Zhao et al. (2023) pyrkivät luomaan järjestelmän, jonka tavoitteena on varoittaa nimenomaan PK-yrityksiä taloudellisen kriisin uhasta. Nimetään näitä tutkimuksia *soveltamiskeskeisiksi*. Myös menetelmäkeskeisten artikkeleiden keskuudessa menetelmän tarkastelun yhteydessä on sitä voitu myös käyttää johonkin sovelluskohteeseen. Esimerkiksi Lin et al. (2025) ja Deng et al. (2025) yhdistävät menetelmään selittävän tekoälyn (explainable artificial intelligence, XAI) tekniikoita lisäämään ennustamiseen läpinäkyvyyttä.

Taulukossa 2 on syntetisoitu liitteeseen A kerättyä tietoa aineiston artikkeleista. Taulukossa on esitelty aineiston jakautuminen menetelmä- ja soveltamiskeskeisiin tutkimuksiin. Eri tutkimukset on myös kategorisoitu niiden pääasiallisen käytetyn koneoppimismenetelmän mukaan. Menetelmäkeskeisten artikkeleiden tapauksessa kategoria määräytyy ensisijaisesti käsitellyn menetelmän lajin mukaan. Sen sijaan

soveltamiskeskeisissä artikkeleissa kategorisointi tapahtuu parhaaksi todetun menetelmän mukaan, jota on sitten jalostettu käyttötarkoitukseensa tutkimuksessa. Pääasiallisten menetelmien lisäksi taulukkoon on kirjattu kaikki muut artikkelissa vertailut ja käsitellyt ennustusmenetelmät, sisältäen niin koneoppimis- kuin tilastolliset menetelmät. Lukuun ottamatta Lin et al. 2025 tuottamaa tutkimusta, kaikissa tutkimuksissa menetelmiä vertaillaan suorituskyvyltään keskenään erityisesti ennustustarkkuudessa.

Aineistossa taulukon 2 mukaisesti tutkimukset selvästi useimmiten valitsevat pääkäsitelyyn boosting-pohjaisia ensemble-menetelmiä ja neuroverkkopohjaisia sovellutuksia. Soveltamiskeskeisten tutkimusten piirissä huomataan erityisesti, että tapauksissa, joissa on valittu boosting-menetelmä, on harkinnassa ollut myös neuroverkkosovellutuksia (esim. Bragoli et al. 2022; Zhao et al. 2023). Toisaalta menetelmäkeskeisten tutkimusten keskuudessa neuroverkot ovat selkeästi suosituimpia. Toisaalta, jos mennään tasolla ylöspäin ja otetaan käsitelyyn ensemble-menetelmät kokonaisuutena, ovat ne lähes yhtä yleisiä menetelmäkeskeisten artikkelien keskuudessa. Barbozan ja Altmanin (2024) ja Machado et al. (2025) käyttämät satunnaismetsät ovat yhtä lailla yksittäisiä menetelmiä yhdisteleviä ensemble-menetelmiä kuin boosting-menetelmätkin.

Vastaavasti soveltamiskeskeisten artikkeleiden joukossa boosting-menetelmät ovat selvästi käytetyin ryhmä. Kun tähän sisällytetään vielä satunnaismetsät, ovat ensemble-menetelmät selvästi useimmiten pääkäsitelyssä. Kokonaisuudessaan pääkäsitelyyn tai parhaaksi aineistossa on useimmiten valikoituneet erilaiset ensemble-menetelmät (boosting, stacking ja satunnaismetsät) ja neuroverkkopohjaiset sovellutukset. Ensemble- ja erityisesti boosting-menetelmien käyttöä perustellaan kirjallisuudessa niiden ylivertaisella suorituskyvillä sekä kyvillä vähentää ylisovittamista ja lisätä yleistettävyyttä (esim. Zhang et al. 2022).


Taulukko 2: Käytetyt menetelmät artikkeleittain. Lyhenteiden selitykset englanniksi; ((artificial) neural network, (A)NN), ((fuzzy) convolution neural network, (F)CNN), (support vector machines, SVM), (decision trees, DT), (random forest, RF), (gradient boosting machine, GBM), (discriminant analysis, DA), (logistic regression, LR), (discrete hazard model, DHM)

Vertailu	Kategori a	Pääasialline n menetelmä	Artikkeli	Kuvaus	Muut menetelmät
Menetelmä	Boosting	XGBoost	Deng et al. (2025)	Yhdistetään koneoppimismenetelmiin XAI	SVM, RF, ANN

				tekniikoita parantamaan läpinäkyvyyttä.	
		CatBoost	Jabeur et al. (2021)	Verrataan CatBoost mallia muihin.	SVM, NN, RF, GBM, DNN, XGBoost, (DA,LR)
	Stacking ensemble	Stacking ensemble (BT, RF, kNN, NN)	Cao et al. (2024)	Laajennetaan tarkastelua hinnoittelutekijöihin (asset-pricing factors).	AdaBoost, CatBoost, XGBoost, LightGBM
	Satunnais metsä	RF	Barboza & Altman (2024)	Verrataan satunnaismetsiä tilastolliseen logistisen regression malliin.	(LR)
	Oma	VDFDP	Huang et al. (2024)	Kehitetään malli, joka menestyy erityisesti tarkasteltaessa puuttellista ja moniulotteista dataa.	RF, SVM, MLP-ANN, (LR)
	Neuroverkko pohjaiset	ANN Z-score hybrid	Wu et al. (2022)	Yhdistetään neuroverkkoihin Altmanin Z-score.	MLP-ANN, (Z-score)
		FCNN	Ben Jabeur & Serret, (2023)	Yhdistetään fuzzy-set teorian muuttujanvalintaa konvoluutioneuroverkkoihin.	SVM, NN, CNN, (DA, LR, PLS-DA)
		CNN	Lin et al. (2025)	Yhdistetään XAI-tekniikoita selittämään mallin toimintaa.	
		Deep learning	Alam et al. (2021)	Verrataan malleja panel-data kontekstissa.	(DHM)
		AWOA-DL	Elhoseny et al. (2025)	Tuetaan syväoppimista AWOA hyperparametrien optimoinnilla.	DNN, (LR)
Soveltamis	Boosting	XGBoost	Bragoli et al. (2022)	Yhdistetään tunnuslukuihin toimialamuuttujia.	RF, NN, (WLR)
		XGBoost	Zhao et al. (2023)	Kehitetään järjestelmä varoittamaan PK-yrityksiä taloudellisesta ahdingosta.	NN, (LR)
		GBDT	Liu et al. (2023)	Tutkitaan erilaisten puupohjaisten gradient boosting mallien toimintaa ja selitetään eri tunnuslukujen yhteyttä ahdinkoon.	RF, NN, SVM, AdaBoost, XGBoost, LightGBM, CatBoost, (LR)
		XGBoost	Papíková & Papík (2024)	PK-yritysten konkurssinennustusta yhdistäen taloudellista ja henkisen pääoman näkökulmaa.	CatBoost
		LightGBM	Zhang et al. (2022)	Kokonaisvaltainen ensemble malli muuttujavalinnasta ennustemallin.	DT, SVM, RF, XGBoost
	Satunnais metsät	RF	Machado et al. (2025)	Ennustetaan luottoriskiä suuren pankin asiakkaiden keskuudessa.	SVM, DT, GBM, XGBoost, ANN, (LR, LDA)
	Neuroverkot	ANN	Aydin et al. (2022)	Tutkitaan mallien räätälöintiä eri sektoreille.	DT
	SVM	SVM	Sehgal et al. (2021)	Pyritään kehittämään ennustusmalli kehittyville markkinoille, tässä; Intia.	ANN, (LR)

Useissa aineiston artikkeleissa havaittiin trendi, jossa koneoppimismallien käyttöä laajennetaan uusilla näkökulmilla. Malleja täydennettiin esimerkiksi läpinäkyvyyttä lisäävillä XAI-menetelmillä tai tutkimuksissa keskityttiin vain tiettyjen yrityssegmenttien ennustamiseen. Papíková ja Papík (2024) yhdistävät perinteisiin taloudellisiin tunnuslukuihin yrityksen henkistä pääomaa kuvaavia tekijöitä, Cao et al. (2024) laajentavat tarkastelua hinnoittelutekijöihin (asset pricing factors), Bragoli et al. (2022) yhdistävät tunnuslukuihin toimialamuuttujia ja Zhao et al. (2023) keskittyvät PK-yrityksiin. Koneoppimismenetelmien hyödyntämistä erityisesti soveltamistapauksissa puoltaa esimerkiksi se, että Bragoli et al. (2022) tuottamassa tutkimuksessa logistisen regression konkurssiyritysten ennustustarkkuus laski, kun taloudellisia tunnuslukuja tuettiin toimialamuuttujilla, kun puolestaan XGBoostin nousi. Tällä on erityisesti merkitystä, sillä konkurssiyrityksen ennustaminen terveeksi on arvioitu olevan 36 kertaa kalliimpaa kuin toisinpäin (Alam et al. 2021)

Kokonaisuudessa konkurssin ennustamiseen käytetään paljon erilaisia koneoppimisen sovellutuksia. Kuvassa 6 on vielä koottu yhteen taulukkoa 2, ja esitetty kokonaisuudessaan eri konkurssin tai taloudellisen ahdingon ennustamismenetelmien esiintyvyyttä aineistossa. Esiintyvyydeksi vaaditaan, että menetelmää on jotenkin käytetty tutkimuksessa eikä ainoastaan sivuttu teoriakatsauksessa. Sinisellä on kuvattu koneoppimismenetelmiä ja punaisella tilastollisia menetelmiä. Menetelmiä on kategorisoitu, kuten taulukossa 2. Huomataan jälleen, että erityisesti neuroverkkopohjaiset sovellutukset nousevat esiin käytetyimpinä.



Kuva 6: Eri ennustusmenetelmien esiintyvyys aineistossa. Koneoppimismenetelmät sinisellä ja tilastolliset menetelmät punaisella.

SVM on käytetty vertailukohtana useimmissa tapauksissa, lukuun ottamatta Sehgal et al. (2021) tuottamaa tutkimusta, jossa kehitettäessä ennustusmallia kehittyville markkinoille, se päihittää neuroverkkomallin. Kuitenkin useimmissa artikkeleissa SVM toimii nimenomaan vertailukohtana käsiteltävälle mallille (mm. Liu et al. 2023) Zhang et al. (2022) mukaan SVM myös valitaan usein toimimaan perusluokittimena ensemblemenetelmille, sillä se on suhteellisen vakaa epätasapainoisessa datassa ja kykenee välttämään ylisovittamista, mutta toimii myös suhteellisen hyvin, kun otoksia on vähän. Perusluokittimena päätöspuut ovat selvästi vähemmän käytettyjä yksinään ja esiintyvät sellaisenaan ainoastaan kolmessa tutkimuksessa (Aydin et al. 2022; Zhang et al. 2022; Machado et al. 2025). Kuitenkin satunnaismetsät, joissa pohjalla on nimenomaan useat päätöspuut, esiintyvät miltei puolessa aineiston artikkeleista (mm. Bragoli et al. 2022; Barboza & Altman 2024; Deng et al. 2025).

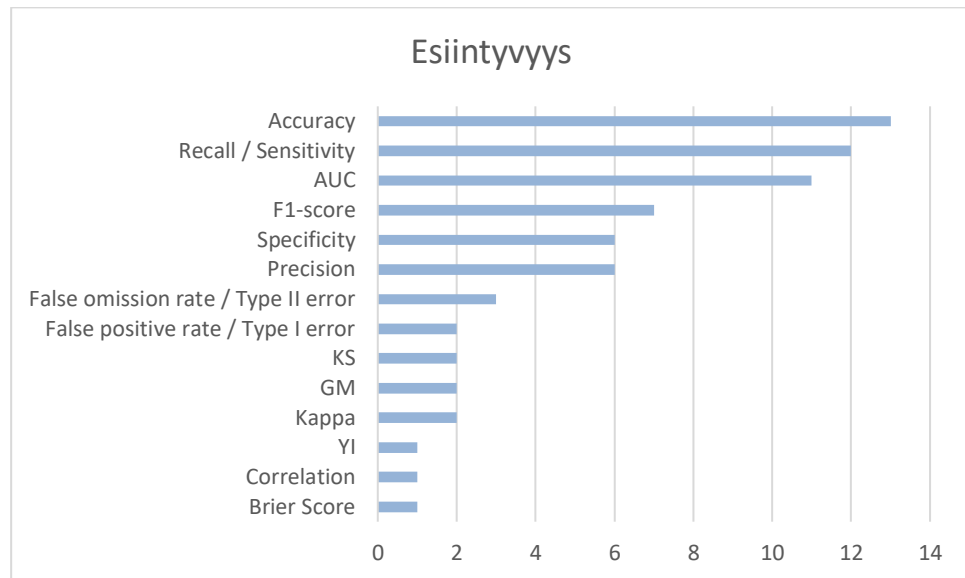
Kuten taulukosta 2 ja kuvasta 6 voidaan huomata, aineistossa selvästi yleisin käytetty tilastollinen ennustusmenetelmä on logistinen regressio. Mikäli tutkimuksessa on päätetty verrata menetelmää tilastollisiin vaihtoehtoihin, on taulukon 2 mukaisesti vähintään yksi niistä ollut logistinen regressio. Vaikkakin logistinen regressio on aineistossa käytetty menetelmä, kumotaan se usein koneoppimismenetelmien paremmuudella (mm. Sehgal et al. 2021; Barboza & Altman 2024). Yleisesti aineistossa koneoppimismenetelmien käyttöä puolletaan usein kyvyllä havaita epälineaarisia ja komplekseja suhteita datassa, (mm. Wu et al. 2022; Deng et al. 2025; Lin et al. 2025).

Kaiken kaikkiaan havaitaan, että pääasiallisessa käsittelyssä 2020-luvun taloudellisen ahdingon ja konkurssin ennustamisen tutkimuksessa on useimmiten tukeuduttu kehittyneempiin ensemble-menetelmiin (boosting, stacking, satunnaismetsät), joissa yhdistellään eri perusluokittimia (mm. Jabeur et al. 2021; Liu et al. 2023; Cao et al. 2024). Toisaalta myös erityisesti raskaammat neuroverkkoratkaisut, kuten konvoluutioneuroverkot ja syväoppiminen vaikuttavat menevän monen kevyemmän menetelmän edelle (mm. Ben Jabeur & Serret 2023; Elhoseny et al. 2025). Joka tapauksessa kirjallisuus vaikuttaa tämän katsauksen perusteella menevän siihen suuntaan, että yksittäiset luokittimet, kuten päätöspuut, SVM:t ja kevyemmät neuroverkot eivät päädy käytettäväksi sellaisenaan taloudellista ahdinkoa ja konkurssia ennustettaessa.

4.2 Ennustustarkkuuden mittarit

Merkittävin ero eri mallien välillä on, kuinka tarkkoja ennustustuloksia sillä saavutetaan. Soveltamiskeskeisissä artikkeleissa pääkäsittelyyn päätyvän mallin valinta tehdään

monessa tapauksessa tämän vertailun perusteella (mm. Sehgal et al. 2021; Zhang et al. 2022; Machado et al. 2025). Puolestaan monet menetelmäkeskeiset artikkelit päätyvät lopulta osoittamaan esittämänsä menetelmän parempaa suorituskkyä muihin menetelmiin nähden (esim. Jabeur et al. 2021; Ben Jabeur & Serret 2023; Huang et al. 2024). Kaikissa aineiston tutkimuksissa mallien suorituskkyä kuvataankin jollain mittarilla. Kuvassa 7 on esitetty koottuna liitteestä A erilaisten mallin suorituskkyä kuvaavien mittareiden esiintyvyyttä aineistossa.



Kuva 7: Ennustustarkkuusmittareiden esiintyvyys aineistossa.

Kuvan 7 mukaisesti huomataan, että kaikista käytetyimpiä mittareita ovat accuracy, recall ja AUC. Tarkkuus (accuracy, ACC) kuvaa kokonaisuudessaan ennustustarkkuutta, eli kuinka hyvin malli ennustaa oikein niin ahdingossa olevia kuin terveitä yrityksiä (Deng et al. 2025). Siihen liittyy kuitenkin ongelma, mikäli sitä käytetään yksinään tapauksessa, jossa lähtötiedot ovat epätasaiset (Ben Jabeur & Serret, 2023). Recall ja sensitivity kuvaavat mallin kykyä ennustaa nimenomaan positiivisia tapauksia, eli ahdinkoon joutuvia yrityksiä. Toisin sanoen recall kertoo, kuinka suuren osuuden malli ennusti oikein kaikista ahdinkoon joutuvista yrityksistä. (Lin et al. 2025) Mikäli aineistossa olisi vain 0,5 % ahdingossa olevia otoksia, on tarkkuus 99,5 %, vaikka malli ennustaisi kaikki terveiksi. Ongelmana on, että tällöin recall on 0 %. Kuten jo aikaisemmin mainittiin, on arvioitu, että konkurssiyrityksen ennustaminen terveeksi on 36-kertaa kalliimpaa kuin toisinpäin.

AUC kuvaa kokonaisvaltaisesti luokittelumallin kyvykkyyttä erotella positiiviset tapaukset negatiivisista yli kaikkien mahdollisten luokittelukynnysten. AUC on mittarina vakaampi epätasapainoisten luokkien tapauksissa verrattuna esimerkiksi tarkkuuteen (Machado et al. 2025). Tarkastellaan seuraavissa luvuissa aineistossa esiintyvien mallien tarkkuuksia

eri metriikoilla eri aikahorisonteissa. Otetaan tarkastelun näkökulmiksi tarkkuus (accuracy) sen yleisyyden takia, mutta tasapainotetaan sitä tarkastelemalla myös recall- ja AUC-arvoja. Nämä sopivat tarkasteluun myös, koska melkein jokaisessa tutkimuksessa on käytetty näistä vähintään kahta.

4.3 Lyhyen aikavälin ennustaminen

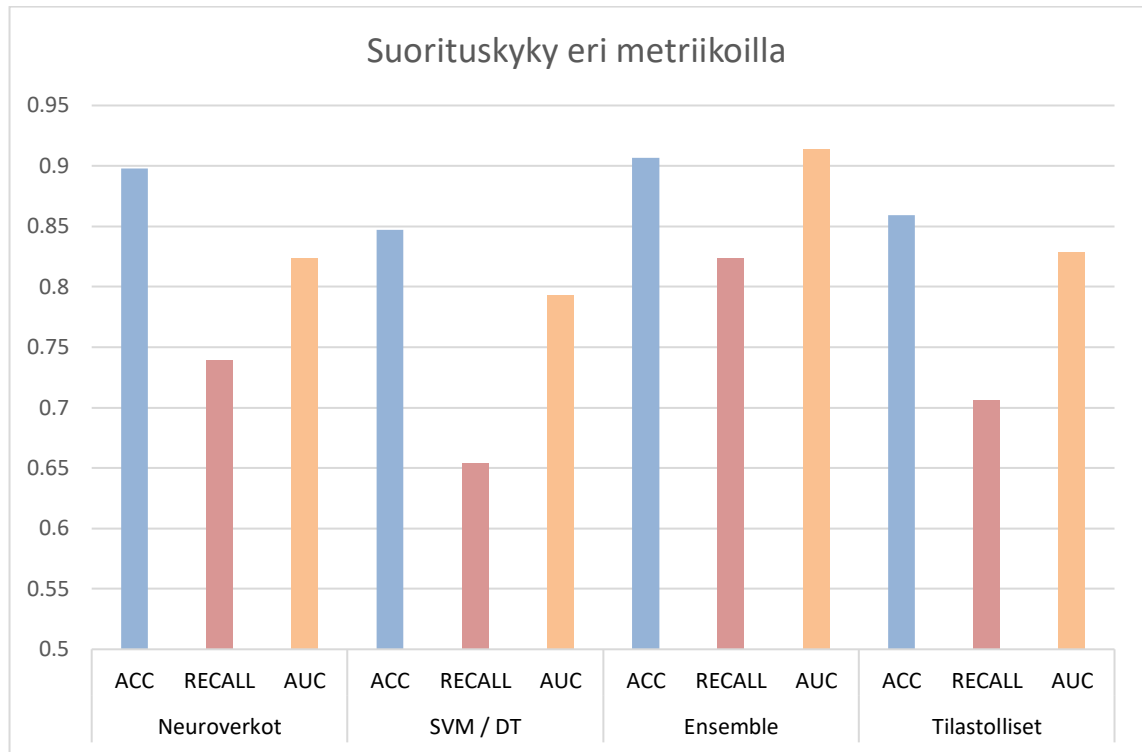
Liitteeseen B on kerätty kokonaisuudessaan kaikki aikaisemmin taulukossa 2 esiteltyjen artikkeleiden menetelmien tarkkuudet kuvattuna ACC, recall ja AUC -mittareilla. Ennustusintervalliksi tarkasteluun otetaan ensimmäiseksi 1 vuosi, sillä se esiintyy kaikissa aineiston artikkeleissa, pois lukien Machado et al. (2025) teettämä tutkimus, jossa ennustusintervalli on 6 kuukautta. Tämä on kuitenkin sisällytetty tarkasteluun. Menetelmät ovat ryhmitelty jälleen ryppäiksi samaan tyyliin kuin aikaisemminkin. Taulukossa vaakarivillä on kuvattuna yksittäinen tutkimus, mallin koulutusaineiston jakauma (konkurssi/terve) ja tutkimuksessa tarkasteltujen menetelmien metriikat. Yksittäisen artikkelin parhaaksi esittäytyneen menetelmän luvut ovat tummennettuna. Alarivillä jokaisen menetelmän kullekin metriikalle on laskettu keskiarvot.

Tarkasteltaessa artikkeleita yksittäin huomataan, että erilaiset ensemble-menetelmät ovat usein niitä käsitellessä artikkeleissa suorituskyvyltään muita parempia. Nämä valikoituvatkin useimmiten menestyksekkäimmiksi. (mm. Jabeur et al. 2021; Liu et al. 2023; Cao et al. 2024) Erityisesti erilaiset boosting-arkkitehtuuria hyödyntävät menetelmät osoittavat hyvää suorituskyyä ja valikoituvat usein parhaaksi, mikäli niitä on tutkimuksessa hyödynnetty (mm. Bragoli et al. 2022; Papíková & Papík 2024; Deng et al. 2025).

Myös neuroverkkopohjaiset sovellutukset menestyvät suhteellisen hyvin ja valikoituvat usein parhaaksi menetelmäksi. Erityisesti kehittyneemmät sovellutukset, kuten konvoluutioneuroverkot ja syväoppiminen ennustavat konkursseja erityisen hyvin. (Ben Jabeur & Serret 2023; Elhoseny et al. 2025; Lin et al. 2025) Kuitenkin huomattavaa on, että lukuun ottamatta Huang et al. (2024) tutkimusta, missään tutkimuksessa, jossa neuroverkot osoittautuvat parhaaksi, ei ole verrattu mihinkään ensemble-menetelmiin. Joka herättää erityisesti kysymyksen, että olisiko tilanne eri, jos vertailussa olisi mukana muitakin kehittyneempiä menetelmiä, kuten XGBoost tai CatBoost, jotka osoittavat muuten vahvaa suorituskyyä monissa tapauksissa (mm. Jabeur et al. 2021; Cao et al. 2024).

Kuvassa 8 esitellään eri menetelmäryhmien keskiarvoja aineistossa. Keskiarvotarkastelu ei ole mieleisin, sillä eri menetelmiä on sovellettu erilaisissa

koulutusaineistoissa, jossa jakaumat ovat erilaisia, ja kuten kuvasta 6 huomataan, havainnot eri menetelmien käytöstä eivät ole tasaisesti jakautuneet. Kuitenkin keskiarvoja tarkastelemalla huomataan tiettyjä trendejä, joita myös aikaisemmin esiin nousseet huomiot tukevat.



Kuva 8: Eri menetelmäryhmien suorituskyky eri metriikoilla (ACC, Recall, AUC)

Kuvasta 8 havaitaan, että tarkkuudeltaan menetelmistä erottuu erityisesti ensemble- ja neuroverkkomenetelmät, jotka keskimäärin saavuttavat molemmat aineistossa ~90 % ennustustarkkuuden. Myös tilastolliset menetelmät, SVM ja päätöspuut saavuttavat korkean, ~85 %, ennustustarkkuuden. Suurin ero menetelmäryhmien välillä havaitaan kuitenkin recall-arvossa, joka on selvästi suurin, ~83 %, ensemble-menetelmillä ja kaikilla muilla < 75 %. Ensemble-menetelmät ennustavat siis selvästi parhaiten erityisesti taloudellisessa ahdingossa tai konkurssissa olevia yrityksiä.

Konkurssidata on usein epätasapainoista, sisältäen huomattavasti enemmän konkurssiyrityksiä kuin taloudellisesti terveitä yrityksiä (Lin et al. 2025). Tämä voi johtaa mallin ylioppimiseen, joka tapahtuu erityisesti neuroverkoille Machado et al. (2025) tuottamassa tutkimuksessa, jossa erityisesti satunnaismetsät ja XGBoost pärjäsivät huomattavasti paremmin epätasapainoisessa datassa. Tätä tukee myös kuvasta 8 havaittava ensemble-menetelmien selvästi korkeammat recall- ja AUC-arvot. Liitteestä B havaitaan myös, että lähes kaikissa tutkimuksissa, joissa neuroverkkomenetelmiä on verrattu ensemble-menetelmiin, saavuttavat ensemble-menetelmät korkeampia AUC-

arvoja, viitaten niiden parempaan kykyyn erotella ahdingossa olevia ja terveitä yrityksiä (mm. Wu et al. 2022; Liu et al. 2023; Cao et al. 2024). Useissa tutkimuksissa, joissa data on erityisen epätasapainoista, ovat ensemble-menetelmät saavuttaneet siitä huolimatta korkeita tuloksia (mm. Sehgal et al. 2021; Bragoli et al. 2022; Cao et al. 2024).

4.4 Pidemmän aikavälin ennustaminen

Tarkastellaan vielä ennustamista ohi yhden vuoden ennustusperiodin. Liitteestä A havaitaan, että useissa artikkeleissa taloudellisen ahdingon ja konkurssin ennustamisen aikajännettä on jatkettu myös vuotta pidemmälle, jopa 5 vuoteen saakka (mm. Liu et al. 2023; Papíková & Papík 2024).

Liitteessä C esitellään liitteen B tavoin eri menetelmien tarkkuuksia koottuna artikkeleittain vuosille 1–5. Tarkastellaan aluksi artikkeleita yksinään. Kuten aikaisemminkin jokaisen artikkelin paras menetelmä on lihavoituna, mutta poiketen aikaisemmasta, nyt myös jokaisen artikkelin jokaisen ennustusvuoden paras menetelmä on lihavoituna. Jälleen monissa tapauksissa erilaiset ensemble, erityisesti boosting-menetelmät menestyvät parhaiten yli kaikkien ennustushorisonttien (mm. Jabeur et al. 2021; Liu et al. 2023; Deng et al. 2025). Ben Jabeurin ja Serretin (2023) tutkimuksessa konvoluutioneuroverkot menestyvät yhden vuoden, neuroverkot kahden ja diskriminanttianalyysi kolmen vuoden aikajänteellä. Vaikka kyseisessä tutkimuksessa ei sovellettu ensemble-menetelmiä, kaikissa muissa liitteen C tutkimuksissa ne osoittautuivat suorituskykyisimmiksi kaikilla ennustushorisonteilla. Tuloksia tulkittaessa on kuitenkin huomioitava, että ensemble-menetelmät ovat aineistossa myös määrällisesti vahvimmin edustettuina.

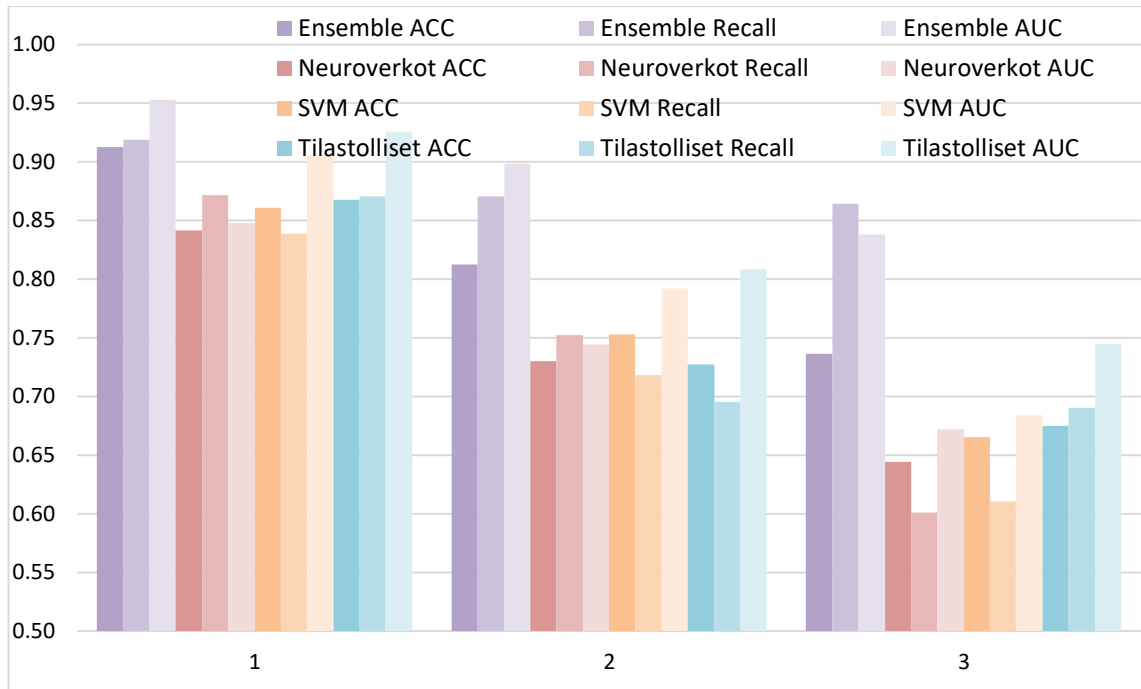
Taulukkoon 3 on kerätty tietoa eri menetelmäryhmien suorituskyvystä. Ryhmät on jaettu vastaavasti kuin kuvassa 8. Taulukon arvot on saatu ottamalla keskiarvot jokaisen menetelmäryhmän jokaisen menetelmän havainnoista eri metriikoilla eri vuosilta. Jokaisen ennustushorisontin paras menetelmä on lihavoituna. Kuten aikaisemminkin, keskiarvotarkastelu ei välttämättä ole mielekkäin menetelmä, sillä samat rajoitukset pätevät, kuin aikaisemminkin. Kuitenkin taulukosta huomataan jälleen, että se tukee aikaisempia havaintoja. Taulukon 3 luvut esitetään myös graafisessa muodossa kuvassa 9. Ennustamista 4-5 vuoden päähän ei ole varsinaisen mielekästä tarkastella, sillä ainoastaan Liu et al. (2023) ja Papíková ja Papík (2024), tarkastelevat ennustamista näin pitkälle ja ainoastaan Liu et al. (2023) tuottamassa tutkimuksessa käsitellään muitakin kuin ensemble-menetelmiä. Täten kuvassa 9 esitetään ainoastaan ennustamista 1–3 vuoden aikajänteellä.

Taulukko 3: Menetelmäryhmien suorituskyky vuosille 1-5. Selitteet: A = ACC, B = Recall ja C = AUC.

Vuosi	Neuroverkot			Ensemble			SVM			Tilastolliset		
	A.	B.	C.	A.	B.	C.	A.	B.	C.	A.	B.	C.
1	0,84	0,87	0,85	0,91	0,92	0,95	0,86	0,84	0,91	0,87	0,87	0,93
2	0,73	0,75	0,74	0,81	0,87	0,90	0,75	0,72	0,79	0,73	0,7	0,81
3	0,64	0,60	0,67	0,74	0,86	0,84	0,67	0,61	0,68	0,67	0,69	0,75
4	0,74		0,74	0,73	0,77	0,75	0,74		0,74	0,74		0,74
5	0,71		0,71	0,70	0,80	0,71	0,72		0,72	0,71		0,71

Taulukon 3 ja kuvan 9 päähavainnot ovat, että kuten tarkasteltaessa yksittäisiä artikkeleita, myös tässä tapauksessa ensemble-menetelmät osoittavat muista poikkeavaa suorituskykyä erityisesti ennustettaessa 1–3 vuoden päähän. Erityisesti positiivisia, eli ahdinkoon tai konkurssiin ajautuvia yrityksiä, tapauksia ensemble-menetelmät ennustavat jopa kolmen vuoden päähän vahvasti. Puolestaan neuroverkkopohjaisten menetelmien tarkkuus sekä kyky ennustaa ahdinkoon joutuvia yrityksiä putoaa alhaiselle tasolle. Ben Jabeurin ja Serretin (2023) tuottamassa tutkimuksessa tilastolliset menetelmät menestyvät neuroverkkoja paremmin ennustettaessa konkurssia 3 vuoden päähän. Huomattavaa on myös, että kehittyneemmät konvoluutioneuroverkot ovat erityisen hyviä 1 vuoden päähän ennustettaessa, mutta putoavat muiden menetelmien alle ennustettaessa pidemmälle (Ben Jabeur & Serret 2023). Myöskään Jabeur et al. (2021) ja Liu et al. (2023) tutkimuksissa neuroverkot eivät osoita erityistä suorituskykyä tilastollisiin menetelmiin nähden ennustettaessa vuotta pidemmälle.

Yleisesti voidaan havaita myös, että ennustuksen tarkkuus tippuu ennustettaessa pidemmälle. Kuitenkin ensemble-menetelmät säilyttävät ennustustarkkuuden menetelmistä parhaiten. Mielenkiintoinen havainto on myös, että tilastolliset menetelmät vaikuttavat säilyttävän suhteellisen tasaisen suorituskyvyn 2 ja 3 vuoden välillä, vaikka esimerkiksi SVM ja neuroverkkojen suorituskyky kärsii.



Kuva 8: Menetelmien suorituskyky 1–3 vuoden ennustushorisontissa. Ensemble-menetelmät kuvattuna violetin, neuroverkot punaisen, SVM oranssin ja tilastolliset sinisen sävyin.

Edelleen on hyvä tiedostaa, että tarkasteltaessa ennustamista usean vuoden päähän, aineisto on rajallinen eikä tällä perusteella pystytä juuri tekemään johtopäätöksiä suuntaan tai toiseen. Kuitenkin aineiston keskuudessa ensemble-menetelmät osoittavat korkeampaa suorituskykyä ennustettaessa useamman vuoden päähän, kun tarkastellaan niin tutkimuksia yksilöinä kuin tutkimuksista muodostettuja keskiarvoja.

5. PÄÄTELMÄT

Työssä tutkittiin systemaattisen kirjallisuuskatsauksen keinoin koneoppimisen käyttöä yrityksen taloudellisen ahdingon ja konkurssin ennustamisessa. Työllä pyrittiin luomaan synteesiä nykyaikaisista käytössä olevista menetelmistä ja niiden suorituskyvystä taloudellisen ahdingon ja konkurssin ennustamisen kontekstissa. Rajatun aineiston turvin pyrittiin selvittämään vastaukset tutkimuskysymyksiin - 1) Millaisia koneoppimisen sovellutuksia alan kirjallisuudessa on tunnistettu yrityksen konkurssin ja taloudellisen ahdingon ennustamiseen? 2) Miten eri konkurssin ja taloudellisen ahdingon ennustamismenetelmät vertautuvat toisiinsa suorituskyvyltään eri mittareilla ja ennustushorisonteilla?

5.1 Työn keskeiset tulokset

Tutkimusaineistossa käytettiin monenlaisia menetelmiä, tutkimus vaikuttaa kuitenkin keskittyneen erityisesti kahdenlaisiin menetelmäryhmiin. Taulukkoon 4 on kerätty synteesi aineistossa havaitusta menetelmistä, jotka on jaettu ryhmiin: ensemble-menetelmät, neuroverkkopohjaiset menetelmät, yksittäiset luokittelijat ja tilastolliset menetelmät.

Lähes jokaisessa aineiston tutkimuksessa käytettiin jossain yhteydessä neuroverkkopohjaisia menetelmiä, usein vertailukohtana ensemble-menetelmille (mm. Jabeur et al. 2021; Deng et al. 2025). Kuitenkin erilaiset ensemble-menetelmät olivat aineiston tutkimuksissa useammin pääkäsittelyssä (mm. Bragoli et al. 2022; Liu et al. 2023). Neuroverkkopohjaisista menetelmistä pääkäsittelyyn päätyi usein kehittyneempiä syväoppimisen sovellutuksia (Ben Jabeur & Serret, 2023; Elhoseny et al. 2025; Lin et al. 2025).

Myös yksittäisistä luokittelijoista support vector machines (SVM) ja tilastollisista menetelmistä logistinen regressio esiintyivät useissa tutkimuksissa. Kuitenkin lukuun ottamatta Sehgal et al. (2021) tutkimusta, olivat ne yleisesti vain vertailukohtia kehittyneemmille menetelmille (mm. Zhang et al. 2022; Huang et al. 2024).

Taulukko 4: *Synteesi aineiston taloudellisen ahdingon ja konkurssin ennustamismenetelmistä.*

Menetelmäperhe	Yksittäiset menetelmät	Havainnot
Ensemble	XGBoost, CatBoost, GBM, LightGBM, GBDT, AdaBoost, Random Forest, Stacking, Bagging	Aineiston suorituskykyisin ryhmä. Erityisesti boosting-menetelmät saavuttivat korkeimpia Recall-arvoja ja sietivät hyvin epätasapainoistakin dataa.
Neuroverkkopohjaiset	MLP-ANN, konvoluutio neuroverkko (CNN), syväoppiminen (DL)	Lähes jokaisessa aineiston tutkimuksessa. Saavuttivat hyviä tuloksia erityisesti lyhyellä aikavälillä. Syväoppiminen mahdollisesti nouseva trendi.
Yksittäiset luokittelijat	SVM (Support Vector Machine), Päättöpuut (DT), kNN	Toimivat nykytutkimuksessa pääasiassa vertailukohtina. SVM on vakaa perusluokitin, mutta häviää lähes poikkeuksetta ensemble-malleille ja neuroverkoille.
Tilastolliset menetelmät	Logistinen regressio (LR), Diskriminanttianalyysi (DA/MDA), Hazard-mallit	Perinteinen standardi, johon uusia malleja verrataan. Suorituskyky jää yleensä koneoppimismalleja heikommaksi aineistossa.

Mitä tulee menetelmien suorituskykyyn, ensemble-menetelmät, erityisesti boosting-menetelmät, saavuttivat aineistossa korkeimman suorituskyvyn kaikissa tutkimuksissa, joissa niitä oli käytetty (mm. Jabeur et al. 2021; Zhao et al. 2023; Deng et al. 2025). Ensemble-menetelmät menestyivät aineistossa kaikissa aikahorisonteissa aina yhdestä vuodesta viiteen vuoteen saakka (Liu et al. 2023; Papíková & Papík 2024). Ensemble-menetelmät demonstroivat myös korkeaa kykyä erottaa nimenomaan ahdinkoon ja konkurssiin ajautuvia yhtiöitä, joka huomataan korkeista recall-arvoista (keskimäärin ~ 83 % vs. muilla menetelmillä keskimäärin < 75 %) (mm. Zhang et al. 2022; Cao et al. 2024). Tällä on suoria vaikutuksia sidosryhmien kokemiin kustannuksiin, sillä ahdinkoon ja konkurssiin ajautuvan yrityksen ennustaminen terveeksi arvioidaan olevan 36-kertaa kalliimpaa kuin väärän hälytyksen antaminen (Alam et al. 2021). Ensemble-menetelmät vaikuttavat myös olevan vastustuskykyisempiä erittäin epätasapainoiselle datalle (Machado et al. 2025).

Vaikkakin neuroverkkopohjaiset sovellutukset olivat aineistossa todella käytettyjä, ne olivat usein suorituskyylytään ensemble-menetelmien heikompia. Kehittyneempienkin konvoluutioneuroverkkujen ennustustarkkuus putosi merkittävästi ennustettaessa vuotta pidemmälle (Ben Jabeur & Serret, 2023).

Vaikka aineiston laajuus ei oikeuta tekemään lopullisia johtopäätöksiä, katsauksen perusteella vaikuttaa siltä, että 2020-luvun konkurssiennustamisessa korostuvat korkean suorituskyylynsä ansiosta erityisesti ensemble-menetelmät ja syväoppimisen sovellukset.

5.2 Tulosten arviointi ja jatkotutkimusaiheet

Tässä kandidaatintyössä onnistuttiin työn tavoitteiden mukaisesti koostamaan ajantasaista tietoa ja analyysiä yrityksen taloudellisen ahdingon ja konkurssin ennustamisesta koneoppimismenetelmillä. Keskeinen kontribuutio on tutkimuskentän syntetisoiminen selkeiksi menetelmäryhmiksi ja ensemble-menetelmien tunnistaminen suorituskyylysimmäksi suuntaukseksi. Vaikka katsaus tarjoaa vain kapean poikkileikkauksen tietyn aikavälin tutkimuksesta, tulosten yhdenmukaisuus eri artikkeleiden välillä lisää johtopäätösten luotettavuutta. Alan ammattilaiset ja organisaatiot voivat hyödyntää työn tuloksia tutustuessaan konkurssin ennustamisen alaan ja arvioidessaan menetelmävaihtoehtoja esimerkiksi kriisin ennustusjärjestelmiin.

Työn tuloksia arviotaessa on kuitenkin huomioitava tulosten yleistettävyyteen liittyvät rajoitteet. Merkittävin rajoite ei ole ainoastaan aineiston koko (18 artikkelia), vaan tarkasteltujen tutkimusten aineistojen heterogeenisyys. Eri tutkimukset ovat käyttäneet dataa eri maista, eri toimialoilta ja eri aikajaksoilta, mikä tekee raportoitujen tarkkuuslukujen suorasta numeerisesta vertailusta haastavaa. Lisäksi termien *konkurssi* ja *taloudellinen ahdinko* määritelmät vaihtelivat tutkimusten välillä; osa ennusti juridista maksukyylyttömyyttä (Jabeur et al. 2021), osa heikkoa kannattavuutta (Barboza & Altman 2024). Näiden syiden vuoksi tämän työn tuloksia ei tulisi tulkita yksittäisten algoritmien ylivoimaisuudeksi vaan menetelmäryhmien suhteellisena paremmuutena. Mainittujen rajoitteiden vaikutuksia mallien tarkkuuteen olisi syytä tutkia erikseen. Yleisestikin datan näkökulmien laajentamisen, esimerkiksi johdon pätevyyyteen tai vuosikertomusten tekstianalyysiin, vaikutuksia olisi syytä tarkastella.

Kehittyneiden koneoppimismenetelmien käytännön soveltamiseen liittyy myös haasteita. Mitä monimutkaisempi malli sen epätodennäköisempää on, että se ymmärretään alalla ja sitä pystytään replikoimaan käytäntöön (Altman & Hotchkiss 2019). Regulaattoreiden, luotonantajien, yritysten ja muiden sidosryhmien tulee ymmärtää mallin

päätöksentekoon vaikuttavia tekijöitä (Zhang et al. 2022; Liu et al. 2023; Deng et al. 2025). Muun muassa Zhang et al. (2022) ja Lin et al. (2025) pyrkivät tutkimuksissaan vastaamaan myös tähän ongelmaan XAI (explainable artificial intelligence)-tekniikoilla. Näiden tekniikoiden käyttöä olisi syytä tarkastella tarkemmin.

Työssä havaittiin, että erityisesti ensemble-menetelmät ja syväoppimissovellukset saavuttavat korkeaa suorituskkyä. Näitä ei oltu kuitenkaan verrattu keskenään aineiston tutkimuksissa, mikä korostaa tarvetta jatkotutkimukselle, jossa nämä menetelmäryhmät asetettaisiin tasapuoliseen vertailuun keskenään.

LÄHTEET

- Alaka, H.A. *et al.* (2018) "Systematic review of bankruptcy prediction models: Towards a framework for tool selection," *Expert Systems with Applications*, 94, pp. 164–184. Available at: <https://doi.org/10.1016/j.eswa.2017.10.040>.
- Alam, N., Gao, J. and Jones, S. (2021) "Corporate failure prediction: An evaluation of deep learning vs discrete hazard models," *Journal of International Financial Markets, Institutions and Money*, 75, p. 101455. Available at: <https://doi.org/10.1016/j.intfin.2021.101455>.
- Alpaydm, E. (2020) *Introduction to machine learning*. Fourth edition. Cambridge, Massachusetts London: The MIT Press (Adaptive computation and machine learning).
- Altman, E.I. (1968) "FINANCIAL RATIOS, DISCRIMINANT ANALYSIS AND THE PREDICTION OF CORPORATE BANKRUPTCY," *The Journal of Finance*, 23(4), pp. 589–609. Available at: <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>.
- Altman, E.I. and Hotchkiss, E. (2006) *Corporate financial distress and bankruptcy: predict and avoid bankruptcy, analyze and invest in distressed debt, third edition*. 3rd ed. Hoboken, N.J: Wiley (Finance professional collection).
- Altman, E.I. and Hotchkiss, E. (2019) *Corporate financial distress, restructuring, and bankruptcy: analyze leveraged finance, distressed debt, and bankruptcy*. Fourth edition. Hoboken, New Jersey: John Wiley & Sons, Inc (Wiley finance series).
- Aydin, N. *et al.* (2022) "Prediction of financial distress of companies with artificial neural networks and decision trees models," *Machine Learning with Applications*, 10, p. 100432. Available at: <https://doi.org/10.1016/j.mlwa.2022.100432>.
- Barboza, F. and Altman, E. (2024) "Predicting financial distress in Latin American companies: A comparative analysis of logistic regression and random forest models," *The North American Journal of Economics and Finance*, 72, p. 102158. Available at: <https://doi.org/10.1016/j.najef.2024.102158>.
- Barboza, F., Kimura, H. and Altman, E. (2017) "Machine learning models and bankruptcy prediction," *Expert Systems with Applications*, 83, pp. 405–417. Available at: <https://doi.org/10.1016/j.eswa.2017.04.006>.
- Ben Jabeur, S. and Serret, V. (2023) "Bankruptcy prediction using fuzzy convolutional neural networks," *Research in International Business and Finance*, 64, p. 101844. Available at: <https://doi.org/10.1016/j.ribaf.2022.101844>.
- Bragoli, D. *et al.* (2022) "Machine-learning models for bankruptcy prediction: do industrial variables matter?," *Spatial Economic Analysis*, 17(2), pp. 156–177. Available at: <https://doi.org/10.1080/17421772.2021.1977377>.
- Breiman, L. (2001) "Random Forests," *Machine Learning*, 45(1), pp. 5–32. Available at: <https://doi.org/10.1023/A:1010933404324>.
- Cao, Y. *et al.* (2024) "Bankruptcy forecasting — Market information with ensemble model," *The British Accounting Review*, p. 101530. Available at: <https://doi.org/10.1016/j.bar.2024.101530>.
- Carbonneau, R., Laframboise, K. and Vahidov, R. (2008) "Application of machine learning techniques for supply chain demand forecasting," *European Journal of Operational Research*, 184(3), pp. 1140–1154. Available at: <https://doi.org/10.1016/j.ejor.2006.12.004>.
- Chen, T. and Guestrin, C. (2016) "XGBoost: A Scalable Tree Boosting System," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. KDD '16: The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco California USA: ACM, pp. 785–794. Available at: <https://doi.org/10.1145/2939672.2939785>.

- Dasilas, A. and Rigani, A. (2024) "Machine learning techniques in bankruptcy prediction: A systematic literature review," *Expert Systems with Applications*, 255, p. 124761. Available at: <https://doi.org/10.1016/j.eswa.2024.124761>.
- Deng, S. *et al.* (2025) "Financial distress warning and risk path analysis for Chinese listed companies: An interpretable machine learning approach," *Economic Modelling*, 152, p. 107288. Available at: <https://doi.org/10.1016/j.econmod.2025.107288>.
- Elhoseny, M. *et al.* (2025) "Deep Learning-Based Model for Financial Distress Prediction," *Annals of Operations Research*, 345(2–3), pp. 885–907. Available at: <https://doi.org/10.1007/s10479-022-04766-5>.
- Freund, Y. and Schapire, R.E. (1997) "A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting," *Journal of Computer and System Sciences*, 55(1), pp. 119–139. Available at: <https://doi.org/10.1006/jcss.1997.1504>.
- Friedman, J.H. (2001) "Greedy function approximation: A gradient boosting machine.," *The Annals of Statistics*, 29(5). Available at: <https://doi.org/10.1214/aos/1013203451>.
- Hastie, T.J., Tibshirani, R. and Friedman, J.H. (2009) *The elements of statistical learning: data mining, inference, and prediction*. 2nd ed. New York: Springer (Springer series in statistics).
- Hotchkiss, E.S. *et al.* (2008) "Bankruptcy and the Resolution of Financial Distress," *SSRN Electronic Journal* [Preprint]. Available at: <https://doi.org/10.2139/ssrn.1086942>.
- Huang, Y., Wang, Z. and Jiang, C. (2024) "Diagnosis with incomplete multi-view data: A variational deep financial distress prediction method," *Technological Forecasting and Social Change*, 201, p. 123269. Available at: <https://doi.org/10.1016/j.techfore.2024.123269>.
- Jabeur, S.B. *et al.* (2021) "CatBoost model and artificial intelligence techniques for corporate failure prediction," *Technological Forecasting and Social Change*, 166, p. 120658. Available at: <https://doi.org/10.1016/j.techfore.2021.120658>.
- Jackson, R.H.G. and Wood, A. (2013) "The performance of insolvency prediction and credit risk models in the UK: A comparative study," *The British Accounting Review*, 45(3), pp. 183–202. Available at: <https://doi.org/10.1016/j.bar.2013.06.009>.
- Janiesch, C., Zschech, P. and Heinrich, K. (2021) "Machine learning and deep learning," *Electronic Markets*, 31(3), pp. 685–695. Available at: <https://doi.org/10.1007/s12525-021-00475-2>.
- Jordan, M.I. and Mitchell, T.M. (2015) "Machine learning: Trends, perspectives, and prospects," *Science*, 349(6245), pp. 255–260. Available at: <https://doi.org/10.1126/science.aaa8415>.
- Kämäräinen, J. (2023) *Koneoppimisen perusteet*. Helsinki: Otatiето.
- Kirkos, E. (2015) "Assessing methodologies for intelligent bankruptcy prediction," *Artificial Intelligence Review*, 43(1), pp. 83–123. Available at: <https://doi.org/10.1007/s10462-012-9367-6>.
- Le, T. (2022) "A comprehensive survey of imbalanced learning methods for bankruptcy prediction," *IET Communications*, 16(5), pp. 433–441. Available at: <https://doi.org/10.1049/cmu2.12268>.
- Lin, Y.-C. *et al.* (2025) "Bankruptcy prediction: Integration of convolutional neural networks and explainable artificial intelligence techniques," *International Journal of Accounting Information Systems*, 56, p. 100744. Available at: <https://doi.org/10.1016/j.accinf.2025.100744>.
- Liu, Jiaming *et al.* (2023) "Interpreting the prediction results of the tree-based gradient boosting models for financial distress prediction with an explainable machine learning approach," *Journal of Forecasting*, 42(5), pp. 1112–1137. Available at: <https://doi.org/10.1002/for.2931>.
- Machado, M.R., Chen, D.T. and Osterrieder, J.R. (2025) "An analytical approach to credit risk assessment using machine learning models," *Decision Analytics Journal*, 16, p. 100605. Available at: <https://doi.org/10.1016/j.dajour.2025.100605>.

- Nazareth, N. and Ramana Reddy, Y.V. (2023) "Financial applications of machine learning: A literature review," *Expert Systems with Applications*, 219, p. 119640. Available at: <https://doi.org/10.1016/j.eswa.2023.119640>.
- Odom, M.D. and Sharda, R. (1990) "A neural network model for bankruptcy prediction," in *1990 IJCNN International Joint Conference on Neural Networks. 1990 International Joint Conference on Neural Networks*, San Diego, CA, USA: IEEE, pp. 163–168 vol.2. Available at: <https://doi.org/10.1109/IJCNN.1990.137710>.
- Ohlson, J.A. (1980) "Financial Ratios and the Probabilistic Prediction of Bankruptcy," *Journal of Accounting Research*, 18(1), p. 109. Available at: <https://doi.org/10.2307/2490395>.
- Papíková, L. and Papík, M. (2024) "Application of intellectual capital in SME bankruptcy," *Applied Economics*, 56(55), pp. 7317–7338. Available at: <https://doi.org/10.1080/00036846.2023.2281291>.
- Ravi Kumar, P. and Ravi, V. (2007) "Bankruptcy prediction in banks and firms via statistical and intelligent techniques – A review," *European Journal of Operational Research*, 180(1), pp. 1–28. Available at: <https://doi.org/10.1016/j.ejor.2006.08.043>.
- Sehgal, S. *et al.* (2021) "On the determinants and prediction of corporate financial distress in India," *Managerial Finance*, 47(10), pp. 1428–1447. Available at: <https://doi.org/10.1108/MF-06-2020-0332>.
- Shi, Y. and Li, X. (2019) "A bibliometric study on intelligent techniques of bankruptcy prediction for corporate firms," *Heliyon*, 5(12), p. e02997. Available at: <https://doi.org/10.1016/j.heliyon.2019.e02997>.
- Shumway, T. (2001) "Forecasting Bankruptcy More Accurately: A Simple Hazard Model," *The Journal of Business*, 74(1), pp. 101–124. Available at: <https://doi.org/10.1086/209665>.
- Vafeiadis, T. *et al.* (2015) "A comparison of machine learning techniques for customer churn prediction," *Simulation Modelling Practice and Theory*, 55, pp. 1–9. Available at: <https://doi.org/10.1016/j.simpat.2015.03.003>.
- Wu, D., Ma, X. and Olson, D.L. (2022) "Financial distress prediction using integrated Z-score and multilayer perceptron neural networks," *Decision Support Systems*, 159, p. 113814. Available at: <https://doi.org/10.1016/j.dss.2022.113814>.
- Zhang, Z. *et al.* (2022) "An explainable artificial intelligence approach for financial distress prediction," *Information Processing & Management*, 59(4), p. 102988. Available at: <https://doi.org/10.1016/j.ipm.2022.102988>.
- Zhao, Z., Li, D. and Dai, W. (2023) "Machine-learning-enabled intelligence computing for crisis management in small and medium-sized enterprises (SMEs)," *Technological Forecasting and Social Change*, 191, p. 122492. Available at: <https://doi.org/10.1016/j.techfore.2023.122492>.
- Zhou, Z.-H. (2025) *ENSEMBLE METHODS: foundations and algorithms*. Second edition: CHAPMAN & HALL CRC (Chapman & Hall/CRC machine learning & pattern recognition).

LIITE A: KIRJALLISUUSKATSAUKSEN ARTIKKELIT

Lähde	Otsikko	Julkaisupaikka	JUF O	Pääasiallisesti käytetty menetelmä	Muut ennustusmenetelmät	Käytetyn datan jakauma ja alue	Ennustusintervalli	Suorituskyvyn mittarit	Tulokulma / Sovellus	Artikkelin lyhyt kuvaus
(Alam et al. 2021)	Corporate failure prediction: An evaluation of deep learning vs discrete hazard models	Journal of International Financial Markets, Institutions and Money	1	Deep learning	Deep learning, discrete hazard model	Yhdysvallat: (ei kerrottu)	1 vuosi	ACC	Panel data	Verrataan syväoppimista ja hazard-malleja "panel data" kontekstissa
(Aydin et al. 2022)	Prediction of financial distress of companies with artificial neural networks and decision trees models	Machine learning with applications	1	ANN, DT	ANN (MLP), DT (CHAID)	Turkki: (ei kerrottu)	1 vuosi	ACC, Precision, sensitivity	Räätälöinti eri sektoreille	Ennustettiin taloudellista ahdinkoa käyttäen neuroverkkoja ja päätöspuita hyödyntäen mallien räätälöintiä eri sektoreille.
(Barboza & Altman 2024)	Predicting financial distress in Latin American companies: A comparative analysis of logistic regression and random forest models	North american journal of economics and finance	1	RF	LR, RF	latinalainen amerikka:: (ei kerrottu)	1-3 vuotta	AUC, ACC, Type I ja II errors, Brier Score	Taloudellisen ahdingon kynnys	Ennustetaan taloudellista ahdinkoa verraten logistista regressiota ja satunnaismetsiä
(Ben Jabeur & Serret 2023)	Bankruptcy prediction using fuzzy convolutional neural networks	Research in International Business and Finance	1	FCNN	FCNN, verrattu DA, LR, SVM, PLS-DA, NN, CNN,	Ranska: (133/133)	1-3 vuotta	ACC, AUC, F-Score, GM, YI, MCC	Fuzzy-set muuttujanvalinta	Konkurssin ennustus yhdistäen fuzzy-set teorian muuttujanvalintaa konvoluutioneuroverkkoihin.
(Bragoli et al. 2022)	Machine-learning models for bankruptcy prediction: do industrial variables matter?	Spatial Economic Analysis	1	Ei varsinaista	XGBoost, NN, RF, WLR (weighted logistic regression)	Italia: (5560/64749)	1 vuosi	True positives, True negatives	Toimialamuuttujien vaikutus	Tutkittiin miten toimialamuuttujien yhdistäminen tunnuslukuihin mallien ennustustarkkuutta
(Cao et al. 2024)	Bankruptcy forecasting — Market information with ensemble model	The British Accounting Review	2	Oma Ensemble-malli	Stacking Ensemble (Boosted Tree, RF, kNN, NN), AdaBoost, CatBoost, XGBoost, LightGBM, NN	Yhdysvallat: (746/19377)	1-3 vuotta	AUC, F1, Recall, Specificity	Stacking-ensemble	Luodaan uusi stacking-ensemble malli konkurssin ennustamiseen laajentaen tarkastelua hinnoittelutekijöihin (asset pricing factors)
(Deng et al. 2025)	Financial distress warning and risk path analysis for Chinese listed companies: An interpretable machine learning approach	Economic modelling	1	XGBoost	XGBoost, SVM, RF, ANN	Kiina: (515/515)	1-3 vuotta	Acc, false omission, true positive, false positive rates	XAI-tekniikat	Lisätään XGBoost mallin läpinäkyvyyttä yhdistämällä käyttöön XAI-tekniikoita.
(Elhoseny et al. 2025)	Deep Learning-Based Model for Financial Distress Prediction	Annals of Operations Research	1	AWOA-DL	Deep Neural Network (DNN), LR	Australia: (383/307), Analects: (25/25), Polish: (495/10008), Taiwanese (220/6599).	1 vuosi	Precision, recall, accuracy, F-Score, Kappa	Hyödynnetään AWOAa syväoppimismallin hyperparametrien optimointiin	Yhdistetään AWOA hyperparametrien optimointia syväoppimiseen ja kehitetään uudenlainen ahdingon ennustusmalli.

(Huang et al. 2024)	Diagnosis with incomplete multi-view data: A variational deep financial distress prediction method	Technological Forecasting and Social Change	3	Oma VDFDP	LR, RF, SVM, MLP, oma VDFDP	Kiina: (98/4018)	1 vuosi	AUC, KS	Moniulotteinen ja puutteellinen data	Rakennetaan oma VDFDP malli, joka menestyy erityisesti puuttellisessa ja moniulotteisessa datassa
(Jabeur et al. 2021)	CatBoost model and artificial intelligence techniques for corporate failure prediction	Technological Forecasting and Social Change	3	CatBoost	DA, LR, SVM, NN, RF, GBM, DNN, XGBoost, CatBoost	Ranska: (133/133)	1-3 vuotta	ACC, AUC	CatBoost	Ennustetaan konkurssia käyttäen CatBoost mallia ja verrataan sitä muihin alalla käytettyihin menetelmiin.
(Lin et al. 2025)	Bankruptcy prediction: Integration of convolutional neural networks and explainable artificial intelligence techniques	International Journal of Accounting Information Systems	1	CNN	CNN	Yhdysvallat: FS0:(5301/15121), FS1:(1:1), FS2(1:2),FS3:(2:1), FS4:(1:1)	1 vuosi	ACC, Kappa, precision, recall, F	XAI-tekniikat	Ennustetaan konkurssia yhdistäen konvoluutioneuroverkkoihin XAI-tekniikoita.
(Liu et al. 2023)	Interpreting the prediction results of the tree-based gradient boosting models for financial distress prediction with an explainable machine learning approach	Journal of Forecasting	1	Ei varsinaista	RF, bagging-DT, AdaBoost.DT, GBDT, XGBoost, LightGBM, CatBoost), LR, SVM, NN, RF	Kiina: (1501/1501)	1-5 vuotta	ACC, AUC, F1-Score, Gmean	Puupohjaiset koneoppimismallit	Vertaillaan erilaisia puupohjaisia gradient boosting malleja ja monia muita koneoppimismalleja ja yhdistetään mallien käyttöön XAI tekniikoita.
(Machado et al. 2025)	An analytical approach to credit risk assessment using machine learning models	Decision analytics Journal	1	Ei varsinaista	LDA, LR, DT, SVM, RF, Gboost, XGBoost, ANN	Alankomaat: (0,8%/99,2%)	6 kuukautta	ACC, AUC, F1, MCC, Sensitivity, Precision	Pankin luottotappioriski	Ennustetaan pankin kannalta negatiivisia asiakkasirtymisiä suuressa hollantilaisen pankin asiakkaiden keskuudessa
(Papikova & Papik 2024)	Application of intellectual capital in SME bankruptcy	Applied Economics	1	XGBoost	XGBoost, CatBoost	Slovakia: (71/53932)	1-5 vuotta	AUC, sensitivity, specificity	Henkisen pääoman yhdistäminen tunnuslukuihin	Käytetään kehittyneitä XGBoost ja CatBoost malleja ja yhdistetään henkistä pääomaa kuvaavia ominaisuuksia tukemaan perinteisiä taloudellisia tunnuslukuja konkurssin ennustamisessa PK-yrityksille
(Sehgal et al. 2021)	On the determinants and prediction of corporate financial distress in India	Managerial Finance	1	Ei varsinaista	SVM, ANN, Logit	Intia: (ei kerrottu)	1 vuotta	ACC	Kehittyvät markkinat (emerging markets)	Pyritään kehittämään ennustusmalli nimenomaan kehittyville markkinoille.
(Wu et al. 2022)	Financial distress prediction using integrated Z-score and multilayer perceptron neural networks	Decision support systems	3	Z-score ANN hybrid	MLP-ANN, Z-score ja molemmat yhdistetty	Kiina: (293/16913)	1 vuosi	True positives, true negatives, false positives, false negatives	Z-score ja MLP-ANN yhdistäminen	Ennustetaan ahdinkoa yhdistäen Altmanin Z-score mallia ja neuroverkoja.
(Zhang et al. 2022)	An explainable artificial intelligence approach for financial distress prediction	Information Processing and Management	3	Ei varsinaista	LightGBM, LR, DT, SVM, RF, XGBoost	Kiina: (1130/1130)	1 vuosi	ACC, AUC, KS, Precision recall, f1	Mallien toimintaa selittävät XAI-tekniikat	Esitellään ja rakennetaan uusi prosessi ensemble-malli johon yhdistetään XAI-tekniikoita selittämään mallin toimintaa tunnistetuille pääsidosryhmille
(Zhao et al. 2023)	Machine-learning-enabled intelligence computing for crisis management in small	Technological Forecasting and Social Change	3	Ei varsinaista	LR, NN, XGBoost, Stacking fusion method kaikista	Kiina: (30/90)	1 vuosi	AUC, Recall, sensitivity	PK-yritykset	Kehitetään järjestelmä varoit-tamaan PK-yrityksiä taloudel-lisesta ahdingosta.

LIITE B: TALOUDELLISEN AHDINGON JA KONKURSSIN ENNUSTAMISMENETELMIEN SUORITUSKYKY AINEISTOSSA ENNUSTETTAESSA YHDEN VUODEN PÄÄHÄN

		Neuroverkot												Ensemble												Tilastolliset menetelmät																																	
		NN			CNN			Deep Learning			SVM			DT			XGBost			RF			LightGBM			AdaBoost			CatBoost			GBM			GBDT			Bagging ensemble			Stacking ensemble			DA			DMM			LR			VOPFD						
	Alueiston jakuma	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC	ACC	Recall	AUC							
Alam et al.	Turkki: (ei kerrottu)	0.9233	1					0.912	0.9371																																																		
Aydın et al.	Turkki: (ei kerrottu)																																																										
Barboza & Alnan	Latinalainen amerikka: (ei kerrottu)																																																										
Bragoli et al.	Italia: (560/64749)			0.8467																																																							
Cao et al.	Yhdysvallat: (746/19377)			0.8374	0.861																																																						
Deng et al.	Kiina: (515/515)	0.7346	0.8197								0.7908	0.7676					0.8575	0.8497		0.8396	0.8497					0.9878	0.9971		0.8735	0.9574		0.9887	0.9949					0.9902	0.9972																				
Ehoseny et al.	Astoria: (283/207), Analects: (25/25), Poilin: (495/10008), Tawarasa (220/6599)																																																										
Huang et al.	Kiina: (98/4018)				0.76																																																						
Jabeur et al.	Ranska: (133/133)	0.9103		0.948				0.7179	0.506	0.8846	0.951							0.9359	0.931	0.9359	0.939																																						
Ben Jabeur & Serret	Ranska: (133/133)	0.8947	0.89	0.95	0.921	0.95	0.95				0.9022	0.91	0.902																																														
Lin et al.	Yhdysvallat: FS0:(5301/15121), FS1:(1-1), FS2:(1-2), FS3:(2-1), FS4:(1-1)																																																										
Lin et al.	Kiina: (1501/1501)	0.872		0.872							0.865	0.865					0.931	0.931	0.929	0.929	0.931				0.914	0.914	0.933	0.933																															
Machado et al.	Alankomaat: (0.8%99,2%)	0.963	0.964	0.873	0.961	0.982	0.667				0.927	0.203	0.648	0.911	0.231	0.688	0.914	0.561	0.879	0.93	0.582	0.893							0.935	0.23	0.737																												
Papikova ja Zsig	Slovakia: (71/33932)																																																										
Sehgal et al.	India: (ei kerrottu)			0.7773																																																							
Wu et al.	Kiina: (293/6913)			0.9826	0.0106																																																						
Zhao et al.	Kiina: (30/90)			0.785	0.76																																																						
Zhang et al.	Kiina: (1130/1130)										0.701	0.811	0.879	0.799	0.69	0.753	0.835	0.808	0.9135	0.832	0.811	0.893	0.847	0.814	0.918				0.914	0.8735	0.9357	0.9537	0.8422	0.9411	0.9291	0.23	0.844	0.936	#####	0.936	0.919	#####	0.919	#####	0.9902	0.9972		0.8831	0.6138	0.8578	0.933	0.8095	#####	0.8349	0.7351	0.8117	#####	0.7883	#####
	Keskivert	0.891	0.5917	0.8114	0.9403	0.846	0.961	0.8846	0.9152	0.506	0.839	0.6729	0.8176	0.8669	0.6287	0.7205	0.8947	0.8353	0.9042	0.8918	0.8036	0.881	0.889	0.9009	0.9487	0.914	0.8735	0.9357	0.9537	0.8422	0.9411	0.9291	0.23	0.844	0.936	#####	0.936	0.919	#####	0.919	#####	0.9902	0.9972		0.8831	0.6138	0.8578	0.933	0.8095	#####	0.8349	0.7351	0.8117	#####	0.7883	#####			

