



Vaasan yliopisto
UNIVERSITY OF VAASA

Ville Linho

Yritysten luottopäätökset tekoälyn ja ihmisen yhteistyönä

Asiantuntijoiden kokemuksia suomalaisessa yritysrahoituksessa

Johtamisen akateeminen yksikkö
Pro gradu -tutkielma
Liiketoiminnan kehittämisen
koulutusohjelma

Vaasa 2026

VAASAN YLIOPISTO**Johtamisen akateeminen yksikkö**

Tekijä:	Ville Linho		
Tutkielman nimi:	Yritysten luottopäätökset tekoälyn ja ihmisen yhteistyönä: Asiantuntijoiden kokemuksia suomalaisessa yritysrahoituksessa		
Tutkinto:	Kauppätieteiden maisteri		
Koulutusohjelma:	Liiketoiminnan kehittäminen		
Työn ohjaaja:	Pekka Töytäri		
Valmistumisvuosi:	2026	Sivumäärä:	60

TIIVISTELMÄ:

Tässä Pro Gradu -tutkielmassa tarkastellaan luottopäätöksiä tekevien ammattilaisten kokemuksia koneoppimismallin tukemassa päätösprosessissa suomalaisessa yritysrahoituksessa. Koneoppimismallien hyödyntäminen on lisääntynyt merkittävästi luottoriskien arvioinneissa. Käytännössä prosessit eivät kuitenkaan ole täysin automatisoituja. Sen sijaan koneoppimismallit toimivat usein päätöksenteon tukityökaluina, jolloin niiden tuloksia arvioidaan ihmisen toimesta osana laajempaa päätösprosessia.

Tutkimuksen tavoitteena on ymmärtää, miten luottopäätöksentekoon osallistuvat asiantuntijat kokevat koneoppimismallien käytön tässä kontekstissa. Tutkimus keskittyy koneoppimismalleihin liitettyihin hyötyihin ja haasteisiin sekä siihen, miten asiantuntijat tulkitsevat ja hyödyntävät mallien tuottamaa tietoa osana omaa päätöksentekoaan ja harkintaansa. Tutkimuksen teoreettinen viitekehys rakentuu ihmisen ja tekoälyn yhteistyötä, sosioteknisiä järjestelmiä ja algoritmien tukemaa päätöksentekoa käsittelevän kirjallisuuden varaan.

Kyseessä on laadullinen tutkimus. Empiirinen tieto kerättiin puolistrukturoiduilla teemahaastatteluilla ja haastateltavana olivat yritysrahoituksessa luottopäätöksiä tekevät asiantuntijat. Kerätty aineisto analysoitiin teoriaohjatun teema-analyysin avulla.

Tutkimuksessa havaittiin, että koneoppimismallit parantavat tehokkuutta, tukevat johdonmukaisuutta ja strukturoivat luottopäätösprosessia. Koetut haasteet liittyvät tapauskohtaiseen kontekstiin, laadulliseen tietoon ja poikkeustapauksiin, jotka eivät ole mallipohjaisen arvioinnin kannalta selkeitä. Löydökset osoittavat myös, etteivät asiantuntijat käytä malleja passiivisesti. Sen sijaan he vertaavat niitä omaan ammatilliseen näkemykseensä ja arvioivat niiden relevanssia jokaisessa rahoitustapauksessa. Näin ollen koneoppimismallit toimivat pääosin ammattilaisen arvion tukimekanismeina, eivätkä sen korvaajana.

Tutkimus havainnollistaa, että koneoppimismallin roolia luottopäätöksenteossa muovaavat teknisen suorituskyvyn ohella se, miten mallien tuottamaa tietoa hyödynnetään osana asiantuntijoiden työskentelyä ja organisaation käytäntöjä.

AVAINSANAT: Koneoppiminen, tekoäly, luottoriski, rahoitus, asiantuntijat

Sisällys

1	Johdanto	6
1.1	Tutkimuksen rakenne	8
2	Koneoppiminen luottopäätöksen tukena	10
2.1	Mitä koneoppiminen tarkoittaa luottopäätöksenteossa	11
2.2	Koneoppimisen hyödyt ja haasteet luottopäätöksenteossa	13
2.2.1	Koneoppimisen hyödyt luottopäätöksenteossa	14
2.2.2	Koneoppimismallien haasteet luottopäätöksissä	16
3	Asiantuntijan ja tekoälyn yhteistyö	19
3.1	Luottopäätöksenteon sosiotekninen järjestelmä	20
3.2	Asiantuntijan rooli, työnjako ja kontrolli	21
3.3	Mallin tuottaman tiedon tulkinta ja ohittaminen	23
3.4	Luottamus, tukeutuminen ja vastuu	25
3.5	Hallinto ja yhteistyön rakenteet	26
4	Tutkimusmenetelmä	30
4.1	Konteksti	31
4.2	Aineiston keruu ja otanta	31
4.3	Analyysimenetelmä	33
4.4	Laadullisen tutkimuksen luotettavuus	35
4.5	Tutkimuksen eettiset periaatteet	36
5	Tutkimustulokset	37
5.1	Teema 1: luottopäätösprosessi ja koneoppimismallin rooli	38
5.2	Teema 2: Tiedon tulkinta ja asiantuntijan harkinta	40
5.3	Teema 3: hyödyt, haasteet ja rajoitteet	42
5.4	Teema 4: tulevaisuus ja ihmisen ja tekoälyn yhteistyö	47
6	Pohdinta	50
6.1	Havainnot	50
6.2	Tutkimuksen kontribuutio	52
6.3	Rajaukset ja ehdotukset	54

6.4	Lopuksi	56
	Lähteet	57
	Liitteet	60
	Liite 1. Päähaastattelukysymykset	60
	Liite 2. Ilmoitus tekoälyn käytöstä	60

Taulukot

Taulukko 1. Keskeiset hyödyt ja haasteet	13
Taulukko 2. Tutkimukseen osallistuneet henkilöt	32
Taulukko 3. Esimerkki analyysin etenemisestä	34
Taulukko 4. Analyysin pää- ja alateemat	37

1 Johdanto

Koneoppimismallien hyödyntäminen osana luottopäätöksiä on yleistynyt nopeasti rahoituslalla, myös yritysrahoituksessa. Kehitystä ovat edistäneet digitaalisen datan lisääntynyt saatavuus, ennusteanalytiikan teknologinen kehitys ja koneoppimismallien todistettu kyvykkyys tehostaa riskien tunnistamista ja luokittelua verrattuna perinteisiin tilastotieteellisiin lähestymistapoihin (Lessmann et al., 2015; Dastile et al., 2020; Ayari et al., 2025). Rahoittamisen kontekstissa koneoppimismalleja hyödynnetään tyypillisesti suurten taloudellisten ja käyttäytymisaineistojen käsittelyyn, tarkoituksena tuottaa jäsenneiltyjä tuloksia, kuten riskipisteitä, luokituksia ja maksukyvyttömyysennusteita. Mallien vakiintuessa osaksi luottokelpoisuusarviointia, keskeiseksi on noussut niiden roolin ymmärtäminen osana päätöksentekoprosesseja sekä tutkimuksellisesta että käytännön liiketoiminnan näkökulmasta.

Koneoppimisen lisääntyminen rahoituspäätöksissä ei tarkoita, että päätöksenteko olisi täysin automatisoitu. Sen sijaan koneoppimismallit toimivat tyypillisesti päätöksenteon tukijärjestelminä, jotka tuottavat strukturoituja tuloksia, joita ihmisasiantuntija arvioi. Kuten Jarrahi (2018) esittää, tekoäly organisaatioiden päätöksenteossa on perustellumpaa nähdä ihmisen harkintaa täydentävänä, ei sitä korvaavana toimijana. Luottopäätöksiä tehdessä tämä tarkoittaa, että lopullinen päätösvalta ja tulkinnallinen vastuu säilyvät pääsääntöisesti asiantuntijoilla, jotka arvioivat mallien tuottamia tuloksia suhteessa kontekstuaaliseen, tapauskohtaiseen ja muuhun laadulliseen informaatioon. Tällöin koneoppimisen tukema luottopäätöksenteko ei ole pelkkä tekninen luokittelutehtävä, vaan ihmisen ja tekoälyn välistä vuorovaikutteista yhteistyötä.

Olemassa oleva tutkimuskirjallisuus on laajalti keskittynyt koneoppimismallien ennustetarkkuuteen, mallien vertailuun ja niiden mukanaan tuoman hyödyn arvioimiseen (Lessmann et al., 2015; Dastile et al., 2020; Ayari et al., 2025). Kirjallisuus on osoittanut, miksi koneoppimismallit ovat yhä vahvemmin integroituneet luotonantoprosesseihin. Pelkkä tekninen suorituskyky ei kuitenkaan selitä, miten näitä

malleja hyödynnetään käytännön päätöksenteossa, jolloin mallien tuottamat tulokset kytkeytyvät asiantuntijaharkintaan ja laajempiin organisatorisiin käytäntöihin.

Akateeminen mielenkiinto onkin siirtynyt pelkästä mallien suorituskyvyn mittaamisesta kohti niitä laajempia olosuhteita, joissa ihminen ja tekoäly yhteistyössä toimivat. Ihmisen ja tekoälyn yhteistyötä tutkiva kirjallisuus ehdottaa, että tekoälyn tukeman päätöksenteon arvo ei riipu vain mallin tuloksesta, vaan miten sitä tulkitaan, miten sitä haastetaan, miten siihen tukeudutaan ja miten se saatetaan yhteen asiantuntijan näkemyksen kanssa (Jarrahi, 2018; Dellermann et al. 2019; Gomez et al., 2025). Myös sosiotekninen tutkimus korostaa, että päätöksien tuloksiin vaikuttavat algoritmin kyvykkyyden lisäksi organisaation käytännöt, käyttöliittymän suunnittelu, roolirakenteet ja erilaiset hallinnolliset järjestelyt (Raso, 2017; Bailey et al., 2020). Lainaliiketoiminnassa nämä kysymykset ovat merkittäviä, sillä mallien tuloksien relevanttiuden, sopivuuden ja luotettavuuden arviointi on usein asiantuntijan vastuulla.

Samanaikaisesti aiempi kirjallisuus on tunnistanut selkeitä haasteita, jotka liittyvät läpinäkyvyyteen, selitettävyyteen, vastuunjakoon ja reiluuteen silloin, kun algoritmeja sovelletaan lainan myöntämisessä (Burrell, 2016; Hansen, 2020; Züger et al., 2025). Tästä näkökulmasta koneoppimismalleja osana luottopäätöksentekoa tulee tarkastella myös malleja käytännön työssään soveltavien ammattilaisten kokemusten kautta.

Vaikka koneoppimista ja algoritmin tukemaa päätöksentekoa käsittelevä tutkimus on lisääntynyt, on yhä rajallisesti tutkittu niiden ammattilaisten kokemuksia, jotka käyttävät mallien tuottamaa tietoa osana konkreettista luottopäätöksentekoa. Tämä tutkimus vastaa tähän tutkimusaukkoon. Tämän tutkimuksen tarkoituksena on tarkastella, miten luottopäätöksentekoon osallistuvat asiantuntijat kokevat koneoppimismallin käytön. Tarkastelun kohteena ovat erityisesti mallien käyttöön liitetyt hyödyt ja haasteet sekä se, miten asiantuntijat tulkitsevat ja hyödyntävät mallien tuottamaa tietoa osana omaa harkintaansa ja päätöksentekoaan. Tutkimuskysymykseen vastaaminen on aiheellista, sillä ilman ymmärrystä ammattilaisten kokemuksista, on vaikeaa arvioida, miten

koneoppimismallit todellisuudessa muokkaavat ammatillista harkintaa ja millä ehdoin ne tukevat laadukasta ja tehokasta päätöksentekoa.

Tutkimuksen päätutkimuskysymys on: miten analyytikot ja luottopäätäjät kokevat koneoppimismallien käytön luottopäätöksenteossa suomalaisessa yritysrahoituksessa? Metodologisesti tutkimus on toteutettu laadullisesti puolistrukturoituna teemahaastatteluna. Haastateltavat ovat luottopäätöksiä tekeviä ammattilaisia. Tämä lähestymistapa on perusteltu, sillä se mahdollistaa syvällistä analyysiä siitä, miten osallistujat jäsentävät työtään, miten he toimivat vuorovaikutuksessa koneoppimismallin kanssa ja millaisia merkityksiä he liittävät koneoppimisen tukemaan päätöksentekoon.

1.1 Tutkimuksen rakenne

Tämä tutkimus koostuu kuudesta luvusta. Ensimmäisessä luvussa esitetään aihe ja kuvataan tutkimuksen taustaa sekä relevanssia. Johdannossa myös identifioidaan tutkimusaukko, tutkimuskysymys sekä -menetelmä ja tutkimuksen tavoite.

Luku kaksi tarkastelee koneoppimisen ja luottopäätöksenteon aikaisempaa tieteellistä kirjallisuutta. Se määrittää koneoppimismallien roolia luottopäätöksenteon kontekstissa ja tutkii keskeisiä hyötyjä ja haasteita malleja sovellettaessa.

Luku kolme esittää tutkimuksen teoreettisen viitekehyksen keskittymällä ihmisen ja tekoälyn yhteistyöhön päätöksentekotilanteissa. Kappale lähestyy koneoppimisen tukemaa luottopäätöksentekoa sosioteknisenä järjestelmänä ja keskustelee asiantuntijan roolista, tulkinnoista, luottamuksesta, vastuusta ja hallinnollisista rakenteista.

Luku neljä kuvaa tutkimuksen metodologiset valinnat. Se esittää tutkimuksen kontekstin, tiedonkeruun ja analyysimenetelmän. Luvussa käsitellään myös periaatteet, joiden pohjalta tutkimuksen luotettavuutta ja eettisyyttä arvioidaan.

Luku viisi esittää tutkimuksen empiiriset havainnot. Tutkimustulokset on jaettu neljään pääteemaan, jotka kuvaavat koneoppimismallia osana luottopäätöksentekoprosessia, mallien tuottaman tiedon analysointia, koettuja hyötyjä ja haasteita sekä ihmisen ja tekoälyn tulevaisuuden kehitystä.

Luku kuusi keskustelee tutkimustuloksista suhteessa aiempaan tieteelliseen kirjallisuuteen ja teoreettiseen viitekehykseen. Luku esittää tutkimuksen tieteellisen ja käytännöllisen hyödyn, arvioi sen rajoitteita ja esittää ehdotukset aiheen tulevaisuuden tutkimussuuntia.

2 Koneoppiminen luottopäätöksen tukena

Tässä kappaleessa koneoppimismalleja tarkastellaan luottopäätöksenteossa teknologisen pohjana. Tämän pohjalta muodostetaan kehys laajemmalle ihmisen ja tekoälyn yhteistyön teorialle. Kappale alkaa selventämällä mitä koneoppimismallien käyttö tarkoittaa luottopäätöksissä ja miten malleja käytetään osana luottokelpoisuusarvioita. Tämän jälkeen tarkastellaan tutkimuksien pohjalta löydettäviä hyötyjä ja haasteita. Tämän rakenne mahdollistaa siirtymisen koneoppimisen määrittelemisestä ja sen roolista niihin mahdollisuuksiin ja rajoitteisiin, jotka muovaavat sen käytännön merkitystä luottopäätöksenteossa.

Perinteinen luottopäätöksenteko oli hidasta työtä, johon vaikuttivat päättäjän intuitio ja subjektiiviset oletukset. Nykyaikaisen pankkitoiminnan kulmakiveksi on sittemmin muodostunut luottoluokitus. Luottoluokitus tarjoaa systemaattisen ja dataan perustuvan tavan arvioida lainanottajan luottokelpoisuutta muuttaen luotonannon prosessia perusteellisesti (Dastile et al., 2020). Luottoluokitus kvantifioi luottoriskin erilaisten muuttujien, kuten lainanhakijan takaisinmaksuhistorian tai taloudellisten lukujen (esim. tilinpäätös) mukaan. Se mahdollistaa objektiivisempaa luottopäätöksentekoa, laskee inhimillisen virheen todennäköisyyttä ja mahdollistaa, että lainanantajat voivat räätälöidä lainaehdot riskiprofiilin mukaan, optimoiden näin riskin ja tuoton suhdetta (Ayari et al., 2025).

Digitaalisen infrastruktuurin ja laajojen tietokantojen kehittyessä luottopäätöksenteon dataintensiivisyys on kasvanut. Rahoituslaitosten analyyttiset mahdollisuudet ovat sitä mukaa lisääntyneet ja näin riskiprofiilin rakentamisen on muuttunut yhä dynaamisemmaksi (Baesens et al., 2003). Näissä olosuhteissa koneoppimismallien käyttö on lisääntynyt rahoitusalaalla empiiristen tutkimusten näyttäessä niiden konkreettisia hyötyjä luottopäätöksenteossa. (Lessmann et al., 2015). Viimeaikaisissa tutkimuksissa on nähtävissä selkeä painotus koneoppimismalleihin perustuvaan luottoluokitukseen sekä niiden mahdollisuuteen erottaa huonoja ja hyviä lainanhakijoita verrattuna perinteisiin luottoluokitusmenetelmiin (Ayari et al., 2025).

2.1 Mitä koneoppiminen tarkoittaa luottopäätöksenteossa

Luottopäätöksenteon kontekstissa, koneoppiminen viittaa datalähtöisiin analyttisiin menetelmiin, joita käytetään tunnistamaan kaavoja historiallisesta datasta ja tätä kautta tuottamaan ennusteita tulevaisuuden luottoriskistä ja luottoluokituksista. Rahoitusallalla koneoppimista käytetään usein osana ennustavaa analytiikkaa, jolloin mallit käyttävät historiallista dataa kuten yhtiön tunnuslukuja tai lainanmaksuhistoriaa arvioidakseen konkurssin tai maksukyvyttömyyden mahdollisuutta (Lessmann et al., 2015).

Luottopäätöksenteossa koneoppimismallit tuottavat todennäköisyyspohjaisia tuloksia tai riskiluokituksia. Tällaisia tuloksia ovat esimerkiksi maksukyvyttömyystodennäköisyys, luottoriskipisteet tai kategorinen riskiluokka, joka asettaa lainanhakijat järjestykseen takaisinmaksukykyyn perustuen (Lessman et al., 2015). Logiikka on induktiivinen, eli historiallisten huomioiden perusteella pyritään löytämään kaavoja, jotka korreloivat luottokelpoisuuden kanssa.

On tärkeää huomata, että useimmissa organisaatioissa koneoppimismallit eivät toimi autonomisina päätöksentekijöinä. Sen sijaan mallien tehtävänä on toimia päätöksenteon tukimekanismina, jonka tarkoitus on tuottaa strukturoitua riskidataa asiantuntijoille. Mallien tulos, kuten riskiluokka tai konkurssitodennäköisyys ei usein toimi lopullisena luottopäätöksenä. Asiantuntijan tehtäväksi jää mallin tuottaman tiedon tuominen osaksi laajempaa arviota, johon voi kuulua kontekstuaalisia, tapauskohtaisia tai laadullisia muuttujia (Jarrahi, 2018).

Kuten Dastile et al. (2020) kuvaavat, koneoppimismallit voidaan luottopäätöksenteon näkökulmasta nähdä osana laajempia päätöstukijärjestelmiä (Decision Support System, DSS). Päätöstukijärjestelmänäkökulma tukee näkemystä tekoälystä apuvälineenä, ei ihmisen harkinnan korvaajana. Päätöstukijärjestelmät tarjoavat datan kautta tietoa, jonka avulla johto voi tehdä päätöksiä epävarmuuden vallitessa. Lessmann et al. (2015) jatkavat näkemyksen mukaisesti, että juuri luottopäätöksien viitekehyksessä

koneoppimismallit toimivat analyyttisenä osana prosessia ja käsittelevät suuria määriä historiallista dataa, jonka pohjalta tuotetaan riskitietoisia tuloksia asiantuntijan päätöksenteon tueksi.

Juuri Lessman et al. (2015) tutkimuksen mukaan koneoppimismallit tuottavat parempaa ennustetietoa verrattuna perinteisempiin tilastotieteen menetelmiin, erityisesti kun käsitellään monimutkaisia, moniulotteisia tietokantoja. Systemaattiset katsaukset osoittavat koneoppimismallien nopeasti lisääntyvää käyttöä luottoriskin arvioinnissa. Lisäksi malleja integroidaan olemassa oleviin institutionaalisiin riskienhallintajärjestelmiin (Dastile et al., 2020). Tämä kehitys selittää osaltaan, miksi tällaiset mallit ovat vakiintuneet osaksi luottokelpoisuusarviointia.

Pelkkä parempi ennustetarkkuuskyky ei tarkoita täysin automaattista päätöksentekoa. Ihmisen ja koneen välistä yhteistyötä käsittelevän kirjallisuuden vahva löydös vaikuttaa olevan selvä: algoritmisten suositusten ja ihmisen suorittaman arvioinnin yhdistäminen tuottaa parempia tuloksia, kuin automaattiset järjestelmät yksinään. Lu & Zhang (2024) osoittavat, että silloin kun asiantuntija yhdistetään koneen tuottaman suosituksen (varsinkin avoimen ja selittävän) kanssa, päätöksien laatu paranee, sillä ihminen pystyy taustoittamaan tuloksia ja korjaamaan mallissa mahdollisesti olevia virheitä. Tämä on linjassa laajemman tukiälyn (augmented intelligence) käsitteen kanssa. Tukiälyn tapauksessa tekoälyjärjestelmät laajentavat analyyttistä kapasiteettia ja ihminen pysyy vastuussa sekä toimii viimeisenä tulkitsevana auktoriteettina (Jarrahi, 2018).

Rahoitusalan kontekstissa koneoppimismalli toimii ”ihminen osana prosessia” - rakenteella (Human-in-the-Loop, HITL). Mallit tuottavat arvioita tai riskipisteitä, mutta lopullinen luottopäätös syntyy asiantuntijan harkinnan perusteella. Käytännön tasolla asiantuntija tuo kontekstuaalista ja tapauskohtaista näkemystä, joita historiallisesta datasta ei aina nähdä (Dastile et al., 2020).

Koneoppimismalli osana luottopäätöksentekoa voidaan parhaiten ymmärtää päätöksenteon tukimekanismina, joka on rakennettu osaksi sosioteknisiä järjestelmiä – ei autonomisena päätöksentekijänä. Sen rooli on tuottaa jäsenneiltyä ja datalähtöistä riskiarviointia, jonka tavoitteena on auttaa, muttei määrittää asiantuntijan arviota. Tämä näkökulma luo asettelun, eräänlaisen vuorovaikutteisen tilan algoritmisten tuotosten ja ihmisen arvion välille. Tämän pohjalta voidaan paremmin arvioida, miten asiantuntijat kokevat ja tulkitsevat koneoppimismalleja osana työtään.

2.2 Koneoppimisen hyödyt ja haasteet luottopäätöksenteossa

Koneoppimismallien lisääntyvää käyttöä luottokelpoisuusarvioinneissa perustellaan usein sillä, että se parantaa arvioinnin laatua ja tekee siitä nopeampaa. Samanaikaisesti tutkimukset ovat löytäneet merkittäviä rajoitteita, jotka liittyvät läpinäkyvyyteen, reiluuteen, vastuuseen ja mallien tuloksien tulkintaan. Tämän vuoksi koneoppimista on tutkimuksissa käsitelty uusien mahdollisuuksien luoja näkökulman lisäksi sen mukanaan tuomien haasteiden näkökulmasta. Seuraavissa osioissa tarkastellaan näitä haasteita ja hyötyjä, sillä tarkoituksena on tuottaa tasapainoinen ymmärrys koneoppimismallien roolista osana luottokelpoisuusarviointia.

Keskeiset olemassa olevan tutkimuksen tunnistamat hyödyt ja haasteet ovat alla taulukossa 1. Taulukko tarjoaa yleiskatsauksen tässä luvussa käsiteltäviin teemoihin, joita tarkastellaan tarkemmin seuraavissa alaluvuissa.

Taulukko 1. Keskeiset hyödyt ja haasteet

Teema	Hyöty	Haaste
Ennustetarkkuus	Lisääntynyt luottoriskiarvion tarkkuus	Huonompi tulkittavuus monimutkaisissa malleissa

Datan käyttö	Kyky käsitellä laajoja ja monimutkaisia tietokantoja	Riippuvuus tiedon laadusta ja läpinäkyvyydestä
Päätöksen laatu	Yhdenmukaisempi, datapohjainen arvio	Vinoumien ja epäiluiden lisääntyminen
Asiantuntijakäyttö	Tukee ihmisarviota päätöksenteossa	Tulkittamisen ja tuloksien haastamisen vaikeudet
Hallinto	Strukturoitu päätöksentekoprosessin tukijärjestelmä	Luottamukseen, selitettävyyteen ja vastuuseen liittyvät haasteet

2.2.1 Koneoppimisen hyödyt luottopäätöksenteossa

Akateeminen kirjallisuus tunnistaa useita hyötyjä koneoppimismallien käyttämisestä luottopäätöksissä, erityisesti verrattuna perinteisiin tilastotieteellisiin lähestymistapoihin. Yksi johdonmukaisimmin raportoiduista hyödyistä on ennustamisen tarkkuus. Lessman et al. (2015) osoittavat, että koneoppimismallit suoriutuvat logistista regressiota tai muita perinteisiä malleja paremmin luottotappioriskin identifioinnissa sekä matalan ja korkean riskin lainanhakijoiden erottamisessa. Lisäksi Dastile et al. (2022) suorittama systemaattinen katsaus kattaa huomattavan määrän empiiristä tutkimusta, joka osoittaa parantunutta luokittelutarkkuutta, kun koneoppimismallitekniikoita käytetään luottoluokitustehtävissä.

Toinen selkeä hyöty liittyy koneoppimismallien prosessointikykyyn. Luottopäätöksenteon dataintensiivisyyden kasvaessa mallit, jotka pystyvät käsittelemään moniulotteista ja heterogeenistä tietoa, tarjoavat käytännön etuja. Koneoppimislähestymistavat on suunniteltu tunnistamaan ja oppimaan toistuvia kaavoja historiallisesta datasta ilman vahvoja oletuksia. Tämän vuoksi mallit ovat

muovattavissa osaksi erilaisia tietorakenteita ja voivat kehittyä lainanottajien käytöksen mukana (Dastile et al. 2020; Lessmann et al. 2015). Tämä joustavuus tukee dynaamisempaa ja datalähtöisempää riskienhallintaa rahoitusallalla.

Alan tutkimus on osoittanut, että päätöksenteon laatu voi parantua koneoppimismalleja hyödynnettäessä. Tuottamalla systemaattisia ja johdonmukaisia todennäköisyysarviota, koneoppimismallit voivat vähentää puhtaasti harkinnanvaraisesta arvioinnista johtuvaa arvioinnin laadun vaihtelua (Dastile et al. 2015). Merkittävänä voidaan pitää esimerkiksi Lu & Zhang (2024) tekemää löydöstä, joka osoitti koneoppimismallin vähentävän hyväksytyjen lainojen sukupuolivinoumaa. Systemaattisen ja reilun datan avulla myös päätösten oikeudenmukaisuus ja läpinäkyvyys voi merkittävästi parantua (Purificato et al., 2022). Strukturoitujen ja johdonmukaisten mallien tuotokset edistävät yhdenmukaisia arviointikriteerejä eri tapauksissa, jolloin luottopäätösprosessi on johdonmukaisempi. Vaikka ihmisen valvonta on keskeisessä osassa, algoritminen pisteytys luo toistettavan analyttisen osan luottopäätösprosessiin.

Lisäksi ihmisen ja tekoälyn yhteistyötä koskeva tutkimus ehdottaa, että algoritmisten ennusteiden yhdistäminen ihmisarvioinnin kanssa tuottaa kokonaisuutena parempia päätöksiä. Lu & Zhang (2024) huomasivat, että auki selitetyt algoritmiset koneoppimismallin tuottamat tulokset voivat johtaa parempiin lopputuloksiin. Lisäksi Wang et al. (2025) mukaan oikein konfiguroitu ihmisen ja koneoppimismallin yhteistyö tuottaa parempia luottopäätöksiä ja parantaa organisaation tekemää voittoa.

Kokonaisuutena koneoppimismallien luottopäätöksissä käyttämisen kirjallisuus vaikuttaa osoittavan näyttöjä tarkemmasta ennustekyvystä, paremmasta laajojen tietokantojen hyödyntämiskapasiteetista, yhtenäisemmästä prosessista ja ihmisen ja algoritmin yhteistyön hyödyistä. Nämä edut muodostavat keskeisen perustelun sille, miksi koneoppimismalleja integroidaan yhä laajemmin luottoriskin arviointiprosesseihin.

2.2.2 Koneoppimismallien haasteet luottopäätöksissä

Koneoppimismallien käyttäminen luottopäätöksissä ei automaattisesti takaa parempia tuloksia. Tutkimuskirjallisuuden kuvaamien hyötyjen ohella löytyy useita merkittäviä haasteita, jotka monimutkaistavat mallien käyttöä asiantuntijajohtoisessa rahoitusalan kontekstissa. Keskeinen löydetty haaste liittyy selitettävyyteen ja läpinäkyvyyteen. Koneoppimismallit, erityisesti monimutkaiset mallit, kuten deep-learning -mallit, voivat toimia niin kutsuttuina mustina laatikkoina, jolloin luottopäätäjän voi olla vaikea ymmärtää, miten sisään syötetty tieto muuttuu spesifeiksi riskiarvioiksi tai pisteiksi. Burrell (2016) jakaa läpinäkymättömyyden eri muodot tahalliseen salailuun, tekniseen kyvyttömyyteen ja koneoppimisjärjestelmien itselleen ominaiseen läpinäkymättömyyteen. Luottopäätöksiä tehdessä tällaiset läpinäkymättömyyden muodot aiheuttavat ongelmia päätäjän prosessille. Tällöin päätöksien perustelu ontuu, avoin viestintä sidosryhmille vaikeutuu ja luottamus koko malliin tai sen tuottamaan tulokseen voi kärsiä.

Läpinäkymättömyyteen liittyy ennustekyvyn ja tuloksen tulkittavuuden välinen jännite. Vaikka koneoppimismallit tuottavat usein selkeästi tarkempia ennusteita (Lessman et al. 2015; Dastile et al. 2020), suurempi monimutkaisuus voi vähentää läpinäkyvyyttä ja sitä kautta päätäjän kokemusta tiedon hallinnasta. Algoritmeja koskevan etnografisen tutkimuksen mukaan organisaatiokontekstissa käyttäjät suosivat usein yksinkertaisempia malleja, sillä ne ovat helpompia valvoa, korjata ja niiden tulokset ovat helpommin selitettävissä (Hansen 2020). Tässä mielessä yksinkertaisuus toimii eräänlaisena hallinnointimekanismina, joka auttaa päättäjiä ylläpitämään vastuun ja valvonnan tunnetta. Tekninen hienostuneisuus ei tällöin automaattisesti takaa käytännön hyödynnettävyyttä.

Toinen rajoite liittyy ihmisen päätäntävaltaan ja mahdollisuuteen ohittaa mallien tuottama arvio. Aikaisemmin tässä tekstissä on todettu, että empiirisen tutkimuksen mukaan päättäjät tekevät mallien riskiarvioiden kanssa yhteistyötä hyvin tuloksin ja että mallien tulokset toimivat usein päätöksenteon pohjana, eivät lopullisena päätöksenä.

Tämä herättää samalla kuitenkin kysymyksen siitä, mikä on asiantuntijan intuition tuoma lisäarvo, varsinkin jos mallien tuoma data ikään kuin sivuutetaan täysin. (Harding & Vasconcelos, 2022). Koneoppimismallien kehittyessä ymmärtämään asiantuntijan arviointia tai intuitiota, voivat perinteiset käsitykset luottoarvioinnin asiantuntijuudesta muuttua.

Vastuunjako voidaan myös nähdä selkeänä kitkaa aiheuttavana tekijänä. Kuten Züger et al. (2025) kuvaavat, ihmisen ja tekoälyn yhteistyön vastuu lainaliiketoiminnassa voi jakautua usean toimijan kesken. Näitä toimijoita ovat sovelluskehittäjät, asiakasrajapinnan toimijat, compliance-toimijat ja muut hallinnolliset toimijat. Lisäksi samankaltaisilla tutkimusalueilla, kuten terveydenhuollon päätöksenteon tukijärjestelmiä koskevassa tutkimuksessa, koneoppimisteknologia voi järjestellä uudelleen koko organisaation työprosesseja ja samalla hämärtää sitä, kuka on vastuussa haitallisista päätöksistä tai niiden seurauksista (Bailey et al. 2020). Rahoitusalan kontekstissa nousee mahdollisuus sille, että muodollinen päätöksenteon vastuu säilyy asiantuntijalla, mutta käytännön vastuu jää epäselväksi. Lisäksi tekoälyn, kuten koneoppimismallin käyttämisen on havaittu vaikuttavan koettuun vastuuseen, jolloin asiantuntijan vastuun käsitys voi muuttua tai vaihdella (Mendel et al., 2025).

Lopuksi koneoppimismallien käyttöönottoon vaikuttaa olennaisesti organisaation konteksti ja olemassa olevat kannustinohjelmat. Lu & Zhang (2024) osoittavat, että ihmisen ja tekoälyn yhteistyön tuomat parannukset lainaliiketoimintaan eivät riipu yksin mallin teknisestä suorituskyvystä, vaan myös työn suunnittelusta, selitettävyyden saatavuudesta ja kannustimista, jotka kannustavat aktiiviseen yhteistyöhön passiivisen passiivisen mukautumisen sijaan. Ilman sopivia hallinnollisia mekanismeja voi syntyä liiallinen riippuvuus koneoppimismallin tuottamiin tuloksiin, kun taas liiallinen skeptismi voi puolestaan haitata mahdollisia konkreettisia hyötyjä. Tämän perusteella koneoppimisen rajoitteet luottopäätöksenteossa eivät ole vain teknisiä. Rajoitteet ovat kietoutuneet sosioteknologisiin järjestelyihin, jotka vaikuttavat kontrolliin, harkintavaltaan ja vastuuseen.

Kokonaisuutena akateeminen kirjallisuus vaikuttaa osoittavan, että koneoppiminen luottopäätöksenteossa tuo mukanaan haasteita, jotka liittyvät läpinäkymättömyyteen, tulkittavuuteen, asiantuntija-arvioinnin statukseen, jakaantuneeseen vastuunkantoon ja organisaation hallinnollisiin toimiin. Nämä jännitteet toimivat perusteluna väitteelle, ettei koneoppimismallien integroinnissa ole kyse vain teknisestä suorituskyvystä ja paremmasta ennustetarkkuudesta. Se merkitsee myös laajempaa muutosta ammatillisissa rooleissa ja päätöksentekokäytännöissä.

3 Asiantuntijan ja tekoälyn yhteistyö

Koneoppimismallien lisääntynyt soveltaminen luottopäätöksissä on siirtänyt akateemista keskustelua puhtaan teknisistä mallin suorituskykyyn liittyvistä kysymyksistä kohti ihmisasiantuntijan ja algoritmisten järjestelmien yhteistyötä. Edellisessä luvussa tarkasteltiin koneoppimismallien roolia luottopäätöksenteon kontekstissa ja tämän luvun painopisteenä on mallien itsensä sijaan mallien käyttämisen laajempi päätöksentekoympäristö. Luottopäätöksenteon, sekä laajemminkin koko rahoitusalan kontekstissa, koneoppimismalleja ei ole suunniteltu korvaamaan päättäjiä, vaan pikemminkin tukemaan heitä tarjoamalla ennusteita, luokittelua tai riskiarvioita. Tämän tuloksena luottopäätöksenteko tapahtuu usein yhteistyöympäristössä, jossa algoritminen analyysi ja inhimillinen arviointityö toimivat vuorovaikutteisesti (Lu & Zhang, 2024; Züger et al., 2025).

Tässä yhteistyön ympäristössä koneoppimismallien tukeman päätöksenteon tehokkuuteen vaikuttaa olennaisesti se, miten asiantuntijat tulkitsevat mallien tuloksia, hyödyntävät niitä päätöksissään ja miten he käyttävät ammatillista arviointiaan suhteessa algoritmien suosituksiin. Viimeaikainen tutkimus korostaa, että algoritmiset päätöksenteon tukijärjestelmät tulisikin nähdä osana laajempia sosioteknisiä järjestelmiä, joissa teknologian tarjoamat työkalut, asiantuntijat ja organisaatiokäytäntö muovaavat päätöksentekoa yhdessä (Bailey et al., 2020; Raso 2017).

Tätä näkökulmaa hyödyntäen, tässä kappaleessa koneoppimismallien merkitystä ammattimaisessa päätöksenteossa tarkastellaan sen kautta, miten asiantuntijat käyttävät algoritmien tuottamia tuloksia sekä miten vastuut, tulkinnat ja tukeutumisen käytännöt näkyvät käytännön päätöksissä. Toiseksi käsitellään sitä, miten asiantuntijat tulkitsevat mallien tuottamaa informaatiota ja millä ehdoin he saattavat kyseenalaistaa tai ohittaa mallien ehdotuksia. Kolmanneksi tutkitaan luottamusta, tukeutumista ja vastuuta keskeisinä ehtoina, jotka muovaavat koneoppimisen käytännön soveltamista päätöksissä. Lopuksi keskustellaan hallinnollisista ja organisatorisista rakenteista, jotka

vaikuttavat siihen, miten ihmisen asiantuntemusta ja näkemystä käytännössä mahdollistetaan, rajoitetaan tai formalisoidaan.

3.1 Luottopäätöksenteon sosiotekninen järjestelmä

Ihmisen ja tekoälyn yhteistyötä tutkiva akateeminen kirjallisuus käsittelee enenevässä määrin yllä kuvattua yhteistyötä sosioteknisen järjestelmän viitekehystä. Sosiotekninen järjestelmä voidaan ymmärtää järjestelynä, jossa päätöksentekoon vaikuttavat algoritmien tehokkuuden ja kyvykkyyksien lisäksi ihmisten roolit, teknologisten käyttöliittymien suunnittelu ja malleja integroivien organisaatioiden erilaiset käytännöt. (Bailey et al., 2022; Raso 2017). Kun asiaa tarkastellaan luottopäätöksenteon kontekstissa, nähdään ettei koneoppimismallin merkitystä voida mitata vain ennustetarkkuuden kautta. Tästä näkökulmasta korostuu se, miten algoritmisten päätöksenteon tukityökalujen merkitykseen vaikuttaa vahvasti se, miten ne integroidaan käytännön työhön ja miten asiantuntijat käsittelevät tuotettuja tuloksia.

Algoritmien tukemassa päätöksentekoprosessissa ihminen pysyy mukana järjestelyjen kautta, joita kuvataan tyypillisesti termeillä *human-in-the-loop* tai *human-in-control*. Hansen (2020) sekä Raso (2017) kuvaavat näitä tilanteina, joissa ihmiset valvovat tai ovat vastuussa päätöksissä järjestelmissä, jotka tukeutuvat algoritmiseen analyysiin. On kuitenkin huomattava, että empiirisen tutkimuksen mukaan ihmisen roolin laajuus ja osallistumisen luonne voivat vaihdella huomattavasti tilanteesta ja toimintaympäristöstä riippuen. Joissain tapauksissa asiantuntijat pääosin tarkistavat ja vahvistavat algoritmin suosituksia, kun taas toisissa he voivat aktiivisesti tulkita, kyseenalaistaa tai jopa ohittaa mallien tuloksia silloin, kun kontekstuaalinen tieto tai asiantuntijan arvio osoittaa mahdollisesti eri suuntaan (Züger et al., 2025).

Tämän perusteella se, että ihminen on prosessissa mukana, ei takaa tosiasiallista kontrollia. Tästä näkökulmasta ihmisen ja tekoälyn yhteistyön syvällisempi ymmärtäminen vaatii analyysiä siitä, miten asiantuntijat toimivat yhteistyössä algoritmien tuottamien tuloksien kanssa ja miten nämä tulokset saatetaan osaksi heidän

päätöksentekoprosessejaan. Asiantuntijoiden päätöksenteossa, kuten luottopäätöksiä tehdessä algoritmiset suositukset ovat yksi informaatiomuoto monen muun asiantuntijan tutkiman kokonaisuuden joukossa. Tämän vuoksi koneoppimismallin tukema luottopäätöksenteko on mielekästä hahmottaa sosioteknisenä kokonaisuutena, jossa roolit, tulkinat, luottamussuhteet ja hallintarakenteet yhdessä määrittävät, miten algoritmista tukea käytetään käytännössä. Seuraavat osiot tarkastelevat tarkemmin näitä muuttujia.

3.2 Asiantuntijan rooli, työnjako ja kontrolli

Tekoälyn tukeman päätöksenteon viitekehyksessä ihmisen roolia ei voida pelkistää vain passiiviseksi algoritmin tuottamien tulosten vastaanottajaksi. Sen sijaan päätöksiä tekevän ihmisen ja koneoppimismallin suhdetta muovaavat vastuunjako, auktoriteetti ja kontrolli päätöksentekoprosessin kulusta. Ihmisen ja tekoälyn yhteistyötä tutkineet Züger et al. (2024) sekä Lu & Zhang (2024) ovat enemmän keskittyneet juuri siihen, miten roolit ja päätöksenteon valta ovat rakentuneet prosesseissa, joissa koneoppimismallit tukevat ammattilaisen arviointityötä.

Tätä työnjakoa voidaan perustellusti käsitteellistää ajatuksella siitä, että ihmisen ja algoritmin kyvykkyyden täydentävät toisiaan. Algoritmiset järjestelmät ovat erityisen tehokkaita välineitä käsittelemään laajoja datasettejä, tunnistamaan tilastollisia säännönmukaisuuksia ja tuottamaan yhdenmukaisia tuloksia. Ihmisasiantuntijat taas ovat tärkeitä tilanteissa, joissa konteksti, laadulliset tekijät tai tapauskohtaiset muuttujat eivät heijastu tiedon kautta riittäväällä tavalla (Jarrahi, 2018). Tästä näkökulmasta ihmisen rooliksi ei jää vain mallin tuottaman tiedon leimaaminen hyväksytyksi, vaan kokonaisvaltaisemman arvion tuottaminen, joka täydentää mallin analyysiä.

Tätä näkökulmaa tukee myös hybridiälykkyyden tutkimus, jossa kuvataan ihmisen ja tekoälyn yhteistyötä järjestelmänä, jonka arvo luodaan ihmisen ja laskentatehon yhdistelmän kautta. (Dellermann et al., 2019). Samansuuntaisesti viimeaikainen tekoälyn avustaman päätöksenteon tutkimus on näyttänyt, että ihmisen osallistumisella

on monta muotoa. Nämä muodot vaihtelevat algoritmien suositusten tarkastamisesta aktiiviseen suositusten säätämiseen tai haastamiseen, kontekstista riippuen. (Gomez et al., 2024). Näin korostuu näkökulma, jonka mukaan ihmisen kontrollin merkitys ei yksin riipu siitä, onko ihminen prosessissa mukana, vaan siitä miten aktiivisesti he voivat käsitellä algoritmien tuloksia.

Mallin ja ihmisen välinen työnjako voi vaihdella organisaation kontekstin ja teknologian käyttöönoton käytäntöjen vaihtelun mukana. Esimerkiksi Züger et al. (2025) osoittavat useita rooleja, joihin asiantuntijat mukautuvat toimiessaan päätöksentekijänä algoritmin tukemana. Joissain tapauksissa asiantuntijat toimivat pääasiallisina päätöksentekijöinä, jotka ottavat algoritmien suositukset huomioon, mutta arvioivat laajaa määrää muitakin päätöksentekoon vaikuttavia muuttujia. Joissain tapauksissa taas päättäjän rooli voi rajoittua enemmän poikkeustilanteiden tarkasteluun tai sellaisten tilanteiden analysoimiseen, jotka ovat ennalta määritettyjen rajojen ulkopuolella. Lisäksi tutkijat huomasivat, että ihmiset voivat toimia myös ns. resilienssimekanismena sosioteknisten järjestelmien sisällä. Tällä tarkoitetaan sitä, että ihminen puuttuu peliin, kun algoritmin tulos vaikuttaa epä johdonmukaiselta, epävarmalta tai kontekstiin sopimattomalta.

Nämä vaihtelevat roolit kuvaavat sitä, että human-in-the-loop-konsepti voi käytännössä edustaa hyvinkin erilaisia ihmisen rooleja. Vaikka termistä voitaisiin päätellä, että ihminen on osa päätöksentekoprosessia, Hansen (2020) sekä Raso (2017) osoittavat, että ihmisen tosiasiallinen vaikutus voi vaihdella aktiivisesta tarkkailusta ja päätöksenteosta suhteellisen rajoittuneeseen algoritmin tuottamien tuloksien valvontaan. Tämän perusteella tutkijat jatkavat korostamaan ns. merkityksellisen inhimillisen kontrollin (meaningful human control) keskeistä roolia. Tällä viitataan tilanteisiin, joissa asiantuntijalla on tarpeeksi tietoa, valtaa ja mahdollisuuksia algoritmisten suositusten kriittiseen arviointiin ja jopa niiden haastamiseen.

Ammatillisessa kontekstissa, kuten luottopäätöksiä tehdessä ihmisiasiantuntijan ja koneoppimismallin työnjaolla on merkitystä. Vaikka mallit voivat tunnistaa tilastollisia

toistuvia kaavoja ja tuottaa yhtenäisiä riskiarvioita, ihmiset ovat vastuussa tämän tiedon tulkinnasta. Tähän tulkintaan ja arviointiin kuuluu sen varmistaminen, että päätökset ovat laajemman kontekstin mukaisia, eli ovat linjassa organisaation politiikan, sääntelyn ja ammatillisten vaatimusten kanssa. Tämän työnjaon rakentumisen ymmärtäminen on tärkeää, jotta voidaan tutkia, miten koneoppimismalleja käytännössä sovelletaan päätöksiä tehdessä.

3.3 Mallin tuottaman tiedon tulkinta ja ohittaminen

Koska mallien tulokset eivät tulkitse itse itseään, niiden käytännöllinen arvo rakentuu tulkinnan varaan. Ammattimaisen päätöksenteon kontekstissa asiantuntijat arvioivat algoritmien tuottamien tuloksien merkityksellisyyttä, uskottavuutta ja luotettavuutta suhteessa yksittäisen tapauksen erityispiirteisiin, ja voivat perustellusti myös kyseenalaistaa tai sivuuttaa ne.

Algoritmien tulokset esitetään usein riskipisteiden tai todennäköisyysarvioiden muodossa. Nämä tulokset summaavat monimutkaisia tilastollisia kaavoja, mutta Züger et al. (2025) mukaan niiden käytännön arvo riippuu siitä, miten päätöksentekijät tulkitsevat niitä erilaisissa ja yksilöllisissä päätöksenteon asiayhteyksissä. Asiantuntijat voivat pitää mallien tuloksia signaaleina tai suosituksina, eivät lopullisina totuuksina ja vastauksina. Asiantuntijat yhdistävät nämä signaalit tai suositukset laajempaan edellä kuvattuun prosessiin. Tämä tulkinnallinen näkökulma osoittaa koneoppimismallin kanssa tapahtuvan päätöksentekoprosessin olevan yhteistyölähtöinen: ihminen on vastuussa mallin tuottaman strukturoidun tiedon merkityksen arvioinnista.

Tämän kanssakäymisen keskiössä on asiantuntijoiden mahdollisuus kyseenalaistaa tai ohittaa algoritmin suosituksia. Harding & Vasconcelos (2022) osoittavat, että monissa eri ammatillisissa yhteyksissä, asiantuntijat ovat pitäneet itsellään mahdollisuuden poiketa mallien tuloksista silloin, kun heidän kokonaisvaltainen arvionsa osoittaa eri suuntaan. Purificato et al. (2022) huomauttavat, että tällaisille poikkeaville arvioille on useita syitä, kuten mallin puutteet kontekstuaalisen laajemman tiedon huomioidussa, datan laatuun

liittyvät huolet tai mallin soveltuvuuden mahdolliset rajoitteet yksittäisiin tapauksiin. Nämä käytännöt osoittavat, että algoritmien tuloksia sisällytetään laajemman päätöksenteon yhteyteen, eivätkä mallit vaikuta korvaavan päätöksen tekijöitä.

Koneoppimismallien tuottamien tulosten tulkittavuudella on myös merkittävä rooli siinä, miten asiantuntijat käytännössä käsittelevät mallin suosituksia. Silloin, kun päätöksenteon tukijärjestelmät tuottavat selityksiä, varmuuden mittareita tai tarkempaa tietoa ennusteisiin vaikuttavista muuttujista, asiantuntijat voivat mahdollisesti paremmin arvioida algoritmien taustalla olevaa päättelylogiikkaa ja näin paremmin yhdistää niitä oman ajattelunsa kanssa (Purifficato et al., 2022). Tällainen tulokinnan tuki voi siis kannustaa aktiivisempaan algoritmien suositusten soveltamiseen, mikä taas kannustaa asiantuntijoita arvioimaan vastaako mallin päättely heidän omaa käsitystään tapauksesta.

Samanaikaisesti, ihmisarvion ja algoritmien suositusten yhdistäminen voi tuoda mukanaan jännitteitä. Algoritmien suosituksia koskeva tutkimus on osoittanut, että päätöksentekijät voivat helposti joko tukeutua liikaa algoritmin tulokseen tai päinvastoin jättää ne kokonaan huomioimatta, jopa tilanteissa, joissa niiden tuottamasta tiedosta on hyötyä. Näitä ilmiöitä kuvataan algoritmissen päätöksenteon tukeen kohdistuvana yli- tai aliluottamuksena (over- and under-reliance) (Logg et al. 2019; Mehrotra et al., 2024). Yliluottamusta voi ilmetä, kun päätöksentekijä yksinkertaisesti hyväksyy algoritmin suosituksen ilman kriittistä riittävää kriittistä arviointia. Aliluottamusta voi taas ilmetä silloin, kun asiantuntijat suosivat omaa arviotaan, vaikka algoritmin ennusteet näyttäisivätkin erittäin korkeaa tarkkuuden tasoa.

Nämä dynamiikat vahvistavat edelleen näkemystä, jonka mukaan algoritmin tuottaman suosituksen rooli päätöksenteossa ei ole yksin kiinni mallin teknisestä kyvykkyydestä, vaan myös siitä, miten asiantuntijat tulkitsevat ja hyödyntävät mallin tuottamia tuloksia. Kun tarkastellaan rahoitettavuuden arviointia ja luottopäätöksiä, joissa asiantuntijan vastuu ja kontekstuaaliset tekijät ovat keskiössä, asiantuntijoiden täytyy

johdonmukaisesti tasapainotella oman arvionsa ja algoritmin havaintojen välillä. Siksi on keskeistä ymmärtää, miten asiantuntijat tulkitsevat mallien tuottamia tuloksia ja millaisissa tilanteissa he päättävät sivuuttaa ne, jotta koneoppimismallien roolia ammattimaisessa päätöksenteossa voidaan tarkastella käytännön tasolla.

3.4 Luottamus, tukeutuminen ja vastuu

Ihmisen ja tekoälyn yhteistyössä luottamus on keskiössä. Algoritmisen päätöksenteon tuen arvo riippuu mallien tuottaman tiedon saatavuuden lisäksi siitä, miten ihmiset käytännössä siihen tukeutuvat. Mehotra et al. (2024) osoittavat, miten ammattimaisien päätöksentekoprosessien yhteydessä luottamus tekoälyyn ei ole vain teknologiaan positiivisesti suhtautumista. Sen sijaan siinä on kyse siitä, miten paljon ammattilaiset pitävät tekoälyn tuotoksia uskottavina, hyödyllisinä ja yhteensopivana omien näkemyksiensä kanssa. Luottamuksen rooli koneoppimismallien tukemassa päätöksenteossa voidaan siis yhdistää laajempaa teemaan: tekoälyn tukeutumiseen, eli miten asiantuntijat arvioivat mallien tuottamaa tulosta, milloin he kyseenalaistavat niitä tai milloin niitä ei lainkaan päätetä hyödyntää.

Mehotra et al. (2024) ovat myös näyttäneet, että tasapainoilu algoritmien suosituksiin tukeutumisen kanssa voi olla haasteellista. Toisaalta päättäjät voivat osoittaa aliluottamusta, kun he ohittavat täysin algoritmien tuottamat suositukset, jopa silloin kun se olisi tosiasiallisesti arvokasta. Toisaalta päättäjät voivat luottaa järjestelmiin liiallisesti hyväksymällä niiden tuotokset ilman riittävää kriittistä arviointia. Tästä näkökulmasta vaikuttaa siltä, että ihmisen ja tekoälyn yhteistyössä ei ole kyse luottamuksen maksimoinnista, vaan oikean tason löytämisestä riittävän kriittisyyden ja tukeutumisen välillä. Aiempi tutkimus osoittaa myös, että algoritmisten suositusten vastaanotto itsessään on erilista eri ihmisten välillä. Logg et al. (2019) katsauksen mukaan löytyy tutkimuksia, jotka toteavat ihmisten välittelevän algoritmisia suosituksia, mutta löytyy myös tutkimuksia, joiden mukaan ihmiset luottavat algoritmin suosituksiin enemmän kuin ihmisarvioon. Tämä vaikuttaa osoittavan, että tekoälyn luottamukseen

vaikuttaa selkeästi mallin objektiivisen laadun lisäksi se, miten päätöksentekijät arvioivat mallien auktoriteettia, johdonmukaisuutta ja legitimitettä.

Algoritmiin malleihin ja niiden tuloksiin nojautumiseen voi myös vaikuttaa päätöksenteon tukijärjestelmä itsessään. Selitettävyyden, luottamusindikaattorit ja muut käyttöliittymän ominaisuudet ovat ratkaisevia tekijöitä siinä, miten käyttäjät työskentelevät mallin tuottamien suositusten kanssa ja miten tämä voi tukea harkitsevampaa tukeutumista (Purificato et al., 2022).

Luottamus ja tukeutuminen ovat sidoksissa vastuukysymyksiin. Tekoälyn tukemassa päätöksenteossa jatkuvaa ihmisarvion läsnäoloa perustellaan usein oletuksella, että he ovat viime kädessä vastuussa lopullisista päätöksistä. Viimeaikainen tutkimus kuitenkin viittaa siihen, että tekoälyn käyttäminen päätöksentekoprosessissa voi muuttaa päättäjän kokemaa vastuun tunnetta. Mendel et al. (2025) osoittavat, että päätöksentekotapauksissa, joissa tekoälyä ilmoitettiin käytetyn, voi yksilön henkilökohtainen vastuun tunne heikentyä. Vähempi tekoälyn tukeutuminen taas assosioitiin vahvempaan vastuun tunteeseen. Näiden löydösten perusteella tekoälyn tukeutumisen asteessa on kyse tuloksien lisäksi siitä, miten päätöksentekijät ymmärtävät oman osansa suhteessa algoritmiin suosituksiin.

Ammatillisissa asiayhteyksissä, kuten luottopäätöksiä tehdessä, nämä haasteet ovat erityisen relevantteja, sillä luottopäättäjien oletetaan tuottavan tehokkaita, johdonmukaisia ja tietoon pohjavia päätöksiä omien arvioidensa pohjalta – omalla vastuulla. Luottamuksen tehtävä tällaisissa ympäristöissä on muokata niitä olosuhteita, joissa päättäjien mukaan algoritmiset suositukset ovat riittävän luotettavia käytettäväksi.

3.5 Hallinto ja yhteistyön rakenteet

Tekoälyn tukemassa päätöksenteossa, algoritmien ja ihmisten yhteistyöhön vaikuttaa myös kaikkien edellä mainittujen lisäksi organisaation järjestelyt, joiden mukaan yhteistyötä tehdään. Näin ollen ihmisen ja tekoälyn yhteistyö voidaan nähdä yhtä lailla

hallinnollisena kysymyksenä kuin kognitiivisena tai käyttäytymiseen liittyvänä ilmiönä. Algoritmisen päätöksenteon tuki riippuu siitä, miten vastuuta allokoidaan, miten ohittamista sallitaan ja miten organisaatiot strukturoivat asiantuntija-arvioiden, mallien tulosten ja muodollisen vastuun välisiä suhteita (Züger et al., 2025, Wang et al., 2025).

Akateemiset tutkimukset näyttävät, että politiikat ja kannustimet vaikuttavat ihmisen ja tekoälyn välisen yhteistyön laatuun. Kokeelliset tutkimukset osoittavat, että ihmisen ja algoritmin muodostama joukkue ei automaattisesti voita ihmistä tai konetta yksinään. Sen sijaan tulokset riippuvat siitä, miten organisaation käytännöt ohjaavat koneiden tuottamien neuvojen hyödyntämistä. Tällaisia käytäntöjä ovat esimerkiksi se, kannustetaanko asiantuntijoita aktiivisesti arvioimaan mallien tuloksia, vai toimimaan vain niiden mukaisesti (Wang et al. 2025; Lu & Zhang, 2024).

Hallinnollisesta näkökulmasta keskeiseen asemaan nousee kysymys siitä, onko ihmisen osallistuminen merkittävää vai enemmänkin muodollista. Züger et al. (2025) argumentoivat, että ihmisen muodollinen läsnäolo luottopäätöksessä ei takaa merkityksellistä kontrollia. Sen sijaan kontrollin määrään vaikuttaa esimerkiksi onko päättäjällä riittävästi aikaa, tietoa ja kokemusta mallin tuottaman tuloksen arvioimiseen tai ohittamiseen. Lisäksi hallinnolliset rakenteet vaikuttavat siihen, miten poikkeustapauksia voidaan käytännön tasolla käsitellä. Jos mallin suositusten ohittamista kartetaan systemaattisesti tai rajoitetaan tiukasti, ihmisen vaikutus päätöksiin voi olla vain nimellinen, vaikka vastuu olisikin muodollisesti ihmisellä.

Hallinnollisten tekijöiden vaikutus ulottuu yksittäisen päätöstapahtuman ulkopuolelle mallien käytön laajempaan elinkaareen. Hansen (2020) osoittaa, että algoritmisen osakekaupankäynnin kontekstissa ihmisen rooli näkyy pääosin mallin suunnittelun, valinnan ja huollon tasolla, eikä niinkään jokaisessa tapauksessa itsessään. Tällaisissa asetelmissä hallinnollisia valintoja tehdään mallien yksinkertaisuuden, tulkittavuuden ja käytön laajuuden kautta. Tämä osoittaa, että ihmisen valvonta tekoälyn tukemissa järjestelmissä on monitasoista: sitä esiintyy mallien kehitysvaiheessa,

käyttöönottovaiheessa ja käytännön päätötapauksissa. Tämän seurauksena yhteistyörakenteita ei voida pelkistää yksinkertaiseksi manuaalisten ja automaattisten päätösten jaotteluksi. Tässä viitekehyksessä päätöksentekorakenteet voidaan selkeästi nähdä myös suunnitteluajan ja käytön aikaisen ohjauksen kerrostettuna järjestelyinä.

Toinen tärkeä hallinnollinen ulottuvuus koskee vastuun jakoa eri organisaation toimijoiden kesken. Tekoälyn tukemissa päätöksentekoprosesseissa vastuu löytyy harvoin yksittäiseltä mallia käyttävältä asiantuntijalta. Sen sijaan vastuu jakautuu usein etulinjan päätöksentekijöiden, riskipäälliköiden, compliance-toimijoiden ja mallin kehittäjien kesken (Züger et al., 2025). Tämä jakauma voi olla välttämätön isojen organisaatioiden yhteydessä, mutta se voi tehdä vastuusta vähemmän selkeää. Raso (2017) mukaan algoritmiset järjestelmät voivat järjestää harkintaa uudelleen sisällyttämällä erilaisia linjauksia teknisiin sääntöihin, jolloin käytännön murheet voivat helposti siirtyä etulinjan ammattilaiselle. Samansuuntaisesti Bailey et al. (2020) demonstroivat, että algoritmiset järjestelmät voivat luoda täysin uusia työtehtäviä, jotka liittyvät tuloksien valvontaan, tulkitsemiseen ja dokumentointiin, jolloin virheen sattuessa voi jäädä epäselväksi kuka on vastuussa.

Tämä näkökulma on erityisen tärkeä rahoituspäätöksissä, jolloin koneoppimismallit voivat luoda uusia kerroksia työntekoon ilman, että vastuunjako selkenee. Asiantuntijoilta voidaan odottaa ohitusten dokumentointia, poikkeusten perustelua ja toimintansa yhdenmukaistamista compliance-vaatimusten kanssa. Näin voi syntyä Bailey et al. (2020) kuvaamaa algoritmista työtä: toimintaa, jota nähdään mallien tuottamien tulosten koordinoinnin ja hallinnoinnin yhteydessä. Tällainen työ on erityisen relevanttia luottopäätöksiä tehdessä, jossa mallien organisaatiotason käyttäminen voi synnyttää uusia seurannan, dokumentoinnin ja sisäisen perustelun käytäntöjä.

Kokonaisuutena tässä käsitelty tieteellinen kirjallisuus ehdottaa, että koneoppimismallien tukemaa päätöksentekoa tulisi ymmärtää sosioteknisenä ilmiönä, ei vain teknisenä kysymyksenä ennustamisen tehokkuudesta. Olemassa oleva tutkimus

osoittaa, että algoritmien tukeman päätöksenteon vaikutukset riippuvat siitä, miten mallien ja ihmisten työtehtävät jaetaan, miten tuloksia tulkitaan, miten tuloksiin luotetaan ja miten niihin nojaututaan sekä miten organisaatiot ovat rakennettu niiden ympärillä. Tieteellinen keskustelu on keskittynyt yleisiin ihmisen ja tekoälyn yhteistyön malleihin, kokeellisiin asetelmiin ja suorituskykyyn liittyviin kysymyksiin, ei niinkään siihen millaiseksi asiantuntijat itsessään kokevat koneoppimismallin kanssa työskentelyn käytännön päätöksentekotyössä.

Erityisen vähän on tietoa siitä, miten luottopäätöksiä tekevät ammattilaiset tulkitsevat mallien tuloksia, integroivat niitä omaan työhönsä sekä millaiseksi he ymmärtävät mallin roolin ympäristössä, jossa vastuu pysyy ihmisellä itsellään. Nämä kysymykset ovat relevantteja suomalaisessa yritysrahoituksessa, sekä vaihtoehtoisen että perinteisen yritysrahoituksen konteksteissa, joissa koneoppimismallit muovaavat alaa. Tämä tutkimus vastaa tähän aukkoon tarkastelemalla juuri yllä mainittuja kysymyksiä.

4 Tutkimusmenetelmä

Tässä tutkimuksessa käytetään laadullista tutkimustapaa. Laadullista tutkimustapaa voidaan perustella tutkimuksen eksploratiivisella luonteella ja sen tarkoituksella syventää ymmärrystä luottopäätäjien kokemuksista koneoppimismallien kanssa yhteistyössä tehdystä luottopäätöksenteosta. Tuomi ja Sarajärvi (2018) kirjoittavat, että laadullista tutkimusta voidaan tarkastella omassa kontekstissaan eri näkökulmista. Braun & Clarke (2006) jatkavat, että laadullinen lähestymistapa on tarkoituksenmukainen silloin, kun tutkimuksen kohteena ovat ilmiöt, joita halutaan ymmärtää yksilöiden kokemusten, niille annettujen merkitysten ja erilaisten tulkintojen kautta, eikä tutkimus rajoitu ainoastaan tilastollisiin yleistyksiin.

Koneoppimismalleja luottopäätöksenteossa on tutkittu viime vuosina paljon. Olemassa oleva tutkimus keskittyy kuitenkin usein määrälliseen tutkimukseen siitä, mikä koneoppimismalli on tehokkain, mikä ennustaa tarkimmin tai mitkä ovat saadut kustannussäästöt. Luottopäätökseen osallistuvan ammattilaisen kokemuksia ja havaintoja koneoppimismallien käyttämisestä osana päätöksentekoa ei ole tutkittu. Tämän tutkimuksen tavoitteena on vastata tähän aukkoon, erityisesti suomalaisen yritysrahoituksen kontekstissa.

Menetelmäksi valittiin puolistrukturoitu teemahaastattelu. Hirsjärvi & Hurme (2022) kuvaavat puolistrukturoidun teemahaastattelun sopivan tutkimuksiin, joissa pyritään ymmärtämään tutkittavien kokemuksia ja näkökulmia ennalta määritettyjen teemojen puitteissa. Menetelmä jättää kuitenkin tilaa tulkinnoille ja esille nouseville ilmiöille. Teemahaastattelu mahdollistaa suoran vuorovaikutuksen tutkittavan kanssa. Tällöin voidaan saada tarkempi käsitys vastauksista, erityisesti tarkentavien kysymyksiä mahdollisuuden vuoksi.

4.1 Konteksti

Tämä tutkimus keskittyy suomalaiseen vaihtoehtoisen (pankkisektorin ulkopuolisen) yritysrahoituksen sekä perinteisen yritysrahoituksen kontekstiin. Molempia ympäristöjä yhdistää asetelma, jossa koneoppimismalli on luottopäätösarviointia tukeva tekijä ja päätösvastuu säilyy asiantuntijalla. Näin ollen tutkimusympäristössä koneoppiminen toimii osana asiantuntijoiden tekemää luottoarviointia, ei autonomisena päätöksentekijänä.

Tutkija on myös itse perehtynyt työnsä kautta organisatoriseen kontekstiin, jossa koneoppimisen tukemaa luottopäätöksentekoa sovelletaan. Tämä voidaan nähdä sekä vahvuutena, että mahdollisena vinouman aiheuttajana. Toisaalta tämä tuki kontekstin ymmärtämistä ja helpotti haastatteluaineiston merkityksellisten tunnisteiden löytämisessä. Toisaalta tämä lisäsi riskiä siitä, että ennestään tutut oletukset vaikuttavat tulkintaan. Riskin lieventämiseksi analyysi toteutettiin iteratiivisesti edeten haastatteluaineistosta kohti laajempia teemoja, ja tulkintoja verrattiin alkuperäisiin lainauksiin empiirisen laadun varmistamiseksi.

4.2 Aineiston keruu ja otanta

Kun yritetään ymmärtää yksilöllisiä kokemuksia ja havaintoja, on tärkeää saada haastattelussa tasapaino systemaattisuuden ja joustavuuden välille (Tuomi & Sarajärvi, 2018). Puolistrukturoitu teemahaastattelurunko on tehty etukäteen, jotta keskustelut etenevät jouhevasti. Kysymysten avoimuus jättää kuitenkin tilaa haastateltavan kertomuksille.

Otanta on tarkoituksenmukainen. Haastattelut kestivät jokainen noin 30 minuuttia ja ne toteutettiin etänä ja taltioitiin. Pattonin (2015) mukaan, laadullisen tutkimuksen otannan tarkoituksena on tuottaa informatiivisesti tiiviitä tapauksia, jotka kuvaavat ilmiötä tutkimuskysymyksen kannalta merkityksellisesti. Tämä tutkimus ei pyri edustamaan kokonaista populaatiota tai kysy kuinka yleistä jokin ilmiö on, vaan kysyy

miten asiantuntijat kokevat koneoppimismallien käytön. Tällöin kokemuksellisiin ja tulkinnallisiin kysymyksiin satunnaisotanta ei ole tarkoituksenmukainen (Cresswell & Poth, 2018). Patton (2015) jatkaa, että tarkoituksenmukainen otanta mahdollistaa osallistujien valinnan selkeiden kriteerien perusteella. Tässä tutkimuksessa näitä kriteereitä ovat osallistuminen luottopäätöksiin ja kokemus koneoppimismallien soveltamisesta. Nämä kriteerit kaventavat mahdollista populaatiota selkeästi.

Haastateltavat valittiin kahden kriteerin perusteella: kokemus luottopäätösten tekemisestä ja käytännön kokemus koneoppimismallin soveltamisesta näissä päätöksissä. Osallistujat hankittiin tutkijan ammatillisen verkoston kautta ja ennen haastatteluja osallistujille annettiin tieto tutkimuksen tarkoituksesta, osallistumisen vapaaehtoisuudesta sekä aineiston käsittelytavoista.

Aineisto kerättiin haastattelemalla neljää luottopäätöksiin osallistuvaa yritysrahoituksen ammattilaista, jotka käyttävät koneoppimismalleja prosessin tukena. Haastateltavat edustivat sekä vaihtoehtoisen että perinteisen yritysrahoituksen konteksteja Suomessa. Yksi haastateltava on luottokomitean johtaja, kaksi ovat analyytikkoja ja neljäs on talousjohtaja sekä analyytikko.

Taulukko 2. Tutkimukseen osallistuneet henkilöt

Haastateltava	Nimike
1	Luottokomitean johtaja
2	Luottoanalyytikko
3	Analyytikko/CFO
4	Yritysanalyytikko

Tämä tutkimus ei pyri tilastolliseen yleistettävyyteen, vaan keskittyy kapeasti määriteltyyn ammattilaisten joukkoon, joilla kaikilla on kokemusta koneoppimismallien hyödyntämisessä luottopäätöksiä tehdessä. Haastattelujen rajallinen määrä tulisi myös

ottaa huomioon kohderyhmän erityispiirteiden kannalta. Tällaisten haastateltavien saatavuus on hyvin rajallinen ja tutkimus pyrki tuottamaan syvällistä kokemusperäistä ymmärrystä tilastollisen edustavuuden sijaan. Otannan riittävyttä arvioidaan ensisijaisesti suhteessa aineiston rikkauteen ja relevanssiin tutkimuskysymyksen kannalta. Otannan kokoon vaikutti myös aineiston kyllästyminen (Guest et al. 2012). Neljän haastattelun jälkeen alkoi esiintyä selkeää teemojen toistuvuutta tutkimuksen kannalta keskeisissä kysymyksissä.

4.3 Analyysimenetelmä

Tutkimuksen aineisto analysoidaan teemoittelemalla. Teema-analyysin tarkoituksena on etsiä ja tutkimuksen kannalta relevantteja merkityskokonaisuuksia, eli teemoja (Braun & Clarke, 2006). Teema muodostuu saman ilmiön kattavista merkityksistä. Teemat voivat myös tuoda esille merkityskokonaisuuksia, jotka täydentävät toisiaan ja kertovat tutkittavan aineiston kokonaiskuvasta.

Teema-analyysiä voidaan tehdä teorialähtöisesti, teoriaohjaavasti tai aineistolähtöisesti. Luonnontieteissä yleisesti käytetyssä teorialähtöisessä analyysissä olemassa oleva tutkimus ja rakennettu teoreettinen viitekehys muovaavat tutkimusprosessia vahvasti. Tällaiset analyysit tähtäävät usein olemassa olevan tiedon testaamiseen uudessa kontekstissa (Braun & Clarke, 2006). Aineistolähtöisessä teema-analyysissä taas ei nojata olemassa oleviin teoreettisiin oletuksiin, vaan teemat johdetaan materiaalista itsestään. Aineistolähtöisessä analyysissä haasteena on tutkijan oma aiempi tietopohja, aiemmat kokemukset, oletukset ja näkökulmat (Tuomi & Sarajärvi, 2018).

Näiden kahden teema-analyysin lähestymistavan välistä löytyy teoriaohjaava teema-analyysi, jossa teoria tukee ja ohjaa analyysiä määrittämättä sitä kokonaan. Tässä lähestymistavassa aiempi tutkimus ja teoreettiset näkökulmat auttavat aineiston ja teemojen strukturoinnissa ja samanaikaisesti empiiriset havainnot poimitaan aineistosta induktiivisesti (Tuomi & Sarajärvi, 2018).

Tässä tutkimuksessa aineistolähtöinen teema-analyysi on harkitsemisen arvoinen lähestymistapa, mutta tutkimuskysymys löytyy jo selkeänä ja se kiinnittyy valmiiksi teoreettiseen olemassa olevaan kirjallisuuteen ihmisen ja tekoälyn teemasta. Tämän tutkimuksen lähestymistavaksi on otettu teoriaohjaava teema-analyysi. Lähestymistapa on perusteltu, sillä tutkimusta ohjasi selkeä tutkimuskysymys, joka yhdistyi olemassa olevaan ihmisen ja tekoälyn yhteistyötä koskevaan teoreettiseen keskusteluun samalla pyrkien silti pysymään herkkänä osallistujien omille kokemuksille ja tulkinnoille.

Analyysi eteni useassa vaiheessa. Ensin haastattelumateriaalit luettiin useaan kertaan tarkoituksena kehittää yleinen ymmärrys datasta kokonaisuudessaan sekä ymmärtää tutkimuskysymyksen kannalta olennaiset lainaukset. Toiseksi koodattiin merkitysyksikköjä, jotka kuvaavat asiantuntijoiden kokemuksia suhteellisen lähellä datatasoa. Nämä alustavat koodit kuvasivat toistuvia havaintoja koskien esimerkiksi mallien roolia prosessissa tai koettuja hyötyjä tai haasteita. Kolmanneksi samankaltaiset koodit ryhmiteltiin toistuviin alateemoihin. Lopuksi nämä alateemat järjesteltiin neljän pääteeman alle. Pääteemat muodostettiin teoreettisen viitekehyksen ja tutkimuskysymyksen perusteella, kun taas alateemoja tarkennettiin haastatteluaineiston iteratiivisen käsittelyn kautta.

Tällä tavoin analyysi rakentui teoreettiselle perustalle, ohittamatta tarvittavaa herkkyyttä haastateltavien omille kertomuksille. Analyyttinen painopiste oli asiantuntijan arvisossa ja koneoppimismallin tuottaman tuodon käytössä. Taulukko 3 (alla) havainnollistaa analyysin etenemistä haastatteluotteista alkuperäisiin koodeihin, alateemoihin ja pääteemoihin.

Taulukko 3. Esimerkki analyysin etenemisestä

Esimerkki haastattelusta	Alustava koodi	Alateema	Pääteema

"Koneoppimismalli on leikkikenttä, jonka sisällä toimitaan."	Malli strukturoi päätöksentekoa	Prosessin strukturointi	Luottopäätösprosessi ja koneoppimismallin rooli
"Sitten menen malliin ja tarkistan, meneekö läpi, ja jos ei niin tarkistan miksi ei."	Oman näkemyksen vertaaminen mallin tulokseen	Vertaileva tulkinta ja uudelleenarviointi	Mallin tuottaman tiedon tulkinta ja asiantuntija-arvio
"Se vaatii vähän jumppaamista."	Tapauskohtainen tarve muokata tuloksia	Mallin käyttäminen käytännössä	Mallin tuottaman tiedon tulkinta ja asiantuntija-arvio

4.4 Laadullisen tutkimuksen luotettavuus

Shenton (2004) kirjoittaa, että laadullisen tutkimuksen tasoa mitataan luotettavuuden kautta. Se antaa vaihtoehdon määrällisille keinoille validiteetin ja reliabiliteetin vahvistamiseen. Kirjoittajan mukaan luotettavuus pohjaa neljään avainosioon: uskottavuus, siirrettävyys, riippuvuus ja vahvistettavuus. Uskottavuus viittaa siihen, kuinka tarkasti tutkimuksen tulokset kuvaavat osallistujien näkökulmia ja sitä voidaan vahvistaa esimerkiksi triangulaation ja osallistujapalautemenetelmien avulla. Siirrettävyyttä käsitellään tarjoamalla kattavia kuvauksia, jotka mahdollistavat tutkimuksen mahdollista soveltamista muihin konteksteihin. Riippuvuus korostaa tutkimuksen läpinäkyvyyttä ja vahvistettavuus keskittyy siihen, että tulokset muodostuvat aineiston, eikä tutkijan vinoumien perusteella.

Tämän tutkimuksen luotettavuutta vahvistetaan tuomalla osa-alueet avoimesti esille, esimerkiksi kertomalla analyysin etenemisestä vaihe vaiheelta. Tuloksissa esitetään

myös suoria lainauksia, korostaen tulkintojen nousevan aineistosta, eikä oletuksista. Validiteettia vahvistetaan käyttämällä vakiintuneita teoreettisia käsitteitä.

4.5 Tutkimuksen eettiset periaatteet

Tässä tutkimuksessa noudatetaan Suomen Tutkimuseettisen neuvottelukunnan keskeisiä eettisiä ohjeita (TENK, 2023). Niissä eritellään, että tutkijan on kunnioitettava tutkittavien henkilöiden ihmisarvoa ja itsemääräämisoikeutta. Tutkijan tulee myös varmistaa, ettei tutkimus vahingoita tutkimukseen osallistuvia tai heidän yhteisöjään. Ohjeiden mukaan tähän tutkimukseen osallistuvilla kerrottiin tutkimuksen tavoitteista, tietojen käsittelystä ja anonymiteetistä sekä tutkimuksen vapaaehtoisuudesta. Anonymiteetti ja luottamuksellisuus ovat tutkimuksen osalta keskiössä, sillä haastateltavat ovat asiantuntijoita kapeahkolla rahoituksen sektorilla, jolloin tunnistettavuuden riski on todellinen. Nimet ja muut tunnisteet on poistettu ja haastateltaviin viitataan numeroiduilla tunnisteilla anonymiteetin suojaamiseksi.

Tutkija on vastuussa tulkintojen rehellisyydestä. Aineistoja ei ole vääristelty tai irrotettu asiayhteydestään. Tulokset on esitetty pyrkimyksellä tasapainoon korostamatta mitään erityistä näkökulmaa. Tuloksia ei myöskään uloteta kontekstia laajemmalle ja tutkimuksen tarkoituksena on ymmärtää ilmiötä eikä arvottaa toimijoita.

5 Tutkimustulokset

Tässä kappaleessa esitetään neljän puolistrukturoidun teemahaastattelun tulokset, joissa asiantuntijoita haastateltiin koneoppimismallien käytöstä luottopäätöksissä suomalaisessa yritysrahoitusmarkkinassa. Tulokset esitetään teemoittain. Keskeisenä painopisteenä on haastateltavien kuvaukset kokemuksistaan mallien ja prosessien keskellä, miten he tulkitsevat ja käyttävät tuloksia sekä mitä hyötyjä ja haasteita he mahdollisesti kokevat.

Analyysin perusteella havaittiin neljä pääteemaa, jotka strukturoivat tämän kappaleen esittämät tulokset. Nämä teemat kehitettiin iteratiivisen prosessin avulla. Prosessissa haastatteludatan merkitykselliset huomiot koodattiin ja edelleen kategorisoitiin neljään ylätasoon temaattiseen kategoriaan. Teemat käsittelivät 1), luottopäätösprosessia ja koneoppimismallin roolia, 2) mallin tuottaman tiedon tulkintaa, 3) mallin käytön koettuja hyötyjä ja haasteita sekä 4) ihmisen ja tekoälyn yhteistyön tulevaisuutta. Tulokset esitetään tämän temaattisen rakenteen mukaisesti, ja suoria haastatteluita hyödynnetään läpi luvun havainnollistamaan, miten teemat nousivat aineistosta. Analyysin perusteella aineistosta tunnistettiin neljä pääteemaa ja niiden sisällä useita toistuvia alateemoja. Taulukko 4 (alla) kokoaa tutkimuksen pää- ja alateemat yhteen. Seuraavissa alaluvuissa kutakin pääteemaa tarkastellaan yksityiskohtaisemmin aineistoesimerkkien avulla.

Taulukko 4. Analyysin pää- ja alateemat

Teema	Alateemat
1. Luottopäätösprosessi ja koneoppimismallin rooli	1.1 Koneoppimismalli prosessia jäsentävänä kehikkona 1.2 Koneoppimismalli portinvartijana 1.3 Koneoppimismalli päätöksenteon tukena
2. Mallin tiedon tulkinta ja asiantuntijan harkinta	2.1 Oman arvion ja mallin tuloksen vertailu 2.2 Mallin tulosten uudelleenarviointi 2.3 Mallin

	käytännön soveltaminen ja muokkaaminen 2.4 Mallin ohittamisen organisatoriset rajoitteet
3.Koetut hyödyt ja haasteet	3.1 Tehokkuus ja nopeus 3.2 Johdonmukaisuus ja standardointi. 3.3 Päätösvarmuuden tukeminen. 3.4 Taloudellisen kokonaiskuvan jäsentäminen. 3.5 Kassavirran ja takaisinmaksukyvyyn arvioinnin rajoitteet. 3.6 Rahoitusrakenteen ja kontekstin huomioimisen puutteet. 3.7 Laadullisen ja ulkoisen tiedon rajallinen huomiointi. 3.8 Mallin toimintalogiikkaan liittyvä epävarmuus.
4.Ihmisen ja tekoälyn yhteistyön tulevaisuus	4.1. Automatisoinnin lisääntyminen. 4.2 Asiantuntijan roolin säilyminen monimutkaisissa tapauksissa. 4.3 Mallien kehitystarve. 4.4 Datan rikastaminen ja kontekstuaalisen herkkyyden lisääminen.

5.1 Teema 1: luottopäätösprosessi ja koneoppimismallin rooli

Haastateltavat kuvaavat koneoppimismallia keskeiseksi luottopäätöksenteon osaksi. Mallin käytännön rooli näkyy kolmena tunnistettavana roolina, jotka ovat (1) prosessia määrittävä kehikko, (2) pakollinen portti ja (3) prosessia tukeva vahvistustyökalu. Nämä kuvaukset ovat rinnakkaisia. Koneoppimismalli voi rakentaa koko päätösprosessia, mutta yksittäisen ammattilaisen työtavat ja organisaation laajempi politiikka vaikuttavat sen käyttöön olennaisesti.

Monet haastateltavat kuvaavat mallia yleisenä kehikkona, joka määrittää luottopäätöksenteon olennaisia rajoja. Mallin kuvataan standardisoivan rahoitusesitysten analyysin lähestymistapaa. Tästä näkökulmasta koneoppimismalli ei toimi vain informaatiolähteenä, vaan osana päätösinfrastruktuuria: malli määrittää mitkä muuttujat ovat relevantteja ja miten prosessin odotetaan sen perusteella jatkuvan.

Haastateltava 1 kuvasi koneoppimismallia luottopäätösprosessin punaisena lankana, mutta ei täysin rajaavana tekijänä:

« Eli jos me voidaan miettiä, että se koneoppimismalli on meille se leikkikenttä, jonka sisällä me ollaan... jossa me toimitaan. »

Samoin haastateltava 4 korosti, että malli antaa pohjan sekä kehikon päätöksenteolle ja että luottoanalyysi rakennetaan mallin läpi osana rutiiniprosessia. Tämä viitekehys korostaa näkökulmaa, jonka mukaan koneoppimismalliin nojataan organisaatiotasolla. Malli koetaan työskentelyyn sisäänrakennettuna olennaisena tekijänä.

Toinen toistuva kuvaus koskee mallia eräänlaisena porttina: jos mallin tulos on negatiivinen, ei sitä voida muuttaa. Tämä portinvartijan rooli toistui myös epäsuorasti muissa kuvauksissa. Kun mallia kuvataan organisaation päätöksenteon pohjana, prosessi edellyttää mallin mukaista linjaa, ellei sen tuloksien kyseenalaistamisille ole selkeitä perusteltavia syitä. On tärkeä huomata, etteivät haastateltavien kuvaukset vaikuta osoittavan, että portinvartijana toimiva malli tekee itsenäisiä päätöksiä. Sen sijaan kuvausten perusteella se luo hyväksyttävät päätösparametrit ja muovaa asiantuntijan tapaa rakentaa analyysiä ja perusteluita.

Toisin kuin portinvartijakehikossa, jotkut haastateltavat korostivat mallin merkitystä tukifunktiona tai päätöksenteon tukijärjestelmänä. Tässä kehikossa koneoppimismallin tuottama tieto ei toimi analyysin lähtökohtana, vaan ammattilaisen oman analyysin ja näkemyksen vahvistajana. Tällöin asiantuntija suorittaa perinteisemmän luottoanalyysin lainanhakijasta ja tämän jälkeen käyttää koneoppimismallin tuloksia strukturoituna tarkistuspisteenä. Tarkistuksessa kuvataan haettavan varmistus omalle näkemykselle ja samalla pyritään tunnistamaan oman analyysin sokeita pisteitä tai muita huomatta jääneitä muuttujia.

Haastateltava 3 kuvaili rutiinia, jolloin ensin suoritetaan itsenäinen analyysi ja sen jälkeen tarkistamaan meneekö kokonaisuus ”mallista läpi”. Tarkistuksen ohessa pyritään tunnistamaan mahdollisia epäkohtia ja palataan tarkastelemaan ja tarvittaessa herkistelemään omaa analyysiä. Tämä verifiointikehikko asettaa koneoppimismallin tasapainottavaksi toiseksi arvioksi, joka voi löytää riskejä, joita asiantuntija ei itse löydä, mutta vastuu kokonaisanalyysistä jää asiantuntijalle itselleen.

Haastateltavien kertomuksista erottui myös koneoppimismallin erilaisia soveltamistapoja luottopäätöksenteon työprosessin eri vaiheissa. Haastateltava 2 huomautti, että historiaan nojaavia tunnuslukuja ja mallin tuottamaa riskidataa voidaan tarkastella aikaisessa vaiheessa, mutta todellinen hyöty saavutetaan sen jälkeen, kun on luotu ennusteet ja lopullinen arvio on valmis. Toisaalta haastateltava 4 kuvaa koneoppimismallin olevan läsnä koko prosessin aikana, jolloin se toimii verrokkina ja päätöksenteon alkupisteenä, vaikka asiantuntijan omaa näkemystä sovelletaankin vahvasti. Kokonaisuudessaan haastatteluiden perusteella voidaan sanoa, että kokemuksiin koneoppimisen roolista vaikuttaa organisaation käytännöt (käyttöpakko tai eri raja-arvot) sekä asiantuntijan omat työtavat (muodostetaanko vahva mielipide ennen vai jälkeen mallin konsultointia).

5.2 Teema 2: Tiedon tulkinta ja asiantuntijan harkinta

Haastateltavat kuvasivat koneoppimismallien tulosten tulkitsemista suhteellisen yhteneväisesti. Yleisesti mallin tietoa ei hyväksytä sellaisenaan, vaan tietoa vertaillaan, sille haetaan selityksiä ja tarvittaessa jopa hienosäädetään. Luottopäätösprosessissa mallin arvo vaikuttaa olevan sidoksissa sen tuottaman tuloksen selitettävyyteen - varsinkin tilanteissa, joissa mallin tuottama tulos ei ole linjassa ammattilaisen arvion kanssa.

Haastatteluista nousi esiin vertaileva työote. Luottoanalyysiprosessi alkaa usein vertailemalla mallin tuloksia asiantuntijan oman näkemyksen kanssa. Kun tulos on samoilla linjoilla kuin luottopäätäjän arvio lainahankkeen rahoitettavuudesta, koetaan

mallin tulos arvion vahvistajana, ei sen tuottajana. Haastateltava 4 huomautti, että monet analyysitapaukset tuntuvat jo hyvin ennustettavilta ennen koneoppimismallin käyttövaihetta, jolloin mallin tuottama tulos voidaan tulkita vahvistukseksi näkemykselle. Haastateltava 3 taas kuvaili tätä vertailevaa analyysiprosessia suoraan:

« Käyn keissin läpi, analysoin riskit - joo tässä on järkeä ja kassavirta toimii. Sitten menen sinne koneoppimismalliin ja katson että meneekö läpi ja jos se ei sieltä mene läpi niin mulle nousee kysymykset : Miksi se ei mee läpi ja oonko mä tehnyt virheen ? Sitten palaan uudestaan katsomaan ja tarkentamaan omaa prosessia. »

Aineiston perusteella voidaan todeta, että koneoppimismallin tuottama yllättävä tulos suhteessa luottopäätäjän omaan näkemykseen aloittaa eräänlaisen diagnostiikkaprosessin. Tällaisessa tilanteessa haastateltavat kuvasivat palaavansa tapaukseen ja tutkivan löysikö koneoppimismalli jotain, mitä ihminen sivuutti, vai onko kyse esimerkiksi koneoppimismallien parametrien yli- tai alipainotuksesta ydessä muuttujassa. Yllä olevan lainauksen lisäksi haastateltava 4 kuvasi vastaavaa yllättävää tilanetta : joskus mallin riskipisteet ovat liian hyviä tai liian huonoja, jolloin hän palaa tutkimaan, mikä voisi analyysissä selittää tuloksia ja voiko algoritmi ohittaa joitain muuttujia. Huomionarvoista on, että kerrottujen kuvausten perusteella tällainen diagnostinen tarkastelu ei rajoitu ainoastaan mallin validoimiseen. Se toimii itsereflektion välineenä : tapaukseen palaaminen voi vahvistaa ammattilaisen arviota tai paljastaa siinä olevia puutteita.

Tiedon tulkinnan yhteydessä haastateltavat kuvasivat konkreettisia tapoja joilla he käsittelevät koneoppimismalleja, erityisesti monimutkaisissa tai epätyypillisissä luottoanalyysitapauksissa. Näihin tapoihin kerrottiin kuuluvan esimerkiksi oletusten säätäminen tai herkistely ja syötettävän tiedot uudelleen järjestely. Tällaisissa tilanteissa kuvattiin mallien tarvitsevan varmistusta siitä, että se tulkitsee tilanteen tarkoituksenmukaisesti – erityisesti silloin kun tilinpäätöstiedot ovat mahdollisesti harhaanjohtavia. Käytännön esimerkki tällaisesta tilanteesta on haastateltava 2 mukaan yrityskauppa, jolloin malli voi tulkita ostettavan yhtiön täysin uudeksi yhtiöksi, minkä

vuoksi sillä on haasteita tulkita tietoa. Malliin syötettävän tiedon muokkaamista haastateltava 2 kuvaa tällaisessa tilanteessa hyvin käytännönläheisesti :

« Sitä pitää vähän jumpata. »

Haastateltava 1 korosti syötettävän tilinpäätöstiedon korjaamisen tarvetta edelleen erityisesti silloin, kun tilinpäätöstiedot ovat harhaanjohtavia. Tämä kuvaa ammattitaidon käyttöä mallin ohessa tilanteessa, jolloin algoritmi näkisi valheellisesti taloudellista suorituskkyä.

Lisäksi osa haastateltavista kuvasi skenaariotyöskentelytapaa. Tällöin asiantuntija testaa miten ennuste-olettamat vaikuttavat tuloksiin, jolloin koneoppimismallin käytöstä on helpompi ymmärtää ja päätösnarratiivia on helpompi perustella. Haastateltava 4 kuvasi tätä prosessia termillä stressitesta.

Vaikka asiantuntija pystyisi selittämään miksi koneoppimismalli tuottaa mahdollisesti harhaanjohtavaa tietoa, saattaa organisaation säännöt rajoittaa tehtäviä toimia. Haastateltava 2 ilmaisi tämän tilanteen suoraan. Jos malli sanoo ei, kohde ei ole rahoituskelpoinen. Tässä näkyy tärkeä erotus mallin tuottaman tuloksen ymmärtämisen ja sen ohittamisen mahdollisuuden välillä. Yleisesti ottaen haastateltavat kuvaavat koneoppimismallin tuottamaa tulosta lähtökohtana merkityksien rakentamisen prosessille, eivät valmiina, lopullisina vastauksina.

5.3 Teema 3: hyödyt, haasteet ja rajoitteet

Haastatteluiden läpi voidaan havaita hyötyjen keskittyvän neljän keskeisen kuvattun hyödyn ympärille: (1) seulonnan ja analyysin nopeus ja tehokkuus, (2) standardisoidumpi ja johdonmukaisempi päätöksentekotyöskentely, (3) luottamus omaan luottopäätökseen ja (4) selkeämpi kokonaiskuva taloudellisesta tilanteesta tiivistettyjen tunnuslukujen ja vertaisarvioiden kautta. Haastatteluista ei rakennu kuva koneoppimismallista, joka korvaa ihmisen, vaan työoloja parantavana toimijana, joka

nopeuttaa prosessia, tekee siitä toistettavamman ja päätöksistä helpommin perusteltavia.

Haastatteluissa nousi toistuvasti esiin maininta siitä, että koneoppimismallin käyttö nopeuttaa tapauksien aikaisen vaiheen ymmärtämistä ja erityisesti vähentää alustavan näkemyksen muodostumiseen vaadittavaa manuaalista työtä. Haastateltavat kuvailivat mallin nopeuttavan alustavaa tapauksien seulontaprosessia ja auttavan tunnuslukujen saatavuudessa. Tämä tukee laajalti priorisointia, eli sitä mitä tapauksia edistetään ja mitkä hylätään jo alkuvaiheessa. Haastateltava 4 kuvasi nopeuden olevan koneoppimismallin käytön keskeinen syy, sillä hänen mukaansa sen avulla voidaan nopeasti luoda kuva tapauksen edistettävyydestä jo alkuvaiheessa:

« No ehkä se on se nopeus ja tehokkuus... Tietyillä luvuilla saadaan aika nopeasti semmoinen käsitys, että kannattaako sitä hanketta edistää vai ei... se ei vaadi kaikkea syvällisempää osaamista, kun voi syöttää tiedot (malliin) niin näkee heti että mitä se on. «

Tämän kuvauksen perusteella rakentuu kuva toiminnallisesta (ajan säästyminen) ja koko organisaation (aikaisen seulonnan tukeminen) tasoista hyödyistä.

Monet haastateltavat yhdistivät koneoppimismallin käytön lisääntyvään johdonmukaisuuteen. Vaikka asiantuntijalla on vastuu arviosta, mallin nähtiin stabiloivan päätöstyötä tarjoamalla toistettavan analyttisen peruslinjan. Tätä kuvattiin prosessin teollistumisella ja subjektiivisten arvioiden aiheuttaman vaihtelun vähentymisellä. Haastateltava 1 artikuloi tätä ideaa laajemman analogian kautta, kuvaten mallia järjestelmänä, joka tuottaa ennalta määritetyistä syötteistä johdonmukaisen peruslinjan tulokselle:

« Luottopäätöslaatu on tasalaatuista, teityllä tapaa siitä häviää analyttikon otsalohkon käyttö ja silloin se on puhtaan matemaattinen tulos.. Se on kuin kahvinkeitin : sä syötät sinne tietyt materiaalit ja jotain tulee ulos. Se voi olla liian vahvaa, jos analyttikko näkee kriittisemmin, tai sitten jos ei ole ymmärrystä tai

työskentelee liian nopeasti siitä tulee laimeeta... Mutta lopputuloksena on aina sama kahvi. «

Tässä mallin etuna ei vaikuta olevan virheettömyys, vaan se, että se tuottaa yhtenäisen tuotantologiikan: tulokset ovat vähemmän riippuvaisia yksilöllisistä vaihteluista ja ankkuroituvat selkeämmin yhteiseen peruslinjaukseen.

Kolmas huomattava etu koskee päätöksenteon viimeistelyä. Kun koneoppimismallin tuottama tulos on linjassa ammattilaisen oman arvion kanssa, se voi vähentää epävarmuutta ja auttaa viemään päätöksenteon maaliin. Näin ammattilaisen on helpompaa sitoutua näkemykseen ja liikkua eteenpäin ilman jatkuvaa tunnetta siitä, että jotain on nyt jäänyt huomaamatta. Haastateltava 3 kuvasi tätä toista kautta: mallin kuvattiin helpottavan tapauksesta irti päästämistä silloin kun molemmat analyysit osoittavat samaan suuntaan, sillä malli vähentää tunnetta siitä, että lisää tutkimusta pitäisi vielä tehdä. Myös haastateltava 4 kuvasi samansuuntaisesti koneoppimismallia pohjan ja selvyiden tuottajana – erityisesti silloin kun on mahdollista testata erilaisia skenaarioita – jolloin päättäjä voi perustella päätöstään vakaan peruslinjauksen kautta.

Viimeisenä haastateltavat kuvasivat mallin tuottavan helposti saavutettavan yleisnäkymän yhtiön talouteen kokoamalla keskeisiä tunnuslukuja, trendejä ja verrokkeja yhteen näkymään. Tämä nähtiin erityisen hyödyllisenä varsinkin vertaillessa tunnuslukujen poimimiseen ja laskemiseen manuaalisesti suoraan tilinpäätöstiedoista. Haastateltava 2 korosti, että malli tarjoaa verokkikontekstia ja kokoaa avaintiedot nopeasti yhteen. Hänen mukaansa tämä tekee merkittävästi asiantuntijaa näkemään mikä vaatii tarkempaa tarkastelua. Tästä näkökulmasta koneoppimismalli tukee asiantuntijan työtä strukturoimalla tietoa ja tekee yhtiön taloudellisen tiedon ensitarkastelusta nopeampaa ja systemaattisempaa.

Kokonaisuutena haastattelijat kuvasivat hyötyjä pragmaattisiksi ja prosessikeskeisiksi. Koneoppimismalli nähdään parantavat tehokkuutta, tukevan johdonmukaista päätöstyötä, vahvistavan luottamusta lopulliseen päätökseen ja tarjoavan strukturoidun

taloustietojen yleisnäkymän sekä verrokkiarvion. Tässä kehyksessä hyödyt eivät vaikuta poistavan asiantuntijuuden tarvetta. Sen sijaan hyödyt kuvaavat mallia asiantuntijan ”parantajana”, joka nopeuttaa työtä, tekee siitä toistettavampaa ja helpompaa jokapäiväisessä päätöksenteossa.

Haasteiden osalta haastateltavat eivät niinkään kuvanneet yksittäisiä mallin ongemia, vaan enemmänkin toistuvia eroja sen välillä, mitä malli on suunniteltu luotettavasti mittaamaan ja sen välillä, mitä asiantuntijat pitivät käytännössä ratkaisevana takaisinmaksukyvyyn ja kokonaisriskin arvioinnissa. Läpi haastatteluiden haasteet vaikuttivat keskittyvän neljän pääalueen ympärille: kassavirran dynamiikka, puuttuva rahoituskonteksti, laadulliset ja ulkoiset tekijät sekä mallin logiikan ja datan käyttäytymisen koettu epävarmuus.

Keskeinen rajoite koskee kassavirtoja ja sitä, miten koneoppimismalli ymmärtää kassavirran kokonaisuudessaan suhteessa takaisinmaksukykyyn. Haastateltava 4 kuvasi tilanteita, joissa koneoppimismallin tuottama tulos on ylioptimistinen sen keskittyessä kannattavuuden mittareihin samalla ohittaen investointien tarpeita ja käyttöpääoman muutosta, erityisesti kasvuyhtiökontekstissa. Samansuuntaisesti haastateltava 2 huomautti, että kassavirtalaskelmat eivät ole mallissa täysin tuettuna, jolloin keskeistä arviointia tulee suorittaa mallin ulkopuolisessa ympäristössä. Tällaisilla haasteilla on merkitystä, sillä haastatteluiden perusteella on löydettävissä käytännön kaava: asiantuntija voi hyväksyä koneoppimismallin tuloksen aloitussignaalina, mutta tulosta ei käsitellä riittävänä näyttönä demonstroidusta takaisinmaksukyvyistä ilman tarkempaa kassavirran arviointia.

Toinen haaste liittyy kokemukseen mallin kyvyttömyydestä huomioida konteksti tai rakennettavan rahoituskokonaisuuden vaikutukset. Haastateltava 3 korosti, että luottoriskin kannalta on olennaista kuinka pitkältä rahoituksesta puhutaan, ja onko käytettävissä vakuuksia. Tästä huolimatta kuvattiin, että koneoppimismalli ei huomioi näitä tekijöitä riskimallinnuksessa. Käytännössä tämä näkökulma kertoo eroavaisuudesta

koneoppimismallin tuottaman ”yleisen” riskiarvion ja luottopäättäjän kohtaaman rahoituskokonaisuuden välillä. Luottopäättäjän näkökulmasta tätä eroa yleisen riskiarvion ja yksittäisen rahoitustapauksen arvioinnin välillä kuvasi haastateltava 4 hyvin selkeästi:

« Ei kyse ole siitä, onko firma riskinen, vaan onko tämä rahoitus riskinen tällä aikahorisontilla. »

Sitaatti havainnollistaa, että asiantuntijan näkökulmasta mallin tuottama yleinen riskiarvio ei yksin riitä, vaan arviointi sidotaan rahoituksen rakenteeseen, aikajänteeseen ja tapauskohtaiseen kokonaisuuteen.

Kolmantena selkeänä haasteena haastateltavat kuvasivat tekijöitä, jotka eivät näy syöttödatassa, eli tilinpäätöstiedoissa. Tällaisista tilanteista esimerkeiksi nousivat yrityksen johdon tai avainhenkilöiden muutostilanteet ja laajempien ulkoiset muuttujien kuten geopoliittisen tilanteen tai toimialan muutokset. Haastateltava 4 korosti juuri sitä, että informaatio ei näy mallin lopputuloksessa silloinkaan, kun se olisi tapauksen kannalta kriittistä. Samansuuntaisesti haastateltava 3 kertoi, että koneoppimismallin määrällistä lähestymistapaa on välttämätöntä täydentää laadullisella asiantuntijan tekemällä arviolla. Tämä rajoite on selkeästi kytköksissä haastattelijoiden kuvaaman ihmisen ammattitaidon tärkeyteen: he kuvasivat mallin olevan arvokas työkalu määrällisen analyysin tekemiseen, kun taas laadullinen ja kontekstuaalinen luotettava arviointi jää koneoppimismallin kykyjen ulottumattomiin.

Viimeisenä useat haastateltavat löysivät rajoitteita koneoppimismallin tuloksien luotettavuuteen ja tulkittavuuteen erityisesti epävarmuuden kautta. Epävarmuutta koettiin olevan siinä, mitkä muuttujat vaikuttavat mallin päätöksiin, miten usein mallia päivitetään, osaako se havainnoida trendejä vai staattisia tilannekuvia ja ovatko mallin tulokset tasaisesti linjassa verrokkitapauksissa. Haastateltava 3 kuvasi olevansa epävarma mallin sisäisestä logiikasta:

« Yksi syy miksi se on hankalaa on se, että mä en tiedä tarkalleen miten se toimii... Mä en ole saanut siihen kunnon vastausta, että miten se ottaa huomioon sen (yhtiön) kehityksen siinä lopullisessa konkurssiriskissä. »

Samoin haastateltava 4 nosti esiin kysymyksiä koneoppimismallin parametreista ja päivityskäytännöistä, erityisesti tilanteissa, joissa operatiivinen ympäristö muuttuu ja historiallinen data ei ehkä enää kuvasta nykyistä tilannetta. Haastateltava 2 lisäsi vielä käytännön huolen liittyen datan tuoreuteen ja miten koneoppimismalli tulkitsee tiettyjä erityistilanteita, jotka voivat vaikuttaa tuloksen koettuun luotettavuuteen.

Kokonaisuutena haastateltavien kokemat haasteet ja rajoitteet sijoittuvat alueille, joilla koneoppimismallin tulos ei ole linjassa ammattilaisen analyysikontekstin kanssa: kassavirtadynamiikka (mm. investoinnit ja käyttöpääoma), rahoitusrakenne (maturiteetti ja vakuuskokonaisuus), laadullinen ja ulkoinen informaatio sekä mallin toimintalogiikkaan liittyvät epävarmuudet ja päivitykset. Mallin käyttämisen hylkäämisen sijaan näiden rajoitteiden kuvattiin vaikuttavan siihen, miten asiantuntijat tukeutuvat mallin tuottamaan tietoon: milloin sitä pidetään vajavaisena ja milloin ihmisen arviota ja analyysiä tarvitaan.

5.4 Teema 4: tulevaisuus ja ihmisen ja tekoälyn yhteistyö

Haastateltavista jokainen kertoi, että heidän arvionsa mukaan koneoppimismallien rooli tulee kasvamaan, mutta näkemykset olivat erilaisia siitä miten se tulee kasvamaan. Useimmin mainittu kehityssuunta oli automaation kasvaminen standardisoiduissa pienemmissä yrityslainatapauksissa. Monimutkaisempien rahoituskokonaisuuksien osalta taas odotettiin, että ihmisen tulee edelleen olla mukana prosessissa, erityisesti laadullisen ja kontekstuaalisen analyysin osalta.

Useat haastateltavat mainitsivat todennäköisen siirtymän kohti automatisoidumpaa päätöksentekoa yritysrahoituksen ”pienessä päässä”. Haastateltava 4 kuvasi suoraan, miten kehitys tulee jatkumaan:

« No kyllä mä luulen, että tuossa pienessä päässä voi mennä aika automatisoituun... Syötät tiedot ja sitten sieltä tulee se päätös. Isommassa päässä se vaatii aina jonkun ihmisen käsittelemään. »

Haastateltava 2 jatkoi samansuuntaisesti tulevaisuudesta, jossa järjestelmä voisi tuottaa suurempia luottopäätösehdotuksia pienissä rahoituksissa. Tällöin asiantuntijalle jäisi enemmän aikaa keskittyä monimutkaisempiin ja merkitykseltään suurempiin rahoituksiin.

Automaation lisäksi haastateltavat kuvasivat tulevaisuuden luottopäätäjän roolin muuttuvan valvovampaan rooliin. Kuvauksissa asiantuntija valvoo koneoppimismallin tukemaa päätösprosessia, käsittelee poikkeuksia ja keskittyy tapauksiin, jotka vaativat tarkempaa arviointia. Haastateltava 1 kuvasi tätä evoluutiona, jossa koneoppimismallista tulee progressiivisesti kyvykkäämpi ja asiantuntijan työ muuttuu työpaikan katoamisen sijaan. Samoin haastateltava 4 korosti, että vaikka koneoppimismallit kehittyvät, ihmisen tietotaitoa ja arviointia tarvitaan, sillä mallit eivät kokoakaan kaikkea relevanttia tietoa monimutkaisissa rahoituskokonaisuuksissa.

Haastateltavat toivat myös esille konkreettisia kehitysehdotuksia koneoppimismalliin pohjaamalle luottopäätöksenteolle. Yksi toistuva ehdotus oli rahoituspäätöksen kokonaisvaltaisempi kontekstualisoiminen – erityisesti silloin, kun mallin arvio on linjassa relevantin aikajänteen ja rahoitusrakenteen kanssa. Haastateltava 3 korosti, miten tärkeää olisi saada tekijöitä, kuten lainan maturiteetti koneoppimismallin riskipisteetyksessä huomioitavien muuttujien joukkoon. Toinen kuvattu kehityskohde oli koneoppimismallin muokattavuus ja päivityskäytännöt. Haastateltava 4 korosti miten tärkeää olisi mahdollisuus koneoppimismallien muokkaamiseen silloin, kun olosuhteet muuttuvat, eikä tällöin tarvitsisi nojata vuosia staattiseen malliin ilman merkityksellisiä muutoksia.

Viimeisenä haastateltavat kuvasivat kehityskulkua, jossa koneoppimismalleille syötettävä tieto rikastuu perinteisten tilinpäätöstietojen tuolle puolen. Erityisesti

kuvattiin suuntaa, jossa mallit ottaisivat huomioon rakenteellisia tai laadullisia elementtejä, joita asiantuntijat jo tarkastelevat käytännössä. Haastateltava 3 kuvasi tällaista tulevaisuuden mallia konkreettisesti seuraavasti :

« Ettei se ole semmoinen, että rakennetaan malli ja se on se seuraavat viisi vuotta. Kun huomataan toistuva kaava, vaikka tietyssä kohdejoukossa paljon enemmän maksuhäiriöitä, kun saadaan selvitettyä mistä se johtuu, niin malliin pystytään tekemään muutoksia ja ottaa nuo (kuviot) huomioon. «

Kokonaisuutena haastateltavat kuvasivat tulevaisuutta, jossa koneoppimismallit tekevät luottopäätösprosessista rutiininomaisempaa, kun taas asiantuntijatyö siirtyy kohti monimutkaisia kokonaisuuksia, poikkeusten käsittelyä ja valvontaa. Kehitysehdotukset käsittelevät mallien ja päätöskontekstin (mm. rahoituksen rakenne) yhteensovittamista, mallien muokattavuutta ja päivitysmahdollisuuksia olosuhteiden muuttuessa sekä mallin yleistä laajentamista, jolloin se voisi ottaa huomioon tekijöitä, jotka ovat asiantuntijan pohdinnan keskiössä.

Seuraavassa kappaleessa siirrytään näiden tuloksien raportoinnista keskustelemaan siitä, mitä tulokset tarkoittavat suhteessa tutkimuksen tutkimuskysymyksiin ja laajempaan kirjallisuuteen koskien ihmisen ja tekoälyn yhteistyötä sekä koneoppimismallien tukemaa päätöksentekoa.

6 Pohdinta

Tässä luvussa keskustellaan, mitä tutkimustulokset kertovat suhteessa aiempaan tutkimukseen ja aiemmin esitettyyn teoreettiseen viitekehykseen. Keskustelun tarkoituksena on tulkita pääasiallisia löydöksiä ja niiden vaikutuksia olemassa olevaan koneoppimismallien ja asiantuntijan päätöksenteon tutkimukseen. Ensiksi löytöjä tulkitaan aikaisemman algoritmin tukeman päätöksenteon ja tekoälyn ja ihmisen yhteistyön teoriakirjallisuuden kautta. Tämän jälkeen käsitellään tutkimuksen tieteellistä kontribuutiota ja käytännön vaikutuksia. Lopuksi käsitellään tutkimuksen rajoituksia ja esitetään ehdotukset tulevaisuuden tutkimukselle.

6.1 Havainnot

Tässä tutkimuksessa tarkasteltiin, miten luottopäätökseen osallistuvat asiantuntijat kokevat koneoppimismallin käyttöä suomalaisessa yritysrahoituksessa. Erityisesti tutkimuksessa pyrittiin ymmärtämään, millaisena asiantuntijat kokevat mallien käytön työssään ja miten mallien tuottama tieto vaikuttaa heidän arvioihinsa ja päätöksenteon prosessiin. Löydöksen perusteella voidaan sanoa, että koneoppimismallit ovat vakiinnuttaneet asemaansa osana luottokelpoisuuden arviointia. Koneoppimismallit vaikuttavat muokkaavaan asiantuntijatyötä ja ne eivät ole korvannut asiantuntijaa kokonaan. Löydökset korostavat asiantuntijoiden tulkitsevaa roolia suhteessa mallin tuottamaan tietoon. Näitä tuloksia voidaan ymmärtää vertaamalla niitä aiempaan ihmisen ja tekoälyn yhteistyötä ja koneoppimismallien tukeman päätöksentekoa käsittelevään tutkimukseen.

Tutkimuksen keskeinen havainto on se, että asiantuntijat eivät pidä koneoppimismallin tuloksia lopullisina päätösinä, vaan sen sijaan he tulkitsevat niitä suhteessa tapauskohtaisiin rahoituskonteksteihin. Haastatellut asiantuntijat kuvasivat arvioivansa mallin riskiarvion uskottavuutta, huomioivansa muuta taloudellista informaatiota ja sekä sitä, miten hyvin mallin tulos kuvaa kyseisen rahoitustapauksen ominaispiirteitä. Tässä mielessä mallin tuottama tieto näyttää toimivan ensisijaisesti lähtökohtana

lisätulkinnalle, ei lopullisena arviona. Tämä löydös on linjassa aiemman ihmisen ja tekoälyn yhteistyötä käsittelevän tutkimuskirjallisuuden kanssa. Aiempi tutkimus korostaa, että algoritmiset järjestelmät toimivat usein päätöksenteon tukivälineinä, joiden tulokset tarvitsevat ihmisen tulkintaa ja kontekstuaalista arviointia (Dellermann et al., 2019; Jarrahi, 2018). Näin ollen tulokset tukevat näkemystä, jossa ihmisasiantuntemuksen rooli on yhä keskeinen osa arviointiprosessia, kun toimitaan monimutkaisissa päätöksenteon ympäristöissä.

Tutkimuksen tulokset viittaavat lisäksi siihen, että koneoppimismallit toimivat luottopäätöksissä pääosin analyttisinä tukityökaluina. Asiantuntijat kertoivat käyttävänsä päätöksissä mallin tuloksia erityisesti aikaisen vaiheen seulonnassa ja vertailukohtana. Tämä viittaa siihen, että mallit auttavat arviointiprosessin strukturoinnissa ja toimivat systemaattisena riskin indikaattorina. Nämäkin havainnot ovat linjassa aikaisemman tutkimuksen kanssa, joka on korostanut, että algoritmitejä integroidaan usein osaksi organisaatioiden päätöksentekoprosesseihin enemmänkin ihmistä avustaviksi työkaluiksi - ei autonomisiksi päätöksentekijöiksi, jotka korvaisivat ihmisen (Baesens et al., 2003; Lessmann et al., 2015). Näin ollen tutkimuksen tulokset vahvistavat käsitystä, jonka mukaan koneoppimismallien luoma arvo ei ole yksin niiden tuoma ennustetarkkuus, vaan arvoa luo myös niiden kyky toimia analyysityön tukijana ja strukturoijana.

Samanaikaisesti tulokset paljastavat tärkeän erin koneoppimismallin ja ihmisen tekemän laajemman arvion välillä. Algoritmeihin perustuvat mallit arvioivat riskejä saatavilla olevan tiedon perusteella, kun taas ihminen arvioi spesifiä rahoitusjärjestelyä suhteessa yksittäiseen organisaatioon ja taloudelliseen kontekstiin. Tämän tuloksena asiantuntijat huomioivat usein tekijöitä, jotka ovat mallien ulottumattomissa. Tällaisia tekijöitä ovat esimerkiksi rahoituksen rakenne, kassavirtaennusteet, vakuudet tai yrityksen tilanteeseen liittyvät laajemmat laadulliset tekijät. Tämä huomio osoittaa mahdollisen kuilun algoritmisen riskiarvion ja kontekstuaalisen päätöksenteon välillä. Aikaisempi tutkimus on osoittanut, että kontekstuaalinen tietoa on relevanttia päätöksenteon

kannalta (Jarrahi, 2018). Tämän tutkimuksen löydökset antavat tälle algoritmille empiiristä tukea kuvaamalla, miten asiantuntijat täydentävät mallien arvioita laadullisella informaatiolla.

Tutkimus tuo esiin myös tärkeän havainnon, joka liittyy asiantuntijoiden luottamukseen mallien tuottamaan tietoon. Tulokset viittaavat siihen, että asiantuntijat kokevat mallit käytännöllisiksi analyysiä avustaviksi työkaluiksi, erityisesti suhteellisen tavanomaisissa tapauksissa, jolloin riittävää historiatietoa on saatavilla. Mallien tuottamaan tietoon nojautumisen taso näyttää kuitenkin vaihtelevan riippuen rahoitustapauksen monimutkaisuudesta ja kontekstuaalisen tiedon saatavuudesta riippuen. Tästä näkökulmasta vaikuttaa siltä, että asiantuntijat kalibroivat luottamustaan algoritmituloksiin tapauskohtaisesti, eivätkä yhdenmukaisesti luota niihin jokaisessa tapauksessa. Tällainen luottamuksen vaihtelu on todettu aikaisemmassa tutkimuksessa keskeiseksi osaksi tehokasta ihmisen ja tekoälyn yhteistyötä, jossa ihminen luottaa valikoiden mallin suosituksen ja on samalla vastuussa kriittisestä arvioinnista (Dellermann et al., 2019).

Kokonaisuutena tutkimustulokset tukevat näkemystä, jonka mukaan algoritmien tukemaa luottopäätöstä kannattaa tarkastella sosioteknisenä prosessina, jossa ihmisen asiantuntijuus ja algoritmin analyysi toimivat yhdessä. Koneoppimismallit tuottavat strukturoitua analyyttisiä näkemyksiä, jotka tukevat riskien arviointia, mutta niiden tulokset vaativat ihmisen tulkintaa ja kontekstualisointia. Seuraavassa osiossa keskustellaan tarkemmin tutkimuksen tieteellisestä kontribuutiosta ja käytännön havainnoista.

6.2 Tutkimuksen kontribuutio

Tämä tutkimus täydentää algoritmien tukemaa päätöksentekoa käsittelevää kirjallisuutta tarkastelemalla, miten asiantuntijat kokevat koneoppimismallien käytön luottopäätöksenteossa suomalaisessa kontekstissa. Aikaisempi tutkimus on laajasti tarkastellut luottoluokitusmallien ennustekyvyyksiä ja koneoppimismallien

kehittymistä rahoituksen riskiarvioinnissa (Baesens et al. 2003; Lessmann et al., 2015; Dastile et al. 2020). Sitä, miten mallit tuodaan osaksi jokapäiväisiä päätöksentekoprosesseja ja miten asiantuntijat niitä tulkitsevat, on taas tutkittu vähemmän. Keskittymällä asiantuntijoiden kokemuksiin, tämä tutkimus antaa empiirisiä havaintoja ihmisen asiantuntijuuden ja koneoppimismallien yhteistoiminnasta oikeassa päätöksenteon kontekstissa.

Ensiksi tutkimus täydentää ihmisen ja tekoälyn yhteistyötä koskevaa kirjallisuutta korostamalla asiantuntijoiden tulkinnallista roolia algoritmien tukiessa päätöksentekoa. Aikaisemman tutkimuksen mukaan silloin, kun päätöksillä on taloudellista merkitystä, on ihmisen rooli tärkeässä osassa, vaikka algoritmi tukee prosessia (Dellermann et al., 2019; Jarrahi, 2018). Tämän tutkimuksen havainnot tukevat tätä näkökulmaa, mutta kertovat myös tarkemmin siitä, miten tämä ihmisen osallistuminen ilmenee käytännössä. Sen sijaan, että asiantuntijat vain validoivat tai hylkäävät mallien tuloksia, he tulkitsevat mallien tuloksia tapauskohtaisesti tai osana laajempaa kokonaisuutta. Näin ollen ihmisen rooli ei ole toimia tekoälyn valvojana, vaan ennemminkin sen tuoman tiedon tulkitsijana.

Toiseksi tutkimus syventää ymmärrystä algoritmista päätöksenteon tukijärjestelmistä rahoitusalan kontekstissa. Aikaisemman tutkimuksen mukaan algoritmituokaluut voivat tukea päätöksentekoa tarjoamalla systemaattista ja tietopohjaista riskiarviointia (Baesens et al., 2003; Lessmann et al., 2015). Tämän tutkimuksen havainnot vahvistavat tätä näkemystä, sillä asiantuntijat kuvasivat käyttävänsä malleja luottoriskiarvioinnin aikaisessa vaiheessa sekä referenssipisteenä. Samanaikaisesti havainnot vihjaavat, että mallien tuloksen hyödyllisyys riippuu siitä, miten hyvin ne sopivat tapauskohtaisiin asiayhteyksiin. Asiantuntijat tukevat mallien arvioita kontekstuaalisella ja laadullisella tiedolla perustuen heidän kokemukseensa. Tämä havainto on linjassa aikaisemman tutkimuksen kanssa, jonka mukaan algoritmeilla voi olla vaikeuksia hahmottaa kontekstuaalista, mutta relevanttia dataa (Jarrahi, 2018). Samanaikaisesti havaintojen perusteella voidaan sanoa, että koneoppimismallien käyttöönotto ei heti korvaa ihmistä,

vaan muovaa ammattilaisen työtä korostamalla tulkintaa ja useamman tietolähteen yhteensovittamista.

Teoreettisten kontribuutioiden lisäksi tutkimuksen perusteella voidaan löytää käytännön hyötyjä koneoppimismalleja hyödyntäville rahoittajille. Havaintojen perusteella mallien käyttöönoton tehokkuuteen vaikuttaa selkeästi se, miten ne integroidaan osaksi organisaation päätöksentekorakenteita. Organisaatiot voivat hyötyä asiantuntijan tulkinnan merkityksen tunnistamisesta ja erityisesti siitä, että päätöksenteon raamit mahdollistavat ammattilaisen suorittaman algoritmituloksen kriittisen arvioinnin. Selkeät prosessit mallien tulosten tarkastelemiseen ja lisätiedon huomioimiseen voivat parantaa algoritmien tukeman päätöksenteon kokonaislaatua. Lisäksi tilanteet, joissa mallin tuottama tulos ei vastaa rahoitustapauksen erityispiirteitä, olisi hyvä nostaa esiin.

Kokonaisuudessaan tutkimus korostaa, että koneoppimismallien arvo luottopäätöksissä ei perustu niiden pelkkään analyysikykyyn, vaan sen vuorovaikutukseen ihmisen asiantuntemuksen kanssa. Tämän perusteella on kriittistä ymmärtää kuvattua vuorovaikutusta silloin, kun halutaan kehittää ja implementoida tehokkaita algoritmien tukemia päätösjärjestelmiä.

6.3 Rajaukset ja ehdotukset

Vaikka tämä tutkimus tuotti hyödyllisiä havaintoja, tulosten tulkinnassa on huomioitava useita rajoitteita. Rajoitteet liittyvät empiirisen aineiston laajuuteen, tutkimuksen rakenteeseen ja tutkimuksen spesifiin kontekstiin.

Tutkimus perustuu suhteellisen rajalliselle ja pienelle laadulliselle otannalle, joka koostuu neljästä haastattelusta. Haastattelujen lukumäärää voidaan katsoa täyttävän laadullisen tutkimuksen käytännön vaatimukset, mutta pieni otos rajaa sitä, missä määrin tuloksia voidaan soveltaa sovelletun kontekstin ulkopuolelle. Tutkimuksen tarkoitus ei ollut tilastotieteellinen yleistys, vaan tarjota syvempää ymmärrystä kokemuksellisesta tiedosta. Tästä huolimatta jatkotutkimukset voisivat laajentaa

empiiristä perustaa huomioimalla suuremman määrän organisaatioita tai laajemman joukon rooleja, jotka ovat mukana luottopäätöksissä.

Toiseksi tutkimus keskittyy erityisesti suomalaiseen yritysrahoitukseen, jossa jo sovelletaan hyvinkin keskeisesti koneoppimista. Tätä kontekstia värittävät organisaation omat käytännöt, sääntelyolosuhteet ja riskikäytännöt, jotka voivat poiketa laajemmasta rahoitusalan ympäristöstä. Näin ollen tutkimustuloksia tulisi tulkita tämän spesifin kontekstin kannalta. Jatkotutkimukset voisivat tarkastella, onko samanlaisia tekoälyn ja ihmisen yhteistyön kaavoja havaittavissa muissa rahoitusalan konteksteissa, kuten henkilöasiakasrahoituksessa tai kansainvälisillä markkinoilla.

Tutkimus keskittyi asiantuntijoiden kokemuksiin ja tulkintoihin. Tämä on linjassa tutkimuksen painopisteen kanssa, mutta tarkoittaa, ettei tutkimus arvioi mallien tuloksien vaikutusta rahoituspäätösten onnistumiseen eikä sitä, miten asiantuntija ja mallin ennusteet toimivat yhdessä mitattavalla tavalla. Tuleva tutkimus voisi yhdistää laadullisia ja määrällisiä menetelmiä sekä tarkastella, miten koneoppimismallien tulokset ja asiantuntija-arviot vastaavat toisiaan käytännössä ja sen vaikutusta tuloksiin.

On tärkeää huomata, että koneoppimismallien ja laajemman tekoälyn kehitys voi tulevaisuudessa muuttaa myös tässä tutkimuksessa tehtyjä tulkintoja. Erityisesti laajojen kielimallien ja muiden tekoälysovellusten kehittyminen voi olennaisesti lisätä järjestelmien kykyä käsitellä monipuolisempaa ja kontekstisidonnaisempaa tietoa. Tässä tutkimuksessa ei kuitenkaan arvioida tällaisten teknologioiden tosiasiallista suorituskkyä yritysrahoituksen päätöksenteossa, joten niiden mahdollisesta vaikutuksesta voidaan tehdä vain varovaisia arvioita. Tuleva tutkimus voisi tarkastella, miten kehittyvät tekoälyratkaisut vaikuttavat asiantuntijaharkintaan, työnjakoon ja vastuun muodostumiseen luottopäätöksissä.

6.4 Lopuksi

Tämän tutkimuksen tarkoituksena oli tarkastella luottopäätöksiin osallistuvien ammattilaisten kokemuksia koneoppimismallien kanssa työskentelemisestä suomalaisessa yritysrahoituksessa. Tuloksien perusteella koneoppimismalleista on tullut vakiintunut osa luottokelpoisuuden arviointiprosessia, mutta ihmisen asiantuntemusta ne eivät korvaa. Mallien rooli on tukea ja strukturoida arviointiprosessia lopullisen arvioinnin ollessa kuitenkin riippuvainen ihmisen tulkinnasta.

Tutkimuksen keskeinen havainto on, että asiantuntijat toimivat ennen kaikkea koneoppimismallin tuottaman tiedon tulkitsijoina. Käytännössä luottopäätöksiä ei tehdä aina täysin mallien tuloksien tai ihmisarvion perusteella, vaan niitä yhdistelemällä. Koneoppimismallit tuottavat riskiperusteista dataa ja asiantuntijat arvioivat tietoa suhteessa yksittäiseen rahoitukseen ja täydentävät sitä laadullisella ja kontekstuaalisella harkinnalla.

Koneoppimismallien luoma lisäarvo ei ole vain niiden tekninen suorituskyky – lisäarvoa luovat tavat, joilla niitä hyödynnetään osana asiantuntijan työtä. Tällaisten mallien käytön lisääntyessä rahoitusmarkkinoilla, algoritmipohjaisen analyysin ja ihmisarvion välisen suhteen ymmärtäminen on keskeistä sekä teoreettisesta että käytännön liiketoiminnallisesta näkökulmasta.

Lähteet

- Ayari, H., Guetari, R., & Kraïem, N. (2025). Machine learning powered financial credit scoring: a systematic literature review. *Artificial Intelligence Review*, *59*, 13. <https://doi.org/10.1007/s10462-025-11416-2>
- Baesens, B., Van Gestel, T., Viaene, S., Stepanova, M., Suykens, J., & Vanthienen, J. (2003). Benchmarking state-of-the-art classification algorithms for credit scoring. *Journal of the Operational Research Society*, *54*(6), 627–635. <https://doi.org/10.1057/palgrave.jors.2601545>
- Bailey, S., Pierides, D., Brisley, A., Weisshaar, C., & Blakeman, T. (2020). Dismembering organisation: The coordination of algorithmic work in healthcare. *Current Sociology*, *68*(4), 546-571
- Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, *3*(2), 77–101. <https://doi.org/10.1191/1478088706qp063oa>
- Burrell, J. (2016). How the machine “thinks”: Understanding opacity in machine learning algorithms. *Big Data & Society*, *3*(1). <https://doi.org/10.1177/2053951715622512>
- Creswell, J. W., Poth, C. N. (2018). *Qualitative inquiry and research design: Choosing among five approaches* (4th ed.). SAGE Publications.
- Dastile, X., Çelik, T., & Potsane, M. (2020). Statistical and machine learning models in credit scoring: A systematic literature survey. *Applied Soft Computing*, *91*, 106263. <https://doi.org/10.1016/j.asoc.2020.106263>
- Dellermann, D., Lipusch, N., Ebel, P., & Leimeister, J. M. (2019). Design principles for a hybrid intelligence decision support system for business model validation. *Electronic Markets*, *31*, 575–596. <https://doi.org/10.1007/s12525-018-0309-2>
- Guest, G., Namey, E., & Mitchell, M. (2012). Collecting and analyzing qualitative data at scale. *Field Methods*, *24*(1), 3–34. <https://doi.org/10.1177/1525822X11430876>
- Gomez, C., Cho, S. M., Ke, S., Huang, C.-M., & Unberath, M. (2024). Human-AI collaboration is not very collaborative yet: A taxonomy of interaction patterns in

- AI-assisted decision making from a systematic review. *Frontiers in Computer Science*, 6, Article 1521066. <https://doi.org/10.3389/fcomp.2024.1521066>
- Hansen, K. B. (2020). The virtue of simplicity: On machine learning models in algorithmic trading. *Big Data & Society*, 7(1). DOI: <https://doi.org/10.1177/2053951720926558>
- Hirsjärvi, S., & Hurme, H. (2022). Tutkimushaastattelu: Teemahaastattelun teoria ja käytäntö. Gaudeamus.
- Harding, M., & Vasconcelos, G. F. R. (2022). Managers versus machines: Do algorithms replicate human intuition in credit ratings? arXiv. <https://doi.org/10.48550/arXiv.2202.04218>
- Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human–AI symbiosis in organizational decision making. *Business Horizons*, 61(4), 577–586. <https://doi.org/10.1016/j.bushor.2018.03.007>
- Lessmann, S., Baesens, B., Seow, H. V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, 247(1), 124–136. <https://doi.org/10.1016/j.ejor.2015.05.030>
- Logg, J. M., Minson, J. A., & Moore, D. A. (2019). Algorithm appreciation: People prefer algorithmic to human judgment. *Organizational Behavior and Human Decision Processes*, 151, 90–103. <https://doi.org/10.1016/j.obhdp.2018.12.005>
- Lu, T., & Zhang, Y. (2024). 1+1>2? Information, Humans, and Machines. *Information Systems Research*, 36(1), 394–418. <https://doi.org/10.1287/isre.2023.0305>
- Mehrotra, S., Jorge, C. C., Jonker, C. M., & Tielman, M. L. (2024). Integrity-based Explanations for Fostering Appropriate Trust in AI Agents. *ACM Transactions on Interactive Intelligent Systems*, 14(1), Article 4. <https://doi.org/10.1145/3610578>
- Mendel, T., Mandal, S., Nov, O., & Wiesenfeld, B. M. (2025). Who is Responsible, the Advisor or the AI? Understanding the Effects of Advisors Disclosing Their AI Use on Their Perceived Responsibility and AI Reliance. *Proceedings of the ACM on Human-Computer Interaction*. <https://doi.org/10.1145/3757524>

- Patton, M. Q. (2015). *Qualitative research & evaluation methods: Integrating theory and practice* (4th ed.). SAGE Publications.
- Purificato, E., Lorenzo, F., Fallucchi, F., & De Luca, E. W. (2022). The use of responsible artificial intelligence techniques in the context of loan approval processes. *International Journal of Human-Computer Interaction*, *39*(7), 1543–1562. <https://doi.org/10.1080/10447318.2022.2081284>
- Shenton, A. K. (2004). Strategies for ensuring trustworthiness in qualitative research projects. *Education for Information*, *22*(2), 63–75. <https://doi.org/10.3233/EFI-2004-22201>
- TENK. (2023). Hyvä tieteellinen käytäntö ja sen loukkausepäilyjen käsitteleminen Suomessa. Tutkimuseettinen neuvottelukunta. Noudettu 1.2.2026 osoitteesta https://tenk.fi/sites/default/files/2023-03/HTK-ohje_2023.pdf
- Tuomi, J., & Sarajarvi, A. (2018). *Laadullinen tutkimus ja sisällönanalyysi*. Tammi.
- Züger, T., Mahlow, P., Pothmann, D., Mosene, K., Burmeister, F., Ketemann, M., & Schulz, W. (2025). Crediting Humans: A systematic assessment of influencing factors for human-in-the-loop figurations in consumer credit lending decisions. *In Proceedings of the 2025 ACM Conference on Fairness, Accountability, and Transparency (FAcCT '25)*. <https://doi.org/10.1145/3715275.3732086>
- Wang, H., Zhang, Y., & Lu, T. (2025). The Power of Disagreement: A Field Experiment to Investigate Human-Algorithm Collaboration in Loan Evaluations. *Management Science*, *72*(1), 96–118. <https://doi.org/10.1287/mnsc.2022.03844>

Liitteet

Liite 1. Päähaastattelukysymykset

1. Voisitko kuvata tyypillisen luottopäätösprosessin omasta näkökulmastasi?
2. Missä vaiheessa koneoppimismalli tulee mukaan päätöksentekoon?
3. Millaisena koet koneoppimismallin roolin tässä prosessissa?
4. Millaisessa muodossa saat koneoppimismallin tuottamaa tietoa?
5. Miten yleensä tulkitset tai arvioit mallin antamaa tulosta?
6. Millaisia hyötyjä koet koneoppimismallien tuovan luottopäätöksentekoon?
7. Miten mallit vaikuttavat työn tehokkuuteen tai päätöksenteon laatuun?
8. Millaisia haasteita tai ongelmia olet havainnut koneoppimismallien käytössä?
9. Onko mallien käyttö herättänyt epävarmuutta tai ristiriitoja päätöksenteossa?
10. Miten kuvailisit yhteistyötä sinun ja koneoppimismallin välillä?
11. Koetko, että oma roolisi asiantuntijana on muuttunut mallien käyttöönoton myötä?

Liite 2. Ilmoitus tekoälyn käytöstä

Tässä tutkimuksessa on hyödynnetty tekoälypohjaisia työkaluja kirjoitusprosessin tukena. Tekoälyä on hyödynnetty Vaasan Yliopiston 27.6.2023 hyväksytyn ohjeistuksen mukaisesti.

Ensimmäinen käytetty työkalu oli ChatGPT (OpenAI). Tekoälyä hyödynnettiin:

- Tekstin kielellisessä hionnassa
- Käsitteiden alustavassa jäsentelyssä
- Yleisessä ideoinnissa

Toinen käytetty työkalu oli Undermind, jota käytettiin pääasiassa lähteiden etsimiseen. Kaikki tekoälyn tuottama sisältö on tarkistettu ja muokattu kirjoittajan toimesta, ja kirjoittaja vastaa työn sisällöstä kokonaisuudessaan.