Tampereen yliopisto

Teija Taimela

TEKOÄLYN HYÖDYNTÄMINEN LUOTTORISKIANALYYSISSA

Informaatioteknologian ja viestinnän tiedekunta
Kandidaattitutkielma
Toukokuu 2026

TIIVISTELMÄ

Teija Taimela: Tekoälyn hyödyntäminen luottoriskianalyysissa
Kandidaattitutkielma
Tampereen yliopisto
Tietojenkäsittelytieteiden tutkinto-ohjelma
Toukokuu 2026

Luottoriskianalyysi on tärkeä osa rahoituslaitosten toimintaa, sillä se voi parhaimmillaan estää kokonaisten liikepankkien kaatumisen tai pienentää finanssikriisin muodostumisen riskiä. Tämän vuoksi luotettavien luottoriskianalyysimenetelmien kehittäminen on tärkeää. Rahoitusmarkkinoiden monimutkaisuus ja saatavilla olevan datan suuri määrä kuitenkin vaikeuttavat luottoriskianalyysin tekemistä perinteisillä menetelmillä.

Tämä kirjallisuuskatsauksena toteutettu tutkielma tarkastelee tekoälyn roolia ja tehokkuutta luottoriskianalyysissa. Tutkielman keskiössä ovat syväoppiminen ja muut kehittyneemmät koneoppimismenetelmät. Työssä pohditaan tekoälyn mahdollisuuksien lisäksi sen rajoitteita.

Tuloksista käy ilmi, että kehittyneemmät koneoppimismenetelmät tehostavat luottoriskianalyysia, ja pystyvät huomioimaan monimutkaisempia yhteyksiä, mihin perinteiset luottoriskianalyysimenetelmät eivät kykene. Tutkimuksissa raportoidut ennustetarkkuudet vaihtelivat noin 85–99 %:n välillä, riippuen käytetystä menetelmästä ja aineistosta. Rahoituslaitosten mahdollisuus hyödyntää näitä menetelmiä voi kuitenkin riippua organisaation resursseista ja saatavilla olevasta datan määrästä. Erityisesti syväoppivat menetelmät tarvitsevat paljon dataa. Tällä hetkellä ei ole olemassa yhtä tiettyä oikeaa mallia, joka sopisi kaikkien rahoituslaitosten tarpeisiin.

Avainsanat: luottoriskianalyysi, tekoäly, koneoppiminen, syväoppiminen

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:

Tekoälysovellusten nimet ja versiot: ChatGPT-5.2

Käyttötarkoitus: Hyödynsin tekoälyä tutkielman kirjoittamisen alkuvaiheessa tutkielman rakenteen suunnittelun apuvälineenä. Esitin tekoälylle aiheideoita, jonka perusteella tekoäly ehdotti erilaisia alustavia sisällysluetteloita. Tämä auttoi hahmottamaan työn kokonaisuutta ja muokkaamaan siitä lopullisen valmiin rakenteen.

Osiot, joissa tekoälyä on käytetty: sisällysluettelo

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

SISÄLLYSLUETTELO

1 Johdanto 1

2 Tekoäly 2

2.1 Koneoppiminen 2

2.2 Syväoppiminen 3

3 Luottoriskianalyysi 5

4 Tekoäly luottoriskianalyysissa 6

4.1 Tekoälymallien hyödyntäminen luottoriskin arvioinnissa 6

4.2 Mallien vertailu ja ennustetarkkuus 7

4.3 Tekoälyn hyödyt ja haasteet luottoriskianalyysissa 10

5 Keskustelu 12

6 Yhteenveto 13

Lähdeluettelo 14

1 Johdanto

Luottoluokitus on keskeinen osa pankkien ja muiden rahoituslaitosten päivittäistä päätöksentekoa. Luottoriskianalyysi muodostuu luokittelumenetelmistä sekä niitä tukevista laskennallisista työkaluista, joiden avulla pankit arvioivat luottokelpoisuutta ja vähentävät toimintaansa liittyviä riskejä (Chang et al., 2025). Nykyaikaiset rahoitusjärjestelmät perustuvat luottoon ja luottamukseen. Luottoriski on keskeinen suure, jonka avulla mitataan ja ennustetaan velallisen maksukyvyttömyyden todennäköisyyttä. Luottoriskin oikea arviointi on siis koko rahoitusjärjestelmän toiminnan kannalta ratkaisevaa. Luottoriskin arvioinnin epäonnistuminen voi johtaa järjestelmätason häiriöihin, kuten vuoden 2008 finanssikriisiin (Shi et al., 2022).

Tämän työn tavoitteena on tutkia, miten tekoälyä, erityisesti kehittyneitä koneoppimisen menetelmiä sekä eri yhdistelmämalleja, voidaan hyödyntää tehokkaasti luottoriskianalyysissa. Lisäksi työssä perehdytään perinteisiin luottoriskianalyysin malleihin ja vertaillaan niitä uudempiin ja kehittyneempiin tekoälymenetelmiin. Perinteiset luottoriskin arviointimenetelmät, vaikka ne ovatkin jossain määrin tehokkaita, eivät usein pysty kuvaamaan nykyaikaisten rahoitusmarkkinoiden monimutkaisuutta (Chang et al., 2025). Tämän vuoksi kehittyneempien työkalujen ja menetelmien tarve ovat kasvaneet. Tässä työssä aihetta tarkastellaan teknisestä näkökulmasta, eli analysoidaan syväoppimismenetelmien ja muiden kehittyneempien koneoppimismenetelmien sekä niitä tukevien tekniikoiden hyödyntämistä luottoriskianalyysissa.

Tässä työssä tutkimusmenetelmänä on kirjallisuuskatsaus. Tutkimusaineisto on kerätty etsimällä aiheeseen liittyviä tieteellisiä vertaisarvioituja artikkeleita. Tutkimusmateriaali on kerätty käyttämällä Andor, Computer Science Database, ScienceDirect, Google Scholar ja ACM Digital Library -tietokantoja. Hauissa on muun muassa käytetty kyselyitä ”deep learning AND credit risk” ja ”machine learning AND credit risk” sekä hakusanoja ”credit risk assessment” ja ”luottoriskianalyysi”.

Hakujen jälkeen aineistosta valittiin mukaan ne artikkelit, jotka käsittelevät tekoälyn, koneoppimisen ja syväoppimisen soveltamista luottoriskin arvioinnissa. Vaikka työssä käytettiin myös vanhempia lähteitä käsitteiden ja luottoriskin teorian määrittelyyn, pyrittiin tutkimusten vertailussa hyödyntämään mahdollisimman uusia, viimeisen kymmenen vuoden aikana julkaistuja artikkeleita.

Tutkielman alussa selitetään syvällisemmin käsitteet tekoäly, koneoppiminen ja syväoppiminen. Luvussa 3 selitetään luottoriski käsitteenä sekä käydään läpi perinteisiä luottoriskianalyysimenetelmiä. Luvussa 4 tarkastellaan aiheeseen liittyviä tutkimuksia. Luvussa vertaillaan kuutta eri tutkimusta sekä käsitellään kehittyneempien luottoriskianalyysimenetelmien hyötyjä, haittoja sekä pohditaan mahdollista jatkokehitystä. Luvussa 5 nostetaan esiin tärkeimmät tutkimuksissa saadut tulokset ja arvioidaan niiden merkittävyyttä. Tutkielma päättyy yhteenvetoon, jossa käsitellään vielä tutkimusten keskeisimmät asiat.

2 Tekoäly

Termi tekoäly on ollut käytössä jo 1950-luvulta lähtien. Tekoälyllä tarkoitetaan koneen kykyä jäljitellä ihmisen älykkyyttä ja suorittaa tehtäviä, jotka normaalisti edellyttäisivät ihmisen kognitiivisia kykyjä, kuten päättelyä ja ongelmanratkaisua (Russell & Norvig, 2010). Nykyään tekoälyä käytetään laajasti eri aloilla, kuten terveydenhuollossa ja rahoitusalalla. Tekoälyn kehitys on lisännyt mahdollisuuksia automatisoida monimutkaisia tehtäviä, mutta samalla se muuttaa monien ammattien luonnetta ja vaatii ihmisiltä uusien taitojen hankkimista. Monet nykyaikaiset tekoälysovellukset perustuvat erityisesti koneoppimiseen ja syväoppimiseen (Sheikh et al., 2023). Nämä oppimismenetelmät hyödyntävät suuria määriä dataa ja erilaisia algoritmeja tehdäkseen ennusteita ja päätöksiä datan perusteella. Kone- ja syväoppimista käsitellään tarkemmin seuraavissa alaluvuissa.

2.1 Koneoppiminen

Koneoppiminen (engl. machine learning) on tekoälyn menetelmä, joka parantaa ohjelmiston suorituskykyä aiemman tiedon ja kokemuksen myötä (Mitchell, 1997). Sen tavoitteena on automatisoida analyyttisten mallien rakentaminen, minkä vuoksi monet nykyiset tekoälyominaisuuksia tarjoavat älykkäät järjestelmät perustuvat usein koneoppimiseen. Koneoppiminen toteutetaan soveltamalla algoritmeja, jotka oppivat iteratiivisesti tehtäväkohtaisesta harjoitusdatasta. Näin tietokoneet voivat löytää piileviä yhteyksiä ja monimutkaisia rakenteita ilman, että niitä tarvitsee ohjelmoida erikseen jokaista yksityiskohtaa varten. Koneoppiminen soveltuu hyvin erityisesti moniulotteiseen dataan liittyviin tehtäviin, kuten luokitteluun ja regressioon. Oppimalla aiemmista laskelmista ja poimimalla

säännönmukaisuuksia suurista tietokannoista, koneoppiminen voi auttaa tuottamaan luotettavia ja toistettavia päätöksiä. Tästä syystä koneoppimisalgoritmeja on sovellettu menestyksekkäästi monilla eri aloilla, kuten luottoriskipetosten tunnistamisessa, luottoluokituksessa, puheen- ja kuvantunnistuksessa sekä luonnollisen kielen käsittelyssä. (Janiesch et al., 2021)

Eräs laajalti käytetty tehokas koneoppimisalgoritmi on päätöspuu (engl. decision tree), joka on suunniteltu ratkaisemaan regressio- ja luokitteluongelmia. Päätöspuu koostuu solmuista ja haaroista, joista juurisolmu eli ylin solmu, on algoritmin tärkeimmäksi katsoma ominaisuus. Algoritmi jakaa opetusaineiston ryhmiin tämän piirteen arvojen perusteella ja jatkaa puun rakentamista rekursiivisesti kussakin ryhmässä, kunnes puu on valmis. Puun haarat ilmaisevat algoritmin valitsemat ryhmittelysäännöt. Lehtisolmu sisältää luokitteluongelmissa ennustetun luokan ja regressio-ongelmissa selitettävän piirteen keskiarvon. Puun antama päätös saadaan selville kulkemalla puuta sääntöjä seuraamalla juurisolmusta lehtisolmuun (Mitchell, 1997). Päätöspuiden etuna on niiden helppo tulkittavuus, sillä mallin päätökset voidaan esittää selkeänä sääntöjoukkona. Piirteiden arvot voivat olla diskreettejä tai jatkuvia (Russell & Norvig, 2010).

Päätöspuita hyödynnetään myös kehittyneemmissä koneoppimismenetelmissä. Esimerkiksi gradienttitehostuspohjainen XGBoost-malli rakentaa sarjan päätöspuita, jossa jokainen uusi puu pyrkii korjaamaan edellisen tekemiä virheitä. Näin useista yksinkertaisista päätöspuista muodostuu yhdessä huomattavasti tarkempi malli (Chang et al., 2025). Päätöspuut ovat laskennallisesti tehokkaita, mutta alttiita ylisovittamiselle. Tämä on yleinen ongelma koneoppimisessa, joka täytyy huomioida myös päätöspuumallia opetettaessa. Ylisovittamista tapahtuu, kun malli mukautuu opetusdataan liian tarkasti. Tämän seurauksena tarkkuus voi heikentyä uuden datan kohdalla, koska malli oppii opetusdatan kohinan eikä kykene tunnistamaan olennaisia rakenteita tai riippuvuuksia (Mitchell, 1997; Russell & Norvig, 2010).

2.2 Syväoppiminen

Viime vuosikymmeninä koneoppimisen ala on tuonut mukanaan useita merkittäviä edistysaskeleita kehittyneissä oppimisalgoritmeissa ja tehokkaissa esikäsittelytekniikoissa. Yksi näistä edistysaskeleista oli keinotekoisten neuroverkkojen (engl. artificial neural network) kehitys kohti yhä useammista kerroksista koostuvia neuroverkkoarkkitehtuu-

reja, joilla on paremmat oppimisominaisuudet. Tällaisia verkkoja kutsutaan syviksi neuroverkoiksi (engl. Deep Neural Network, DNN), ja niissä voi olla satoja kerroksia. Syviin neuroverkkoihin perustuvaa koneoppimista kutsutaan syväoppimiseksi (engl. deep learning) (Goodfellow et al., 2016).

Neuroverkkojen kerrokset muodostavat hierarkkisen rakenteen, jossa alemmat kerrokset oppivat yksinkertaisempia piirteitä ja ylemmät kerrokset yhdistävät niitä monimutkaisemmiksi esityksiksi (Janiesch et al., 2021). Neuroverkkojen kerrokset ovat kytkettyjä toisiinsa, ja ne koostuvat syötekerroksesta, useista piilokerroksista sekä ulostulokerroksesta. Kukin kerros koostuu neuroneista. Syötekerros vastaanottaa raakadatan ja välittää sen piilokerroksille. Piilokerrokset analysoivat dataa edelleen, erottavat siitä olennaisia piirteitä ja välittää tuloksen seuraavalle kerrokselle. Neuroni saa siihen liittyviltä neuroneilta reaalilukuina esitettyjä signaaleja, joiden voimakkuutta säätelevät neuronien välisten yhteyksien eli synapsien painoarvot. Neuroni laskee painotetut signaaliarvot yhteen ja tuottaa summasta aktivointifunktion avulla lähtevän signaalin, joka välitetään seuraavan kerroksen neuroneille synapsien kautta. Kun dataa käsitellään ja siirretään kerroksesta toiseen, syvä neuroverkko muodostaa yhä korkeamman tason esityksiä datasta, jotka rakentuvat aiempien kerrosten tuottamiin yksinkertaisempiin esityksiin. Kun ulostulokerros saa viimeisen kerroksen tuottamat dataesitykset, se voi esimerkiksi luokitella datan ennalta määriteltyihin luokkiin. Täten järjestelmä kykenee oppimaan suuresta määrästä dataa monimutkaisia rakenteita sekä tunnistamaan erilaisia piirteitä automaattisesti. (Sheikh et al., 2023; Sun & Vasarhelyi, 2018). Mitä syvempi verkko on, sitä monimutkaisempia piirteitä se pystyy tunnistamaan. Tämä mahdollistaa moniulotteisten ilmiöiden mallintamisen ja tekee syväoppimisesta erityisen tehokkaan suurten ja monimuotoisten datakokonaisuuksien analysoinnissa (Janiesch et al., 2021). Tämän vuoksi syväoppimista käytetään esimerkiksi luonnollisen kielen käsittelyssä sekä kuvan- ja puheentunnistuksessa. Syväoppimismallit ovat monissa sovelluksissa parempia kuin pinnalliset koneoppimismallit ja perinteiset data-analyysimenetelmät. Viime vuosina syväoppimisen merkitys on kasvanut huomattavasti erityisesti suurten datamäärien ja lisääntyneen laskentatehon ansiosta (Sheikh et al., 2023).

Yksi syväoppimisen sovellus on luonnollisen kielen käsittely (engl. natural language processing), jossa pyritään mallintamaan ihmiskieltä (Janiesch et al., 2021). Viime vuosina luonnollisen kielen käsittelyssä on siirrytty kohti suuria kielimalleja (engl. large language models), jotka perustuvat suurilla tekstimäärillä opetettuihin syviin neuroverk-

koihin. Nämä mallit ovat parantaneet muun muassa keskustelubottien toimintaa. Kehittyneimmät suuret kielimallit ovat generoivia, esikoulutettuja transformer-malleja (engl. Generative Pre-trained Transformer, GPT), joita käytetään esimerkiksi ChatGPT-keskusteluboteissa. ChatGPT:n menestys on ollut ennennäkemätöntä ja se popularisoi sen taustalla olevan teknologian, erityisesti suurten kielimallien tutkimuksen (Alammar & Grootendorst, 2024).

3 Luottoriskianalyysi

Luottoriski määritellään lainanantajan kokemana riskinä, joka syntyy, jos oikeushenkilö tai velallinen organisaatio ei maksa lainaamaansa rahasummaa takaisin ehtojen mukaisesti. Luottoriski on yksi suurimmista rahoituslaitosten liiketoimintaan liittyvistä riskityypeistä, jonka vuoksi sen asianmukainen hallinta on tärkeää. Luottoriskiin vaikuttavat sekä suhdannevaihtelut että yrityskohtaiset tapahtumat. Tyypillisesti luottoriski pienenee talouden noususuhdanteessa, koska vahvat tulokset pitävät yleisen maksukyvyttömyysasteen alhaisena. Sen sijaan talouden laskusuhdanteessa luottoriski kasvaa, koska tulokset heikkenevät, mikä vaikeuttaa muun muassa lainojen takaisinmaksua. Yrityskohtainen luottoriski puolestaan liittyy yksittäisen yrityksen liiketoimintaan tai toimialaan liittyviin tapahtumiin eikä ensisijaisesti yleisiin suhdannevaihteluihin. (Neal, 1996)

Luottoriskin hallitsemiseksi pankit ja muut rahoituslaitokset hyödyntävät luottoanalyysia, joka on prosessi, jossa analysoidaan, onko lainanottaja kelpoinen luoton saajaksi. Luottoanalyysissa arvioidaan lainanottajan takaisinmaksuhalukkuus, lainanottajan kyky maksaa laina takaisin, lainanottajan taloudellinen vahvuus, lainanottajan vakuudeksi antamat varat sekä lainan taloudelliset olosuhteet ja erityisehdot. Prosessissa arvioidaan myös maksukyvyttömyyden todennäköisyyttä ja mahdollista taloudellista tappiota. (Celik, 2019)

Perinteiset luottoriskimallit ovat toimineet pitkään pankkitoiminnan luottoriskin arvioinnin selkärankana. Merkittävimpiä malleja ovat logistinen regressio, päätöspuut ja diskriminanttianalyysi (Chang et al., 2025). Logistinen regressio arvioi maksukyvyttömyyden todennäköisyyttä lainanottajien piirteiden perusteella. Soveltamalla logistista funktiota selittävien muuttujien lineaariseen yhdistelmään logistinen regressio tuottaa todennäköisyysarvon, jonka avulla lainanottajat voidaan luokitella eri riskiluokkiin (Chang et al., 2024). Päätöspuumallit (luku 2.1) luovat vuokaaviomaisen rakenteen, joka on intuitiivinen ja tarjoaa selkeän kuvan päätöksentekoprosessista. Tämän vuoksi päätöspuut

ovat erityisen hyödyllisiä käytännön sovelluksissa. (Mitchell, 1997; Wang et al., 2020). Diskriminanttianalyysi pyrkii löytämään selittävien muuttujien lineaarisen yhdistelmän, joka erottaa eri luokat mahdollisimman hyvin toisistaan. Diskriminanttianalyysi olettaa, että selittävät muuttujat noudattavat normaalijakaumaa, ja pyrkii maksimoimaan ryhmien välisen eron. Klassinen sovellus diskriminanttianalyysista luottoriskiluokitukseen on malli, jossa asiakkaat luokitellaan maksukykyisiin ja maksukyvyttömiin erottelufunktiota käyttäen (Thomas et al., 2002).

4 Tekoäly luottoriskianalyysissa

Perinteisten tilasto- ja koneoppimismenetelmien on havaittu olevan riittämättömiä luottotietojen muuttujien välisten monimutkaisten suhteiden selvittämiseen tietojen määrän kasvaessa (Shen et al., 2021). Tämän vuoksi yhä useammissa tutkimuksissa on tarkasteltu erilaisia kehittyneempiä koneoppimismenetelmiä, kuten syväoppimista, ja todettu niiden olevan suotuisia tapoja luottoriskin arviointiin ja laskemiseen. Tässä luvussa käsitellään kuutta eri tutkimusta, joissa luottoriskinanalyysissa käytetään näitä menetelmiä.

4.1 Tekoälymallien hyödyntäminen luottoriskin arvioinnissa

Monet maat ovat kiinnittäneet tarkkaa huomioita liikepankkien luottoriskien hallintaan, ja se on usein keskeinen huolenaihe rahoituslaitoksissa. Liikepankkeja koskevien selvityksien ja tutkimuksien mukaan suuri määrä hyvin toimivia liikepankkeja on kaatunut huonon luottoriskin hallinnan vuoksi (Liu, 2022). Lisäksi rahoitusmarkkinoihin vaikuttavat jatkuvasti erilaiset tapahtumat, kuten covid-19-tauti, inflaatio ja taantumat, jotka voivat horjuttaa asiakkaiden taloudellista vakautta. Epävakaassa taloustilanteessa hallitsematon tai huonosti hallittu luottoriski voi johtaa vakaviin taloudellisiin vaikeuksiin, jopa konkurssiin. Vaillinaisen luottoriskihallinnan seuraukset voivat olla katastrofaalisia ja vaikuttaa paitsi itse liiketoimintaan myös sidosryhmiin ja laajempaan rahoitusekosysteemiin (Chang et al., 2024).

Tekoälystä on tullut ratkaisevan tärkeä työkalu luottoriskin arvioinnissa, sillä luottoriski on luonteeltaan monimutkainen ja epävakaa ilmiö. Nykyisessä luottoriskin arviointityössä tarvitaan uusia teknologioita kompensoimaan vanhojen menetelmien puutteita. (Liu, 2022; Raji et al., 2024) Kaikki tämä havainnollistaa, miksi tekoälyä hyödynnetään yhä useammin luottoriskiarvioinnissa.

Luottoriskin arviointi voidaan pohjimmiltaan nähdä luokitteluongelmana. Luokittelumallin rakentaminen alkaa havaittujen sosioekonomisten muuttujien analysoinnilla, minkä jälkeen rakennetaan malli ja uudet luotonhakijat arvioidaan ja heidät luokitellaan ennalta määriteltyihin luottoluokkiin. Perinteisesti käytetyt tilastolliset menetelmät, kuten logistinen regressio ja diskriminanttianalyysi tuottavat luotettavia tuloksia vain, kun aineisto on luonteeltaan tietyn muotoinen. Tilastolliset mallit tekevät esimerkiksi riippumattomuus- ja jakaumaoletuksia. Nämä oletukset eivät kuitenkaan aina toteudu käytännössä, mikä voi johtaa harhaan arvioinnissa. Koneoppimisen on havaittu tarjoavan tehokkaita ratkaisuja luokittelutehtäviin ja koneoppimistekniikat, kuten neuroverkot, tukivektorikoneet (engl. support vector machine) sekä erilaiset päätöspuut, kuten luokittelu- ja regressiopuut (engl. classification and regression trees), ovat yleistyneet luottoriskijärjestelmissä. Viime aikoina rahoituslaitoksissa on sovellettu erityisesti syväoppivia neuroverkkoja (DNN), sillä ne kykenevät käsittelemään suuria määriä dataa sekä pystyvät paljastamaan luottotietomuuttujien välisiä monimutkaisia suhteita. (Shen et al., 2021; Sun & Vasarhelyi, 2018)

4.2 Mallien vertailu ja ennustetarkkuus

Shen et al. (2021) kehittivät uuden yhdistelmämenetelmän luottoriskin arviointiin. Tutkimuksessa yhdistettiin AdaBoost-algoritmi ja syväoppiva pitkän lyhytkestomuistin verkko (engl. Long Short-Term Memory, LSTM). Tavoitteena oli myös parantaa epätasapainoisten luokkien käsittelyä kehittämällä tehokkaampi menetelmä vähemmistöluokan havaintojen lisäämiseksi luottodataan. LSTM-verkkoa käytettiin tässä tutkimuksessa perusoppijana, koska sillä on saavutettu hyviä tuloksia finanssimarkkinoiden ennustamisessa. AdaBoost yhdisti useita LSTM-malleja monimalliyhdistelmäksi. Tämän avulla saatiin syväoppimiseen perustuva yhdistelmämenetelmä, joka tunnistaa luottoriskin tehokkaammin kuin useimmat muut yleisesti käytetyt luottoluokitusmenetelmät. Tutkimuksessa suoritettiin kokeita, joissa verrattiin ehdotettua mallia muihin luottoriskin arviointitekniikoihin. Mallien luokittelukyvyn mittarina käytettiin erottelukäyrän (engl. Receiver Operating Characteristic Curve, ROC) alaista pinta-alaa (engl. Area Under the Curve, AUC). AUC-arvo vaihtelee nollan ja yhden välillä. Malli kykenee erottelemaan luokkia sitä paremmin, mitä lähempänä arvo on ykköstä. Tämä on luottoluokituksessa laajasti käytetty suorituskykymittari. Mallien suorituskykyä arvioitiin kahdella eri datajoukolla, ja LSTM-malli saavutti korkeimmat AUC-arvot (0,803 ja 0,749) molemmissa tapauksissa.

Raji et al. (2024) vertailivat tutkimuksessaan perinteisiä luottoriskianalyysimenetelmiä uudempiin tekoälymenetelmiin. Perinteisiksi vertailumalleiksi he valitsivat logistisen regression ja päätöspuut, ja uudemmiksi menetelmiksi valikoituivat gradienttitehostus (engl. Gradient Boosting Machine, GBM) ja DNN. Tulokset osoittivat, että GBM- ja DNN-mallit ovat luottoriskianalyysissa tehokkaampia kuin perinteinen logistinen regressio. GBM ja DNN osoittautuivat logistista regressiota paremmaksi kaikilla tutkimuksissa käytetyillä mittareilla. GBM- ja DNN-menetelmien luokittelutarkkuudet olivat 85,0 % ja 88,0 %, ja DNN-menetelmän AUC-arvo oli 0,93.

Chang et al. (2024) tarkastelivat, miten koneoppimismalleja voidaan hyödyntää luottokorttiasiakkaiden luottoriskin ennustamisessa. Tutkimuksen tavoitteena oli tunnistaa asiakkaat, jotka eivät todennäköisesti kykene maksamaan velkojaan takaisin. Tutkimuksessa käytettiin luottokorttidataa, jota esikäsiteltiin poistamalla poikkeavia havaintoja ja valitsemalla tärkeimmät selittävät muuttujat. Tämän jälkeen aineistoon sovellettiin useita malleja, jotka olivat logistinen regressio, satunnaismetsä, LightGBM- ja AdaBoost-algoritmit, XGBoost ja neuroverkko. Tulosten perusteella XGBoost-malli suoriutui parhaiten kaikilla käytetyillä mittareilla. XGBoost-mallin luokittelutarkkuus oli 99,3 %, ja AUC-analyysin perusteella XGBoost suoriutui parhaiten luottoriskin luokittelussa. Tutkimuksen mukaan XGBoost-mallin parempi ennustetarkkuus voi auttaa pankkeja tekemään luotettavimpia luottopäätöksiä, mikä voi johtaa pienempiin luottotappioihin sekä tehokkaampaan riskienhallintaan.

Sun ja Vasarhelyi (2018) käyttivät tutkimuksessaan DNN-mallia, jonka avulla ennustettiin vakavia maksuhäiriöitä brasilialaisen pankin asiakasdatan perusteella. Data sisälsi henkilötietoja, kuten ikä, sukupuoli, tulot, asuinpaikka ja luottopisteet, kertynyttä tilitapahtumatietoa sekä kuukauden mittaista transaktiodataa. Tutkimuksessa käytetty DNN-malli koostui viidestä täysiin toisiinsa kytketystä kerroksesta, jotka olivat syötekerros, kolme piilokerrosta ja ulostulokerros. Syötekerros vastaanotti alkuperäisen asiakasdatan, piilokerrokset käsittelivät ja yhdistelivät tietoa, ja ulostulokerros tuotti lopullisen luokittelun siitä, oliko asiakas maksuhäiriöinen vai ei. Hyperparametrit, kuten piilotettujen kerrosten ja neuronien määrä sekä aktivointifunktiot, valittiin ristikkohakumenetelmällä optimaalisen suorituskyvyn saavuttamiseksi. Mallin suorituskykyä verrattiin perinteisiin menetelmiin, kuten tavallisiin neuroverkkoihin, naiiviin Bayes-luokitteluun, logistiseen regressioon ja päätöspuihin. Tulosten mukaan DNN suoriutui yleisesti paremmin kuin vertailumallit, ja sen luokittelutarkkuus oli 99,6 % ja AUC-arvo oli 0,92.

Liu (2022) tarkastelee tutkimuksessaan vastavirta-algoritmilla opetettuun neuroverkkoon perustuvaa mallia pankkien luottoriskin arvioinnissa. Tutkimuksen mukaan neuroverkko soveltuu hyvin luottoriskin mallintamiseen, koska se kykenee oppimaan aineistosta itsenäisesti, mukautumaan uusiin havaintoihin sekä käsittelemään epävarmuutta ja monimutkaisia epälineaarisia riippuvuuksia. Menetelmän etuna pidetään myös sitä, että se ei sisällä merkittäviä subjektiivisia oletuksia, mikä parantaa arvioinnin objektiivisuutta. Tutkimuksessa rakennettiin kokeellinen tietokanta yritysten taloudellisista tunnusluvuista, jonka pohjalta muodostettiin opetus- ja testausmallit. Tulosten perusteella malli paransi luottoriskin tunnistamisen tehokkuutta saavuttaen samalla yli 90 %:n ennustetarkkuuden. Mallin avulla pankit pystyvät arvioimaan yritysten luottoriskiä aiempaa tarkemmin, mikä tukee luottopäätöksentekoa sekä luottojen hinnoittelua. Lisäksi tutkimus korostaa, että mallia tulisi soveltaa yhdessä pankkien olemassa olevien riskienhallintamallien kanssa sekä pankkikohtaiseen historialliseen dataan perustuen.

Chang et al. (2025) vertailevat eri koneoppimisalgoritmeja luottoriskin ennustamisessa. Tutkimuksessa käytettiin muun muassa logistista regressiota, tukivektorikonetta, neuroverkkoja ja gradienttitehostuspohjaisia malleja. Tutkimuksessa hyödynnettiin ajantasaista ja laajaa aineistoa isobritannialaisten asiakkaiden pankkilainojen maksuhäiriöistä. Lisäksi tutkimuksessa arvioitiin, mitkä muuttujat vaikuttavat eniten tuloksiin. Tämä on relevanttia, koska pankki- ja finanssialalla sääntely vaatii päätösten läpinäkyvyyttä. Tutkimus yhdistää luottoriskianalyysin toimitusketjun rahoitukseen, mikä laajentaa näkökulmaa yksittäisestä asiakkaasta koko liiketoimintaverkostoon. Toimitusketjun rahoitus tarjoaa lainansiirtotapahtumia, jotka hyödyttävät kaikkia tähän ketjuun kuuluvia sidosryhmiä, mukaan lukien ostajaa, hankkijaa ja pankkia. Huono luottoriskin hallinta toimitusketjun rahoituksessa voi aiheuttaa tappioita rahoittajille. Koneoppimisalgoritmit ovat kuitenkin parantaneet merkittävästi luottoriskien ennustejärjestelmien tarkkuutta toimitusketjun rahoituksessa.

Chang et al. (2025) tulosten perusteella gradienttitehostuspohjainen malli suoriutui parhaiten verrattuna muihin malleihin, sen ennustetarkkuus oli 82,49 % ja AUC-arvo oli 0,66. Logistinen regressio sen sijaan pärjäsi huonoiten. Tuloksista nousi myös esiin, että miesasiakkailla oli suurempi todennäköisyys ajautua maksuhäiriöön verrattuna naisasiakkaisiin. Miehillä tämä todennäköisyys oli 14 % ja naisilla sen sijaan 9 %. Lisäksi 18–33-vuotiaat olivat kaikkein altteimpia maksuhäiriöille, kun taas 54-vuotiailla ja sitä vanhemmilla oli vähiten maksuhäiriöitä. Tutkimuksessa havaittiin myös, että epäjohdonmu-

kainen maksuhistoria vaikuttaa merkittävästi siihen, että ajautuuko asiakas maksuhäiriöön vai ei. Tutkijat esittävät, että koneoppimismalleja tulisi käyttää yhdessä selitettävän tekoälyn (engl. explainable AI) menetelmien kanssa, jotta voidaan paremmin ymmärtää taloudellisen riskin takana olevat tekijät.

4.3 Tekoälyn hyödyt ja haasteet luottoriskianalyysissa

Vaikka kehittyneemmät koneoppimismenetelmät suoriutuvat usein selvästi paremmin kuin perinteiset mallit, monissa aiemmissa tutkimuksissa on todettu, ettei mikään yksittäinen luokittelumenetelmä tuota parhaita tuloksia kaikissa tilanteissa. Tuoreimmissa tutkimuksissa onkin käytetty hybridi- ja yhdistelmämalleja luottoriskin arvioinnissa. Näissä tutkimuksissa on osoitettu, että nämä kehittyneemmät mallit ovat tarkempia sekä pystyvät paremmin vähentämään kustannuksia ja parantamaan tehokkuutta verrattuna perinteisiin luokittelumenetelmiin. (Shen et al., 2021)

Raji et al. (2024) toteavat, että esimerkiksi luottoanalyysimenetelmänä pitkään käytetyn logistisen regression yksinkertainen rakenne ja usein rajallinen muuttujajoukko voi johtaa siihen, että osa väestöstä jää alipalvelluiksi tai luokitellaan virheellisesti. Tämän vuoksi kehittyneemmät luottoriskianalyysimenetelmät palvelevat paremmin nykyajan luottoriskin analysointia. He myös toteavat, että tekoälyyn perustuvat luottoluokitushakemukset kohtaavat haasteita ja esteitä niiden tuomista hyödyistä huolimatta. Keskeisiä huolenaiheita ovat muun muassa datan yksityisyyden suojaan liittyvät riskit, läpinäkyvyyden ja vaadittavan raportoinnin puute sekä päätöksenteon selitettävyyden heikkous. Tämän vuoksi julkisten talousinstituutioiden on huomioitava eettiset näkökohdat vastatakseen globaalin teknologisen kehityksen vaatimuksiin.

Sun ja Vasarhelyin (2018) tutkimus osoittaa, että syväoppiminen tarjoaa lupaavan lähestymistavan luottoriskin hallintaan erityisesti silloin, kun käytettävissä oleva data on suurta ja monimutkaista. DNN-mallia voidaan hyödyntää luottoriskin arvioinnin automatisoinnissa sekä riskiasiakkaiden tunnistamisessa jatkoseurantaa varten. Tulokset viittaavat siihen, että tulevaisuudessa voidaan kehittää huomattavasti tehokkaampia luottoriskin ennustemalleja hyödyntämällä syväoppimisen avulla laajempaa ja monimutkaisempaa dataa, kuten kuvia ja äänidataa. Tutkimuksessa tunnistettiin kuitenkin myös rajoitteita. Vaikka DNN-malli oli tehokas, se ei tunnistanut kaikkia maksuhäiriöitä, ja sen tarkkuus

oli osin heikompi kuin perinteisillä neuroverkoilla. Tämä johtuu osittain siitä, että syväoppimismallit vaativat suuria datamääriä toimiakseen optimaalisesti. Lisäksi käytetty aineisto kattoi vain yhden kuukauden ajanjakson, mikä rajoittaa tulosten yleistettävyyttä.

Shen et al. (2021) tutkimuksessa ehdotettu menetelmä, jossa yhdistettiin AdaBoost-algoritmi ja LSTM-neuroverkko, saavutti erinomaisia tuloksia luottoluokituskyvyssä verrattuna muihin yleisesti käytettyihin luottokelpoisuuden arviointimenetelmiin. Tämä voi merkittävästi auttaa pankkeja ja muita rahoituslaitoksia kehittämään parempia sisäisiä luottoluokitusjärjestelmiä, vähentämään riskejä ja lisäämään tuottoja.

Liu (2022) toteaa, että luottoriskin arviointi on erittäin monimutkaista, ja siinä on edelleen monia puutteita, joita on syytä tutkia lisää. Lisäksi tutkimuksessa todettiin, että vaikka neuroverkkomallit tarjoavat lupaavia tuloksia, jatkossa haasteena on edelleen muun muassa olennaisen informaation erottaminen suurista ja monimutkaisista tietomassoista.

Chang et al. (2025) toteavat, että on mahdollista rakentaa koneoppimismalleja, joita voidaan hyödyntää korkean riskin päätöksenteossa, kuten luottopäätösten arvioinnissa, ja jotka saavuttavat erittäin hyvän tarkkuuden tarjoten samalla selkeitä selityksiä mallin ennusteita ohjaavista tekijöistä. Tulosten perusteella gradienttipohjainen malli sopi parhaiten luottokelpoisuuden ennustamiseen verrattuna muihin malleihin. Tutkimuksessa tuodaan myös esiin, että vastustus tekoälyjärjestelmiä kohtaan on vielä melko yleistä rahoitusalalla, vaikka on viitteitä siitä, että kyseiset järjestelmät parantaisivat esimerkiksi toimitusketjujen rahoituksen toimintaa. Keskeinen tekijä näiden järjestelmien käyttöönoton lisäämisessä on niiden tahojen luottamuksen saavuttaminen, jotka hyötyisivät niiden käyttämisestä. Tämän vuoksi on tärkeää, että nykyaikaisten tekoälyjärjestelmien tulee olla helposti selitettäviä sen lisäksi, että ne suoriutuvat paremmin kuin perinteiset menetelmät. He, jotka aikovat hyödyntää tekoälyjärjestelmiä, haluavat ymmärtää tarkasti, miten järjestelmät toimivat, jotta niihin voidaan täysin luottaa. Kun ottaa huomioon järjestelmien monimutkaisuuden, tämä ei ole helppo tehtävä. Lisäksi tulokset osoittavat, että luottokelpoisuuden ennustaminen binäärisenä luokitteluongelmana on haastavaa, sillä asiakkaan riskitaso ei yleensä jakaudu selkeästi kahteen luokkaan. Yhtenä haasteena myös mainittiin, että epätasapainoinen data monimutkaistaa analyysia ja laskentaa, mikä on yleinen ongelma tällaisessa aineistossa.

5 Keskustelu

Chang et al. (2024) osoittavat, että koneoppimismallit, kuten LightGBM, AdaBoost ja XGBoost voivat tehokkaasti erottaa maksukykyiset ja maksukyvyttömät luottokorttiasiakkaat toisistaan. Erityisesti XGBoost-malli suoriutui parhaiten kaikilla arviointimittareilla, mikä korostaa gradienttitehostuspohjaisten mallien vahvuutta luottoriskin ennustamisessa. Gradienttitehostuspohjainen malli suoriutui paremmin luottoriskin analysoinnissa kuin perinteiset vanhat luottoriskianalyysin menetelmät myös Raji et al. (2024) ja Chang et al. (2025) tutkimuksissa. Nämä tulokset tukevat käsitystä, että kehittyneemmät koneoppimismallit voivat tarjota pankkeihin konkreettista hyötyä päätöksenteossa, esimerkiksi pienentämällä luottotappioita ja tehostamalla riskienhallintaa.

Shen et al. (2021) kehittivät yhdistelmämenetelmän, jossa syväoppiva LSTM-neuroverkko yhdistettiin AdaBoost-algoritmiin. Tämä lähestymistapa paransi ennustetarkkuutta erityisesti epätasapainoisten luokkien käsittelyssä ja suurten, moniulotteisten data-aineistojen analysoinnissa. Sun ja Vasarhelyi (2018) käyttivät DNN-mallia, joka tunnisti automaattisesti olennaisia rakenteita laajoista asiakasdatan kokonaisuuksista ja paransi ennustetarkkuutta verrattuna perinteisiin menetelmiin. Raji et al. (2024) käyttivät DNN-mallia, joka suoriutui paremmin kaikilla mittareilla verrattuna perinteisiin luottoriskianalyysin menetelmiin. Myös Liu (2022) havaitsi, että neuroverkot voivat parantaa luottoriskin tunnistamista.

Tutkimukset osoittavat, että kehittyneemmät koneoppimismallit voivat tehostaa luottoriskin arviointia merkittävästi. Monet koneoppimismallit, erityisesti XGBoost, tarjoavat hyvän ennustetarkkuuden ja toimivat tehokkaasti myös suhteellisen rajallisilla datamäärillä. Lisäksi ne pystyvät mallintamaan epälineaarisia riippuvuuksia ilman, että mallista tulee liian monimutkainen tai vaikeasti tulkittava. Syväoppimismallit puolestaan pystyvät hyödyntämään suuria data-aineistoja sekä tunnistamaan monimutkaisia epälineaarisia suhteita, mikä voi parantaa ennustetarkkuutta epätasapainoisessa ja monimutkaisessa datassa. Lisäksi Chang et al. (2025) tekevät tärkeitä huomioita vastuullisten ja läpinäkyvien tekoälyjärjestelmien kehittämisestä niin rahoitusalalla kuin sen ulkopuolellakin.

Mallien valinta käytännön sovelluksissa riippuu datan koosta, monimutkaisuudesta ja organisaation resursseista. Koneoppimismallit ovat vakaita ja luotettavia, ja syväoppimisen lähestymistavat tarjoavat lisäarvoa erityistapauksissa, joissa tarvitaan monimutkaisempaa analyysia ja automaattista piirteiden tunnistusta. On tärkeää huomata, että monia

perinteisiä luottoriskin arviointimenetelmiä, kuten logistista regressiota ja päätöspuita on käytetty finanssialalla jo vuosikymmeniä. Niiden tehokkuus perustuu suhteellisen yksinkertaisiin tilastollisiin malleihin, jotka sopivat hyvin pienempiin ja vähemmän monimutkaisiin data-aineistoihin (Sun & Vasarhelyi, 2018). Kuitenkin vuoden 2008 finanssikriisin jälkeinen ympäristö, markkinoiden monimutkaistuminen ja saatavilla olevan datan määrän kasvu ovat osoittaneet, että perinteiset mallit eivät aina pysty ennustamaan riskitilanteita riittävän tarkasti. Tämän vuoksi kehittyneemmät koneoppimismenetelmät ovat nousseet keskiöön. Toisin sanoen, vaikka koneoppimismallit eivät ole uusi keksintö, niiden kyky analysoida monimutkaista dataa ja sopeutua nopeasti muuttuviin riskitekijöihin tekee niistä arvokkaita luottoriskianalyysissa.

6 Yhteenveto

Tässä kandidaatintyössä tutkittiin, miten tekoälyä hyödynnetään nykyisin luottoriskianalyysissa. Lisäksi työssä perehdyttiin perinteisiin luottoriskianalyysin menetelmiin ja niiden puutteisiin nykyajan monimutkaisessa finanssimaailmassa sekä vertailtiin perinteisiä menetelmiä tekoälymenetelmiin.

Työssä tunnistettiin kehittyneemmällä koneoppimisella olevan tärkeä merkitys luottoriskianalyysissa. Syväoppimismenetelmät ja kehittyneemmät yhdistelmämallit ovat tehokkaita ja suotuisia vaihtoehtoja luottoriskin arviointiin. Ne kykenevät käsittelemään suurta määrää dataa sekä analysoimaan rahoitusmarkkinoiden monimutkaisuutta. Tekoälyn käyttöönotto luottoriskin analysoinnissa parantaa merkittävästi taloudellisten riskien arvioinnin tarkkuutta ja perusteellisuutta. Finanssialan kehitys edellyttää tekoälyteknologian käytön lisäämistä ja sen integroimista.

Rahoitusmarkkinoiden jatkuva monimutkaistuminen tuo itsessään haasteita luottoriskin analysointiin, minkä vuoksi uusien mallien kehittäminen ja soveltaminen on tärkeää myös tulevaisuudessa. Yhteenvetona voidaan kuitenkin todeta, että tekoälyn hyödyntäminen luottoriskin arvioinnissa on suotuisaa, sillä vaillinaisella luottoriskin arvioinnilla voi olla negatiivisia vaikutuksia jopa koko maailmantalouteen.

Lähdeluettelo

Alammar, J. & Grootendorst, M. (2024). *Hands-On Large Language Models: Language Understanding and Generation*. O'Reilly Media.

Atitallah, S. B., Driss, M., Boulila, W. & Ghézala, H. B. (2020). Leveraging Deep Learning and IoT big data analytics to support the smart cities development: Review and future directions. *Computer Science Review*, *38,* Article 100303. https://doi.org/10.1016/j.cosrev.2020.100303

Celik, S. (2019). Credits and credit analysis in banking sector. Teoksessa A. Akinci (toim.), *Interdisciplinary Public Finance, Business and Economics Studies – Volume II* (ss.153–158). Peter Lang.

Chang, V., Sivakulasingam, S., Wang, H., Wong, S. T., Ganatra, M. A. & Luo, J. (2024). Credit risk prediction using machine learning and deep learning: A study on credit card customers. *Risks, 12*(11), Article 174. https://doi.org/10.3390/risks12110174

Chang, V., Xu, Q. A., Akinloye, S. H., Benson, V. & Hall, K. (2025). Prediction of bank credit worthiness through credit risk analysis: An explainable machine learning study. *Annals of Operations Research*, *354*(1), 247–271. https://doi.org/10.1007/s10479-024-06134-x

Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning.* The MIT Press.

Janiesch, C., Zschech, P. & Heinrich, K. Machine learning and deep learning. (2021). *Electronic Markets, 31*(3), 685–695. https://doi.org/10.1007/s12525-021-00475-2

Liu, L. (2022). A self-learning BP neural network assessment algorithm for credit risk of commercial bank. *Wireless Communications and Mobile Computing, 2022*(1), Article 9650934. https://doi.org/10.1155/2022/9650934

Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.

Neal, R. S. (1996). Credit derivatives: new financial instruments for controlling credit risk. *Economic Review, 81*(2), 15–27.

Raji, A. A. H., Alabdoon, A. H. F. & Almagtome, A. (2024). AI in credit scoring and risk assessment: Enhancing lending practices and financial inclusion.

Proceedings of the 2024 International Conference on Knowledge Engineering and Communication Systems (ICKECS) (ss. 1–7). IEEE. https://doi.org/10.1109/ICKECS61492.2024.10616493

Russell, S. J. & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach* (3rd ed.). Pearson.

Sheikh, H., Prins, C. & Schrijvers, E. (2023). Artificial intelligence: Definition and background. Teoksessa *Mission AI* (ss. 15–41). Springer. https://doi.org/10.1007/978-3-031-21448-6_2

Shen, F., Zhao, X., Kou, G. & Alsaadi, F. E. (2021). A new deep learning ensemble credit risk evaluation model with an improved synthetic minority oversampling technique. *Applied Soft Computing, 98,* Article 106852. https://doi.org/10.1016/j.asoc.2020.106852

Shi, S., Tse, R., Luo, W., D'Addona, S. & Pau, G. (2022). Machine learning-driven credit risk: A systematic review. *Neural Computing and Applications*, *34*(17), 14327–14339. https://doi.org/10.1007/s00521-022-07472-2

Sun, T. & Vasarhelyi, M. A. (2018). Predicting credit card delinquencies: An application of deep neural networks. *Intelligent Systems in Accounting, Finance and Management, 25*(4), 174–189. https://doi-org.libproxy.tuni.fi/10.1002/isaf.1437

Thomas, L. C., Edelman, D. B. & Crook, J. N. (2002). *Credit Scoring and Its Applications.* SIAM.

Wang, Y., Zhang, Y., Lu, Y. & Yu, X. (2020). A comparative assessment of credit risk model based on machine learning --a case study of bank loan data. *Procedia Computer Science, 174*, 141–149. https://doi.org/10.1016/j.procs.2020.06.069