

Anton Matrosov

**TEKOÄLYN HYÖDYNTÄMINEN OSANA RAHOITUS-
PÄÄTÖSTÄ**



JYVÄSKYLÄN YLIOPISTO
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA
2024

TIIVISTELMÄ

Matrosov, Anton

Tekoälyn hyödyntäminen osana rahoituspäätöstä

Jyväskylä: Jyväskylän yliopisto, 2023, 48 s.

Tietojärjestelmätiede, kirjallisuuskatsaus

Ohjaaja: Clements, Kati

Tekoäly on lähivuosina saavuttanut suuren suosion yhteiskunnassamme. Sen käyttö työpaikalla ja arjessamme on suosituempaa, kun koskaan ennen. Tekoälynyleistyminen on tuonut mukanaan muutoksia toimintamalleihimme, ja monet prosessit on mahdollista jättää osittain tai kokonaan tekoälyn vastuulle.

Tekoälyn adoptoiminen rahoitusalueelle on ollut hidasta ja varautunutta, vaikka tekoälyn implementointi toisi alalle uusia, tehokkaampia ja tarkempia toimintamalleja. Tekoäly kykenisi analysoida dataa ja tehdä päätökset täysin tietoon ja tietomalleihin perustuen, samalla eliminoiden ihmisvirkailijan puolueellisuuden ja mahdolliset epähuomiot. Tutkimuksessa huomataan tekoälyimplementoinnin kokeilujen tuovan positiivisia tuloksia etenkin tiedon tarkentumiseen ja datan analysointiin samalla nopeuttaen päätösprosessia sekä eliminoimalla ihmisvirkailijan puolueellisuuden.

Tietoälyn implementointi riskienhallintaan on suuri prosessi, jota on tutkittu vuosien varrella monesta eri näkökulmasta käyttäen monia erilaisia kaavoja ja malleja, mutta tekoälyn implementoinnin laajuuden ansiosta on vielä monta ongelmaa ja haastetta, jotka tulisi ratkoa ennen teknologian hyödyntämistä arkikäytössä. Suurimmiksi haasteiksi tutkimuksissa nousivat mm. tekoälyn analysoinnin tarkkuus, tietoturva ja kyberriskien ehkäisy lisääntyneen laitteiston ja datan ansiosta sekä tekoälyn käyttöä koskevien lakien, ohjeistuksien ja yleisten toimintamallien puute. Tehokkaaseen riskienhallintapolitiikkaan tekoälyn avulla vaaditaan helposti muokattava algoritmi, joka osaa laskea ennustuksen tarkasti, tarvittavat turvallisuustoimenpiteet toiminnan takaamiseksi sekä lakeja ja ohjeistuksia, jotta tekoälyn käyttöä voitaisiin valvoa ja tarkastella.

Asiasanat: tekoäly, yritysrahoitus, koneoppiminen,

ABSTRACT

Matrosov, Anton

Utilization of artificial intelligence as part of financial decision

Jyväskylä: University of Jyväskylä, 2023, 48 p.

Computer Science, Literature Review

Supervisor: Clements, Kati

Artificial intelligence (AI) has gained significant popularity in our society in recent years. Its use in the workplace and our daily lives is more prevalent than ever before. The widespread adoption of AI has brought about changes in our operational models, and many processes can now be partially or entirely entrusted to AI.

The adoption of AI in the financial sector has been slow and cautious, despite the potential for AI implementation to bring new, more efficient, and accurate operational models to the industry. AI can analyze data and make decisions based entirely on knowledge and data models, eliminating human bias and potential oversights. The research notes that experiments with AI implementation in risk management yield positive results, particularly in refining information and analyzing data, while also speeding up decision-making processes and eliminating human bias.

Implementing AI in risk management is a complex process that has been studied from various perspectives over the years, using many different formulas and models. However, due to the scope of AI implementation, there are still many problems and challenges that need to be addressed before the technology can be widely used in everyday situations. Key challenges identified in the research include the accuracy of AI analysis, cybersecurity, and prevention of cyber risks due to increased hardware and data, as well as the lack of laws, guidelines, and general operational models regarding the use of AI. Effective risk management policies using AI require an easily adaptable algorithm that can accurately calculate predictions, necessary security measures to ensure functionality, laws, and guidelines for monitoring and overseeing the use of AI.

Keywords: artificial intelligence, corporate finance, machine learning.

KUVIOT

KUVIO 1 Tekoälyn erilaiset käytöt finanssialalla.....	11
KUVIO 2 Tekoälyn myymien osakkeiden tulos verrattuna edellisten tutkimuk- sien tuloksiin.....	23
KUVIO 3 Kolmikerroksisen verkkomallin rakenne	25
KUVIO 4 XGBoost- algoritmin suosituimman Exact Greedy- alogoritmin ra- kenne.....	27
KUVIO 5 SHAP-mallin peruskaava sekä sen parametrien määritelmät.....	28
KUVIO 6 ANN ja Fuzzy logic- mallien vertailun tulokset osakkeen hintakehi- tyksen ennustamisessa.....	31
KUVIO 7 ANN ja Fuzzy logic- mallien vertailun tulokset myyntitulosten ennus- tamisen ensimmäisessä testierässä.....	32
KUVIO 8 ANN ja Fuzzy logic- mallien vertailun tulokset myyntitulosten ennus- tamisen toisessa testierässä	33
KUVIO 6 Shap mallin peruskaava sekä sen parametrien määritelmät.	28
KUVIO 7 XGBoost- algoritmin suosituimman Exact Greedy- algoritmin ra- kenne.....	29
KUVIO 9 Paranneltu SHAP-mallin peruskaava	34
KUVIO 10 Looginen malli vastaan XGBoost- malli.....	35

TAULUKOT

TAULUKKO 1 Puusarjamallin ominaisuuksien vertailu	27
TAULUKKO 2 DeepAr-algoritmin vertailu muihin algoritmeihin	37
TAULUKKO 3: Keskeisimmät havainnot tekoälyn käyttö osana parempaa pää- töksentekoa maksuliikenteessä.....	40
TAULUKKO 4: Keskeisimmät havainnot tekoälyn käyttö osana parempaa pää- töksentekoa pääomamarkkinoilla	41
TAULUKKO 5: Keskeisimmät havainnot tekoälyn käyttö osana parempaa pää- töksentekoa pankkitoiminnassa	42
TAULUKKO 6 Keskeisimmät havainnot tekoälyn käyttö osana parempaa pää- töksentekoa investoinnihallinnassa	43
TAULUKKO 7 Keskeisimmät havainnot tekoälyn käyttö osana parempaa pää- töksentekoa vakuutusprosessissa.....	44

SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT

TAULUKOT

1	JOHDANTO	VIRHE. KIRJANMERKKIÄ EI OLE MÄÄRITETTY.
2	TEKOÄLY.....	9
	2.1 Tekoäly finanssialalla	9
	2.2 Tekoälyn käyttöönoton haasteet	11
	2.2.1 Tekoälyn koulutushaasteet	12
	2.2.2 Tekoälyn lakien ja säännöksiä puute	13
	2.2.3 Tekoälyn turvallisuushaasteet	14
3	YRITYSRAHOITUS.....	16
	3.1 Rahoitusprosessissa hyödynnettävä tekoäly.....	17
	3.2 Yritysrahoituksen päätöksenteko.....	18
4	TEKOÄLYN HYÖDYNTÄMINEN YRITYSRAHOITUKSESSA	20
	4.1 Tekoälyn potentiaali finanssialalla.....	20
	4.2 Tekoälyn käyttö osana parempaa päätöksentekoa maksuliikenteessä	22
	4.3 Tekoälyn käyttö osana parempaa päätöksentekoa pääomamarkkinoilla.....	24
	4.4 Tekoälyn käyttö osana parempaa päätöksentekoa pankkitoiminnassa	28
	4.5 Tekoälyn käyttö osana parempaa päätöksentekoa investoinnihallinnassa	29
	4.6 Tekoälyn käyttö osana parempaa päätöksentekoa vakuutusprosessissa.....	34
5	YHTEENVETO	38
6	LÄHTEET	45

1 JOHDANTO

Tekoäly (Artificial Intelligence) on tiede, jonka tarkoituksena on saada tietokoneet tekemään asioita, jotka ovat vaatineet älykkyyttä ja perinteisesti tehty ihmisvoimin (Ostmann & Dorobantu, 2021). Tekoäly on suhteellisen uusi ilmiö yhteiskunnassa, mutta uutuudesta huolimatta saavuttanut suuren suosion lyhyessä ajassa. Tekoälyn käyttö työtehtävien nopeuttamiseen, helpottamiseen ja yksinkertaistamiseen on saanut paljon suosiota, ja monet yritykset ovat ottaneet tekoälyn osakseen toimintaansa erilaisissa muodoissa (Kruse, Wunderlich ja Beck, 2019). Monelle kuluttajista tekoäly on parhaiten tuttu asiakaspalveluista, itsepalvelukassoilta tai räätälöidyistä suositteluista sosiaalisesta mediasta. Tekoäly on tullut jäädäkseen ja lyhyessä ajassa muodostunut suureksi osaksi arkeamme, jota ilman ei voisi enää kuvitella pärjäävänsä nykyaikaisessa maailmassa (Qi & Xiao, 2018).

Tekoälyn yleistymiseen on suhtauduttu vaihtelevasti. Tekoäly on helpottanut arkeamme monella tavalla, mutta samalla tuonut mukanaan uusia haasteita. Yritykset ovat ottaneet tekoälyn osakseen päivittäistoimintojaan, ja nykyajan yritysmaailmasta onkin yleistä havaita tekoälytoimintaa esimerkiksi virtuaaliassistentin roolissa tai osana kirjanpito- sekä hallinto-ohjelmaa. Käyttäjän on helppoa syöttää tekoälylle tiedot ja generoida tekoälyavustuksen avulla vastaus nopeasti ja tarkasti. Tekoäly on saanut suurimmaksi osaksi positiivista palautetta nopeutensa ja yksinkertaisuutensa vuoksi, sillä tekoälyavusteiset työtehtävät voidaan suorittaa huomattavasti nopeammin kuin perinteisillä keinoilla. Monet yrityksen eri tehtävistä on saatu virtaviivaisemmaksi ja yksinkertaisemmaksi sekä yritykselle, että asiakkaalle (Dhaigude & Lawande, 2022).

Finanssialalla muutoksen ja tekoälytoiminnon lisääntymiseen on suhtauduttu varautuen tekoälyn uutuuden vuoksi. Alan toiminta on vahvasti datapainoinen ja pitää sisältään monia salassapitovelvollisuuden alle putoavia asiakirjoja, joita ei voida luovuttaa julkiseksi tiedoksi tai syöttää tekoälyohjelmaan ilman varmistusta ohjelman turvallisuudesta. Rahoituspäätöksiä ei myöskään tehdä pelkkään tekoälyyn luottaen, vaan jokaisessa rahoitushankkeessa on mukana omat luottovirkailijat, jotka keräävät ja analysoivat tietoa usein perinteisin

metodein, joka on usein hidasta, vaivalloista ja työllistää suurta määrää yrityksen työntekijöistä.

Tutkielman tarkoituksena on vastata kysymykseen: *miten rahoittaja pystyisi tekemään parempia rahoituspäätöksiä tekoälyä hyödyntäen*. Tutkielma suoritetaan kirjauskatsauksena, jossa analysoidaan tekoälyn nykytilaa, tehokkuutta ja haasteita kehittymiselle. Kirjalliskatsauksessa käytetyt artikkelit ovat haettu aiheeseen liittyvillä avainsanahauilla JykDokista ja Google Scholarista. Avainsanahakujen pohjalla on pyritty valitsemaan artikkeleja, jotka käsittelevät tekoälyn nykytilaa, nykytilan haasteita sekä ratkaisuehdotuksia haasteisiin. Hauissa huomioidaan myös vanhemmat artikkelit, jos artikkelit ovat myöhemmin toimineet lähtökohdaksi uusille ratkaisuille tai algoritmeille. Tutkimuksen artikkelit ovat kansainvälisiä lähteitä ja tarkoituksena on saada mahdollisimman monipuolinen kokonaiskuva maailmanlaajuisista tilanteista sekä alueiden mahdollisista kehitys- tai lähestymistapaeroavaisuuksista.

Kirjallisuuskatsauksen tarkoituksena on tutustua aiheesta tehtyihin tutkimuksiin sekä selvittää suurimmat haasteet tekoälyn käytön yleistymiselle osana rahoitusprosessia. Katsauksessa käsitellään myös tekoälyn koulutusprosessia sekä erilaisien algoritmien heikkouksia ja vahvuuksia ja yritysrahoituksen nykytilaa sekä sen heikkouksia ja haasteita. Valikoitujen tutkimusten tuloksia verrataan ja analysoidaan keskenään parhaan vaihtoehdon saamiseksi sekä selvittääkseen mahdolliset heikkoudet ja vähemmälle huomiolle jääneet epäkohdat.

Tekoälyteknologian kehittyminen turvallisuuden, saatavuuden ja tarkkuuden osalta tarkoittaisi parempia lainapäätöksiä asiakkaille sekä rahoittajille. Tekoälyn tarkka raportti antaisi lainankäsittelijälle mahdollisimman tarkan ja monipuolisen kuvan rahoitusta pyytävän asiakkaan taloudellisesta tilanteesta, jotta asiakkaalle voitaisiin tarjota hänen tarpeisiinsa parhaiten sopiva luotto mahdollisimman pienellä riskillä täten varmistaen vastuullisen rahoitustavan sekä minimoiden maksukyvyttömyyden tapahtumista. Sen lisäksi luottokäsittelijän työ määrä vähenisi, jolloin hän voisi keskittyä enemmän yksittäiseen hankkeeseen kerrallaan sekä pystyisi tehdä päätöksen mahdollisimman selkeän ja monipuolisen asiakaskartoituksen pohjalta, joka ottaisi huomioon kaikki mahdolliset riskitekijät sekä mahdolliset muutokset.

Tekoälypohjainen lähestymistapa toisi vakautta pankkien ja maiden talouspolitiikan sekä vähentäisi todennäköisyyttä ajautua taloudellisiin vaikeuksiin sekä finanssikriiseihin. Myös yleinen turvallisuus ja epävakaas finanssialalla pieneni ja tilalle tulisi varmemmat ja turvallisemmat rahoitushankkeet, näin vähentäen epävastuullista ja riskialtista toimintatapaa. Vastuullisuus finanssialalla kannustaisi vastuullisempaan liiketoimintaan, vakaampiin taloudellisiin oloihin ja taloudelliseen hyvinvointiin yhä useammalle asiakkaalle.

Tekoälyteknologian käytön uutuuden ansiosta on kuitenkin mahdotonta karvoittaa kaikki mahdolliset haasteet ja kehityskohdat, jota tekoälyn implementointi voisi tuoda mukanaan. Tekoälyn käyttö työtehtävissä ja arjessa on uusi konsepti, joka on mahdollistunut vasta tietokoneiden ja oheislaitteistojen riittävän laskentavoiman ansiosta. Laskentatoimirajoitusten takia etenkin vanhempien tutkimuksen tulokset voivat olla osittain rajoittuneita, sillä tutkimuksen

tuloksia ja algoritmien potentiaalia ei voitu testata noudattaen oikeiden olosuhteiden muuttujia ja tilanteita.

2 TEKOÄLY

Tekoäly on tieteenä laaja käsite, jonka määrittelemisen yhteen lauseeseen on hankalaa. Tässä tutkimuksessa tekoäly on määritelty tieteenä, tiede, jonka tarkoituksena on saada tietokoneet tekemään asioita, jotka ovat vaatineet älykkyyttä ja perinteisesti tehty ihmisvoimin (Ostmann & Dorobantu, 2021). Tekoälyn avulla tietokoneet ja muut laitteistot saadaan ajattelemaan ihmisten lailla, jotta tietokone voisi automatisoida tehtävienkulunjoko osittain tai kokonaan, parantaen tehtävän lopputulosta, suoritusnopeutta tai muuta osa-aluetta (Najem, Bahnasse ja Talea 2022).

Tekoälyn juuret voidaan jäljittää takaisin 1940-luvulle, jolloin amerikkalainen tieteiskirjailija Isaac Asimov julkaisi novellinsa Runaround. Samaan aikaan englantilainen matemaatikko Alan Turing kehitti Bombe-niminen koodinmurtajan Britannian hallitukselle tarkoitukseen Saksan armeijan toisessa maailmassa käyttämän Enigma-koodin purkamiseen. Bomben onnistuminen siinä, missä yksikään ihmismieli ei ennen ollut onnistunut sai Turingin pohtimaan kyseisten koneiden älykkyyttä ja kapasiteettia (Haenlein & Kaplan, 2019).

Vuonna 1950 Turing julkaisi tärkeän artikkelinsa "Computing Machinery and Intelligence", jossa hän kuvaili älykkäiden koneiden luomista ja erityisesti, kuinka testata niiden älykkyyttä (Haenlein & Kaplan, 2019). Myöhemmin Turingin testinä tunnettu toimintamalli on edelleen käytössä, ja sitä pidetään nykyään parhaana käytäntönä testata laitteen älykkyyttä. Termi "tekoäly" otettiin virallisesti käyttöön vuonna 1956 Marvin Minskyn ja John McCarthyn pitämän tekoälyprojektin ansiosta (Haenlein & Kaplan, 2019).

Lähivuosina tekoäly on kehittynyt räjähdysmäisesti. Kehityksen takana on havaittavissa useampi yhteiskunnallinen muutos, jonka takana olevia vaikuttajia on digitalisoituminen, laskentavoiman huima kehittyminen tietokoneiden kehityksen muodossa ja internetin lisääntyminen arjessa. Muutokset ovat lisänneet datan kulkua ja varastointia, joka on puolestaan johtanut tietopohjaiseen päätöksentekoon (Kaya, Schildbach ja Schneider, 2019). Myös tietokoneiden prosessorit ja laskentavoima on kasvanut huomasti viimeisen 10 vuoden aikana, joka on puolestaan mahdollistanut nopeamman ja tarkemman laskentatehon. Suuren data-saatavuuden ja nopean laskentatehon ansion lisäksi myös datan varastointikulut, tiedonlouhinta ja IT-alan asiantuntijoiden lisääntyminen ovat nostaneet tekoälyn toteutettavuutta ja toimintakykyä (Kaya, Schildbach ja Schneider, 2019).

2.1 Tekoäly finanssialalla

Tekoäly on finanssialalla suosittu työkalu, joka on saanut suurta suosiota nykyajan rahoituslaitteilla. Alalla tekoälyä käytetään moniin pienempiin tehtäviin, kuten asiakaspalveluun ja hakemusten prosessin nopeuttamiseen. Alan toiminta on kuitenkin monimutkaista ja pitää sisällään paljon tietojärjestelmiä,

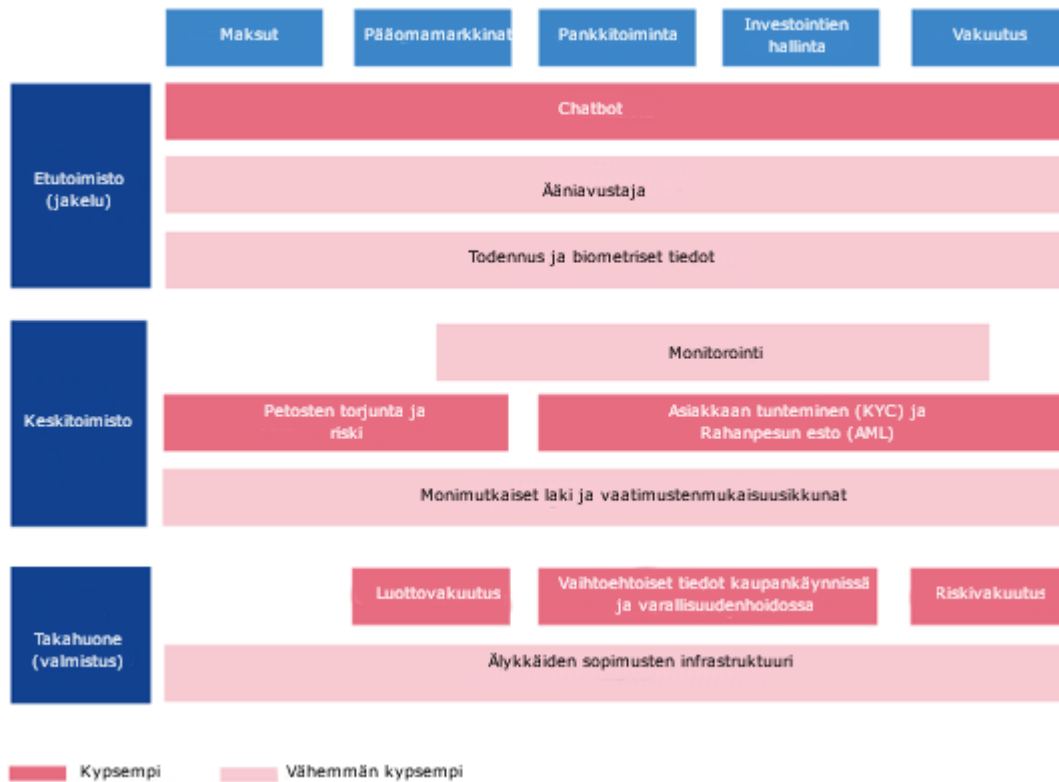
toimintamalleja ja sääntelyitä. Tämän lisäksi kilpailu on kovaa, ja jokaisen instituution oletetaan harjoittavan ympäristöystävällistä ja vastuullista liiketoimintaa. Tekoälyllä on potentiaalia vaikuttaa moneen finanssialan osa-alueen toimintaan, samalla nopeuttaen ja tehostaen toimintamalleja (Kruse, Wunderlich ja Beck, 2019). Tekoäly kannustaa rahoituslaitoksia vähentämään kustannuksia, hallintoriskejä, parantamaan palvelun laatua ja kasvattaa voittoa käyttämällä tekoälyä ja koneoppimista hyödykseen (Xie, 2019).

Tekoälyn suosion lisääntyminen on aiheuttanut paljon haasteita ja monimutkaisuuksia rahoitusalailla. Giudicin (2018) mukaan tekoälyn potentiaalisuus ratkaisemaan haasteita ja nopeuttamaan työtehtäviä on tunnustettu, mutta teknologian implementointi on suuri ja haastava prosessi. Tekoälyn käytön lisääntyminen on alalle positiivinen ilmiö, kunhan alalla käytettävät toimintamallit ovat suunniteltu ja kehitelty vastuullisesti mahdollisten riskien minimoimiseksi (Giudici, 2018).

Tekoälyn onnistunut implementointi vaatii paljon dataa ja data-analytiikkaa. Suuren datamäärän siirto pilvialustoille altistaa kyseisen datan mahdollisille tietovuodoille ja kyberhyökkäyksille. Finanssialalla asiakastiedot ja dokumentit ovat keskeisessä roolissa, ja huoli niiden kadottamisesta, tietovuodoista tai ulkoisen toimijan pääsystä tietoihin on suuri (Kruse ym., 2019).

Finanssiteknologian (Fintech) lisääntyminen ja yleistymisen on pakottanut finanssialan adaptoitumaan ja tarjoamaan asiakkaille myös digipohjaisia ratkaisuja. Krusen ym., (2019) mukaan etenkin diginatiivisukupolvet (vuodesta 1995 eteenpäin syntyneet) odottavat helposti ymmärrettäviä ja omaksuvia finanssituotteita sekä yksinkertaisen käyttöliittymän ja asiakkaalle räätälöidyn käyttökokemuksen (Kruse, Wunderlich, ja Beck, 2019). Vuonna 2018 tehdyssä tutkimuksessa yli puolet aikuisista Euroopan unionissa käyttävät verkkopankkia hoitaakseen arjen asioinnin, ja osassa maissa, esim. Tanskassa, verkkopankin käyttäjien määrä voi olla jopa 90 % asukkaista (Kaya, Schildbach ja Schneider, 2019).

Finanssiala on laaja ala, johon mahtuu monta erilaista toimijaa, työtehtävää ja osa-alueita. Tekoäly on laajasti käytössä finanssialan eri tehtävissä ja osa-alueilla (Kuvio 1, Fernández, 2019). Osa tehtävistä koskevat koko organisaatiota, toiset puolestaan keskittyvät omien osa-alueiden työtehtävien hoitamiseen. Osa tehtävistä, johon tekoäly on implikoitu pyrkivät parantamaan asiakaskokemusta, kun taas toiset pyrkivät optimoimaan tai muuttamaan prosesseja rahoituspalvelujen tarjoamisen eri vaiheissa esimerkiksi käyttämällä uusia tietolähteitä valitakseen sijoitukset tai määrittääkseen riskipreemiot (Fernández, 2019).



Kuvio 1: Tekoälyn erilaiset käytöt sekä niiden kypsyys finanssialalla (Mitä kypsempi, sitä kehittyneempi teknologia niiden takana on) (Fernández, 2019).

Finanssialan valvovat viranomaiset ovat myös integroineet tekoälyn osakseen toimintaansa. Useat keskuspankit ovat alkaneet sisällyttää tekoälyä esimerkiksi mikro- ja makrovakauden valvontaan, tiedon hallintaan, ennustaminen tai petollisen toiminnan havaitseminen (Fernández, 2019). Tekoälyn avulla voidaan esimerkiksi seurata ja kirjata epäilyttäviä tilisiirtoja, ennustaa hintamuutoksia erilaisilla markkinoilla sekä lisätä laadunhallintaa esim. viranomais- ja asiakasraportoinnin suhteen. Tekoälyä hyödynnetään todella laajaan tehtäväkirjoon ja erilaiseen dataan, josta osa on salassa pidettävää (esimerkiksi yrityksen taloudelliset raportit ja vuosineljänneksen talouslukemat) (Fernández, 2019).

2.2 Tekoälyn käyttöönoton haasteet

Tekoäly on muodostunut hyödylliseksi työkaluksi finanssi- ja vakuutus-alalla. Alan toiminta on monimutkaista ja pitää sisällään paljon tietojärjestelmiä, toimintamalleja ja sääntelyä. Alan kilpailu on kovaa, ja jokaisen rahalaitoksen oletetaan harjoittavan ympäristöystävällistä ja vastuullista liiketoimintaa. Tekoälyn hyödyntäminen tuo yritykselle nopeammat ja paremmat toimintamallit, helpottaa päivittäisten tehtävien suorittamista samalla parantaen asiakastytyväisyyttä nopeutuneen palvelun vuoksi (Kunnathuvalappil, 2018). Tekoälyn laajuus ja monimutkaisuus voivat kuitenkin aiheuttaa ennennäkemättömiä

haasteita ja riskejä yritykselle. Etenkin datan ja laitteiston lisääntymisen mukana kohonneet kyberriskit ja tietoturvariskit voivat aiheuttaa yritykselle suuria haasteita (Maple, Szpruch, Epiphaniou, Staykova, Singh, Penwarden & Avramovic, 2023).

Tekoälyn integraatiossa yrityksen toimintaan on noussut esille paljon uhkia ja rajoituksia. Yleisimmät uhkat, jota tekoälyn integraatioprosessissa voi kokea, liittyvät tekoälyn koulutukseen, turvallisuuteen tai lakien puutteeseen (Lin 2019). Tekoälyn käytön yleistymisellä ja integraatiolla voi olla myös negatiivinen vaikutus ihmisten työllistymiseen ja kouluttamiseen. Liiallinen luotto tekoälyyn johtaa haluttomuuteen opiskella työtehtäviin kuuluvia taitoja sekä vähentää itsenäisen ajattelun taitoa tekoälyn helppouden takia (Kruse, Wunderlich, & Beck, 2019).

Finanssialan sekä yritysten tapahtumien ennustamista haastaa myös ihmismuuttujien, eli ihmisen toiminnasta aiheutuvien virheiden vaikutus. Ihmismuuttujalla tarkoitetaan muuttujaa, joka on ihmisen aiheuttama, etukäteen suunnitteleman tapahtuma, jota ei pystytä ennustamaan etukäteen millään parametreillä, esimerkiksi ihmisen tekemä arviointivirhe raportoinnissa tai huomaamattomuuttaan aiheutunut työtapaturma. Tekoälyn käyttö voi huomattavasti vähentää ihmismuuttujan aiheuttaman virheen tapahtumista, mutta ei poistaa sitä kokonaan yhtälöstä (Fernández, 2019).

Tekoälyn käytön haasteisiin keskittyvät tutkimukset nostavat esille monia epäkohtia, jotka voivat haitata sekä hidastaa tekoälyn kehitystä sekä yleistymistä. Maplen ym. (2023) tutkimus tunnisti monia haasteita sekä epäkohtia tekoälyn implementoinnissa, mutta ongelmiin sekä mahdollisiin seurauksiin ei perehdytä syvällisesti. Krusen ym. (2019) sekä Linin (2019) tutkimuksissa havaitut havainnot vastaavat Maplen ym. (2023) tutkimuksessa havaittuja ongelmia, mutta tutkimukset ovat huomattavasti suppeampia. Tutkimuksista voidaan päätellä tekoälyimplementoinnin yleisempien haasteiden olevan tiedossa, mutta ratkaisut haasteille jäävät usein puutteelliseksi ennakoinnin vaikeuden takia.

2.2.1 Tekoälyn koulutushaasteet

Tekoälyalgoritmit on koulutettava soveltumaan yrityksen tarpeisiin. Koulutuksessa käytetty data voi olla puolueellista tai väärää, jolloin koulutusprosessissa ajautuu virheitä, jotka voivat haitata tekoälyn päätöstentekokykyä. Puolueellinen tai tarkastamaton data, jota käytetään tekoälyn koulutuksessa voi johtaa tekoälymalleihin tai kaavoihin, jotka tuottavat puolueellisia ja epätarkkoja päätöksiä (Maple ym., 2023). Lähivuosina tutkijat ja data-analyttikot ovat huomanneet, että suurin riski tekoälyn puolueellisuudelle ilmenee koodaus- ja koulutusvaiheessa työntekijän virheen eli ihmismuuttujan takia. Jos tietovirheitä ei huomata ajoissa, virheellinen tieto saattaa jäädä pysyvästi tietokantaan vaikeuttamaan päätöksenteon oikeellisuutta (Johnson, Pasquale, & Chapman, 2019).

Tekoäly oppii tunnistamaan kaavoja ja yhtäläisyyksiä sille annettusta tiedosta. Tekoäly on puolueeton toimija, ja tekee päätöksensä täysin sille annettujen ja opetettujen tietojen perusteella. Näin ollen tekoäly ei pysty tunnistamaan

odottamattomia tilanteita tai käsittelemään datassa ilmenevää ihmisen vuorovai-
kutusta, jolloin tekoälyn päättely voi muuttua puolueelliseksi tai suorastaan vir-
heelliseksi (Taeihagh, 2021).

Tekoäly pystyy oppimaan finanssialan käytännön ja ennustamaan tulevai-
suuden näkymät vain, jos se on koulutettu tunnistamaan tietyt piirteet, joiden
pohjalta tehdä päätöksiä. Syöttäessä tietoja tekoälyyn tulisi huomioida tietojen
mahdollinen puolueellisuus, vanhat toimintatavat sekä syötetyn tiedon sisältä-
mät ihmisiltä pohjautuvat ennakkoluulot ja harhakuvitelmat. Syötetyn tiedon
minkäänlainen vääristyminen voi johtaa vääristettyyn sekä puolueelliseen en-
nustukseen. Väärin perustein arvioitu ennustus voi olla taloudellisesti suuri tap-
pio sekä aiheuttaa yritykselle mainehaittaa ja epäluottoa tekoälyn arviointikykyi-
hin (Lin, 2019), (Johnson, 2019) & (Maple ym., 2023).

Sisään syötetystä tiedosta vastaavan henkilön tulisi varmistaa, että kerätty ja
syötetty tieto on tarkkaa, ja että tietojen eheys säilyisi. Sen lisäksi on varmistet-
tava, että tieto on puolueetonta, eikä sisällä kirjoittajien tai kolmannen osapuolen
puolueellisia näkemyksiä (Ashta & Herrmann, 2021). Puolueelliset näkemykset
sekä muu tiedon poikkeaminen neutraalisuudesta voi aiheuttaa esimerkiksi lai-
nahakemuksen hylkäämisen epärelevantteihin kriteereihin vedoten. Tekoälyä
kehittävien henkilöiden tulisi olla tarkkoja ja kriittisiä syöttämistään tiedoista
(Maple ym., 2023).

Tekoälyn puolueellisuuden tutkimuksissa korostetaan usein tarkkuutta tie-
tojen syötössä ja vastuullista liiketoimintaa, joka vähentäisi riskiä sekä huonoja
toimintatapoja (Maple ym., 2023), (Johnson ym., 2019), (Taeihagh, 2021), (Ashta
& Herrmann, 2021) & (Lin, 2019). Lakien ja säännöksiä puute on kuitenkin jo-
kaisessa tutkimuksessa esillä, joka hankaloittaa yhtenäisten toimintamallien ke-
hitystä ja viivästyttää sekä hankaloittaa tekoälyn käytön yleistymistä. Tutkimuk-
sissa ei saada yhtenäistä mielipidettä siitä, kenelle lakien säätäminen kuuluisi.
Lakien puuttumisen takia ei myöskään voida arvioida toimintamallien parem-
muutta tai tehokkuutta laillisuuden näkökulmasta, vaan tutkimukset nostavat
vain esimerkkejä yleisimmistä virheistä tekoälyn koulutustoiminnossa.

2.2.2 Tekoälyn lakien ja säännöksiä puute

Tekoälyn implementointi finanssialan työtehtäviin on laaja prosessi, jossa te-
koäly on päästettävä käsiksi moniin tietoihin, jotka ovat liikesalaisuuksia tai sa-
lassapitovelvollisuuden alle kuuluvia asiakirjoja. Tekoälyyn liittyvä lainsäädäntö
on usein puutteellista, eikä sisällä selkeitä ohjeita, jotka rajaisivat yrityksen teko-
älytoiminnot soveltuvaksi ja epäsoveltuvaksi. Lainsäädännön puute aiheuttaa
vaikeuksia ja epävarmuutta tekoälyn toiminnan laillisuuden seurannalle, sään-
telylle sekä raportoinnille. Seurannan puute voi aiheuttaa tekoälyn hyödyntämi-
sen laittomiin toimintoihin, esimerkiksi laittomaan varainhallintaan, rahojen al-
kuperän peittelyyn sekä muihin laittomiin toimintoihin (Li, Yi, Chen, ja Peng,
2021). Tekoälyn käytön lisääntynyt suosio aiheuttaa myös finanssialan toiminta-
mallien muutosta, jolloin lainsäädännön tulisi seurata perässä ja päivittää vastaa-
maan sen hetken vaatimuksia (Li ym., 2021).

Lainsäädännön puute hankaloittaa myös tekoälyn oikeaoppista kouluttamista sille määriteltyyn tehtävään. Jotta koulutus tehtävään onnistuisi, tekoälyalgoritmiin syötetyn tiedon tulisi olla puolueetonta ja vääristämätöntä neutraalia tietoa. Ilman lainsäädäntöä on kuitenkin vaikea määritellä laillisesti oikeaa ja asiaan kuuluvaa tietoa vääränlaisesta ja potentiaalisesti laittomasta tiedosta, esimerkiksi toisen asiakkuuden arkaluontoisista tiedoista. Valvonnan ja lakien puute hankaloittaa myös ongelmien ennakoimista ja saattaa kannustamaan uusia ja kokemattomia yrityksiä osallistumaan korkeariskiseen toimintaan, joka pahimmillaan aiheuttaa taloudellista heilahtelua ja kriisejä (Li ym., 2021).

Selkeiden ja tasapuolisten lakien ja säännöksiin puute on isoin haaste, joka estää tekoälyn yleistymistä finanssialalla. Molemmista tutkimuksissa (Li ym., 2021) & (Maple ym., 2023) todetaan lainsäädännön lisääntymisen olevan suurin edistäjä tekoälylle, sillä yhteiset lait ja säännökset rajaisivat yritykselle sallitut toiminnot ja loisivat tasavertaisen pohjan tekoälyn yleistymiselle. Tutkimuksessa todetaan uusien lakien kehittymisen olevan hidas ja pitkä prosessi, joka sisältää paljon testausta, kokeiluja ja virheitä, mutta samalla loisi laillisen pohjan tulevaisuuden tekoälyimplementoinnille.

2.2.3 Tekoälyn turvallisuushaasteet

Tietojärjestelmien ja teknologian kehitys on tuottanut suuria etuja yrityksen maksuliikenteeseen sekä muihin osa-alueisiin kuten työtehokkuuteen ja kilpailuetuihin. Teknologian lisääntynyt määrä on kuitenkin luonut monelle yritykselle ympäristön, jossa tietoturvan rooli on korkeampi, kun koskaan ennen (Basallo, Senti & Sanchez, 2018). Lisääntyneet verkkopohjaiset tapahtumat kuten maksuliikenne tai tietojen siirto ovat aiheuttaneet turvallisuushaasteita, ja yritykseen kohdistuneet kyberhyökkäykset ovat voineet altistaa yrityksen asiakkaita tietovuodoille, joka heijastuisi haittana asiakkaalle ja mainehaittana yritykselle (Basallo, Senti & Sanchez, 2018). Finanssialan yritysten laitteet ja ohjelmistot ovat riskialttiita palvelunestohyökkäyksille, tietovuodoille sekä muille turvallisuusuhkille (Cao & Zhai, 2022).

Moni tekoälyn osa-alueista on edelleen kokeiluvaiheessa, joka saattaa tuottaa finanssialan yritykselle riskejä ja ongelmia käyttöönottovaiheessa (Li ym., 2021). Tekoälyn käyttämillä algoritmeilla voi olla heikkouksia ja virheitä, jotka altistavat kyseisen ohjelman kyberhyökkäyksille ja tietovuodoille. Tietovuodot eli salassa pidettävän datan menetys voi johtaa suuriin rahallisiin tappioihin, laillisiin vastuihin sekä mainehaittaan (Maple ym., 2023). Tekoälyn koulutukseen ja muuhun käyttöön kerättävä data tulisi suojella asiaan kuuluvalla tavalla. Tiedon salaamisen laiminlyönti voisi hidastaa tekoälyn implementointia alalle sekä heijastua asiakasluottamuksen vähenemisenä tekoälyä testaavaan yritykseen.

Tekoälyn toiminnan turvallisuuden parantamista varten yritysten tulisi investoida suuria summia rahaa ja aikaa tietoturvan vahvistamiseksi, joka nostaa kynnystä tekoälyn käyttöön pienille ja keskisuurille yrityksille (Kruse ym., 2019) & (Li ym., 2021). Tekoälyn turvalliseen käytönottoon ja valvomiseen tarvitaan myös korkeasti koulutettuja työntekijöitä työskentelemään tekoälyohjelmien

rinnalle (Maple ym., 2023). Tämän lisäksi tietovuotojen korjaamisprosessit ovat pitkiä, ja prosessin aikana tietoturvahyökkäyksen aloittanut rikollinen voi saada haltuunsa tärkeitä tietoja, vahingoittaen luottoa tekoälyyn sekä alan kehitystä (Li ym., 2021).

Tekoälyn turvallisuushaasteet kulkevat käsi kädessä 2020-luvulla yleistyneiden tietoturvariskien kanssa ja ovat suuri riski koko tekoälyohjelman elämäkäärässä. Ongelmille ei ole yhtä ratkaisua, ja tutkimuksissa nostettiin useampi tapa, miten mahdolliset kyberhyökkäykset voisivat vaikuttaa tekoälyn ja yrityksen toimintaan. Esimerkiksi Cao & Zhai (2022) tuovat tutkimuksessaan esille yleisimmät tietoturvariskit, jotka aiheuttavat hankaluuksia projekteille. Tutkimukset eivät kuitenkaan esitä konkreettisia ratkaisuja tai parasta toimintatapaa, jolla tekoälytoiminnot olisivat turvattuja. Li ym. (2021) korostavat myös tekoälyn varhaista kehitysvaihetta, jolloin ei voida tarkasti määritellä, miten hyvin tietoturva integroituisi tekoälyohjelmiin.

Tutkimuksissa korostuu myös operaation suuri hinta, joka voi ohjata monen yrityksen pois mahdolliselta tekoälyimplementaatiolta kohti edullisimpia toimintametoja (Kruse ym., 2019) & (Li ym., 2021). Prosessin kehitysvaihe ja siihen liittyvät haasteet voivat koitua yritykselle vaikeaksi ja kalliiksi kokeiluksi, joka rajaa mahdolliset kokeilut suuryrityksille, joiden taloudellinen tilanne sekä korkeakoulutettu henkilöstö sen sallisi (Maple ym., 2023). Tuloksissa ei ilmene yhtä oikeaa tai parasta toimintatapaa, ja tutkimuksista voidaan päätellä oikean toimintatavan selvittämisen, testaamisen ja implikoinnin olevan pitkä ja haasteellinen prosessi, josta ei voi varmaksi sanoa olevan hyötyä yrityksen toiminnalle.

3 YRITYSRAHOITUS

Suomen yritysrahoitus on laajasti pankkikeskeinen. Vaikka pankki ei ole suurin rahoittaja Suomessa, sen rooli on etenkin pienille ja keskikokoisille yrityksille keskeinen (Savolainen, 2017). Rahalaitosten lisäksi myös ulkomaalainen rahoitus ja yritysten väliset lainat ovat yleisiä, mutta keskittyvät lähinnä suuryhtiöihin. Lähivuosina tekoälyavustus ja finanssiriskin kartoituksen helpottuminen on kasvattanut peer-to-peer (P2P) lendingin eli vertaislainauksen suosiota, vähentäen välikäsien tarvetta ja parantaen pienyritysten mahdollisuutta saada lainarahoitusta (Cao & Zhai, 2022).

Yritysrahoituksen kilpailuttaminen on ollut pitkään tarkasti säädeltyä, sillä säätelemätön ala johtaisi tarpeettomiin riskeihin ja sitä kautta mahdolliseen taantumiaan tai finanssikriisiin, joista viimeisin oli subprime-lainojen aiheuttama maailmanlaajuinen finanssikriisi vuonna 2008 (Vives, 2019). Kriisin jälkeinen yritysrahoitustoiminta on ollut nousujohteista ja innovoivaa. Perinteisten yritysrahoitusta tarjoavien toimijoiden rinnalle on noussut uusia kilpailijoita ja tuotteita, jotka ovat mahdollistaneet taloudellisen kasvun ja hajauttaneet rahoituksen riskiä (Vives, 2019).

Teknologian kehitys ja digitalisoituminen ovat aiheuttaneet pankkipalveluiden siirtymisen kivijalkakonttoreista digitaaliseksi. Finanssialan siirto digitaaliseksi on parantanut palveluiden saatavuutta ja palvelunopeutta, sekä avannut oven avoimuudelle ja mahdollistanut rahoituksen tarjoamisen useammalle yritykselle ja asiakkaalle (Cao & Zhai, 2022). Rahoituspalveluiden siirtyminen digitaaliseksi on myös muuttanut asiakkaiden vaatimuksia ja odotuksia palvelulta, sekä auttanut finanssiteknologian eli Fintechin yleistymistä (Vives, 2019).

Finanssialalla tekoälyä hyödynnetään osana arjen toimintoja. Tekoälylle myönnetään monenlaisia tehtäviä, ja niiden toimenkuvat vaihtelevat asiakaspalvelusta luottoluokitukseen. Tekoälyä ja koneoppimista hyödynnetään myös erilaisissa rahoitus- ja sääntelytehtävissä tukiroolina, eli tekoälyä ei käytetä päätöksen tekemiseen vaan työtä tukevana konsulttina. (Naim, 2022).

Tekoälyn ja digitalisaation yleistymisen on muuttanut finanssialan toimintaa avoimemmaksi ja monipuolisemmaksi. Uusien perinteisten pankkien kanssa kilpailevien rahoittajien määrä on noussut ja näin vähentänyt luottoriskin keskittymistä yhdelle toimijalle sekä lisäänyt kilpailua (Vives, 2019). Tekoälyn avulla työtehtäviä on mahdollisuus automatisoida, joka nopeuttaa yrityksen työntekijöiden työtaakkaa sekä nopeuttaa käsittelyaikaa asiakkaalle. Tekoälyn yleistymisen myötä moni rahoituslaitos on hyötynyt muutoksesta ja muuttanut toimintaansa edes osittain tekoälyä hyödynnettäväksi. Tekoälyä hyödynnetään kuitenkin lähinnä asiakaspalvelu- ja luokittelutehtävissä, jossa vastuu on suhteellisen pieni.

3.1 Rahoitusalan monimuotoisuus

Rahoitusallalla on monenlaisia prosesseja, tehtäviä ja työnkuvia. Alan laajuuden vuoksi on vaikea kuvailla tai hahmottaa keskeistä tehtävää, mutta jokainen rahoitusalan tehtävistä on osa suurempaa rahaliikennettä, joka kulkee yksityishenkilöiden, yritysten ja rahoituslaitosten välillä. Fernándezin (2019) tutkimuksessa finanssialan prosessit voidaan karkeasti jakaa viiteen kategoriaan, jotka vastaavat tiettyyn asiaankohdistuvasta maksuliikenteestä. Jokainen viidestä osa-alueesta ovat elintärkeitä yrityksen toiminnan kannalta, ja osa-alueiden koko ja vaikutus toimintaan voi vaihdella yrityskohtaisesti. Toiminnan osa-alueet ovat maksut, pääomamarkkinat, pankkitoiminta, investoinnin hallinta ja vakuutukset (Kuvio 1) (Fernández, 2019).

Maksut eli maksuliikenne on elintärkeä toiminto nyky-yhteiskuntamme toiminnalle (Fernández, 2019). Maksuliikenne on vastuussa kaikkien maksujen liikumisesta ostajan ja myyjän välillä niin perinteisissä liikkeissä, kun verkkokaupoissakin. Maksuliikenne on pankkien välistä tai yhden pankin sisällä tapahtuvaa varainsiirtoa, jolla rahat saadaan perille nopeasti, helposti ja turvallisesti. Maksun alkuperä on jäljitettävissä, ja maksutietojen avulla voidaankin vähentää huomattavasti harmaan talouden, rahanpesun sekä muiden talousrikoksien tapahtumista läpinäkyvyytensä ansiosta. Nykyinen maksuliikenne on suurimaksi osaksi digitaalista liikennettä (Cao, 2020), joka toimii verkkopankkien sekä muiden maksuvälityspalveluiden avulla, mutta perinteisemmät maksutavat kuten pankkikortit ja käteinen ovat silti osa maksuliikennettä, vaikka niiden suosio onkin hiipunut vuosien varrella (Cao, 2020). Maksuliikenteen suurin riskialue on talousrikoksien ja harmaan talouden tunnistaminen ja estäminen, joka on hankalaa perinteisin keinoin (Faccia, Moşteanu, Cavaliere & Mataruna-Dos-Santos, 2020).

Pääomamarkkinat eli osakemarkkinat on osa-alueista rahalliselta arvolta suurin ja myös riskialttein osa-alue (Fernández, 2019). Monella rahoituslaitoksella suuria omaisuuksia osakemarkkinoilla niin yksittäisten osakkeiden, kun isompien portfolioiden ja lainojen muodossa. Osakemarkkinoiden hinnoittelun vaihtelu on suoraan yhteydessä maailman taloudelliseen tilanteeseen, jolloin jokaisella uutisella ja tapahtumalla voi olla seurauksia yrityksen omaisuuden arvon nousuun tai alentumiseen. Kyseinen vuorovaikutus hankaloittaa liikkeiden ennustamisen tapahtumien arvaamattomuuden vuoksi (Xie, 2019). Osakemarkkinoiden liikehdintää on vaikea ennustaa, joka nostaa myös osa-alueen riskialttiutta samalla korostaen vastuullisen ja turvallisen liiketoiminnan painoarvoa. Pääomamarkkinoiden suurin uhka on ulkoisen tapahtuman tai ilmiön aiheuttama taloudellinen epävakaus sekä väärin arvioidut riskit. Pääomariskien kartoituksessa on suosittu manuaalikäsittelyä ja suhtauduttu varautuen automaatio-prosessin arvioihin. (Xie, 2019).

Pankkitoiminta eli pankkipalvelut ovat rahoituslaitosten perinteisin osa-alue, johon kuuluu pankin tarjoamat palvelut kuten tilipalvelut, lakiapu ja säilytyspalvelut. Pankkitoiminta kohdistuu suurimmaksi osaksi pankeille, vaikka alalla

onkin muita toimijoita kuten vakuutusfirmoja ja sijoitusyhtiöitä (Ashta & Herrmann, 2021). Muut toimijat eivät perinteisesti tarjoa asiakkailleen säilytysmahdollisia vaan käyttävät pankkien tarjoamia palveluita kuten maksutilejä liiketoimintansa hoitamiseen. Pankkitoiminta koskee sekä henkilöasiakkaita että yritysrahoituksia. Pankkitoiminnan palveluita on pyritty digitalisoimaan nopeimpien työprosessien, saatavuuden ja saavutettavuuden parantamiseksi, ja pankkitoiminnan suurin riski on siihen kohdistuvat kyberhyökkäykset ja tietovuodot (Qi & Xiao, 2018). Pankkitoiminnan palvelut ovat myös tarkkaan valvottuja ja säädeltyjä.

Investoinnin hallinta eli varainhoito on finanssialan palvelu, jossa ammattilainen hoitaa ja hallinnoi yrityksen tai yksityishenkilön erilaisia omaisuuksia kuten osakkeita ja rahastoja. Varainhoidon kysyntä on noussut lähivuosina perinteisten pankkipalveluiden muuttuessa digitaaliseksi, ja korostuneen kysynnän vuoksi pankkitoimintaan on lähivuosina esitelty monia uusia tuotteita varainhoitoon liittyen (Zheng, Zhu, Li, Chen & Tan, 2019). Osa-alueen toiminta on läheisessä yhteistyössä pääomamarkkinoiden kanssa, sillä pääomamarkkinoiden muutokset voivat heijastua suoraan asiakkaan omaisuuden arvon alenemisessä tai nousussa. Osa-alueen suurimmat riskit ovat tietoturvariskit ja asiakkaan tietoja kalastelevat huijaukset sekä kyberhyökkäykset (Cao & Zhai, 2022).

Vakuutusten osa-alue on perinteisesti vakuutusyhtiöille kuuluva osa-alue, mutta lähivuosina osa-alueen tuotteiden tarjonta on yleistynyt muissa finanssilaitoksissa. Osa-alueen keskeinen tavoite ja toiminta perustuu yksilöiden, yritysten ja omaisuuden vakuuttamiseen (Qi & Xiao, 2018). Vakuuttamisen ideana on turvata omaa tai yrityksen toimintaa sekä varautua mahdollisiin toimintaan kohdistuviin riskeihin sekä odottamattomiin tapahtumiin ja onnettomuuksiin. Vakuutustoiminnan suurimmat riskit ovat mahdolliset kyberhyökkäykset, riskialttiit vakuutus sopimukset sekä mahdolliset suuret tragediat (Cao & Zhai, 2022).

3.2 Yritysrahoituksen päätöksenteko

Yritysrahoituksen riski on määritelty seuraavanlaisesti: ”todennäköisyys, että tietty epäsuotuisa tapahtuma tapahtuu ilmoitetun ajanjakson aikana tai johdetaan tietyistä haasteista” (Demirag, Khadaroo, Stapleton & Stevenson, 2011). Jokaisessa rahoitushankkeessa arvioidaan ja analysoidaan hankkeen riskialttiutta, asiakkaan tarkoituksena on tunnistaa ja hallita rahoitustoimintaan liittyviä rahallisia riskejä. Pankki tai muu rahoituslaitos ei lähde hankkeeseen mukaan, jos riskit konkurssille tai maksukyvyttömyydelle ovat sen mielestä liian suuret. Jos tarpeeksi moni tai yksittäinen suuri pankin myöntämä laina osoittautuu maksukyvyttömäksi eli joutuu konkurssiin, voi sillä olla tuhoisat seuraukset (Savvides, 2011).

Jokaisen yrityksen rahoitustarpeet ovat ainutlaatuisia, ja jokaisessa on otettava huomioon yrityksen toimiala, taloudellinen tilanne sekä monet muut tekijät, joiden perinteinen kartoittaminen veisi paljon aikaa ja työvoimaa (Zheng ym., 2019). Kaikkia maksukyvyttömyyden aiheuttavia tekijöitä ei myöskään

voida kartoittaa hakuprosessin aikana, ja esimerkiksi alan muutokset tulevaisuudessa tai odottamattomat muutokset yrityksen toiminnassa voivat aiheuttaa maksuvaikeuksia sekä pahimmassa tapauksessa yrityksen konkurssin.

Yritysrahoituksessa asiakkuuden sekä rahoitushankkeen riskiä pyritään kartoittamaan käyttäen apuna ulkopuolisia konsultteja sekä analyyseja, jotka pyrkivät käymään läpi kaikki mahdolliset skenaariot sekä niiden tapahtumistodennäköisyydet (Demirag ym., 2011). Rahoitusriskin tarkka kartoitus on hankala tehtävä, ja ainoa tapa arvioida takaisinmaksua asianmukaisesti on merkityksellisten kassavirtaennusteiden avulla. Läpikohtaisen analyysin tavoitteena on hahmottaa kyseiset riskitekijät rahoituksen elinkaaren aikana ja selittää, miten jokainen riskitekijä vaikuttaisi yrityksen takaisinmaksukykyyn (Savvides, 2011).

Useimmille rahoitushankkeille rahoittaja vaatii takauksia tai muita vakuuksia, jotta projektin riskit saataisiin pienennettyä siedettävälle tasolle. Lisäehdot sekä vakuudet ovat yleisiä tapoja suojautua odottamattomilta tapahtumilta ja varmistua, että asiakas harjoittaa vastuullista liiketoimintaa ilman suurempia riskejä (Savvides, 2011).

Jokaisessa rahoitushankkeessa on aina riski. Riski prosenttia sekä tapahtumastodennäköisyyksiä voidaan arvioida ja kartoittaa, mutta lopullisen riskin tarkka ennustaminen on vaikea tehtävä. Savvidesin (2011) tutkimuksessa tunnistetaan yleisimmät riskitekijät, jotka ovat johtaneet edellisiin finanssikriiseihin. Vastuullisuus ja varovaisuus nousevat tutkimuksessa keskiöön, mutta tutkimus on enemmän suuntaa antava, kun ratkaisuja tarjoava. Tutkimus keskittyy pääosin menneisyyden finanssikriisien analysointiin ja virheiden tunnistamiseen, jotta tiedossa olevat virheet eivät toistuisi. Demirag ym. (2011) ja Zheng ym. (2019) keskittyvät analysoimaan nykyisen riskikartoituksen prosesseja sekä korostavat etenkin prosessien hitautta ja monimutkaisuutta, johon tekoäly voisi olla ratkaisu. Tutkimukset eivät kuitenkaan esitä ratkaisua ongelmalle, vaan korostavat ainoastaan käytössä olevien prosessien heikkoudet ja epäkohdat.

4 TEKOÄLYN HYÖDYNTÄMINEN YRITYSRAHOITUKSEN PÄÄTÖKSENTEOSSA

4.1 Tekoälyn potentiaali finanssialalla

Kasvavan digitalisaatio- ja teknologiapainotteisen finanssialan mukana on kehittynyt ympäristö, jossa tekoälyn hyödyntämisessä voi olla suuria hyötyjä finanssialalle. Lin ym., (2021) mukaan tekoälyä implementoivien rahoituslaitosten tulisi pyrkiä avoimeen ja yhtenäiseen linjaan rahoituspäätöksiä koskien, jotta jokaisella laitoksella olisi mahdollisimman realistinen kuva asiakkaan taloudellisesta tilanteesta. Tämän lisäksi avoimuudella olisi myös positiivisia seurauksia toiminnanvalvontaa varten, jotta alalle syntyisi yhtenäinen lainsäädäntö ja toimintamallit (Li ym., 2021).

Avoimuuden puute voi heijastua tiedon epäsymmetriana etenkin pienempien rahalaitosten operoinnissa, sillä heillä on huomattavasti pienempi tietokanta, kun suurilla pankeilla ja rahoituslaitoksilla. Tekoälyn kehittyessä tiedon epäsymmetrisyys voi heijastua tietämättömyytenä ja kokemattomuutena, joka voi kasvaa suureksi riskiksi tekoälyn implementoinnin yhteydessä pienemmissä rahoituslaitoksissa (Mazzucato, Schaake, Krier & Entsminger, 2022). Alan yhtenäiset toimintamallit, pankkien välinen avoimuus ja yhdenvertainen päätösmenetelmä tulisi perustua selkeihin parametreihin, jotka olisivat tarvittaessa selitettävissä ja perusteltavissa loogisesti (Giudici, 2018) & (Mazzucato ym., 2022).

Finanssialan elinehto on tieto. Tiedot yrityksen taloudellisesta tilanteesta, toimintaan kohdistuvista riskeistä sekä tulevaisuuden näkymistä ovat tärkeitä tietoja yrityskartoituksessa ja rahoituspäätöksessä. Mitä enemmän tietoa rahoittaja saa yrityksestä, sitä paremmat lähtökohdat onnistuneelle yrityksen tulevaisuuden ennustamiselle. Onnistunut riskien ennustus heijastuu sekä lainanantajalle että rahoittajalle suurempana liikevoittona ja pienempänä riskinä (Zhang & Kedmey, 2018). Digitalisaation mukana lisääntyneet tiedotusvälineet ovat lisänneet saatavan tiedon määrää huomasti, mutta samalla hankaloittanut muutosten ennustamista perinteisin keinoin, sillä suuremman tietomäärän analysointi vie enemmän aikaa. Sen lisäksi myös väärän tiedon määrä on lisääntynyt ja tiedon laadun sekä alkuperän arviointi ja mediakriittisyys ovat nousseet keskeisiksi tekijöiksi (Zhang & Kedmey, 2018).

Tekoäly on kaksipuolinen miekka. Dhaiguden & Lawanden (2022) mukaan investoinnit tekoälyn käyttöönottoon ja kehitykseen voivat säästää yrityksen resursseja kuten työtunteja ja aikaa. Tekoälyinvestoinnit nopeuttavat prosesseja, sekä samalla parantavat yrityksen liikevaihtoja. Tekoälyn implementoinnin jälkeen myös kartoituksen tuloksen tarkkuus on parantunut, joka näkyy vähenevänä määränä maksuvaikeuksia rahoitettavilla yrityksillä (Dhaigude & Lawande, 2022). Cheatham, Javamardianin ja Samandarin (2018) mukaan tekoälyllä on potentiaalia tehdä suuria muutoksia organisaation toiminnassa, mutta muutoksien mukana organisaatio voi havaita uusia uhkia ja haasteita, joihin tulisi

varautua asianmukaisin keinoin. Tekoälyn käytön tulisi perustua vastuulliseen toimintamalliin ja sille on oltava tarkoin suunniteltu. Tekoälyn lisääntyminen finanssialalla voi myös vaikuttaa negatiivisesti työllistymiseen pienemmän työntekijävaatimuksen myötä (Cheatham, Javanmardian & Samandari, 2019). Tekoälyn hyödyntäminen rahoitusalan työkaluna voi aiheuttaa paljon haittaa organisaatiolle, jos tekoälyn implementointi epäonnistuu tai on huonosti suunniteltua. Tekoälyjärjestelmän implementointi ei ole helppo tehtävä, sillä siirtyminen automaatiotehtäviin vaatii paljon suunnittelua ja vastuuta. Tekoäly on myös implementoitava tarpeeksi läpinäkyvällä tavalla, jotta sen toimintaa olisi mahdollista valvoa ja kehittää (Felzmann, Fosch-Villaronga, Lutz, & Tamò-Larrieux, 2020).

Tekoälyn epäonnistunut implementointi voi esiintyä mainehaittana, turvallisuusriskinä, tietovuotoina, sekä asiakkaiden luoton vähenemisenä. Tekoälylle syötettävä data voi sisältää salassa pidettävää tietoa, joka vääriin käsiin joutuessa voi aiheuttaa paljon tuhoa (Kruse ym., 2019), (Cao, ym., 2022) ja (Maple ym., 2023). Tekoälyä ei tulisi itsenäisesti päästää suorittamaan mitään prosessia, vaan jokaisella toiminnolla ja osa-alueella tulisi olla ihmisvalvoja, joka toimisi laadun ja toiminnan valvojana. Tämän lisäksi valvojan tulisi toimia viimeisenä tarkastuspisteenä ennen tekoälyn generoimien tietojen lähettämistä eteenpäin yrityksen sisäisesti tai julkisesti (Fernández, 2019) ja (Li ym., 2021). Tekoälyn uuden sukupolven eli AI 2.0:an integraatio ja testaus finanssialaan on jo alkanut, mutta testauksen kokonaisuus on alkuvaiheessa. Onnistuneen integraation alkuvaiheessa suunnittelun ja asiakkaiden toiveiden kuuntelulla on suuri merkitys onnistumisen kannalla (Zheng, Zhu, Li, Chen & Tan, 2019). AI 2.0:lla tarkoitetaan tekoälyn yleistymistä ja sen yleistyvää mahdollisuutta toimia teknologiapainotteisen muutoksen uranuurtajana ja finanssialan laajaskaalaisen automaation ja digitalisoitumisen muutoksen avustajana (Zheng ym., 2019).

Muutoksien takia tekoälyn rooli on muuttunut keskeisemmäksi ja käytännönläheisemmäksi. Tekoälyn avulla voidaan yksinkertaistaa monet prosessit, joka auttavat ajan sekä rahan säästämiseen yrityksen arkitoiminnoissa. Yksi finanssialan suurimmista eduista tekoälyyn liittyen verrattuna muihin aloihin on sen suuri datankäyttö raporttien, arvioiden ja muiden asiakirjojen muodossa. Datan suuri määrä auttaisi tekoälyn oppimista ja kehittämistä (Zheng ym., 2019) & (Dhaigude ym., 2022). Datan merkityksen kasvaessa myös datan turvallisuuden kuten kyberturvaan ja yksityisyydensuojaan on syytä suhtautua vakavasti (Kruse ym., 2019), (Li ym., 2021) ja (Maple ym., 2023).

Tekoälyllä, automatisoinnilla ja koneoppimisella on potentiaalia olla suuria vaikuttajia niin mikro- kuin makrotaloudessa (Naim, 2022). Uudistuksilla on suuri potentiaali muuttaa alan toimintatapoja, käytäntöjä ja vaatimuksia nykyajan yritysrahoituksen toimintamalleissa. Tekoälyn hyödyntäminen ja käytön yleistymisen on luonnollinen seuraava askel alalla, jossa teknologiapainotteisuus ja suuri datan määrä on yleistynyt huomattavasti digitalisaation myötä. Tekoälyohjelmien markkinoiden on ennustettu myös kasvavan vuosittain keskimäärin 56 % ja arvioiden mukaan tekojärjestelmämarkkinoiden arvo vuonna 2024 olisi noin 11.1 biljoonaa dollaria (Li ym., 2021).

Fernándezin (2019) tutkimuksessa finanssialan toiminnot jaetaan viiteen erillaiseen osa-alueeseen: maksut, pääomamarkkinat, pankkitoiminta, investoinnin hallinta ja vakuutukset. Jokainen osa-alue on erilainen ja jokaisella alueella on omat haasteensa, jotka pitäisi ratkaista toiminnan kehittyessä nopeammaksi ja tehokkaammaksi. Tekoälyllä olisi potentiaalia tarjota jokaiselle osa-alueelle ainutlaatuisen ratkaisun, joka olisi mahdollista muokata yrityksen tarpeita vastaavaksi ja pystyisi potentiaalisesti ratkaisemaan osa-alueita vaivaavat haasteet, samalla luoden arvoa sekä yritykselle että sen asiakkaalle.

4.2 Tekoälyn käyttö osana parempaa päätöksentekoa maksuliikenteessä


Perinteistä palvelua tarjoavien kivijalkakonttorien tilalle tulleet digitaaliset palveluväylät kuten verkkopankki ovat nopeuttaneet ja helpottaneet maksuliikennettä. Pankkien asiakkailleen tarjoamat verkkopankkialustat toimivat täysin verkossa ja ovat tärkeässä roolissa verkkomaksujen ja rahaliikenteen ylläpitämisessä (Cao, 2020). Digitaalisen väylän palveluiden korkea automaatiotaso ja käytön helppous ovat lisänneet palvelunopeutta ja tehokkuutta. Matalakitkaiset ja korkeasti automatisoidut asiakaspalvelualustat ovat nousseet suosiossa huimasti ja on tunnistettu olevan yksi tärkeimmistä kasvavista trendeistä vähittäispankkialalla vuonna 2021 (Hunter & Güzey, 2021). Digitaaliseen maksuliikenteeseen siirtyessä on kuitenkin huomattu turvallisuuspuutteita etenkin rahanpesun ja muiden finanssirikosten estämisessä.

Digitaalisten maksuliikenteen lisääntyessä suuren tapahtumamäärän valvonta hankaloituu. Perinteisillä metodeilla suoritettava valvonta on hankalaa sekä työlästä, ja työllistää monta yrityksen toimihenkilöä, jolloin yrityksen tulisi palkata lisää työvoimaa nostoen yrityksen kuluja (Faccia ym., 2020). Lisääntynyt työvoima toimi myös hidasteena yrityksen digitalisoitumiselle, sillä yrityksen resurssit sidottiin työvoimaan uusien teknologian sijasta. Faccian ym. (2020) tutkimuksessa ehdotetaan ratkaisuksi ennakoivaa tekoälyalgoritmia, joka voisi automaattisesti seurata epäilyttäväksi merkittyjä tilitapahtumia ja tunnistaa sille koulutettujen kaavojen perusteella mahdolliset väärinkäytöt. Tekoäly kykenisi laskemaan todennäköisyyden väärinkäytölle, jonka jälkeen talousrikosanalyttikko tai muu yrityksen työntekijä voisi keskittyä tutkimaan tapauksia, jossa talousrikoksen todennäköisyysprosentti olisi tarpeeksi korkea (Faccia ym., 2020).

Ding, Zhang, Liu, & Duan (2015) kehittivät tutkimuksessaan ennakoitavan tekoälymallin, joka sopisi talousrikollisuuden tarkkailuun ja tutkimiseen. Tutkimuksessa käytetty tekoälymalli opetettiin ennustamaan tulevia osakkeen hinnanmuutoksia käyttäen syväoppimalleja sekä taloudellisia uutisia. Parametreja muokkaamalla malli voidaan kouluttaa tunnistamaan myös epäilyttävät maksutapahtumat. Malli voidaan kouluttaa hyödyntämällä suuria määriä uutisia tai

yksittäisien tapausten avulla esimerkiksi anaöysoimaan uutisotsikon sanoista tunnussanat, jotka osuvat sille määriteltyyn algoritmiin (Ding ym., 2015).

Algoritmin ympärille voitaisiin rakentaa hermoverkosto, joka tukee analyysin suorittamista sekä vanhojen tiedonyhdistämisen epäilyttävään tapahtumaan, jotta tekoäly voisi tehdä sekä lyhyt- että pitkäaikaisen arvion (Ding ym., 2015). Tutkimuksessa käytettyä syväoppia ja syy-seuraussuhteita hyödyttävä algoritmi testattiin markkinaolosuhteissa, jossa tekoäly osti ja myi osakkeita vanhoista ja uusista talousuutisista saatuun tietoon vedoten. Tekoäly onnistui ennustamaan osakemuutoksia 64.21 % todennäköisyydellä ja 0.40 tarkkuudella. (Mathewsin korrelaatiokerroin (MCC), jossa 1 = täydellinen ennuste ja 0 = satunnainen ennuste). Tämän lisäksi tekoälyn myymien osakkeiden tuottomäärä oli dollareissa 6,774 dollaria, joka on huomattavasti parempi tulos, kun edellisissä tutkimuksissa (kuvio 2). Dingin ym. (2015) tutkimuksessa käytetty tekoälyalgoritmi on siis tarkka tunnistamaan sille annettuihin parametreihin sopivat tapahtumat, ja näin ollen pystyisi myös löytämään sekä arvioimaan epäilyttävät maksutapahtumat sille annettujen parametrien mukaisesti. Tutkimuksessa käytetty tekoälyohjelma ei kuitenkaan pystynyt arvaamaan jokaista tapahtumaa täydellisellä tarkkuudella, jolloin ohjelman tekemät hälytykset jouduttaisiin silti tarkastamaan ihmisen toimesta. Ohjelma nopeuttaisi ja automatisoisi epäilyttävien maksujen valvontaa, samalla vähentäen työntekijöiden työkuormaa.



Kuva 4: Yksittäisten osakeennusteiden kehitystulokset (yritykset on nimetty niiden ticker-symbolien mukaan)

	Keskiverto tulos
Luss and d'Aspremont [2012]	\$8,694
Ding et al. [2014]	\$10,456
EB-CNN	\$16,785

Taulukko 3: 15 yksittäisen yrityksen keskimääräinen voitto

	Indeksiennuste		Yksittäinen osakeennuste		
	Tarkkuus	MCC	Tarkkuus	MCC	Tuotto
Luss [2012]	56.38%	0.07	58.74%	0.25	\$8,671
Ding [2014]	58.83%	0.16	61.47%	0.31	\$10,375
EB-CNN	64.21%	0.40	65.48%	0.41	\$16,774

Kuvio 10: Tekoälyn myymien osakkeiden tulos verrattuna edellisten tutkimuksien tuloksiin. Tekoälyn alkupääoma oli 10 tuhatta dollaria. Oikeassa taulukossa nähdään myös mallin ennustatarkkuus niin indeksille kun yksittäiselle osakkeelle. (Ding ym., 2015).

4.3 Tekoälyn käyttö osana parempaa päätöksentekoa pääomamarkkinoilla

Maailmanlaajuiset pääomamarkkinat ovat kooltaan suuret, ja aiheuttavat suuruutensa vuoksi monia haasteita rahoitusalan yrityksille. Etenkin suuryrityksen isoissa ja monimutkaisissa rahoitushankkeissa käsittelyprosessi on pitkä, ja tiedon analysointi perinteisin keinoin usein työlästä automatisoitujen päätösprosessien puuttumisen takia. Suuren tietomäärän analysointi manuaalisesti lisää myös ihmismuuttujavirheen tapahtumistodennäköisyyttä. Ongelman ratkaisuksi pankit pyrkivät siirtämään tietonsa digitaaliseen muotoon, jossa tieto olisi nopeammin ja helpommin saatavilla automaatioprosessien kehittyessä. Rahoituslaitokset kuitenkin suhtautuvat automaattiseen päätöksentekoon varautuen ja etenkin suurien rahoitushankkeiden käsittely on usein hidasta, sillä hakemus käsitellään ihmisvoimin useamman tahon toimesta harkiten ja analysoiden jokainen kohta perinpohjaisesti (Hunter & Güzey, 2021).

Pienien rahoitushankkeiden kartoitus olisi mahdollista automatisoida käyttämällä tekoälyä, sillä tekoälyn nopea prosessointi ja laskentavoima voisi analysoida tietoa suoraan hakijan hakemuksesta, jonka jälkeen tekoäly saisi digitaalisesta tietokannastaan loput asiakasta koskevat tiedot (Cao & Zhai, 2022). Saadun tiedon avulla tekoäly voisi tehdä ennusteet asiakkaan taloudellisesta tilanteesta nykyhetkellä sekä arvion tulevaisuuden maksukyvyistä. Tekoälyn tietopankkeihin voitaisiin kerätä myös vaihtoehtoista tietoa asiakkaan ostokäyttäytymisestä esimerkiksi digitaalinen jalanjäljen avulla. Caon & Zhain (2022) mukaan lainanhakijan ostokäyttäytyminen verkossa on yksi monista keinoista ennustaa mahdollista maksukyvyttömyyttä. Kiinassa vaikuttava Ant Financial on ottanut käyttöönsä vaihtoehtoiseen dataan perustuvan luottoluokitusjärjestelmän, jossa lainaa varten hankittava tieto voidaan poimia esimerkiksi asiakkaan sosiaalisesta mediasta, verkko-ostoksista tai mobiilitililtä (Qi & Xiao, 2018) & (Cao & Zhai, 2022).

Asiakkuuden koosta johtuvat pitkät käsittelyajat voivat kuormittaa yritystä sekä aiheuttaa mahdollisia asiakkuuden menetyksiä pitkän odotusprosessin vuoksi. Luottoriskin arvioimisen monimutkaisuus ja arvioinnin vaihteleva tarkkuus on ollut kauan tutkittu ilmiö, joihin ei ole yhtä selkeää ratkaisua. Luottoriskin arviointi on huomattavasti vaikeampaa isoissa rahoitushankkeissa monimutkaisuuden ja monen riskitekijän vuoksi. Perinteisin keinoin ison kokonaisuuden analysointi vie paljon aikaa, joten tekoälyn kouluttaminen olisi kannattavaa isojen kokonaisuuksien analysointiin ja arviointiin (Aziz & Dowling, 2019).

Tekoälyn kykyä arvioida yrityksen taloudellista tilaa on tutkittu jo monta vuosikymmentä, vaikka tekoälyn käyttö on yleistynyt vasta lähiaikoina. Tekoälyn tutkiminen yleistyi 90-luvulla tietokoneiden yleistyessä kodeissamme. Ensimmäisen tutkimuksen testit keskittyivät tietokoneohjelmien kykyihin erottamaan yritykset turvallisiin ja riskialttiisiin kohteisiin niille annetun tiedon perusteella (Altman, Marco, & Varetto, 1994). Tutkimuksessa pyrittiin selvittämään pystyisikö tietokone analysoimaan sille syötettyä dataa, tunnistamaan kaavat ja

hyödyntämään kyseiset kaavat tulevaisuuden taloudellisten riskien kartoittamiseen.

Altmanin ym., (1994) tutkimuksessa tietokoneen palauttama malli oli yksinkertainen, lineaarinen tai epälineaarinen malli, joka pystyi arvioimaan tulevaisuuden maksuvaikeuksien ilmenemisten todennäköisyyttä. Malli teki arvionsa ainoastaan sille annetun datan perusteella, eikä kyennyt ottamaan arviossaan huomioon esimerkiksi epäloogisia tai ihmisen toiminnasta johtuvia virheitä. Tutkimuksessa tietokoneeseen syötettiin yhteensä 426 yrityksen tiedot, joista puolet olivat taloudellisesti terveitä yrityksiä ja puolet taloudellisesti vaikeuksissa olevia. Tutkimuksessa käytetty ohjelma onnistui luokittelemaan yritykset vuoden ennen taloudellisten vaikeuksien ilmenemistä 87.6 % tarkkuudella (terveet yritykset) ja 92.6 % tarkkuudella (epäterveet yritykset). Tietokone onnistui tunnistamaan vanhasta datasta syy-seuraussuhteet ja arvioimaan yrityksen tulevat maksuongelmat noin 90 % tarkkuudella (Altman ym., 1994). Tekoälyn mallinnuksen keinot, tarkkuus ja ennustusperusteet ovat muuttuneet tietokoneiden ja laskentavoiman kehittyessä. Uuden vuosituhannen alussa tutkijat alkoivat kehittämään yksinkertaisia malleja monimutkaisemmaksi, jotta mallit kykenisivät käsittelemään enemmän dataa nopeammin ja tarkemmin.

Zhangin, Caon ja Schniederjansin (2004) julkaistussa tutkimuksessa esitellään keinotekoiseen neuroverkkoon perustuvaa ennustusmallia. Artificial neural network (ANN) eli keinotekoinen neuroverkko on koneoppimismalli, joka inspiroituu ihmisaivojen rakenteesta ja toiminnasta. Malli koostuu rakenteeltaan kootuista solmuista, jotka ovat jakautuneet syöte-, piilo- ja lähtökerrokseen (Tiwari, Sriwastava & Gera, 2020). Malli soveltuu parhaiten monimutkaisiin tehtäviin kuten taloudellisen datan analysointiin. Mallin vahvuus perustuu ihmisaivoa mukailevaan toimintamalliin, joka kykenee tunnistamaan tietojen väliset riippuvuussuhteet sekä ulkoiset vaikuttavat tekijät. Mallin käyttö taloudellisen datan käsittelyyn auttoi myös hahmottamaan ihmismielen tekemät virheet arvioinnissa sekä korjaamaan ne totuutta vastaavaksi (Zhang, Cao ja Schniederjans, 2004).

Koneoppimismallia käytettiin tutkimuksessa hyödyntäen 283 yrityksen taloustietoja 41 eri toimialalta. Tutkimuksessa käytetty kolmen kerroksen eteenpäin suuntaava neuroverkko on laajalti hyväksytty kykenevän arvioimaan mikä tahansa jatkuva funktio, jos keskikerroksen yksiköitä on riittävästi (Zhang, Cao ja Schniederjans, 2004). Tavallisen kolmen kerroksen verkkomallin rakenne on ilmaistu tarkemmin kuviossa 3.

$$Y_t = f[(X, \alpha, \beta] = \sum_{j=1}^n \alpha_j \log \text{sig} \left(\sum_{i=1}^k \beta_{ij} x_i + \beta_{0j} \right)$$

Kuvio 3: Kolmikerroksisen verkkomallin rakenne, missä Y_t on verkon tulos, X on syötevektori, x_i on i :s syöte, n on keskikerroksen yksiköiden lukumäärä, k on syötteiden lukumäärä, α edustaa vektoria keskikerroksen ja lähtökerroksen yksiköiden välisistä kertoimista (painoista), β osoittaa matriisia keskikerroksen ja syötekerroksen yksiköiden välisistä kertoimista, α_j on paino lähtökerroksesta, joka yhdistää j th piilotetun kerroksen yksikön lähtöön, $\beta_{-j} = \{\beta_{-ij}, i = 1, 2, \dots, k\}$ on

keskikerroksen yksikön j painovektori, β_0j on keskikerroksen yksikön j vinopaino ja $\log \text{sig}$ on logistinen siirtofunktio $\log \text{sig}(a) = 1/[1 + \exp(-a)]$ (Zhang, Cao ja Schniederjans, 2004).

Tutkimuksessa syötettiin yrityksen historiallinen osakekohtainen tulos, ja verrattiin saatuja tuloksia mallin arvioihin. Tutkimuksessa huomattiin tulosten olevan tarkempia neuroverkkomallilla, kun perinteisillä keinoilla tai lineaarisilla mallinnuksilla (Altman ym., 1994). Tutkimuksessa kuitenkin painostetaan ennustetarkkuuden olevan parempi, kun neuroverkon arvioihin on lisätty perinteisiä kirjanpituuttajia. Tutkimus suosittelee parhaiden tulosten saavuttamiseksi käytettävän molempia, ja toteaa parhaiden tulosten olevan saavutettavissa epälineaarisin keinoin (Zhang ym., 2004). Tutkimuksessa ei voitu myöskään osoittaa pitkän aikavälin tuloksia puuttuvan datan vuoksi. Keinotekoisiiin neuroverkkoihin perustuvaa mallintamista on käytetty monessa tutkimuksessa.

Mallilla on tutkittu yrityksen riskialttiutta edellisvuosien taloudellista dataa hyödyntäen ja malli on osoittautunut tarkaksi osoittaen noin 0.3311 prosentin virhemarginaalin (Pacelli, Bevilacqua, & Azzollini, 2011). Tutkimuksessa hyödynnetty malli on edeltäjäänsä huomattavasti tehokkaampi, jonka ansiosta uusi neuroverkkomalli pystyy käsittelemään enemmän dataa samanaikaisesti ja on edeltäjäänsä tehokkaampi. Tietokonekehityksen ja laskentavoimaparannuksen ansiosta myös tutkimuksessa pystyttiin käyttämään suurempaa otantaa, näin saavuttaen tarkemmat tulokset. Epälineaarinen algoritmi voi auttaa yritystä hyödyntämään tekoälyä saamaan paremmat arviot tulevaisuuden maksukyvyistä, mahdollisista piilevistä riskeistä sekä muista asioista, joka saattaisi jäädä kokeenemmalta luottovirkailijaltakin huomaamatta. Malli ei kuitenkaan ole täydellinen ennustaja, joten mallin arvion pohjalta ei tulisi tehdä myönteistä tai kielteistä päätöstä, vaan käyttää suuntaa antavana mielipiteenä.

Lineaarisen mallin algoritmin lisäksi lähivuosina on noussut toinen tehokas riskinkartoitusmalli, joka on saanut suosiota etenkin koneoppimisen kehityksessä tehokkuutensa ja skaalautumisensa vuoksi. Tree Boosting Model eli puusarjamalli on oppimistekniikka, joka yhdistää vahvan ennustusvoiman ja heikot parametrit (mallissa ilmaistuna ”matalat puut”) vahvaksi ennustusmalliksi. Mallin toiminta perustuu yksinkertaisiin joko - tai malleihin, jotka koulutetaan peräkkäin samalla vahvistaen yhden ”puun” ennustamiskapasiteettia osana isompaa puujoukkoa (Chen & Guestrin, 2016).

XGBoost (Extreme Gradient Boosting) on tällä hetkellä yksi tehokkaimmista puusarjamallia hyödyntävistä koneoppimisen algoritmeista. Se on suunniteltu luokittelu- ja regressiomallin ongelmiin ja sitä on käytetty paljon tekoälyn koulutuksessa. Mallin tehokkuus perustuu sen skaalautuvuuteen ja laskentatehoon, jonka lisäksi mallin tuloksia on helppo tulkita ja yleistää (Chen & Guestrin, 2016). XGBoostissa päätöspuiden laajuutta ja oppimissyvyyttä voi säätää projektin luonteen mukaan, ja päätösprosesseja voi tarkistella osissa paremman ymmärrettävyyden saavuttamiseksi.

XGBoostin laajan käytettävyyden vuoksi sitä on käytetty monenlaisissa tehtävissä. Koulutusmallin muokkautuvuus ja saatavuus monissa eri koodauskielissä sekä helppo integroituminen muihin järjestelmiin tekee siitä helposti lähestyttävän ja käytettävän oppimismallin moneen eri tarkoitukseen. XGBoostin

käyttömahdollisuudet ovat laajempia, kun kilpailijoilla (kuvio 6) ja mallin suosituinta algoritmia (Greedy algorithm, kuvio 7) on käytetty suurien yritysten kuten Allstaten ja Yahaon luokittelutehtävissä. Pilvipalveluihin integroitu malli on valmis käytettäväksi myös Aasian jättien kuten Tianchin ja Alibaban järjestelmien kanssa. (Chen & Guestrin 2016).

Taulukko 1: Suurten puutehostusjärjestelmien vertailu.

Järjestelmä	exact greedy	approximate global	approximate local	out-of-core	sparsity aware	parallel
XGBoost	Kyllä	Kyllä	Kyllä	Kyllä	Kyllä	Kyllä
pGBRT	Ei	Ei	Kyllä	Ei	Ei	Kyllä
Spark MLlib	Ei	Kyllä	Ei	Ei	Osittain	Kyllä
H2O	Ei	Kyllä	Ei	Ei	Osittain	Kyllä
scikit-learn	Kyllä	Ei	Ei	Ei	Ei	Ei
R GBM	Kyllä	Ei	Ei	Ei	Osittain	Ei

Taulukko 1: Kuuden yleisimmän puusarjamallin järjestelmien (algoritmien) tukemisen vertailun vertailu (Chen & Guestrin, 2016).

Algoritmi 1: Exact Greedy Algoritmi Split Findingille

Input: I , instance set of current node

Input: d , feature dimension

$gain \leftarrow 0$

$G \leftarrow \sum_{i \in I} g_i, H \leftarrow \sum_{i \in I} h_i$

for $k = 1$ **to** m **do**

$G_L \leftarrow 0, H_L \leftarrow 0$

for j **in** $sorted(I, \text{by } x_{jk})$ **do**

$G_L \leftarrow G_L + g_j, H_L \leftarrow H_L + h_j$

$G_R \leftarrow G - G_L, H_R \leftarrow H - H_L$

$score \leftarrow \max(score, \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{G^2}{H + \lambda})$

end

end

Output: Split with max score

Kuvio 4: XGBoost- algoritmin suosituimman Exact Greedy- algoritmin rakenne (Chen & Guestrin, 2016).

XGBoost- puumalli on tehokas ja skaalautuva algoritmi, joka on yksi kehittyneimmistä ja tarkimmista algoritmeista tällä hetkellä. Malli ei kuitenkaan ole täydellinen ennustuskyvyltään, jolloin mallin antamaan arvioon on suhtauduttava varauksella ja lopulliset päätökset tehtävä luottoa myöntävän virkailijan toimesta. XGBoostin ennustustarkkuudesta ei ole myöskään tarpeeksi todellista tilannetta vastaavassa olosuhteessa, joissa alan säännöt ja toimintamallit voisivat mahdollisesti rajoittaa mallin ennustustehokkuutta.

4.4 Tekoölyn käyttö osana parempaa päätöksentekoa pankkitoiminnassa

Pankkitoiminnan osa-alue on alueista laajin. Pankkitoiminta pitää sisällään monia erilaisia palveluita ja niihin liittyviä lakia ja säädöksiä. Pankki toiminnan tulisi olla mahdollisimman avointa ja yhdenvertaista, jotta alan toimintaa voisi valvoa mahdollisimman tehokkaasti. Tämän lisäksi avoimuus vähentäisi vastuu- tonta liiketoimintaa sekä talousrikollisuutta (Li ym., 2021). Myös tekoölytoimin- nan pankkipalveluissa tulisi olevan täysin tulkittavissa ja selitettävissä, jotta nii- den syy-seuraussuhde olisi mahdollisimman selkeä ja tarvittaessa todennetta- vissa.

Edellisten tekoölymallien tulosten perustelu ja loogisuus on luonut jopa niitä tutkineille tutkijoille tulkitsemisvaikeuksia (Lundberg & Lee, 2017). Lundbergin ja Leen ehdottama SHAP-rakenne (SHapley Additive exPlanation) on yhtenä- nen lähestymistapa, joka mukailee ihmisten intuitiota ja on tarvittaessa lasketta- vissa auki matemaattisen kaavan avulla. Kaava on ainutlaatuinen lähestymisrat- kaisu, sillä sen avulla voidaan varmistua täysin tietojen aitoudesta ja paikkansa- pitävyydestä matemaattisin keinoin sekä arvioida kaavan tarjoamaa arviota linea- arisesti. SHAP-mallin rakenne on tehokkaampi kuin lineaariset mallit, samalla mukaillen ihmisen intuitiota, joka osoittaa rakenteen laskennallisen tehon ja loo- gisen selityksen päätöksenteon helpottumiseen (Lundberg & Lee, 2017).

Lundbergin & Leen tutkimuksessa tutkitun SHAP-mallin matemaattinen kaava on hyvin muokkautuva kaava, jota voidaan käyttää erilaisiin toimenpitei- siin muokkaamalla peruskaavan parametreja toimenpiteeseen sopivilla muuttu- jilla. SHAP-malleihin lukeutuvia malleja ovat esimerkiksi Linear SHAP- ja Deep Shap, jotka ovat malliin perustuvia kaavoja, joista ensimmäisellä pystytään las- kemaan perinteisiä lineaarimalleja ja jälkimmäisellä puolestaan syviä hermover- kostoja. SHAP-mallin peruskaava on tarkemmin esitelty kuviossa 5.

Lause 2 (Shapley- ydin) määritelmässä 1, tietyt muodot $\pi_{x'}$, L , ja Ω jotka tekevät yhtälön 2 ratkaisut yhdenmukaisiksi ominaisuuksien 1-3 kanssa, ovat:

$$\begin{aligned}\Omega(g) &= 0, \\ \pi_{x'}(z') &= \frac{(M-1)}{(M \text{ valitsee } |z'|) |z'| (M - |z'|)}, \\ L(f, g, \pi_{x'}) &= \sum_{z' \in Z} [f(h_x(z')) - g(z')]^2 \pi_{x'}(z'),\end{aligned}$$

jossa $|z'|$ on nollasta poikkeavien elementtien määrä z' .

Kuvio 5: SHAP- mallin peruskaava sekä sen parametrien määritelmät.

Tutkimuksissa todetaan SHAP-kaavan toimivuus ja sen laaja käyttöskaalautu- vuus muokattavuutensa ansiosta. SHAP-mallin implementointi osaksi pankki- toimintoja toisi luotettavan ja räätälöitävän algoritmin, joka sopisi muokkaa- malla lähes kaikkiin alalla suoritettaviin työtehtäviin. Malli on täysin avoin, sillä jokaisen parametrin vaikutus voidaan laskea auki matemaattisesti, jolloin mallin

antaman ennusteen tai arvion voi todeta varmasti oikeaksi. Mallia ei ole kuitenkaan testattu koskaan todellisessa työympäristössä, joten sen käytännöllinen tehokkuus sekä mahdolliset kehityskohteet ja epähuomiot ovat vielä selvittämättä.

4.5 Tekoälyn käyttö osana parempaa päätöksentekoa investoinnihallinnassa

Varainhoidon haaste piilee tarjottujen palveluiden laajuudessa. Rahoituslaitoksen asiakkailta on erilaiset omaisuudet ja tarpeet, joten myös palvelujen on oltava muokattavissa vastaamaan jokaisen asiakkaan erilaisia tarpeita. Sen lisäksi varainhoidon tulosten riippuvuus pääomamarkkinoiden trendeistä ja muutoksista hankaloittavat palvelujen suunnittelua ja korostavat hyvän suunnittelun tärkeyttä varainhoidon tuotekehityksessä. Varainhoidossa hyödynnettävän tekoälyn tulisi ottaa huomioon algoritmeissaan muokattavuus, loogisuus ja mahdolliset ulkopuoliset muuttujat kuten pääomamarkkinamuutokset ja ihmisvirheet eli ihmisen toiminnasta tai käytöksestä johtuvat tapahtumat.

Pacelli, Bevilacqua ja Azzolini (2011) testasivat tutkimuksessaan neuron ja dollarin välistä vaihtokurssia hyödyntäen ANN- mallia selvittääkseen vaihtokurssin hinnoitteluprosessia. Tutkimuksen hypoteesina oletetaan, että hinnoitteluprosessi ei ole satunnainen ja Fama:n taloudellisten markkinatietojen tehokkuusaste on heikko. FAMA:lla tutkimuksessa tarkoitetaan Fama French -mallia, joka on vuonna 1992 kehitetty varojen hinnoittelumalli, joka laajentaa pääomahinnoittelumallia (CAPM) lisäämällä kokoriskin ja arvoriiskitekijät CAPM:n markkinariskitekijään (Hayes, 2022). Neuroverkkomalliin syötettiin seitsemän hinnan kehitykseen vaikuttavaa muuttujaa: keskimääräiset tuotot valtion joukkovelkakirjoista euroalueella sekä Yhdysvalloissa, raakaöljyn hinta, päivittäinen EUR-USD vaihtokurssi, edellisen päivän vaihtokurssi verrattuna lähtöpäivään, kullin spot-hinta ja päivän Nasdaq- indeksi. Tämän lisäksi jokaisen muuttujan historiallinen arvo laskettiin. Tutkimuksen suoritettua molemmat tutkimuksen hypoteeseista todettiin päteviksi ja näin ollen hinnanmuutoksen ennustamisen todettiin kannattavaksi tulevaisuuden tutkimuksen kohteeksi. Tutkimuksessa huomattiin, että markkinoilla tapahtuva hinnankehitys ei ole satunnaista vaan edes osittain ennakoitavaa. Hintaan vaikuttavat tekijät ja niiden keskinäinen vaikutus siis ohjaavat hinnan muutoksia markkinalla (Pacelli ym., 2011). Tutkimuksessa käytetty malli koostui 24 neuronin syötekerroksesta sekä kahdesta, kymmenen ja kolmen neutronin piilokerroksesta. Kyseinen rakenne oli huomattavasti tehokkaampi ja kykenevämpi kuin vuoden 2004 tutkimuksen (Zhang ym., 2004) mallissa, joka koostui kolmesta piilokerroksesta, joissa oli yhteensä 16 neuronia.

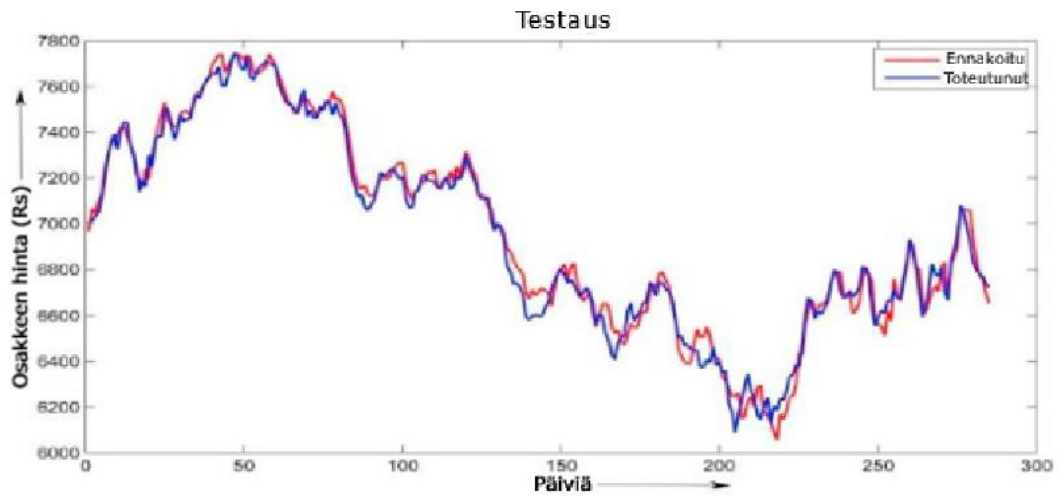
Ihmisaivoja mukailevaa ANN-mallia on vuosien saatossa yritetty parantaa ja tarkentaa, jotta malli soveltuisi useampaan käyttöön ja osaisi ottaa ennustuksissaan huomioon myös epäloogiset ihmismuuttujat. Tarkemman mallin kehittämisen toivossa ANN-malliin on yhdistetty muita menetelmiä paremman tuloksen toivossa. Tiwari ym. (2020) tutkivat kahden tekoälymenetelmän

implementoinnista osakemarkkina- ja myyntiennusteisiin. Tutkimus perustuu edellisiin ANN-menetelmän tutkimuksiin ja niiden tuloksiin. (Zhang ym., 2004) ja (Pacelli ym., 2011). Tutkimuksessa käytetyt menetelmät ANN ja Fuzzy Logic tuovat lopullisessa ennustuksessa esille omien mallien vahvuudet ja heikkoudet. Menetelmien käytännöllistä tehokkuutta vertaillaan käyttäen keskihajontaa suoritusindeksinä, eli tärkeimpänä ominaisuutena pidetään mallin arviointitarkkuutta ja tulosten toistuvuutta.

Fuzzy logic- eli sumennetun logiikan oppimismalli on matemaattinen kehys, jota käytetään tietojenkäsittelyssä ja tekoälyssä epävarman ja epätarkan tiedon käsittelyyn. Malli perustuu binäärilogiikkaan ja päätelee lopullisen tuloksensa totuuden ja epätotuuden väliltä (Tiwari ym.,2020). Tämä mahdollistaa hienovaraisten päätöksenteon, joka ottaa huomioon totuuden ja epätotuuden todennäköisyyden annettujen tietojen perusteella. Malli koostuu päättelymoottorista sekä sumennetuista osista, jotka auttavat muuttamaan datan epämääräiset tiedot tulkittavaksi dataksi.

Tiwarin ym. (2020) tutkimuksessa testataan neuroverkkojen ja sumennetun logiikan mallintamissa osakehinnan ja myynnin ennustuksessa sekä markkinasegmenttien jakamiseen. Tuloksia ennustetaan syöttämällä dataa, jonka perusteella tekoäly kehittäisi tulevaisuuden hintakehityksen mallin. Osakkeiden ennustukseen syötettiin noin neljän vuoden ajalta valittujen osakkeiden hintahistoria. Myyntiennustukseen syötettiin kaksi dataerää, joista ensimmäinen keskittyi tuotemarkkinointiin ja toinen dataerä mobiilioperaattorin tulostietoihin viiden vuoden (2011–2016) ajalta.

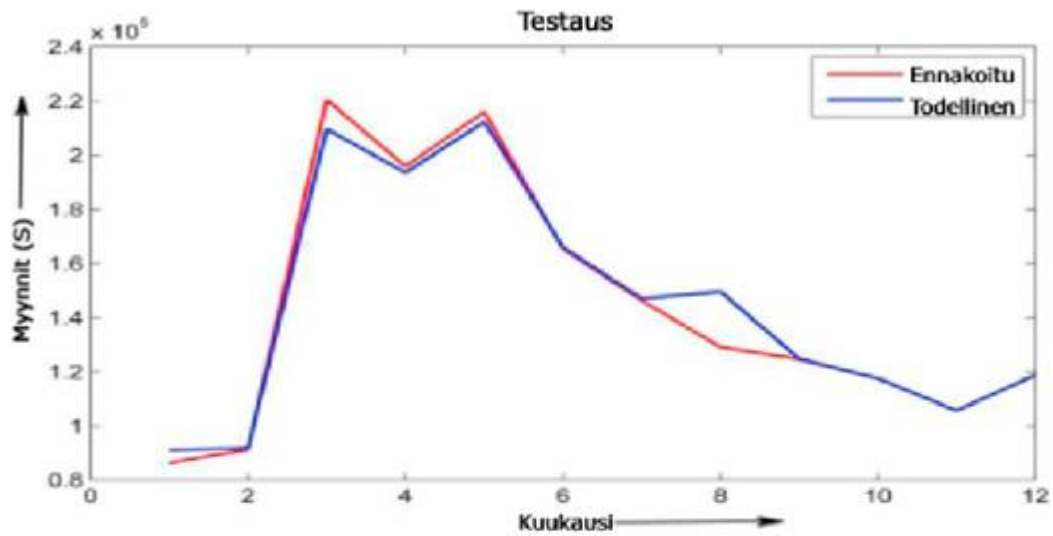
Tutkimustuloksessa huomataan mallien eroavaisuudet ja soveltuvuudet erilaisiin työtehtäviin. Osakkeen hintakehityksessä molemmat mallit suoriutuivat hyvin ja olivat suurimmaksi osaksi tarkkoja. ANN-malli onnistui ennustamaan osakkeen hintakehityksen tarkemmin (98.67 % prosenttien tarkkuudella vastaan Fuzzy Logic-mallin 98.03 % prosenttia, kuvio 6), sekä pienemmällä keskimääräisellä neliövirheellä (1.42 vs. 1.63, kuvio 6). Myyntilukujen ennustamisessa tulokset olivat erilaisia kahdessa dataerässä. Ensimmäisessä dataerässä ANN- malli onnistui ennustamaan luvut huomattavasti tarkemmin (96.19 % vs. 91.35 %, kuvio 47) ja huomattavasti pienemmällä virrehajonnalla (1.09 vs. 5.93, kuvio 7). Toisessa dataerässä tulos oli täysin päinvastainen ja Fuzzy logic- malli suoriutui huomattavasti tarkemmin (96.10 % vs. 93.60 %, kuvio 8) sekä huomattavasti pienemmällä virrehajonnalla (0.05 % vs. 0.80 %, kuvio 8).



Esimerkki 1. Ennakointimetodien suorituskyvyn vertailu

Ennakointiteknikka	Keskimääräinen neliövirhe	Tarkkuus
ANN	1.42	98.67
Fuzzy	1.63	98.03

Kuvio 6: ANN ja Fuzzy logic- mallien vertailun tulokset osakkeen hintakehityksen ennustamisessa. (Keskimääräinen neliövirhe ja tarkkuus) (Tiwari ym.,2020).

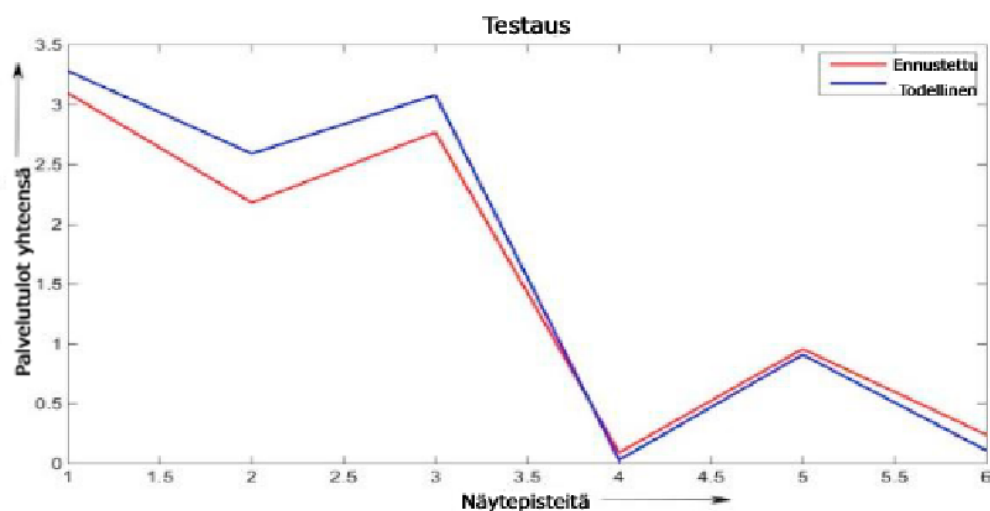


Kuva 4. käyrä todellisesta ja ennustetusta myynnistä neuroverkon testauksen aikana (tietojoukko 1)

Taulukko 2. tietojoukon ennustettujen teknikoiden suorituskyvyn vertailu

Ennakointitekniikka	keskimääräinen neliövirhe	tarkkuus
ANN	1.09	96.19
Fuzzy	5.93	91.35

Kuvio 7: ANN ja Fuzzy logic- mallien vertailun tulokset myyntitulosten ennustamisen ensimmäisessä testierässä (Keskimääräinen neliövirhe ja tarkkuus) (Tiwari ym., 2020).



Kuva 6. käyrä todellisista ja ennustetuista tuloista neuroverkon testauksen aikana (tietojoukko 2)

Taulukko 3. Tietojoukon 2 ennustettujen tekniikoiden suorituskyvyn vertailu

Ennustustekniikka	Keskimääräinen neliövirhe	Tarkkuus
ANN	0.80	93.60
Fuzzy	0.05	96.10

Kuvio 8: ANN ja Fuzzy logic- mallien vertailun tulokset myyntitulosten ennustamisen toisessa testierässä (Keskimääräinen neliövirhe ja tarkkuus) (Tiwari ym.,2020).

ANN-malliin perustuva laskelmointi tunnistaa datasta löytyvät keskeiset tiedot ja organisoii saadun tiedon, kun taas sumennetun logiikan mallit arvioivat saadun tiedon tapahtumistodennäköisyyttä. Molemmat logiikkamallit ovat suunniteltu erilaisiin tehtäviin, eikä yhtä logiikkamallia voida pitää toista parempana rakenteellisen eroavaisuuden takia. Tutkimuksessa huomataan molempien ennustusmallien tulosten eroavaisuudet sekä molempien mallien korkea ennustustarkkuus. Vaikka molemmat mallit suoriutuivat hyväksyttävän virhemarginaalin puitteissa, ANN-mallin tuloksia voidaan pitää tarkempina sekä todennäköisempinä pienemmän virrehajonnan vuoksi (Tiwari ym., 2020). Kahden mallin yhdistynyt käyttö sekä molempien mallien vahvuudet soveltuvat varainhoidon työkaluksi muokkautuvuutensa vuoksi hyvin, sillä kahden mallin eroavaisuudet ja vahvuudet luovat ainutlaatuisia yhdistelmiä, jotka ovat helposti muokattavissa vastaamaan asiakkaan omaisuutta ja tavoitteita. Malleja ei ole testattu oikeissa olosuhteissa, joten ei voida varmaksi sanoa voisiko mallien tulokset muuttua lisäämällä lisäparametrejä sekä alakohtaisia rajoituksia sekä sääntöjä.

4.6 Tekoälyn käyttö osana parempaa päätöksentekoa vakuutusprosessissa

Vakuutusprosessien keskeinen tehtävä on ennakoida mahdollisia riskejä, ennen kuin riskit syntyvät ja vakuuttaa asiakkaat riskin sattumisen varalle. Riskin kartoittaminen perinteisin keinoin voi olla hankalaa ja työlästä, eikä yksi riskin kartoituskeino ole sopiva jokaiselle asiakkaalle asiakaserojen vuoksi. Tekoälyohjelmalla olisi potentiaalia helpottaa vakuutusprosessia asiakkaalle, samalla luoden lisää asiakastytyvyyttä sekä tuottoja yritykselle. (Pisoni & Diaz-Rodriguez, 2023). Tekoälyohjelma voisi helpottaa asiakkaan riskikartoittamista syväoppimallilla, joka olisi helposti muokattavissa sopimaan asiakkaaseen sekä ottamaan huomioon taustalla vaikuttavat riskitekijät kuten asiakkaan sairaudet tai elämäntyylin (Kumar & Srivastava, 2019). Riskin todentamiseen on olemassa monta erilaista. Yleisimmin käytössä olevat mallit perustuvat regressiomalleihin (Chen & Guestrin, 2016) tai ovat koneoppimisalgoritmeilla koulutettuja malleja (Zhang ym., 2018) & (Tiwari ym., 2020). Mallien antamat ennusteet ja ennustustarkkuus ovat vaihtelevia, jolloin käyttäjällä saattaa herätä huoli tuloksien eroavaisuuden takia ja ennustusten paikkansapitävyydestä. Yksinkertaisempia malleja, kuten lineaarisia ja loogisia regressiomalleja on helpompi tulkita, mutta niiden ennustuskyky voi olla rajoitettua. Monimutkaisemmissa malleissa ennustettavuus on usein parempi, mutta monimutkaisuutensa vuoksi mallien tuloksia on vaikea tulkita. Kompromissin ratkaisemiseksi on ehdotettu koneoppimisen tehostamisen malleja, jotka ovat tarkkoja sekä ennustettavia (Bussmann, Giudici, Marinelli & Papenbrock 2020).

Bussmann ym., (2020) ehdottavat tutkimuksessaan agnostista eli teknologisesti neutraalia jälkikäsitelyä, joka soveltuisi ennustetuloksen tulkitsemiseen huolimatta mallin tuottotavasta. Tutkimuksessa käytetyt metodit perustuvat vuonna 2017 tehtyyn tutkimukseen (Lundberg & Lee, 2017), jossa Shapleyn arvoihin perustuvalla SHAP-menetelmällä voitaisiin kartoittaa riskiä luotettavasti ja selkeästi tukeakseen tekoälyn tekemiä ennusteita. Luottoriskin kartoittaminen Shapleyn arvojen avulla toisi tutkimuksen mukaan tarkempia tuloksia ja saattaisi parantaa ennusteiden loogisuutta ja selitettävyyttä (Bussmann ym., 2020). Tutkimuksessa käytetty laskenta jokaisen mallin tarkkuudelle ja selitettävyydelle perustuu SHAP-malliin (Lundberg & Lee, 2017) ja tutkimuksessa käytetty malli (kuvio 9) on ainoa, joka täyttää vaatimukset paikalliselle tarkkuudelle, jatkuvuudelle ja johdonmukaisuudelle.

$$\phi_k(x_i) = \sum_{x' \subseteq C(x) \setminus x_k} \frac{|x'|!(M - |x'| - 1)!}{M!} [\hat{f}(x' \cup x_k) - \hat{f}(x')], \quad (7)$$

Kuvio 9: Paranneltu SHAP-mallin peruskaava, Missä $C(x) \setminus x_k$ on kaikkien mahdollisten mallien joukko, lukuun ottamatta muuttujaa x_k ($m = 1, \dots, M$), $|x'|$ ilmaisee muuttujien lukumäärää mallissa x' , M on saatavilla olevien muuttujien määrä, $\hat{f}(x' \cup x_k)$ ja $\hat{f}(x')$ ovat ennusteet, jotka liittyvät kaikkiin mahdollisiin mallikonfiguraatioihin, mukaan lukien muuttuja x_k , ja lukuun

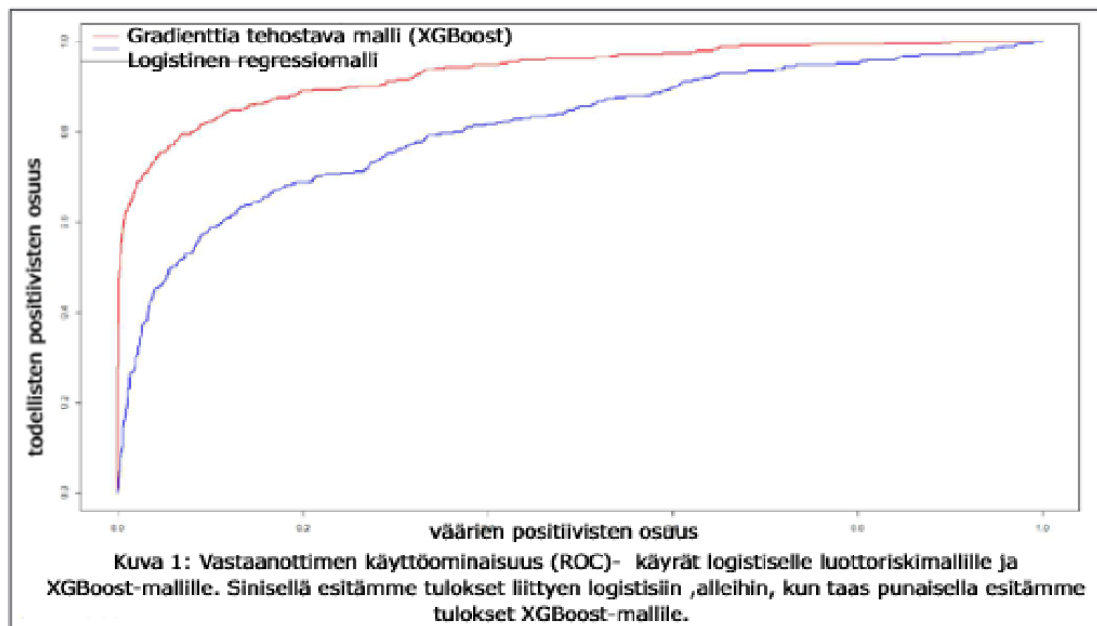
ottamatta muuttujaa x_k , vastaavasti. Luku $\hat{f}(x' \cup x_k) - \hat{f}(x')$ määrittelee muuttujan x_k vaikutuksen kuhunkin yksittäiseen ennusteeseen (Lundberg & Lee, 2017).

Testausta varten mallille hankittu data perustuu eurooppalaisen ulkoisen luottoluokituslaitoksen (ECAI) tietoihin. Laitos erikoistuu luottoluokitukseen P2P- alustoille, jotka keskittyvät pk-yrityksen kaupalliseen lainaamiseen (Bussmann ym., 2020). Dataotannassa on yhteensä 15,045 pk-yrityksen vuoden 2015 luottotiedot sekä samojen yritysten tiedot vuoden päästä. Tiedot jaetaan kategorioihin 0 eli aktiivinen yritys ja 1 eli maksuhäiriöinen yritys. Dataotannassa terveiden yritysten suhde epäterveisiin yrityksiin on noin 10.9 %. Mallin ennakointia pyrintään parantamalla käyttämällä myös XGBoost-puualgoritmia (Chen & Guestrin, 2016).

Tutkimuksessa käytetty data jaettiin koulutusmateriaaliksi (80 %) ja harjoitusmateriaaliksi (20 %). Molempiin datamateriaaliin käytettiin XGBoost-mallia, jota verrattiin loogisen regressiomallin tulokseen (Kuvio 10). Tuloksissa on huomattavissa XGBoostin tuoma lisäetu, sillä regressiomallin paras tulos (0.81) oli huomattavasti epätarkempi, kun XGBoost- mallia käyttänyt ennustemalli (0.93). Tutkimuksen empiiriset havainnot viittaavat selitettävien tekoälymallien kyvykkyydestä edistää ymmärrystämme riskeistä ja tuloksia saatuja tuloksia loogisesti.

Dusemann et al.

XVI in Credit Risk Management



Kuvio 10: Looginen malli vastaan XGBoost- malli (Chen & Guestrin, 2016).

Tekoälyn ennustuskykyä voidaan tarkentaa ja parantaa entisestään lisäämällä kyseiseen tekoälyalgoritmiin Ding ym. (2015) tutkimuksessa testattua ennakoivaa mallia, joka pystyisi ennustamaan osakkeissa tapahtuvaa hinnanmuutosta syväoppia ja taloudellisia uutisia hyödyntämällä. Tutkimuksessa syväoppimisen kouluttautumiseen käytetään yli 10 miljoonaa tapahtumaa Reutersin ja Bloombergin taloudellisista uutisista (Bussmann ym., 2020). Tutkimuksessa

käytetyn datan tilalle voitaisiin soveltaa muuta dataa, esimerkiksi vakuutuksessa käytettävää asiakkaan vakuutus- tai terveystietoa. Tietolähdettä muokkaamalla saataisiin vakuutusriskin laskemista varten malli, joka pohjautuisi täysin asiakkaan omiin vakuutusdataan, jolloin malli pystyisi laskemaan asiakkaan riskikertoimen mahdollisimman tarkasti ja tulos voitaisiin laskea matemaattisesti auki mallissa esiintyvän SHAP-mallin ansiosta.

Asiakkaan vakuutustarpeiden ja riskin kartoittaminen on hankalaa, jos arviota ei voida perustella datalähteellä. On tärkeää, että vakuutuksen kartoituksessa otetaan huomioon asiakkaan tiedot riittävän monipuolisesti samalla ottaen huomioon syy-seuraussuhteet. Suurien datatietojen syväoppiminen on monelle algoritmille hankalaa (Salinas, Flunkert, Gasthaus, & Januschowski, 2020). Suurin osa ennustummalleista ja metodeista keskittyvät pienien ryhmien tai aikavälin ennustukseen. Lähivuosina on noussut kysyntä myös suuremmalle ja monimutkaisemmalle laskentamenetelmälle, joka kykenisi kerralla laskemaan suuremman määrän dataa tai pidemmän aikajakson tapahtumat yhdellä kerralla (Salinas ym., 2020). Lähivuosina kehitetyllä DeepAR-mallilla on potentiaalia syväanalysoida suuria määriä dataa kerralla. Malli perustuu syväoppimisalgoritmiin, joka käyttää autoregressiivisiä ja toistuvia neuroverkkoja rakentaakseen globaalin mallin kaikesta menneestä historiallisesta datasta.

DeepAR:in käyttöönoton suurimmat haasteet perustuvat menneisyyden datan opetteluun. Suuren datakirjon ansiosta tekoälyn koulutus kyseiseen malliin on pitkä prosessi ja prosessin aikana on varmistettava, että data on oikeaa ja puolueetonta. Tekoälyn koulutuksen jälkeen mallille syötetään haluttu ajanjakso, ja malli kykenee analysoimaan ajanjakson tietojen avulla tulevaisuuden ennusteen käyttämällä laskukaavaa. Mallin apuna on encoder-decoder rakenne, joka auttaa mallia generoimaan oikean tiedon mittaamalla aikasarjojen tapahtumia ja niiden todennäköisyyttä (Salinas ym., 2015). Tämän jälkeen malli muodostaa saadun tiedon perusteella tulevaisuusennusteen. Tutkimuksen testausvaiheessa mallin todettiin tarkimmaksi syväoppimisen malliksi sen kehittyneen rakenteensa vuoksi, ja etenkin mallin laskennan- sekä ennustustarkkuus ja skaalautuminen auttoivat sitä erottumaan vertailussa (Taulukko 2).

Tarkkuusmittarit verrattuna vahvimpaan aiemmin julkaistuun menetelmään (perustaso)

(L, S)	0.5-risk				0.9-risk				Keskiverto
	parts								
	(0, 1)	(2, 1)	(0, 8)	all(8)	(0, 1)	(2, 1)	(0, 8)	all(8)	
Snyder (baseline)	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
Croston	1.47	1.70	2.86	1.83	-	-	-	-	1.97
ISSM	1.04	1.07	1.24	1.06	1.01	1.03	1.14	1.06	1.08
ETS	1.28	1.33	1.42	1.38	1.01	1.03	1.35	1.04	1.23
rnn-gaussian	1.17	1.49	1.15	1.56	1.02	0.98	1.12	1.04	1.19
rnn-negbin	0.95	0.91	0.95	1.00	1.10	0.95	1.06	0.99	0.99
DeepAR	0.98	0.91	0.91	1.01	0.90	0.95	0.96	0.94	0.94

(L, S)	ec-sub				all(33)	(0, 2)	(0, 8)	(3, 12)	all(33)	Keskiverto
	(0, 2)	(0, 8)	(3, 12)							
Snyder	1.04	1.18	1.18	1.07	1.0	1.25	1.37	1.17	1.16	
Croston	1.29	1.36	1.26	0.88	-	-	-	-	1.20	
ISSM (baseline)	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	
ETS	0.83	1.06	1.15	0.84	1.09	1.38	1.45	0.74	1.07	
rnn-gaussian	1.03	1.19	1.24	0.85	0.91	1.74	2.09	0.67	1.21	
rnn-negbin	0.90	0.98	1.11	0.85	1.23	1.67	1.83	0.78	1.17	
DeepAR	0.64	0.74	0.93	0.73	0.71	0.81	1.03	0.57	0.77	

(L, S)	ec				all(33)	(0, 2)	(0, 8)	(3, 12)	all(33)	Keskiverto
	(0, 2)	(0, 8)	(3, 12)							
Snyder	0.87	1.06	1.16	1.12	0.94	1.09	1.13	1.01	1.05	
Croston	1.30	1.38	1.28	1.39	-	-	-	-	1.34	
ISSM (baseline)	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	
ETS	0.77	0.97	1.07	1.23	1.05	1.33	1.37	1.11	1.11	
rnn-gaussian	0.89	0.91	0.94	1.14	0.90	1.15	1.23	0.90	1.01	
rnn-negbin	0.66	0.71	0.86	0.92	0.85	1.12	1.33	0.98	0.93	
DeepAR	0.59	0.68	0.99	0.98	0.76	0.88	1.00	0.91	0.85	

Huomaus: parhaat tulokset on merkitty lihavoidulla (alempi on parempi)

Taulukko 2: DeepAr-algoritmin vertailu muihin algoritmeihin tarkkuuden perusteella. Tarkin tulos on tummennettu (Salinas ym., 2015).

Riskin laskeminen vakuutusarviota varten on pitkä ja hankala prosessi, ja monesti asiakkaita erottavat tekijät jätetään täysin huomioimatta perinteisiä kartoituskanoja käyttäessä. Tekoälyllä olisi potentiaalia tehdä prosessista nopeampi ja tarkempi, samalla tuoden lisäarvoa asiakkaalle sekä yritykselle. Riskikartoitukseen käytetyt algoritmit ovat myös todella tarkkoja, mutta eivät kuitenkaan täydellisiä. Algoritmeja ei myöskään ole testattu oikeassa ympäristössä, joten ympäristön vaikutuksia tuloksiin sekä tarkkuuksiin ei voida arvioida täysin päteväällä tavalla.

5 YHTEENVETO

Kirjallisuuskatsauksessa pyrittiin löytämään ratkaisua siihen, miten rahoittajat voivat tehdä parempia päätöksiä rahoitusalan eri osa-alueilla hyödyntäen tekoälyä ja tämän analysointi- sekä arviointitaitoja. Kirjallisuuskatsauksen aikana huomattiin useampi tekijä, jotka hankaloittavat tekoälyn yleistymistä ja tarkentumista nykyajan rahoitusmarkkinalla. Kirjallisuuskatsauksen tutkimuksessa käytettiin vertaisarvioituja tutkimuksia, joissa oli mukana aiheeseen liittyviä empiirisiä sekä analyttisiä tutkimuksia.

Tekoälyn kehitys, koulutus ja käyttöönotto ovat jokainen hankalia prosesseja, jotka vaativat paljon resursseja, testausta ja aikaa oikeanlaisen ja turvallisen toiminnan takaamiseksi. Tekoälyn kehitys on vasta hiljattain kehittynyt koneellisesti tasolle, jolloin tavallisen yrityksen laitteisto on tarpeeksi tehokas suurten ja vaativien algoritmien käyttöön. Tekoäly rahoituspäätöksessä on käsitteenä melko uusi, jolloin myös erilaisia algoritmeja ei olla päästy testaamaan käytännössä. Tämän ansiosta ei ole tarpeeksi tutkittua tietoa algoritmien ja tekoälymallien mahdollisista virheistä ja epäkohdista, jotka hidastavat myös ohjelmistojen käyttöönottoa yrityksissä kuten pankeissa ja rahoituslaitoksissa.

Yksi suurimmista haasteista tekoälyn kehitykselle on alikehittynyt ja osittain puutteellinen lainsäädäntö tekoälyn käytön ja valvomisen osalta. Tekoälyn kyvyt ovat olleet kauan tiedossa, mutta vasta nykyaikaisen laskentavoiman avulla olemme päässeet hyödyttämään tekoälyn tarjoamia ominaisuuksia käytännössä niin työ- kuin arkielämässä. Käyttökokeilujen aikana on noussut moni kysymys toiminnan laillisuudesta, läpinäkyvyydestä ja valvonnasta, joihin ei ole olemassa lakiseikkoja, jotka ohjaisivat toimintaa. Näin ollen jokainen yritys on joutunut selvittämään ongelmansa itse samalla punniten eettisiä ja moraalisia kysymyksiä tekoälyn käyttöä koskien. Yhteinen lainsäädäntö koskien pakollista läpinäkyvyyttä, valvontaa sekä työtapoja toisi yhtenäisen linjan sallituille ja ei sallituille toiminnalle, joka auttaisi yrityksiä kokeilemaan ja rakentamaan tekoälytoimintansa tasavertaiselle pohjalle.

Lainsäädännön puute on aiheuttanut epäselkeyksiä tekoälyn implikoinnissa, negatiivista luotettavuutta niin yrityksiltä kuin yrityksiltäkin ja pahimmassa tapauksissa jopa laittomia liiketoimia kuten ylimääräisen henkilötiedon keräämistä. Tekoälyyn liittyvät haasteet vähentävät ihmisten luottoa uuteen teknologiaan, jonka takia kehitys hidastuu sillä yhä useampi, yritys näkee tekoälyn negatiivisessa valossa. Yhteinen lainsäädäntö tulisi olla kaikille yrityksille sama, mutta tutkimuksissa ei esitetä ehdotuksia, kuka olisi vastuussa lakien säätämisestä tai kuinka tiukkoja lakien tulisi olla. Jatkotutkimusehdotuksista voisi olla lakien tai säännösten vaikutus tekoälyn suosioon ja käyttötehokkuuteen.

Tekoälyprosessien epätarkkuus ovat yksi suuri tekijä, joka estää tekoälyn kehityksen nopeuttamista. Lähivuosina tutkitut ja edellisten algoritmien päälle kehitetyt tekoälyalgoritmit ovat kehittyneet huomasti, ja monimutkaisimmat algoritmit kykenevät ennustamaan testitulosten mukaan jo melkein sadan prosentin tarkkuudella yrityksen tulevaisuuden näkymiä. Tekoäly ei kuitenkaan kykene

ottamaan laskelmissaan huomion ihmismuuttujan eli virheen, joka tapahtuu ihmisen toimesta ja on näin ennustamaton tekijä. Vaikka testitulokset ohjatussa ympäristössä voivat viestiä algoritmien olevan tarkkoja, aihe vaatii jatkotutkimuksia oikeassa ympäristössä käyttäen relevanttia yritysdataa, jolla yritykset tekevät käsin suuria rahoituspäätöksiä. Tämän lisäksi olisi myös kannattavaa tutkia jatkotutkimuksessa algoritmia, joka pyrkisi mahdollisimman hyvin ottamaan huomioon ihmismuuttujan osaksi ennustustaan.

Tekoälyimplementoinnin kallis hinta ja mahdolliset tietoturvariskit ovat suuria haasteita yrityksille, näin hidastaen tekoälyn kehitystä. Tietoturvariskien merkitys nousee etenkin finanssialalla, sillä monet alalla liikkuvat asiakirjat ovat salattua tietoa täynnä taloudellisia avainlukemia, yrityssalaisuuksia sekä henkilöllisyystietoa, jotka voisivat aiheuttaa tietovuodoissa paljon ongelmia asiakkaille sekä rahoittajalle. Tekoälyn implementointi osaksi yrityksen toimintaa on myös hankala ja monimutkainen prosessi, joka vaatii paljon resursseja sekä aikaa. Tutkimuksissa tiedostetaan yrityksiin kohdistuvat tietoturvariskit, mutta toimintatapa yrityksen ongelmien ratkaisulle on usein epäselkeä ja vaihtelee suuresti tutkimuksesta toiseen. Myös lainsäädännön puute aiheuttaa vaikeuksia, sillä laki ei rajoita tai ohjaa ongelmien ratkaisua tiettyyn suuntaan. Tietoturvamurrot ja kyberhyökkäykset voivat tulla yritykselle kalliiksi, ja yksi jatkotutkimuksen kohteista voisi olla muutoksen hintakustannuksen pienentäminen tai tietoturvan vahvistaminen eri tekoälyalgoritmeissa.

Tekoälyn hyödyntäminen on suhteellisen uusi ja kehittyvä prosessi, joka vaatii lisää tutkimusta, kehittämistä ja seuranta. Tekoälyn käytön uutuuden vuoksi moni maa, yritys ja organisaatio ei ole säätänyt selkeää tai yhtenäistä linjaa tekoälyn käytölle, joka lisää epäselkeyttä ja mahdollisia väärinkäyttötilanteita. Tekoälyyn on suhtauduttava varoen etenkin finanssialalla alan arkaluontoisten tietojen vuoksi, mutta tekoälyä on samalla tutkittava ja kehitettävä sen suuren potentiaalinsa vuoksi. Tekoälyssä on monia haasteita ja epäselvyyksiä, mutta rauhallisen ja vastuullisen lähestymistavan avulla tekoäly voi olla suuri apu rahoituksessa niin asiakkaalle kuin rahoittajallekin. Tekoälyn käytön lisääntymisen ja integroinnin keskeisimmät havainnot jaettuna Fernándezin (2019) tutkimuksessa esitettyihin osa-alueisiin näkyvät taulukoissa alla.

Tekoilyn käyttö osana parempaa päätöksentekoa maksuliikenteessä	Vaikutukset	Lähteet
Nopea ja helppo maksutapa	Käytön helppous ja maksujen nopeus vetää asiakkaita puoleensa, asiakaskunta kasvava.	Cao (2020)
Jäljitettävyys / Talousrikollisuuden ennakointi	Maksutietojen avulla talousrikosten havainnointi ja estäminen	Cao (2020) Faccia ym. (2020)
Integraatio kesken	Osa maksupalveluista joudutaan hoitamaan perinteisin tavoin konttorilla asioimalla	Cao (2020)
Maksujen seuranta	Maksujen määrän vuoksi hankala seurata maksuja ihmisvoimalla, mahdollinen laiton maksuliikenne jää huomaamatta	Faccia ym. (2020)
Ennakoitava lineaarinen tekoilymalli	Tekoily mahdollista kouluttaa tunnistamaan asetettuihin raameihin sopivaa maksua, ilmoitus epäilyttävästä maksutapahtumasta	Ding ym. (2015)
Tekoilymallin tarkkuus	Tekoilymallin ennustus ja arviointitarkkuus ei täydellinen, saattaa aiheuttaa virhetilanteita.	Ding ym. (2015)
Päätösten tarkkuus	Ihmisten tekemien virheiden määrä pienenee tekoilyä hyödyntämällä	Fernández. (2019)
Tekoilyä koskevan lainsäädännön puute	Hankaloittaa implementointia ja koulutusta, tekoilyn käyttö laittomiin toimintoihin	Li ym., (2021) Maple ym., (2023)
Tekoilyalgoritmien testauksen puute tositilanteissa	Ei varmaa tietoa tekoilyn toimintatehokkuudesta tositilanteissa	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)
Algoritmien ennustustarkkuus	Algoritmit tarkkoja, mutta voivat kuitenkin ennustaa väärin.	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)
Tietoturvariski	Kysynnän vuoksi kasvanut asiakasmäärä, enemmän tietoja alttiina tietovuodoille ja kyberhyökkäyksille	Cao & Zhai. (2022) Maple ym., (2023)

Taulukko 3: Keskeisimmät havainnot tekoilyn käyttö osana parempaa päätöksentekoa maksuliikenteessä.

Tekoälyn käyttö osana parempaa päätöksentekoa pääomamarkkinoilla	Vaikutus	Lähteet
Vaikea ennakoida	Taloudellisia tapahtumia vaikea ennakoida, esim. (sodat, luonnonilmiöt)	Xie, (2019)
Pitkät käsittelyajat	Suuret rahoitushankkeet sisältävät suuren määrän tietoa, jonka käsittely käsin vie paljon aikaa työntekijöiltä	Aziz & Dowling, (2019).
Pienet hankkeet nopeita	Pienemmissä hankkeissa vähemmän huomioon otettavia seikkoja, tekoälyavusteinen automaattinen päätös	Cao & Zhai, (2022)
Mahdollisuus automatisointiin	Suurempien hankkeiden automatisointi mahdollista tekoälyalgoritmien avulla.	Qi & Xiao, (2018) & Cao & Zhai (2022)
Resurssisäästöt	Tekoäly nopeuttaa prosessia, vapauttaa yrityksen resursseja muihin toimintoihin	Dhaisude ja Lawande, (2022).
Epälineaariset mallit riskikartoituksessa, ANN	Ihmisaivojen toimintaa mukaileva malli, joka muokattavissa yrityksen vaatimuksiin riskikartoituksessa	Zhang ym., (2004) Tiwari ym., (2020)
Pieni virhemarginaali	ANN virhemarginaali todettu 0.3311	Facelli, Berilacqua, ja Azzollini, (2011)
Skaalautuva XGBoost	Toinen sopiva riskienkartoitusmalli, joka soveltuu etenkin luokittehu- ja regressiomalleihin	Chen & Guestrin (2016).
Päätösten tarkkuus	Ihmisten tekemien virheiden määrä pienenee tekoälyä hyödyntämällä	Fernández, (2019)
Tekoälyä koskevan lainsäädännön puute	Hankaloittaa implementointia ja koulutusta, tekoälyn käyttö laittomiin toimintoihin	Li ym., (2021) Maple ym., (2023)
Tekoälyalgoritmien testauksen puute tositilanteissa	Ei varmaa tietoa tekoälyn toimintatehokkuudesta tositilanteissa	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)
Algoritmien ennustustarkkuus	Algoritmit tarkkoja, mutta voivat kuitenkin ennustaa väärin.	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)
Tietoturvariski	Kysynnän vuoksi kasvanut asiakasmäärä, enemmän tietoja alttiina tietovuodoille ja kyberhyökkäyksille	Cao & Zhai, (2022) Maple ym., (2023)

Taulukko 4: Keskeisimmät havainnot tekoälyn käyttö osana parempaa päätöksentekoa pääomamarkkinoilla.

Tekoälyn käyttö osana parempaa päätöksentekoa pankkitoiminnassa	Vaikutus	Lähteet
Laajuus	Kaikki pankin palvelut, vaatii muokattavan tekoölyalgoritmin	Ashta & Herrmann, (2021)
Lähivuosien digitalisaatiosiiirtymä	Pankkipalveluiden siirtyminen digitaaliseksi nostaa nopeiden ja helppojen palvelutapojen kysyntää, tekoälyn tuoma helpotus keskeisessä asemassa.	Qi & Xiao, (2018)
Kyberhyökkäykset ja tietovuodot	Digitaalisten palveluiden yleistymisen lisää digitaalista tietoa, joka altistuu ulkopuolisten hyökkäykselle	Qi & Xiao, (2018).
Avoimuus keskeistä	Rahoitusalan toiminta oltava avointa alan toiminnan valvomisen helpottamiseksi ja mahdollisten väärinkäyttöjen torjumiseksi. Herättää myös luottamusta asiakkailta.	Li ym., (2021)
Avoin ja todennettava laskentamalli	SHAP-mallin toiminta kaavamaisista ja läpinäkyvää sekä tarvittaessa tarkistettavissa laskemalla algoritmin kaava matemaattisesti.	Lundberg & Lee, 2017
Päätösten tarkkuus	Ihmisten tekemien virheiden määrä pienenee tekoölyä hyödyntämällä	Fernández, (2019)
Tekoölyä koskevan lainsäädännön puute	Hankaloittaa implementointia ja koulutusta, tekoälyn käyttö laittomiin toimintoihin	Li ym., (2021) Maple ym., (2023)
Tekoölyalgoritmien testauksen puute tositilanteissa	Ei varmaa tietoa tekoälyn toimintatehokkuudesta tositilanteissa	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)
Algoritmien ennustustarkkuus	Algoritmit tarkkoja, mutta voivat kuitenkin ennustaa väärin.	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)
Tietoturvariski	Kysynnän vuoksi kasvanut asiakasmäärä, enemmän tietoja alttiina tietovuodoille ja kyberhyökkäyksille	Cao & Zhai, (2022) Maple ym., (2023)

Taulukko 5: Keskeisimmät havainnot tekoälyn käyttö osana parempaa päätöksentekoa pankkitoiminnassa.

Tekoälyn käyttö osana parempaa päätöksentekoa investoinninhallintaa	Vaikutukset	Lähteet
Suosio noussut lähivuosina	Kasvava asiakaskanta, kysyntää myös tulevaisuudessa, ensimmäisen toimijan etu	Zheng ym., 2019
Laajat asiakastarpeet	Jokaisen asiakkaan tarpeet ja tavoitteet erilaisia, vaatii muokattavaa kaavaa, joka pärjää erilaisissa tehtävissä (Fuzzy Logic ja ANN- malli, binäärinen ja lineaarinen)	Pacelli, Bevilacqua ja Azzolini (2011) Tiwari ym. (2020)
Tietoturvariski	Kysynnän vuoksi kasvanut asiakasmäärä, enemmän tietoja alttiina tietovuodoille ja kyberhyökkäyksille	Cao & Zhai (2022) Maple ym., (2023)
Läheinen toiminta pääomamarkkinoiden kanssa	Riippuvuus pääomamarkkinoihin saattaa aiheuttaa nousu- tai laskukausia	Xie, (2019)
Päätösten tarkkuus	Ihmisten tekemien virheiden määrä pienenee tekoälyä hyödyntämällä	Fernández, (2019)
Tekoälyä koskevan lainsäädännön puute	Hankaloittaa implementointia ja koulutusta, tekoälyn käyttö laittomiin toimintoihin	Li ym., (2021) Maple ym., (2023)
Tekoälyalgoritmien testauksen puute tositilanteissa	Ei varmaa tietoa tekoälyn toimintatehokkuudesta tositilanteissa	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)
Algoritmien ennustustarkkuus	Algoritmit tarkkoja, mutta voivat kuitenkin ennustaa väärin.	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)

Taulukko 6: Keskeisimmät havainnot tekoälyn käyttö osana parempaa päätöksentekoa investoinninhallinnassa.

Tekoälyn käyttö osana parempaa päätöksentekoa vakuutusprosessissa	Vaikutukset	Lähteet
Lisäarvon luominen	Tekoäly helpottaisi ja nopeuttaisi asiointia, samalla luoden asiakastyytyvyyttä sekä tuottoja yritykselle	Pisoni & Diaz-Rodriguez, (2023)
Asiakkaiden eroavaisuudet	Jokaisella asiakkaalla omat riskitekijät taustalla, esim. sairaudet tai elämäntyyli	Kumar & Srivastava, (2019)
Päätöksen selkeys	Riskikartoituksen tekeminen loogista mallia käyttäen helpottaisi päätöksen ymmärtämistä, (esim. SHAP + agnostinen jälkikäsitely)	Lundberg & Lee, (2017) Bussmann ym., (2020)
Riskikartoitus syvääppinismallilla	Tarkka ja monipuolinen riskiarvio helpottaisi ja tarkentaisi päätöksentekoa	Salinas ym., (2015) Salinas ym., (2020)
Tietoturvariski	Kysynnän vuoksi kasvanut asiakasmäärä, enemmän tietoja alttiina tietovuodoille ja kyberhyökkäyksille	Cao & Zhai, (2022) Maple ym., (2023)
Päätösten tarkkuus	Ihmisten tekemien virheiden määrä pienenee tekoälyä hyödyntämällä	Fernández, (2019)
Tekoälyä koskevan lainsäädännön puute	Hankaloittaa implementointia ja koulutusta, tekoälyn käyttö laittomiin toimintoihin	Li ym., (2021) Maple ym., (2023)
Tekoälyalgoritmien testauksen puute tositalanteessa	Ei varmaa tietoa tekoälyn toimintatehokkuudesta tositalanteissa	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)
Algoritmien ennustustarkkuus	Algoritmit tarkkoja, mutta voivat kuitenkin ennustaa väärin.	Tiwari ym., (2020) Lundberg & Lee (2017) Chen & Guestrin (2016) Bussmann ym. (2020) Ding ym. (2015)

Taulukko 7: Keskeisimmät havainnot tekoälyn käyttö osana parempaa päätöksentekoa vakuutusprosessissa

6 LÄHTEET

Altman, E. I., Marco, G., & Varetto, F. (1994). *Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience)*. *Journal of banking & finance*, 18(3), 505-529.

Ashta, A., & Herrmann, H. (2021). *Artificial intelligence and fintech: An overview of opportunities and risks for banking, investments, and microfinance*. *Strategic Change*, 30(3), 211-222.

Aziz, S., & Dowling, M. (2019). *Machine learning and AI for risk management. Disrupting finance: FinTech and strategy in the 21st century*, 33-50.

Basallo, Y. A., Senti, V. E., & Sanchez, N. M. (2018). *Artificial intelligence techniques for information security risk assessment*. *IEEE Latin America Transactions*, 16(3), 897-901.

Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2020). *Explainable AI in fintech risk management*. *Frontiers in Artificial Intelligence*, 3, 26.

Cao, L. (2020). *AI in finance: A review*. Available at SSRN 3647625.

Cao, Y., & Zhai, J. (2022). *A survey of AI in finance*. *Journal of Chinese Economic and Business Studies*, 20(2), 125-137.

Cheatham, B., Javanmardian, K., & Samandari, H. (2019). *Confronting the risks of artificial intelligence*. *McKinsey Quarterly*, 2(38), 1-9.

Chen, T., & Guestrin, C. (2016, August). *Xgboost: A scalable tree boosting system*. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 785-794).

Ding, X., Zhang, Y., Liu, T., & Duan, J. (2015, June). *Deep learning for event-driven stock prediction*. In *Twenty-fourth international joint conference on artificial intelligence*.

Demirag, I., Khadaroo, I., Stapleton, P., & Stevenson, C. (2011). *Risks and the financing of PPP: Perspectives from the financiers*. *The British Accounting Review*, 43(4), 294-310.

Dhaigude, R., & Lawande, N. (2022, February). *Impact of Artificial Intelligence on Credit Scores in Lending Process*. In *2022 Interdisciplinary Research in Technology and Management (IRTM)* (pp. 1-5). IEEE.

Faccia, A., Moşteanu, N. R., Cavaliere, L. P. L., & Mataruna-Dos-Santos, L. J. (2020, September). *Electronic money laundering, the dark side of fintech: An*

overview of the most recent cases. In Proceedings of the 2020 12th international conference on information management and engineering (pp. 29-34).

Felzmann, H., Fosch-Villaronga, E., Lutz, C., & Tamò-Larrieux, A. (2020). *Towards transparency by design for artificial intelligence.* Science and Engineering Ethics, 26(6), 3333-3361.

Fernández, A. (2019). *Artificial intelligence in financial services.* Banco de Espana Article, 3, 19.

Giudici, P. (2018). *Fintech risk management: A research challenge for artificial intelligence in finance.* Frontiers in Artificial Intelligence, 1, 1.

Hayes, A. (2022, May 31). *Fama and French Three Factor Model Definition: Formula and Interpretation.* Investopedia. Haettu November 13, 2023, from <https://www.investopedia.com/terms/f/famaandfrenchthreefactor-model.asp>

Hunter, S., & Güzey, O. (2021). *Difficult decisions in uncertain times: AI and automation in commercial lending.* Journal of AI, Robotics & Workplace Automation, 1(1), 63-69.

Johnson, K., Pasquale, F., & Chapman, J. (2019). *Artificial intelligence, machine learning, and bias in finance: toward responsible innovation.* Fordham L. Rev., 88, 499.

Kaya, O., Schildbach, J., AG, D. B., & Schneider, S. (2019). *Artificial intelligence in banking.* Artificial intelligence.

Kruse, L., Wunderlich, N., & Beck, R. (2019). *Artificial intelligence for the financial services industry: What challenges organizations to succeed.*

Kumar, N., Srivastava, J. D., & Bisht, H. (2019). *Artificial intelligence in insurance sector.* Journal of the Gujarat Research Society, 21(7), 79-91.

Kunnathuvalappil Hariharan, N. (2018). *Artificial Intelligence and human collaboration in financial planning.*

Li, Y., Yi, J., Chen, H., & Peng, D. (2021). *Theory and application of artificial intelligence in financial industry.* Data Science in Finance and Economics, 1(2), 96-116.

Lin, T. C. (2019). *Artificial intelligence, finance, and the law.* Fordham L. Rev., 88, 531.

Lundberg, S. M., & Lee, S. I. (2017). *A unified approach to interpreting model predictions.* Advances in neural information processing systems, 30.

- Maple, C., Szpruch, L., Epiphaniou, G., Staykova, K., Singh, S., Penwarden, W., ... & Avramovic, P. (2023). *The AI revolution: opportunities and challenges for the finance sector*. arXiv preprint arXiv:2308.16538.
- Mazzucato, M., Schaake, M., Krier, S., & Entsminger, J. (2022). *Governing artificial intelligence in the public interest*. UCL Institute for Innovation and Public Purpose, Working Paper Series (IIPP WP 2022-12). Retrieved April, 2, 2023.
- Naim, A. (2022). *Role of Artificial Intelligence in Business Risk Management*. American Journal of Business Management, Economics and Banking, 1, 55-66.
- Najem, R., Amr, M. F., Bahnsse, A., & Talea, M. (2022). *Artificial Intelligence for Digital Finance, Axes and Techniques*. Procedia Computer Science, 203, 633-638.
- Ostmann, F., & Dorobantu, C. (2021). *AI in financial services*. Alan Turing Institute. doi, 10.
- Pacelli, V., Bevilacqua, V., & Azzollini, M. (2011). *An artificial neural network model to forecast exchange rates*. Journal of Intelligent Learning Systems and Applications, 3(02), 57-69.
- Pisoni, G., & Díaz-Rodríguez, N. (2023). *Responsible and human centric AI-based insurance advisors*. Information Processing & Management, 60(3), 103273.
- Qi, Y., & Xiao, J. (2018). *Fintech: AI powers financial services to improve people's lives*. Communications of the ACM, 61(11), 65-69.
- Salinas, D., Flunkert, V., Gasthaus, J., & Januschowski, T. (2020). *DeepAR: Probabilistic forecasting with autoregressive recurrent networks*. International Journal of Forecasting, 36(3), 1181-1191.
- Savolainen, E. (2017). *Yritysrahoitus pankkikeskeistä mutta monipuolista*.
- Savvides, S. C. (2011). *Corporate lending and the assessment of credit risk*. Journal of Money, Investment and Banking, (20).
- Taeihagh, A. (2021). *Governance of artificial intelligence*. Policy and society, 40(2), 137-157.
- Tiwari, R., Srivastava, S., & Gera, R. (2020). *Investigation of artificial intelligence techniques in finance and marketing*. Procedia Computer Science, 173, 149-157.
- Vives, X. (2019). *Competition and stability in modern banking: A post-crisis perspective*. International Journal of Industrial Organization, 64, 55-69.
- Xie, M. (2019, April). *Development of artificial intelligence and effects on financial system*. In Journal of Physics: Conference Series (Vol. 1187, No. 3, p. 032084). IOP Publishing.

Zheng, X. L., Zhu, M. Y., Li, Q. B., Chen, C. C., & Tan, Y. C. (2019). *FinBrain: when finance meets AI 2.0*. *Frontiers of Information Technology & Electronic Engineering*, 20(7), 914-924.

Zhang, X. P. S., & Kedmey, D. (2018). *A budding romance: finance and AI*. *IEEE MultiMedia*, 25(4), 79-83.

Zhang, W., Cao, Q., & Schniederjans, M. J. (2004). *Neural network earnings per share forecasting models: A comparative analysis of alternative methods*. *Decision Sciences*, 35(2), 205-237.