Tampereen yliopisto

Leevi Pöyry

KONEOPPIMISEN HYÖDYNTÄMINEN VALMISTAVASSA TEOLLISUUDESSA

Kandidaatintyö
Johtamisen ja talouden tiedekunta
Tarkastaja: Ulla Saari
4/2025

TIIVISTELMÄ

Leevi Pöyry: Koneoppimisen hyödyntäminen valmistavassa teollisuudessa
The utilization of machine learning in the manufacturing industry
Kandidaatintyö
Tampereen yliopisto
Tuotantotalouden tutkinto-ohjelma
Huhtikuu 2024

Koneoppiminen on teknologiana hyvin lupaava valmistavan teollisuuden käyttötarkoituksiin. Ala on kuitenkin kehittynyt viime vuosina nopeasti tutkimuspuolella, mutta tuotantokäyttöön päätyneitä sovelluksia on syntynyt niukasti. Tämän kandidaatintyön tavoitteena oli tutkia parhaita tapoja hyödyntää koneoppimista valmistavassa teollisuudessa sekä selvittää parhaita toimintatapoja koneoppimisen käyttöönoton edistämiseksi organisaatiossa.

Tutkimus toteutettiin kirjallisuuskatsauksena hyödyntäen lähteinä tieteellisiä julkaisuja. Tutkimuksessa on neljä osaa. Ensimmäisessä osassa esitellään aihetta ja tutkimusmenetelmiä, käydään läpi työn rakennetta ja perustellaan tutkimuksen tärkeyttä. Toisessa osassa tutustutaan koneoppimiseen ja koneoppimismallien kouluttamiseen teoreettiselta pohjalta. Kolmannessa osassa perehdytään tieteellisen tutkimuksen avulla koneoppimisen parhaisiin sovellustapoihin, käytön esteisiin ja toimintatapoihin, joilla voidaan edistää koneoppimisen hyödyntämistä valmistavan teollisuuden yrityksissä. Neljännessä osassa työn tulokset kootaan yhteen ja niiden pohjalta pyritään vastaamaan tutkimuskysymyksiin sekä tunnistamaan mahdollisia jatkotutkimustarpeita ja pohditaan tutkimuksen toteutusta kriittisesti.

Koneoppimisella viitataan ohjelmiin, joita ei ole tehty kokonaan ohjelmoijan toimesta, vaan ne käyvät läpi koulutusvaiheen, jonka aikana ne oppivat sääntöjä opetusdatasta. Tutkimuksissa koneoppimismallien suorituskyky on ollut hyvä rajatuissa ongelmissa, joita ei kuitenkaan ole ollut mahdollista ratkaista perinteisen ohjelmoinnin keinoin. Esimerkiksi konenäkö ja ennusteiden tekeminen moniulotteisen datan pohjalta ovat tällaisia ongelmia.

Tutkimuksessa usein esiintyviä käyttökohteita ovat ennustava huolto, laadunvalvonta, tuotannonohjaus sekä toimitusketjun hallinta. Koneoppimisella pystytään teoriassa ratkaisemaan monia ongelmia, joihin yleensä tarvittaisiin ihmisen harkintaa. Käytännössä organisaatioissa on kuitenkin monia taloudellisia, organisatorisia, strategisia, teknologisia ja laillisia ongelmia käyttöönoton esteinä. Järjestelmällisellä käyttöönoton lähestymisellä ja onnistuneella muutosjohtamisella monet esteet ovat poistettavissa.

Avainsanat: koneoppiminen, tekoäly, valmistava teollisuus

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -ohjelmalla

TEKOÄLYN KÄYTTÖ OPINNÄYTTEESSÄ

Opinnäytteessäni on käytetty tekoälysovelluksia:

☐ Ei

☒ Kyllä

Ilmoitukseni mukaan olen käyttänyt opinnäytteessäni tutkielmaprosessin aikana seuraavia tekoälysovelluksia:

ChatGPT 4o, ChatGPT 4.5, ChatGPT o4-mini-high

Käyttötarkoitus:

Hakusanojen etsiminen ja arvioiminen, kielentarkistus, rakenteen ideointi ja palautteen pyytäminen.

Osiot, joissa tekoälyä on käytetty:

Koko työ. Mikään kohta työssä ei kuitenkaan sisällä tekoälysovelluksen kirjoittamaa tekstiä, vaan koko työ on minun itse kirjoittama.

Olen tietoinen siitä, että olen täysin vastuussa koko opinnäytteeni sisällöstä, mukaan lukien tekoälyllä tuotetut osat, ja hyväksyn vastuun mahdollisista eettisten ohjeiden rikkomuksista.

ALKUSANAT

Tekoäly aiheena kiinnosti minua jo ennen työn aloittamista, mutta tarkempi näkökulman tarkentaminen vei aikaa ja tarkka aihe ehti muuttua muutamaan otteeseen työprosessin aikana. Koneoppimisen hyödyntäminen valmistavassa teollisuudessa valikoitui lopulta työn aiheeksi, sillä se yhdisteli tuotantotalouden ja tekoälyn sivuaineopintojani, jotka olivat muuten tuntuneet melko erillisiltä kokonaisuuksilta. Tämän työn avulla sain yhdistettyä oppimaani, minkä uskon sekä parantaneen itse työtä, mutta myös olleen minulle henkilökohtaisesti tärkeää juuri kahden muuten erillisen aihepiirin yhdistämiseksi.

Tahdon kiittää läheisiäni, jotka ovat tukeneet minua työn tekemisen aikana, sekä lehtori Tommi Mahlamäkeä, joka auttoi minua suuntaamaan työtäni oikeaan suuntaan. Erityiskiitokset haluan esittää työni ohjaajalle Ulla Saarelle, joka oli aina nopeasti saatavilla, pysyi kannustavavana ja varasi aikaa kahdenkeskeisiin tapaamisiin, vaikka työni venyikin alkuperäisestä aikataulusta.

Tampereella 29.4.2025

Leevi Pöyry

SISÄLLYSLUETTELO

1. JOHDANTO 1
1.1 Tutkimuksen tavoitteet ja tutkimusmenetelmä 1
1.2 Tutkimuksen rakenne 3
2. OPPIVAT KONEET 4
2.1 Mallien koulutus 4
2.2 Oppimisparadigmat 6
2.2.1 Ohjattu oppiminen 6
2.2.2 Ohjaamaton oppiminen 7
2.2.3 Osittain ohjattu oppiminen 8
2.2.4 Vahvistusoppiminen 8
2.3 Koneoppimisen haasteita 9
3. KONEOPPIMISEN HYÖDYNTÄMINEN VALMISTAVASSA TEOLLISUUDESSA 12
3.1 Ennustava huolto 12
3.1.1 Ennustavan huollon haasteet 13
3.2 Laadunvalvonta 14
3.2.1 Laadunvalvonnan haasteet 14
3.3 Tuotannonohjaus 15
3.3.1 Tuotannonohjauksen haasteet 15
3.4 Toimitusketjun hallinta 16
3.4.1 Toimitusketjun hallinnan haasteet 16
3.5 Esteitä koneoppimisen käyttöönottoon 16
3.6 Parhaat toimintatavat koneoppimisen hyödyntämiseen valmistavassa teollisuudessa 17
4. PÄÄTELMÄT 19
4.1 Tutkimuksen tulokset 19
4.2 Tutkimuksen arviointi ja jatkotutkimustarpeet 20
LÄHTEET 22

1. JOHDANTO

Digitalisaation myötä yritykset keräävät nykyisin paljon dataa omasta toiminnastaan ja asiakkaistaan, minkä paremmassa hyödyntämisessä koneoppimisella on paljon potentiaalia. Koneoppimisen keskeinen hyöty on kyky käsitellä suuria informaatiomääriä ja löytää täysin uusia kuvioita, joiden avulla voidaan luoda uutta ymmärrystä, tehostaa toimintaa ja avustaa päätöksentekoa (Moradi & Dass, 2022).

Teollista liiketoimintaa on muovannut menneisyydessä useamman kerran uudet teknologiat, kuten sähkö, langaton viestintä, tietokone ja internet. Ne ovat helpottaneet datan keräämistä, käsittelyä tai siirtämistä, mutta päätöksenteko on aina ollut ihmisten vastuulla. Koneoppiminen on ensimmäinen teknologia, joka pystyy monissa tapauksissa tekemään päätöksiä itsenäisesti tai hyvin vähäisellä valvonnalla. (Paschen, Wilson & Ferreira, 2020) Esimerkiksi jo vuonna 2012 tekoälyjärjestelmät kykenivät tunnistamaan liikennemerkkejä kuvista kaksi kertaa luotettavammin kuin ihmiset ja lukemaan käsin kirjoitettua tekstiä lähes yhtä hyvin (Ciregan, Meier ja Schmidhuber, 2012). Nykyiset järjestelmät suoriutuvatkin jo monista vastaavista tehtävistä huomattavasti ihmistä paremmin. Järjestelmien kyky tehdä päätöksiä vähentää työntekijöiden työkuormaa, minkä takia sen onnistunut hyödyntäminen toiminnassa voi olla hyvinkin arvokasta.

Termejä tekoäly (engl. artificial intelligence) ja koneoppiminen (engl. machine learning) käytetään kirjallisuudessa välillä samoista ja välillä eri asioista. Kämäräisen (2023) mukaan tekoäly on kuitenkin kattotermi useille teknologioille ja koneoppiminen kuuluu täten tekoälyn alle. Tätä määritelmää käytetään tässäkin työssä. Eri tekoälyn alle kuuluviin teknologioihin ei perehdytä sen enempää, sillä tämä työ keskittyy koneoppimiseen. Koneoppimisella viitataan ohjelmiin, joita ei ole tehty kokonaan ohjelmoijan toimesta, vaan ne käyvät läpi koulutusvaiheen, jonka aikana ne oppivat sääntöjä opetusdatasta (Kämäräinen, 2023).

1.1 Tutkimuksen tavoitteet ja tutkimusmenetelmä

Työ toteutettiin, koska koneoppiminen on nopeasti kehittyvä uusi teknologia, jolla on paljon potentiaalia valmistavan teollisuuden sovelluksissa. Parhaat toimintatavat koneoppimisen hyödyntämisessä eivät kuitenkaan ole vielä vakiintuneita, joten tässä työssä pyri-

tään vastaamaan siihen, mitä tämänhetkinen tutkimus nostaa tärkeimmiksi asioiksi koneoppimisen onnistuneessa hyödyntämisessä. Ensin aihetta lähestytään teoreettiselta pohjalta tieteellisissä tutkimuksissa esiintyvien hyödyntämistapojen kartoittamisella, minkä jälkeen pyritään selvittämään, mikä on paras tapa lähestyä koneoppimisen käytön lisäämistä valmistavan teollisuuden yrityksissä.

Tutkimuskysymyksiksi muodostuivat:

- Miten koneoppimista voidaan hyödyntää valmistavassa teollisuudessa?
- Millä tavoilla koneoppimisen käyttöönottoa voidaan tukea valmistavassa teollisuudessa?

Tutkimus tehtiin kirjallisuuskatsauksena ilman empiiristä tutkimusta. Aineisto koottiin ensisijaisesti hakemalla artikkeleita Scopus-tietokannasta. Hakusanoina käytettiin koneoppimiseen ja teolliseen toimintaan liittyviä englanninkielisitä termejä. Aihepiirin tieteellisiä kirjoja etsittiin Tampereen yliopiston ylläpitämästä Andor-tietokannasta. Tulososaan valittujen Scopus-artikkeleiden hakutermit on kuvattu taulukossa 1.

Taulukko 1: Hakutermejä tulososassa

Hakusana	Tulosten määrä (valittu määrä)	Valitut artikkelit
"machine learning” AND ("industry 4.0" OR manufacturing OR industrial) AND applications AND (”predictive maintenance” OR ”quality inspection” OR ”quality control” OR ”anomaly detection” OR ”production planning” OR ”production scheduling”) AND (review OR survey OR framework)	104 (3)	Lazzaro et al. 2024 Manta-Costa et al. 2024 Ördek et al. 2024
"machine learning” OR ”artificial intelligence” AND ("industry 4.0" OR manufacturing OR industrial) OR factory OR factories AND ("economic impact" OR "return on investment" OR "ROI" OR "financial analysis" OR ”mone*” OR "business case" OR "cost-benefit" OR ”best practice*”)	110 (3)	Awaisi et al. 2024 Cannas et al. 2024 Rakholia et al. 2024

Lähteiden laatua arvioitiin Julkaisufoorumin luokitusta käyttäen. Tutkimuksen lähteinä käytettiin vähintään tason 1 lehdissä julkaistuja tieteellisiä artikkeleita, lukuun ottamatta muutamia tulososion ulkopuolella käytettyjä lähteitä, jotka sisälsivät taustoituksen kannalta tärkeää tietoa. Näidenkin lähteiden kohdalla laatua arvioitiin tarkastelemalla julkaisijan muita töitä ja tiedon yhtenäisyyttä muiden julkaisujen kanssa. Hakutuloksia karsittiin aluksi otsikoiden mukaan, minkä jälkeen luettiin jäljelle jääneiden artikkeleiden abstraktit. Jos lähde vaikutti edelleen tutkimukseen soveltuvalta, arvioitiin artikkelin soveltuvuutta sisältöä silmäilemällä ja tuloksia tarkastelemalla. Valitut artikkelit luettiin lopulta kokonaan ja niihin palattiin aina tarvittaessa. Helmenkasvatusmenetelmällä (Schlosser *et al.*, 2006) valittiin lisäksi kolme artikkelia: Babic et al. (2021), Bertolini et al. (2021) ja Usuga Cadavid et al. (2020). Kaikki näistäkin olivat Julkaisufoorumin tason 1–2 artikkeleita.

Ongelmia lähteiden valinnassa aiheutti alan nopea viimeaikainen kehitys, minkä takia monet lähteet vain muutamankin vuoden takaa sisälsivät jo vanhentunutta tietoa esimerkiksi koneoppimisen kyvykkyyksistä tai vaadittavista resursseista. Alan termistö ei myöskään ole vielä vakiintunutta. Lähteitä valittiin pääasiassa vain vuosilta 2024 ja 2025, jotta tutkimus olisi mahdollisimman ajantasainen.

1.2 Tutkimuksen rakenne

Tutkimuksen toisessa osassa tarkastellaan koneoppimista teoreettiselta pohjalta. Aluksi käydään läpi koneoppimismallien oppimisprosessia, minkä jälkeen tutustutaan koneoppimisen oppimisparadigmoihin. Tämän osion tavoitteena on antaa lukijalle riittävä tekninen ymmärrys kolmannen osan tuloksien tulkintaa varten. Kolmas osa on tutkimuksen tulososa, jossa käydään läpi tutkimuskirjallisuudessa esiintyviä koneoppimisen hyödyntämistapoja valmistavassa teollisuudessa sekä parhaita toimintatapoja teknologian hyödyntämisen edistämiseksi.

Neljännessä osassa tulokset kootaan yhteen ja vastataan tutkimuskysymyksiin niiden perusteella. Lopuksi pohditaan tutkimusta ja tuloksia kriittisesti ja esitetään mahdollisia jatkotutkimussuuntia.

2. OPPIVAT KONEET

Alan Turing esitti vuonna 1950 artikkelissaan *Computing machinery and intelligence* idean koneista, jotka voisivat oppia kokeilun, palkintojen ja rangaistusten avulla ilman erillistä ohjelmointia. Hän haaveili tulevaisuuden koneiden osaavan pelata shakkia, havainnoida ympäristöä ja puhua englantia. Monien mielestä hänen ideansa olivat varmastikin ylioptimistisia, mutta nyt 75 vuotta myöhemmin tietokoneiden kyvykkyydet ovat ylittäneet hänen haaveensakin.

Turingin idean ja tietokoneiden kehityksen innoittamana tekoälyn ja koneoppimisen tutkiminen alkoi 1950-luvulla, mutta sen aikaiset tietokoneet olivat laskentateholtaan riittämättömiä. Ajoittain aihepiirin tutkimus on kiihtynyt tietokoneiden ja algoritmien kehityttyä, mutta joka kerta kehitys on pysähtynyt teknologian jäädessä vajaaksi odotuksista. Tekoälyn tutkimus onkin koostunut lisääntyneen kiinnostuksen ajanjaksoista ja niiden väliin jäävistä hiljaisemman kehityksen ajoista. Näitä ajanjaksoja kutsutaan yleensä tekoälykeväiksi ja -talviksi. (Duan, Edwards ja Dwivedi, 2019) 2010-luvun alkupuolella alkanut tämänhetkinen tekoälykevät on seurausta näytönohjaimien (engl. graphics processing unit, GPU), tallennustilan halpenemisen ja neuroverkkoihin perustuvien koneoppimismallien kehityksestä (Sevilla *et al.*, 2022). Lisäksi Googlen vuonna 2017 kehittämä neuroverkkojen Transformer-arkkitehtuuri (Vaswani *et al.*, 2017) mahdollisti ChatGPT:n kaltaisten suurten kielimallien luomisen.

Koneoppimisen perusideana on datan ja algoritmien avulla saada aikaiseksi malleja, joiden avulla voidaan ratkaista ongelmia, joiden ratkaiseminen on niiden monimutkaisuuden vuoksi vaikeaa perinteisen sääntöpohjaisen ohjelmoinnin keinoin (Kumar, Rani ja Singh Khangura, 2023). Koneoppimista on siis yksinkertaisimmillaan parhaiten datapisteiden sijoittumista kuvaavan suoran sovituksen löytäminen. Monimutkaisimmillaan koneoppimista ovat nykyaikaiset suuret kielimallit, jotka kykenevät ymmärtämään ja luomaan ääntä, tekstiä ja kuvia lähes yhtä hyvin kuin aihealueen asiantuntijat.

2.1 Mallien koulutus

Itse oppiminen tapahtuu kolmivaiheisessa prosessissa, jota voidaan pitää samankaltaisena ihmisten oppimisprosessiin verrattuna. Ensin koneoppimismalli tekee päätöksen datan pohjalta. Toisessa vaiheessa päätöstä arvioidaan hukkafunktion (engl. loss function) perusteella. Hukkafunktio laskee jollakin tavalla, kuinka väärässä ennuste tai luokittelu on. Lopuksi mallia säädetään niin, että sen päätös olisi samalla datalla vähemmän

väärässä eli hukkafunktion arvo olisi pienempi. (Kumar, Rani ja Singh Khangura, 2023) Ihmiset oppivat samankaltaisesti arvioimalla omia päätöksiä ja oppimalla niistä niin, että päätökset johtaisivat useammin haluttuihin lopputuloksiin tulevaisuudessa.

Mallin päätöksenteko tarkoittaa joko jonkin ennusteen tekemistä tai luokittelua datan pohjalta. Malli yrittää siis löytää kuvioita datasta ja tehdä päätöksiä siitä, mitä tulosteen pitäisi olla. (Kumar, Rani ja Singh Khangura, 2023) Esimerkiksi aiemmin mainitussa lineaarisessa regressioanalyysissä ennuste olisi suoran yhtälö datapisteiden perusteella tai suuressa kielimallissa seuraava sanan osa perustuen aiemmin esiintyneisiin sanojen osiin.

Jotta voidaan oppia, on oltava jokin tapa arvioida tehtyjä päätöksiä. Mallin tekemää päätöstä verrataan parhaaseen mahdolliseen päätökseen hukkafunktion avulla. Hukkafunktio laskee jollakin tavalla tehdyn ja parhaan mahdollisen päätöksen erotuksen. (Kumar, Rani ja Singh Khangura, 2023) Lineaarisessa regressioanalyysissä hukkafunktiona voitaisiin käyttää esimerkiksi keskineliövirhettä (engl. mean squared error), joka kertoo kuinka suuri datapisteiden ja suoran välisten etäisyyksien neliö on keskimäärin. Suurten kielimallien tapauksessa hukkafunktion on oltava hieman edistyneempi, sillä kielen monimutkaisuuden vuoksi virheen arviointi ei ole myöskään yksiselitteistä. Yksinkertaisissa ongelmissa, joiden ratkaisu voidaan saada selville muutamalla tuhannella arvauksella, saattaa virhe sisältää pelkästään yhden luvun, kun taas monimutkaisissa ongelmissa virhe lasketaan vektorina, jolloin sillä on sekä suuruus että suunta.

Kun päätöksen virheen arviointiperusteet on määritetty, voidaan muuttaa mallin parametrejä (engl. parameters) niin, että päätökset johtavat pienempään hukkafunktion arvoon (Kumar, Rani ja Singh Khangura, 2023). Suoraa sovittaessa parametrejä olisivat kulmakerroin ja vakiotermi, joita voidaan ongelman yksinkertaisuuden vuoksi säätää arvaamalla. Suurissa kielimalleissa parametrejä voi olla satoja miljardeja, joten arvaamalla säätäminen ei ole mahdollista. Koulutusalgoritmit kuitenkin mahdollistavat säätämisen, sillä hukkafunktion ilmoittama virhe sisältää myös suunnan. Tätä kolmivaiheista koulutusprosessia toistetaan, kunnes mallin suorituskyky ei enää parane (Kumar, Rani ja Singh Khangura, 2023). Koulutusprosessin eteneminen on esitetty kuvassa 1.

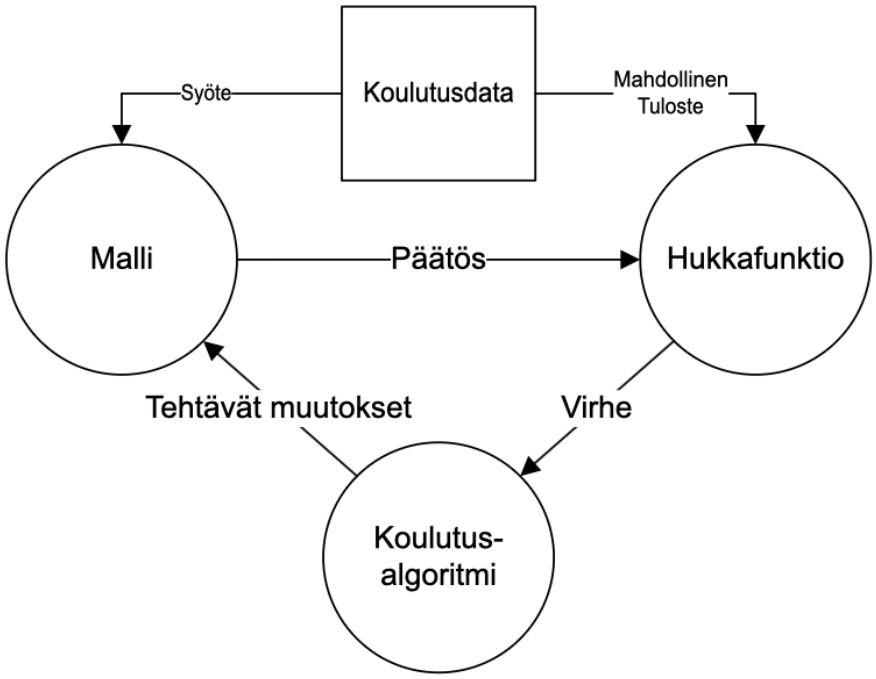

Kuva 1: Koneoppimismallin koulutusprosessi

2.2 Oppimisparadigmat

Yleensä oppimistavat jaetaan neljään luokkaan: ohjattu oppiminen, ohjaamaton oppiminen, osittain ohjattu oppiminen ja vahvistusoppiminen. (Kumar, Rani ja Singh Khangura, 2023) Paradigmat viittaavat enemmän datan tyyppiin kuin itse koneoppimismalleihin, sillä datan luonne määrittää, millaista uutta tietoa siitä voidaan tuottaa. Tässä työssä ei syvennytä tarkemmin siihen, miten koneoppimismallit käsittelevät dataa, sillä teollisuussovellusten kannalta keskeisempää on, millaista dataa prosessista on saatavilla ja mitä sen avulla voidaan saavuttaa, ei niinkään mallien tekninen toteutus. Oleellista on kuitenkin tietää, että mallit ovat aina kyseiseen käyttötarkoitukseen räätälöityjä, eikä samaa mallia pysty usein sellaisenaan soveltamaan eri käyttötarkoituksiin. Oppimisparadigmat on esitelty taulukossa 2.

2.2.1 Ohjattu oppiminen

Ohjattu oppiminen (engl. supervised learning) on koulutusta datalla, joka sisältää syötteen ja halutun tulosteen. Mallin tavoitteena on luoda tuloste syötteen perusteella ja algoritmi kouluttaa sitä tähän suuntaan. (Kumar, Rani ja Singh Khangura, 2023) Esimerkiksi laadunvalvontaa suorittava malli voitaisiin kouluttaa tuotteesta kerätyllä datalla, joka on luokiteltu sen mukaan, onko tuote laatuvaatimukset täyttävä vai viallinen, sekä mikä vikatyyppi siinä on. Koulutusvaiheen jälkeen malli osaa ennustaa pelkän tuotteesta ke-

rätyn datan avulla läpäiseekö tuote laadunvalvonnan tai mikä vika siinä on. Ohjatun oppimisen ongelmat jaotellaan edelleen regressio- ja luokitteluongelmiin (Kumar, Rani ja Singh Khangura, 2023).

Regressio on arvojen ennustamista niitä selittävien muuttujien perusteella. Syöte voi sisältää sekä numeerisia, että kategorisia muuttujia, joiden perusteella malli luo jatkuvan yhden tai useamman numeron tulosteen. (Kumar, Rani ja Singh Khangura, 2023) Esimerkiksi tuotteen kysynnän ennustaminen on regressiotehtävä, jossa muuttujat sisältäisivät tietoa kysyntään vaikuttavista asioista, kuten säästä, myynnin asiakastapaamisista, vuodenajasta tai asiakkaiden markkinatilanteesta.

Luokittelun tavoitteena on jaotella syöte ennalta määriteltyihin luokkiin. Kuten regressiossa, syöte voi sisältää numeerisia ja kategorisia muuttujia, mutta tuloste on diskreetti eli jaettu luokkiin. (Kumar, Rani ja Singh Khangura, 2023) Teollisuudessa luokittelua voitaisiin käyttää esimerkiksi vikatyyppien tunnistamiseen kuvien perusteella, koneongelmien tunnistamiseen sensoridatan avulla tai trukkien vapaana olon tunnistamiseen valvontakamerakuvan perusteella.

2.2.2 Ohjaamaton oppiminen

Ohjaamattomassa oppimisessa (engl. unsupervised learning) käytetty data ei sisällä haluttua tulostetta, vaan tavoitteena on löytää datasta yhteyksiä tai ryhmitellä sitä (Kumar, Rani ja Singh Khangura, 2023). Esimerkiksi asiakkaiden ostoskäyttäytymisestä on mahdollista löytää samankaltaisia asiakassegmenttejä tai usein yhdessä ostettuja tuotteita. Ohjaamattoman oppimisen ongelmat on yleensä jaoteltu ryvästykseen (engl. clustering) ja yhteyksien etsimiseen (engl. association) (Kumar, Rani ja Singh Khangura, 2023), jolle ei ole vakiintunutta suomenkielistä termiä.

Ryvästyksessä tavoitteena on ryhmitellä samankaltaiset datapisteet yhteen niiden ominaisuuksien perusteella. Mahdollisista datassa esiintyvistä ryhmistä tai luokista ei ole etukäteen tietoa, vaan tavoitteena on löytää rakennetta ilman tätä tietoa. Ryhmittely tapahtuu jonkinlaisen samankaltaisuusmittarin perusteella. Yksinkertaisimmillaan samankaltaisuutta voidaan mitata pisteiden etäisyydellä toisistaan, mutta yleensä perusteet ovat monimutkaisempia ja tehokkaampia. (Kumar, Rani ja Singh Khangura, 2023) Aiemmin mainittu asiakassegmenttien löytäminen on ryvästysongelma.

Yhteyksien etsiminen on tyypillisesti transaktiodatalle tehtävää käsittelyä, jonka tavoitteena on löytää mitkä tapahtumat esiintyvät usein yhdessä tai vaihtoehtoisesti, mitkä tapahtumat esiintyvät usein yksin (Kumar, Rani ja Singh Khangura, 2023). Asiakkaiden

ostoskäyttäytymistä tutkittaessa voitaisiin siis saada esimerkiksi selville, että tomaattipyreen ja säilykeananaksien kanssa ostetaan usein myös pitsajuustoraastetta.

Koska ohjaamattomassa oppimisessa tavoitteet eivät ole tarkasti määriteltyjä ihmisen toimesta, on saatujen tuloksien tulkitseminen usein haastavaa. Löydetyt ryhmät tai yhteydet saattavat olla niin moniulotteisia ja intuition vastaisia, että niiden esittäminen helposti ymmärrettävässä muodossa voi olla mahdotonta. Tämän vuoksi sidosryhmät saattavat suhtautua tuloksiin skeptisesti. (Kumar, Rani ja Singh Khangura, 2023)

2.2.3 Osittain ohjattu oppiminen

Osittain ohjattu oppiminen (engl. semi-supervised learning) yhdistelee ohjatun ja ohjaamattoman oppimisen menetelmiä tavoitteena saavuttaa molempien menetelmien hyötyjä ilman molempien haittoja. Osittain ohjatulla oppimisella voidaan saavuttaa hyviä tuloksia silloin, kun syötedataa on paljon saatavilla, mutta haluttuja tulosteita on olemassa vähän ja niitä on kallista tuottaa. Aluksi mallia voidaan kouluttaa syöte-tuloste-pareilla ohjatun oppimisen menetelmin, minkä jälkeen koulutusta voidaan jatkaa ohjaamattoman oppimisen menetelmillä. Tämän menetelmän onnistunut soveltaminen on ohjattua ja ohjaamatonta oppimista vaikeampaa mallien monimutkaisuuden vuoksi, mutta sillä voidaan saavuttaa joissakin tilanteissa hyviä tuloksia. (Kumar, Rani ja Singh Khangura, 2023)

2.2.4 Vahvistusoppiminen

Vahvistusoppiminen (engl. reinforcement learning) on koulutustapa, jossa malli oppii kokeilemalla ja algoritmi palkitsee tai rankaisee mallia koulutuksen aikana sen mukaan, kuinka hyvin se suoriutuu halutun mittarin perusteella. Mallille annetaan syötteenä tietoa ympäristöstä, jossa se toimii ja tulosteena malli antaa siltä pyydettyjä arvoja, joilla se voi vaikuttaa palkitsemisalgoritmin mittaamaan asiaan. (Kumar, Rani ja Singh Khangura, 2023) Esimerkiksi navigaattori saattaisi etsiä parasta reittiä kokeilemalla ja palkitsemisalgoritmi voisi palkita lyhyttä matka-aikaa ja rangaista suurta käännösten määrää. Vahvistusoppiminen sopii hyvin tehtäviin, joissa tavoitteena on jonkin mitattavissa olevan asian optimointi.

Taulukko 2: Koneoppimisen oppimisparadigmat

(Kämäräinen, 2023; Kumar, Rani ja Singh Khangura, 2023)

Paradigma	Vahvuudet	Heikkoudet	Käyttökohteita
Ohjattu oppiminen	Hyvä suorituskyky luokittelu- ja regressiotehtävissä	Vaatii halutun tulosteen sisältävää dataa	Regressio Luokittelu
Ohjaamaton oppiminen	Hyvä löytämään ryhmiä ja yhteyksiä tunnisteettomasta datasta	Tulokset vaikeita tulkita ja toimintaperiaate vaikea ymmärtää	Asiakassegmenttien löytäminen Poikkeuksien tunnistaminen Transaktiodatan analysointi
Osittain ohjattu oppiminen	Kaiken koulutusdatan ei tarvitse sisältää tulostetta, mutta tulokset ovat lähes yhtä hyviä ohjatun oppimisen kanssa	Teknisesti vaikea toteuttaa Saattaa tehdä vaikeasti huomattavia virheitä Vaatii hieman syöte-tulostepareja	Luokittelu Regressio
Vahvistusoppiminen	Hyvä löytämään parhaan toimintatavan monimutkaisessa ympäristössä	Saattaa optimoida haluttua asiaa ei-toivotulla tavalla	Optimointi

2.3 Koneoppimisen haasteita

Vaikka koneoppiminen onkin tehokas teknologia ja teoriassa melko yksinkertaista käyttää, on sen käytännön soveltamisessa monia ongelmia. Uutta sovellusta kehittäessä tarvitaan koulutusdataa, jota usein joko ei ole riittävästi saatavilla, se on hyvin yksipuoleista tai muuten huonolaatuista (Kumar, Rani ja Singh Khangura, 2023). Kuvitellaan esimerkiksi tilanne, jossa tuotteista on kerätty laatudataa monta vuotta, mutta sinä aikana käytetty raaka-aine on vaihtunut, laadun mittaustapaa on muutettu, kaikki työntekijät eivät ole tehneet kirjauksia löydetyistä virheistä ja välillä osa antureista ovat olleet viallisia tai poissa käytöstä. Tällaisella datalla mallin kouluttaminen on lähes varmasti mahdotonta, ainakin ilman työlästä datan siivousta.

Kun on saatu paljon laadukasta dataa, päästään kouluttamaan mallia. Oikean malliarkkitehtuurin valitseminen jokaiseen tehtävään on kuitenkin vaikeaa, sillä usein monet erilaiset arkkitehtuurit soveltuvat tehtävän ratkaisemiseen, mutta niiden välillä on silti suuria eroja siinä, kuinka hyvin ne tehtävästä suoriutuvat. Koulutusvaiheessa on myös varot-

tava mallin ylioppimista (engl. overfitting), jossa malli oppii koulutusdataa ulkoa sen sijaan, että se opettelisi datasta löytyviä sääntöjä. Ylioppineen mallin tunnistaa siitä, että se suoriutuu todella hyvin koulutusdatalla testattaessa, mutta uudella datalla tulokset ovat huonoja. Ylioppimisen vastakohta on alioppiminen (engl. underfitting), jolloin malli taas oppii vain osan datan säännöistä, eikä sen suorituskyky ole kovin hyvä. (Kämäräinen, 2023)

Koulutetun mallin käyttöönottoa ennen on kuitenkin huomioitava vielä monia asioita. Jotta yrityksen toimintaan päästään tekemään muutoksia, on sidosryhmille osoitettava muutoksen tuovan parannuksia. Ongelmana monissa koneoppimismalleissa on kuitenkin se, että niiden toimintaperiaatetta ja tulosteita voi olla hyvin vaikeaa tulkita, varsinkin jos aihepiiristä ei ole kattavaa osaamista. Mallien toimivuutta tositilanteissa voi myös olla vaikeaa arvioida ennen niiden käyttöönottoa. (Kumar, Rani ja Singh Khangura, 2023)

Koko toiminta vaatii lisäksi riittäviä resursseja, osaamista ja tietosuojan huomioimista. Datan kerääminen, käsittely, mallien luonti, koulutus ja käyttöönotto vaativat ymmärrystä sekä yrityksen toiminnan luonteesta, että itse koneoppimisesta. (Rakholia *et al.*, 2024) Osaamisen lisäksi tarvitaan laskentatehoa, jotta malleja voidaan kouluttaa. Monien mallien käyttö ei vaadi koulutuksen jälkeen suuria määriä laskentatehoa, mutta osa vaatii sitä varten suunniteltuja tietokoneita. Arkaluontoista dataa käsitellessä myös tietosuoja on huomioitava, jolloin esimerkiksi suuri osa pilvipalveluista rajautuu pois. (Kumar, Rani ja Singh Khangura, 2023) Ongelmia on koottu taulukkoon 3.

Taulukko 3: Yleisiä ongelmia koneoppimissovelluksien kehittämisessä

Ongelma-alue	Ongelma	Esimerkki
Data	Datan puute	Dataa ei ole kerätty tai sitä on kerätty vain välillä
	Puolueellinen data	Osaa vikatyypeistä on kirjattu paremmin kuin toisia
	Huonolaatuinen data	Dataa kerätty viallisesta anturista
Malli	Mallin valinta	Monia ongelmia voi ratkoa useammalla erilaisella mallilla, mutta eri mallien suorituskykyä ei voi tietää tarkkaan ennen koulutusta
	Koulutuksen onnistuminen	Ylioppiminen, alioppiminen tai epäonnistunut piirteiden valinta
	Mallin tulkinta	Mallien toimintaa on usein vaikea ymmärtää ja tulosteita voi olla vaikeaa esittää
Rajalliset resurssit	Laskenta	Joidenkin mallien koulutus tai käyttö vaativat paljon laskentaa, mikä vaatii suuria rahallisia investointeja
	Osaaminen	Teollisen prosessin ymmärrys ja koneoppimisen osaaminen pitää yhdistää onnistuneesti
Turvallisuus	Luotettavuus	Mallien pitää olla riittävän luotettavia, jotta niitä voidaan ottaa osaksi toimintaa
	Tietosuoja	Koulutusdata voi sisältää arkaluontoista tietoa

3. KONEOPPIMISEN HYÖDYNTÄMINEN VALMISTAVASSA TEOLLISUUDESSA

Koneoppimista pystytään teoriassa soveltamaan valmistavassa teollisuudessa kaikkialla, missä jonkin tiedon pohjalta pitää tehdä ennusteita tai päätöksiä. Viimeisten 10–15 vuoden aikana koneoppimista on alettu hyödyntää monissa valmistavan teollisuuden prosesseissa, joissa sillä on saatu olemassa olevia prosesseja tehokkaammiksi tai luotua kokonaan uusia tapoja toteuttaa asioita esimerkiksi robotiikan avulla (Kumar, Rani ja Singh Khangura, 2023).

Manta-Costa et al. esittävät valmistavan teollisuuden koneoppimissovelluksia tutkivassa artikkelissaan (2024) viisi keskeistä tapaa, joilla valmistavassa teollisuudessa hyödynnetään koneoppimista: ennustava huolto (engl. predictive maintenance, PdM), poikkeuksien tunnistaminen (engl. anomaly detection), tuotannonohjaus, laadunvalvonta sekä ihmisten ja robottien vuorovaikutus. Ördek et al. (2024) puolestaan luokittelevat tavat neljään kategoriaan: huoltojen hallintaan, laadunvalvontaan, tuotannonohjaukseen ja toimitusketjun hallintaan. Awaisi, Ye ja Sampalli (2024) nostavat kolme merkittävää käyttötarkoitusta valmistavassa teollisuudessa: ennustava huolto, koneiden valvonta ja tuotannon optimointi.

Koska ihmisten ja robottien vuorovaikutus on melko epämääräinen aihe, siihen ei tässä työssä paneuduttu. Ennustavalla huollolla ja huoltojen hallinnalla sekä tuotannonohjauksella ja tuotannon optimoinnilla viitataan artikkeleiden sisällön perusteella samoihin asioihin, joten niitä käsiteltiin yhdessä. Poikkeuksien tunnistamisella ja koneiden valvonnalla viitataan menetelmiin, joita hyödynnetään ennustavassa huollossa ja laadunvalvonnassa, joten niitä ei myöskään käsitellä erikseen. Jäljelle jäivät neljä tarkasteltavaa käyttötarkoitusta: ennustava huolto, laadunvalvonta, tuotannonohjaus ja toimitusketjun hallinta.

3.1 Ennustava huolto

Ennustava huolto pyrkii ennustamaan trendejä, mallintamaan käyttäytymistä ja löytämään korrelaatioita, jotta huoltoprosesseja pystytään paremmin suunnittelemaan. Tavoitteena on vähentää koneiden häiriöaikaa, laskea kustannuksia sekä lisätä hallintaa, laatua ja tuotantoa. (Manta-Costa *et al.*, 2024) Perinteisesti huolto on tehty ennaltaehkäisevästi joko ajan mukaan eli tiettynä päivänä esimerkiksi tehdasseisokkien aikaan,

iän mukaan eli laitteen käyttöiän perusteella tai jonkin muun ehdon mukaisesti, esimerkiksi käyttötuntien perusteella. Näitä päätöksiä tehdessä on kuitenkin valittava pidemmän käyttöiän ja hajoamisriskin väliltä. Ennustavassa huollossa huoltoja tehtäisiin ideaalitilanteessa vain koneen todellisen kunnon mukaan, mikä vähentäisi turhaa huoltoa liian aikaisen huollon takia sekä koneiden rikkoutumisia liian myöhäisen huollon takia. Pidemmän käyttöiän ja hajoamisriskin välillä ei jouduttaisi valitsemaan, sillä huolto tehtäisiin aina siinä vaiheessa, kun se on tarpeellista. (Lazzaro, D'Addona ja Merenda, 2024) Tuotantoprosessissa syntyvä data ei sisällä syöte-tuloste-pareja, joten pääasiassa ennustavan huollon mallit koulutetaan ohjaamattoman ja osittain ohjatun oppimisen menetelmillä (Manta-Costa *et al.*, 2024).

Vaiheet ennustavan huollon käyttöönottoon eivät ole vielä vakiintuneet, mutta Lazzaro, D'Addona ja Merenda (2024) esittävät kolme asiaa, jotka pitää huomioida. Ensimmäinen on kaikkien ennustettavan järjestelmän kriittisten muuttujien tunnistaminen. Tähän vaaditaan kattavaa ymmärrystä järjestelmän toiminnasta, tavoitteista ja sen roolista osana laajempaa kokonaisuutta. Toinen artikkelissa tunnistettu asia on näiden muuttujien mittaaminen. On oltava antureita, joilla voidaan jatkuvasti mitata järjestelmän toimintaa, mikä mahdollistaa vikaantumisesta viittaavien muutosten havaitsemisen. Viimeisenä on itse ennusteiden ja päätösten tekeminen. Monet viat ovat sellaisia, että niiden ilmaantuminen on mahdollista havaita poikkeavasta anturidatasta ennen kuin järjestelmä on vielä kokonaan hajonnut. Tämä mahdollistaa huollon suunnittelun ja osien hankinnan ennen kuin vika pahenee tuotannon keskeyttämisen vaativaan tilaan. Esimerkiksi hajoamassa oleva laakeri saattaisi lämmetä enemmän kuin normaalisti, pitää poikkeavaa ääntä ja nostaa sitä pyörittävän moottorin virrankulutusta. Tämä muutos anturidatassa voitaisiin havaita eikä vikaa huomattaisi vasta laakerin hajotessa ja tuotannon keskeytyessä.

3.1.1 Ennustavan huollon haasteet

Iso osa ennustavan huollon tutkimuksesta keskittyy laitteiden hajoamisajan ennustamiseen kontrolloiduissa olosuhteissa (Manta-Costa *et al.*, 2024). Käytännön ongelmat jäävätkin helposti huomioimatta, sillä kontrolloidut olosuhteet ovat melko erilaisia oikeasta tuotantoympäristöstä. Manta-Costa et al. (2024) esittää kolme merkittävää käytännön ongelmaa. Ensimmäinen ongelma on data: tuotantoprosessista kerättyä dataa ei välttämättä ole koulutusta varten riittävästi saatavilla ja data yleensä sisältää vain vähän vikatiloja, koska niitä osataan perinteisinkin menetelmin välttää varsin hyvin. Toiseksi ennustusprosessi on käytännössä aina rakennettu nykyisen tuotantoprosessin päälle, mistä seuraa ongelmia sujuvan integraation ja tulevaisuuden päivitysmahdollisuuksien kanssa. Kolmas esitetty ongelma on resurssien puute, koska mallit vaativat jatkuvaa ylläpitoa.

Esimerkiksi koneeseen tehdyt säädöt voivat vaikuttaa mallin toimivuuteen, jos se luokittelee uudella tavalla toimivan koneen vialliseksi. Näiden muutosten tekeminen vaatii osaavaa työvoimaa.

3.2 Laadunvalvonta

Koneoppimisen avulla pystytään suorittamaan laadunvalvontaa keräämällä dataa valmistettavasta tuotteesta. Koneiden suorittama laadunvalvonta on monissa tilanteissa nopeampaa, luotettavampaa ja helpompaa kuin ihmisen suorittama valvonta. Vaikka dataa tuotteesta voidaan kerätä lukemattomilla tavoilla, kamerapohjaiset laadunvalvontasovellukset ovat suosituimpia niiden helppouden ja edullisuuden vuoksi. Automatisoitu laadunvalvonta myös mahdollistaa jokaisen tuotteen tarkistamisen hidastamatta ja lisäämättä vaiheita tuotantoon. (Manta-Costa *et al.*, 2024)

Ördek et al. (2024) listaavat seitsemän kykyä koneoppimisalgoritmeille laadunvalvonnassa: asiantuntijoiden korvaaminen paremmalla suorituskyvyllä, laatuongelmien aikainen tunnistaminen, moniulottuvuuksisen datan tulkinta, laadun parantaminen, hyvä suoriutuminen viallisten tuotteiden tunnistamisessa, erilaisten tuotantoteknologioiden kanssa toimiminen ja luonnollisten virheiden erottaminen vakavista virheistä. Babic et al. (2021) löydösten mukaan koneoppimispohjaiset laadunvalvontasovellukset suoriutuvat ihmisiä selkeästi paremmin ja ovat nykyään suhteellisen edullisia ottaa käyttöön. Monet yritykset eivät kuitenkaan vielä hyödyntäneet tällaisia järjestelmiä.

Babic et al. (2021) mukaan kameroilla dataa keräävä ja kuvia analysoiva laadunvalvonta oli yleisin käytössä oleva teknologia. Kuvadataa on helppoa kerätä ja sen käsittelyyn oli olemassa vakiintuneita käytäntöjä teollisuuden ulkopuolella. Teollisuudessa käsittelytavat eivät kuitenkaan olleet vielä vakiintuneita ja käytettävät ohjelmistot sekä vioista kerättävä tieto eivät olleet yhtenäisiä tutkimusten välillä. Osassa heidän analysoimissaan tutkimuksissa järjestelmä tuotti hyvin vähän tietoa laadusta, kun taas osassa se kertoi vian tarkan sijainnin, koon ja tyypin. Laadunvalvontaa voidaan toteuttaa vain poikkeamia etsimällä ohjaamattoman oppimisen keinoin tai tarkkoihin vikatyyppeihin luokittelemalla ohjatun oppimisen ja osittain ohjatun oppimisen keinoin (Manta-Costa *et al.*, 2024).

3.2.1 Laadunvalvonnan haasteet

Laadunvalvonnan haasteet ovat hyvin samankaltaisia kuin ennustavan huollon haasteet, sillä laadunvalvonnassa tavoitteena on löytää vikoja tuotteesta, kun taas ennustavassa huollossa etsitään vikoja koneista, joten prosesseissa on paljon yhtäläisyyksiä. Keskei-

nen ero on kuitenkin se, että vianetsinnän kohde vaihtuu koko ajan sekä samalla koneella saatetaan tehdä useita eri tuotteita, jolloin samojen antureiden pitää soveltua laajemmin eri käyttötarkoituksiin.

Nopeus ja tuotteiden vaihtuvuus nostetaan Manta-Costa et al. (2024) artikkelissa keskeisiksi ongelmiksi. Nopeuden takia mallin pitää kyetä käsittelemään dataa vähintään yhtä nopeasti kuin tuotantolinjalla etenee tuotteita, mikä on haastavaa suurien mallien tai hyvin nopeiden linjastojen kanssa. Kyky vaihtaa uusiin tuotteisiin lyhyen ajan sisällä, kun koneella valmistetaan eri tuotteita sekä pidemmällä aikavälillä, kun tuotteisiin tulee päivityksiä, vaatii jatkuvaa mallien kehittämistä. Babic et al. (2021) mainitsee jatkuvan kehittämistarpeen lisäksi kamerapohjaisten järjestelmien ongelmaksi erilaisten tuotteiden kuvaamisen, sillä esimerkiksi tummaa mattapintaista tuotetta täytyy kuvata hyvin erilaisella valotuksella ja kameran asetuksilla kuin vaaleaa ja kiiltävää esinettä.

3.3 Tuotannonohjaus

Yksittäisten prosessien tasoa ylempänä tuotannonohjauksessa koneoppimista voidaan hyödyntää prosessien ohjaamisessa ja valvonnassa, varastonhallinnassa ja materiaalivirtojen ohjaamisessa, aikataulutuksessa ja aika-arvioiden luomisessa. Monet tuotannonohjauksen tehtävät ovat vahvistusoppimisen avulla ratkaistavia ongelmia, sillä niissä on selkä tavoite ja rajatut toimintamahdollisuudet. Esimerkiksi automaattitrukkien reittivalintojen automatisointi tapahtuu vahvistusoppimisen menetelmillä. (Usuga Cadavid *et al.*, 2020)

Ördek et al. (2024) nostaa erityisesti aikataulutuksessa saavutettavat hyödyt esille. Simuloimalla pystytään saavuttamaan hyviä tuloksia, mutta nekin ovat yleensä sääntöpohjaisia, jolloin niiden kyvykkyydet ovat rajallisemmat. Vahvistusoppimista hyödyntämällä pystytään huomioimaan useita tavoitteita, kuten tuotantokustannukset, läpäisyaika, tasapainoinen työkuorma ja joustavuus, mikä vaatisi sääntöpohjaiselta järjestelmältä monimutkaista laskentaa.

3.3.1 Tuotannonohjauksen haasteet

Jotta tehtaasta voidaan koota riittävästi dataa tuotannonohjausta varten, vaaditaan paljon infrastruktuuria. Koneoppimismalli on myös vaikeaa saada huomioimaan kokonaisuus, josta tuotannonsuunnittelijalla yleensä olisi hyvä ymmärrys. (Manta-Costa *et al.*, 2024) Ördek et al. (2024) analysoimista tutkimuksista yhdessäkään ei ollut koko tuo-

tannonsuunnittelua annettu koneoppimismallille oikeassa tehtaassa. Tämä viittaisi siihen, että rajatuissa suunnitteluongelmissa mallit toimivat hyvin, mutta tuotannonsuunnittelijan tehtävää on vaikea korvata.

3.4 Toimitusketjun hallinta

Toimitusketjun hallinnassa keskeisessä osassa on ajantasaisen tiedon ja ennusteiden saatavuus. Rakholia et al. (2024) mukaan koneoppimisalgoritmit voivat analysoida varastotasoja, tehdä kysyntäennusteita ja huomioida logistiset haasteet tuotannonsuunnittelussa, varastonhallinnassa ja jakelussa. Näillä keinoilla voitaisiin saavuttaa parannuksia asiakastyytyväisyyteen, vähentää varaston loppumisia ja lyhentää toimitusaikoja. Bertolini et al. (2021) jakoivat toimitusketjun hallinnan sovellukset mallinnukseen ja koordinointiin, kysynnän ennustamiseen ja varastonhallintaan. Käytännössä kaikissa kuitenkin koneoppimista hyödynnettiin toimittajien ja asiakkaiden ja materiaalivirtojen mallintamiseen ja tulokset olivat perinteisiä menetelmiä hieman parempia.

3.4.1 Toimitusketjun hallinnan haasteet

Analysoiduissa artikkeleissa ei mainita erityisesti toimitusketjun hallintaa koskevia haasteita, mutta aiemmin mainitut dataa, mallien valintaa ja luotettavuutta koskevat ongelmat vaikuttavat myös toimitusketjun hallintaa varten tehtyihin sovelluksiin.

3.5 Esteitä koneoppimisen käyttöönottoon

Koneoppiminen on lupaava teknologia, mutta sen hyödyntäminen valmistavassa teollisuudessa ei ole vielä kovin laajaa. Cannas *et al.* (2024) tunnistivat 22 estettä tekoälysovellusten käyttöönottoon toimitusketjussa viidestä kategoriasta: taloudelliset, organisatoriset, strategiset, teknologiset ja lailliset syyt. Tutkimuksen löydökset ovat tarkemmin esitetty taulukossa 4.

Taulukko 4: Cannas et al. (2024) tunnistamat esteet tekoälysovellusten käyttöönottoon teollisuudessa (mukaillen lähteestä Cannas et al. 2024)

Kategoria	**Esteet**
Taloudelliset esteet	Korkeat investointikustannukset, oman pääoman puute ja ulkoisen rahoituksen saamisen vaikeus
	Investointien taloudellisten hyötyjen epäselvyys, kokemuksen puute teknologiaan investoinnista
	Investointipäätöksiä tukevien riskienhallintatyökalujen puute
Organisatoriset esteet	Osaavan työvoiman puute
	Yrityksen sisäinen kulttuuri ei tue teknologista edistymistä
	Muutosvastaisuus
	Tietämyksenhallintajärjestelmien ja sidosryhmien yhteistyön puute
Strategiset esteet	Muutoksien vaikeus ja heikko muutosjohtaminen
	Teknologiastrategian puuttuminen ja heikko lähestymistapa käyttöönottoon
	Ylimmän johdon sitoutumisen puute
	Lean-tuotannon ja jatkuvan kehittämisen puute
	Sidosryhmien heikko sitoutuminen
	Huono teknologian ymmärrys ja sen strategisen tärkeyden ymmärtämättömyys
	Tutkimuslaitosyhteistyön puute
	Huonot tutkimus- ja kehittämistoiminnan käytännöt
Teknologiset esteet	Huono IT-infrastruktuuri
	Eri laitteiden ja teknologioiden integraatio-ongelmat
	Haluttu teknologia on vielä uusi
	Tiedonjakamisen vastustus
	Huonolaatuinen data
Lailliset esteet	Tietoturvan lainsäädännön puute
	Standardien ja säädöksien puute datan omistajuuden ja tekijänoikeuksien osalta

3.6 Parhaat toimintatavat koneoppimisen hyödyntämiseen valmistavassa teollisuudessa

Esteet antavat suuntaa sille, mitä kannattaa tehdä, jos koneoppimista haluaa hyödyntää toiminnassa. Rakholia et al. (2024) myös ehdottavat oman tutkimuksensa lopussa parhaita toimintatapoja tekoälyteknologioiden hyödyntämiseen. Heidän tutkimuksessansa eriteltiin 10 asiaa: laadukkaan datan saatavuuden varmistaminen, eri alojen osaajien yhteistyön tukeminen, tietoturvan priorisointi, aloitus pienillä kokeiluilla ennen laajempaa

käyttöönottoa, koulutuksen tarjoaminen henkilöstölle, eettisten ongelmien huomioiminen, säädösten ja lainsäädännön seuraaminen, paikallisen ja pilvilaskennan yhdistely, teknologian suorituskykyindikaattoreiden määrittely ja seuraaminen sekä palaute- ja seurantajärjestelmien kehittäminen. Mikään näistä ei vaikuttaisi suoraan Cannas et al. (2024) tunnistamiin taloudellisiin esteisiin, mutta hyvät käytännöt ja osaamisen kartoittaminen auttaisivat niihin epäsuorasti, sillä taloudellisen hyödyn ja riskien arviointi helpottuisi, mikä taas parantaisi rahoituksen saamisen mahdollisuuksia.

Manta-Costa et al. (2024) esittivät suunnitteluperiaatteita teollisuustekoälylle. He mainitsevat työssään laajalti samoja asioita kuin Rakholia et al. (2024) ja Cannas et al. (2024), mutta työssä korostetaan erityisesti kestävyyden ja standardoinnin puute. Kestävyydellä tutkimuksessa viitataan käytäntöihin, jotka mahdollistavat teknologian ylläpidon ja kehittämisen tulevaisuudessa ja standardoinnilla käytänteiden ja datan yhtenäistämiseen sekä yrityksen, että koko toimialan sisällä. Taulukossa 5 on eritelty parhaita toimintatapoja koneoppimisen hyödyntämiseen teollisuudessa.

Taulukko 5: Parhaita toimintatapoja koneoppimisen hyödyntämiseen teollisuudessa.

Toimintatapa	Miksi kannattaa tehdä
Järjestelmällinen datan kerääminen ja tallentaminen	Mahdollistaa mallien koulutuksen ilman, että dataa tarvitsee kerätä tai käsitellä paljoa
Henkilöstön yhteistyö ja koulutus	Vähentää muutosvastaisuutta Tukee kehitystä Lisää luottamusta
Eettisten ongelmien huomioiminen	Lisää luottamusta Lisää läpinäkyvyyttä
Tietoturvan huomioiminen	Lisää luottamusta Estää tietovuotoja
Palautejärjestelmien käyttöönotto	Tukee jatkuvaa kehittämistä Auttaa ongelmakohtien löytämisessä
Ylläpitoon panostus	Varmistaa teknologian luotettavuuden tulevaisuudessa Mahdollistaa jatkuvan kehittämisen
Datan ja toimintatapojen standardointi	Helpottaa teknologian laajaa käyttöönottoa Helpottaa koulutusta

4. PÄÄTELMÄT

Tämän tutkimuksen tavoitteena oli tarkastella koneoppimisen hyödyntämisen nykytilaa valmistavan teollisuuden yrityksissä ja tunnistaa hyviä toimintatapoja koneoppimisen käyttöönoton edistämiseksi. Näiden kahden kysymyksen ohjaamana saatiin parempi ymmärrys siitä, mitä koneoppimisella voidaan saavuttaa ja mitä yritykset voivat tehdä hyötyjen saavuttamiseksi. Tutkimuksen merkittävimmät tulokset käydään läpi tässä osiossa ja ne ovat esitetty taulukossa 6.

4.1 Tutkimuksen tulokset

Tutkimuksen alussa tutkimusta ohjaamaan valittiin kaksi tutkimuskysymystä: miten koneoppimista voidaan hyödyntää valmistavassa teollisuudessa, ja millä tavoilla koneoppimisen käyttöönottoa voidaan tukea valmistavassa teollisuudessa? Ensimmäiseen kysymykseen vastauksena tunnistettiin neljä asiaa: ennustava huolto, laadunvalvonta, tuotannonohjaus ja toimitusketjun hallinta. Ennustava huolto on koneiden kunnon mallintamista anturidataa analysoimalla, jolloin vikaantumiset on mahdollista ennustaa. Tämä vähentää turhaa huoltamista sekä koneiden rikkoutumisia optimoimalla huollot todellisen tarpeen mukaisiksi. (Lazzaro, D'Addona ja Merenda, 2024; Manta-Costa *et al.*, 2024)

Koneoppimispohjainen laadunvalvonta on tuotteiden laadun mallintamista anturidataa analysoimalla. Sen avulla voidaan tehdä laadunvalvonnasta nopeampaa, kattavampaa ja tarkempaa. (Babic, Farahani ja Wuest, 2021; Manta-Costa *et al.*, 2024; Ördek, Borgianni ja Coatanea, 2024)

Tuotannonohjauksessa koneoppiminen on pääasiassa vahvistusoppimisen menetelmiä hyödyntäen tehtyä optimointia. Sitä voidaan hyödyntää aikataulujen, materiaalivirtojen ja kaluston käytön suunnittelussa huomioiden halutut tavoitteet. (Usuga Cadavid *et al.*, 2020; Manta-Costa *et al.*, 2024; Ördek, Borgianni ja Coatanea, 2024)

Toimitusketjun hallinnassa koneoppimista voidaan hyödyntää ennusteiden tekemisessä, varastoiden optimoinnissa ja logistiikkasuunnittelussa, mikä parantaa toimitusvarmuutta ja vähentää hukkaa. (Bertolini *et al.*, 2021; Rakholia *et al.*, 2024)

Toiseen kysymykseen on monia vastauksia, jotka kuitenkin kaikki liittyvät organisaation tapaan mahdollistaa koneoppimista, eikä itse koneoppimisen tekniseen toteutukseen. Keskeisimmät löydökset olivat järjestelmällinen datan hallinta, monialainen yhteistyö, pienet kokeilut ennen tuotantosovelluksia, palaute ja seuranta, eettisyys ja tietoturva

sekä standardointi. Ongelmat koneoppimisen hyödyntämisessä eivät usein johdu teknologian puutteista, vaan ne liittyvät enemmän osaamiseen ja organisaation tapaan toteuttaa asioita. Hyvillä käytänteillä ja johtamistavalla voidaan mahdollistaa koneoppimisen käyttöönottoa valmistavan teollisuuden yrityksissä. (Cannas *et al.*, 2024; Manta-Costa *et al.*, 2024; Rakholia *et al.*, 2024)

Taulukko 6: Tutkimuksen tulokset

Tutkimuskysymys	Keskeiset löydökset	Keskeiset lähteet
Miten koneoppimista voidaan hyödyntää valmistavassa teollisuudessa?	Ennustava huolto, laadunvalvonta, tuotannonohjaus ja toimitusketjun hallinta	Manta-Costa et al. (2024) Lazzaro, D'Addona & Merenda (2024) Ördek et al. (2024) Rakholia et al. (2024)
Millä tavoilla koneoppimisen käyttöönottoa voidaan tukea valmistavassa teollisuudessa?	Järjestelmällinen datan hallinta, monialainen yhteistyö, pienet kokeilut, palaute ja seuranta, eettisyys ja tietoturva, standardointi	Rakholia et al. (2024) Cannas et al. (2024) Manta-Costa et al. (2024)

4.2 Tutkimuksen arviointi ja jatkotutkimustarpeet

Tulososaan valittiin laadun varmistamiseksi vain Julkaisufoorumin tason 1–3 JUFO-luokituksen omaavissa lehdissä julkaistuja tieteellisiä artikkeleita. Artikkeleita löytyi runsaasti, mutta on mahdollista, että tärkeitä artikkeleita jäi työn ulkopuolelle, sillä koneoppiminen on nopeasti kehittyvä ala, eikä termistö ole siksi vielä vakiintunutta. Tämä asia kuitenkin tiedostettiin jo hakuja tehdessä, minkä takia monia eri hakutermejä testattiin ennen lopullisten lausekkeiden valintaa. Tutkimuskysymykset olivat melko laajoja, mikä osaltaan vaikeutti työn rajaamista, mutta haut eivät lopulta tuottaneet liian suuria tulosmääriä tarkkaa läpikäyntiä varten.

Koneoppimisen hyödyntämistapojen suhteellisen hyödyn vertailu oli saatavilla olevan aineiston avulla vaikeaa, sillä kvantitatiivista tietoa saavutetuista hyödyistä oli saatavilla todella niukasti. Yksi hyvä jatkotutkimuskohde olisi eri hyödyntämistapojen kvantitatiivinen vertailu, jotta organisaatioissa pystyttäisiin käyttämään resursseja kaikkein hyödyllisimpiin kohteisiin. Toinen jatkotutkimustarve on aiheen tapaustutkimukset, joissa tarkastellaan taloudellista puolta. Teollisuuden tapaustutkimuksia koneoppimissovelluksista kyllä löytyy, mutta saavutettuja taloudellisia hyötyjä eriteltiin hyvin harvoin. Alun perin

tutkimuksen tavoitteena oli tehdä analyysiä juuri eri menetelmien taloudellisesta hyödystä investointien kannalta, mutta tutkimusta oli saatavilla niin vähän, että taloudellista vertailua ei ollut mahdollista tehdä.

LÄHTEET

Awaisi, K.S., Ye, Q. ja Sampalli, S. (2024) ‘A Survey of Industrial AIoT: Opportunities, Challenges, and Directions’, *IEEE Access*, 12, pp. 96946–96996. Saatavilla: https://doi.org/10.1109/ACCESS.2024.3426279.

Babic, M., Farahani, M.A. ja Wuest, T. (2021) ‘Image Based Quality Inspection in Smart Manufacturing Systems: A Literature Review’, *Procedia CIRP*, 103, pp. 262–267. Saatavilla: https://doi.org/10.1016/j.procir.2021.10.042.

Bertolini, M., Mezzogori, D., Neroni, M. ja Zammori, F. (2021) ‘Machine Learning for industrial applications: A comprehensive literature review’, *Expert Systems with Applications*, 175, p. 114820. Saatavilla: https://doi.org/10.1016/j.eswa.2021.114820.

Cannas, V.G., Ciano, M.P., Saltalamacchia, M. ja Secchi, R. (2024) ‘Artificial intelligence in supply chain and operations management: a multiple case study research’, *International Journal of Production Research*, 62(9), pp. 3333–3360. Saatavilla: https://doi.org/10.1080/00207543.2023.2232050.

Ciregan, D., Meier, U. ja Schmidhuber, J. (2012) ‘Multi-column deep neural networks for image classification’, in *2012 IEEE Conference on Computer Vision and Pattern Recognition*. *2012 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 3642–3649. Saatavilla: https://doi.org/10.1109/CVPR.2012.6248110.

Duan, Y., Edwards, J.S. ja Dwivedi, Y.K. (2019) ‘Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda’, *International Journal of Information Management*, 48, pp. 63–71. Saatavilla: https://doi.org/10.1016/j.ijinfomgt.2019.01.021.

Kämäräinen, J. (2023) *Koneoppimisen perusteet*. Otatieto.

Kumar, R., Rani, S. ja Singh Khangura, S. (2023) *Machine Learning for Sustainable Manufacturing in Industry 4.0: Concept, Concerns and Applications*. 1st edn. Boca Raton: CRC Press. Saatavilla: https://doi.org/10.1201/9781003453567.

Lazzaro, A., D’Addona, D.M. ja Merenda, M. (2024) ‘A Detailed Study on Algorithms for Predictive Maintenance in Smart Manufacturing: Chip Form Classification Using Edge Machine Learning’, *IEEE Open Journal of the Industrial Electronics Society*, 5, pp. 1190–1205. Saatavilla: https://doi.org/10.1109/OJIES.2024.3484006.

Manta-Costa, A., Araújo, S.O., Peres, R.S. ja Barata, J. (2024) ‘Machine Learning Applications in Manufacturing—Challenges, Trends, and Future Directions’, *IEEE Open Journal of the Industrial Electronics Society*, 5, pp. 1085–1103. Saatavilla: https://doi.org/10.1109/OJIES.2024.3431240.

Moradi, M. ja Dass, M. (2022) ‘Applications of artificial intelligence in B2B marketing: Challenges and future directions’, *Industrial Marketing Management*, 107, pp. 300–314. Saatavilla: https://doi.org/10.1016/j.indmarman.2022.10.016.

Ördek, B., Borgianni, Y. ja Coatanea, E. (2024) ‘Machine learning-supported manufacturing: a review and directions for future research’, *Production & Manufacturing Research*, 12(1), p. 2326526. Saatavilla: https://doi.org/10.1080/21693277.2024.2326526.

Paschen, J., Wilson, M. ja Ferreira, J.J. (2020) ‘Collaborative intelligence: How human and artificial intelligence create value along the B2B sales funnel’, *Business Horizons*, 63(3), pp. 403–414. Saatavilla: https://doi.org/10.1016/j.bushor.2020.01.003.

Rakholia, R., Suárez-Cetrulo, A.L., Singh, M. ja Simón Carbajo, R. (2024) ‘Advancing Manufacturing Through Artificial Intelligence: Current Landscape, Perspectives, Best Practices, Challenges, and Future Direction’, *IEEE Access*, 12, pp. 131621–131637. Saatavilla: https://doi.org/10.1109/ACCESS.2024.3458830.

Schlosser, R.W., Wendt, O., Bhavnani, S. ja Nail-Chiwetalu, B. (2006) ‘Use of information-seeking strategies for developing systematic reviews and engaging in evidence-based practice: the application of traditional and comprehensive Pearl Growing. A review’, *International Journal of Language & Communication Disorders*, 41(5), pp. 567–582. Saatavilla: https://doi.org/10.1080/13682820600742190.

Sevilla, J., Heim, L., Ho, A., Besiroglu, T., Hobbhahn, M. ja Villalobos, P. (2022) ‘Compute Trends Across Three Eras of Machine Learning’, in *2022 International Joint Conference on Neural Networks (IJCNN)*. *2022 International Joint Conference on Neural Networks (IJCNN)*, Padua, Italy: IEEE, pp. 1–8. Saatavilla: https://doi.org/10.1109/IJCNN55064.2022.9891914.

Turing, A.M. (1950) ‘Computing Machinery and Intelligence’, *Mind, New Series*, 59(236), pp. 433–460.

Usuga Cadavid, J.P., Lamouri, S., Grabot, B., Pellerin, R. ja Fortin, A. (2020) ‘Machine learning applied in production planning and control: a state-of-the-art in the era of industry 4.0’, *Journal of Intelligent Manufacturing*, 31(6), pp. 1531–1558. Saatavilla: https://doi.org/10.1007/s10845-019-01531-7.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., *et al.* (2017) ‘Attention is All you Need’, in *Advances in Neural Information Processing Systems*. Curran Associates, Inc. Saatavilla: https://proceedings.neurips.cc/paper_files/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html (Accessed: 2 April 2024).

LIITTEET

Liite 1: Scopus-haut

Hakusana	Tulosten määrä (valittu määrä)	Valitut artikkelit
"machine learning” AND ("industry 4.0" OR manufacturing OR industrial) AND applications AND (”predictive maintenance” OR ”quality inspection” OR ”quality control” OR ”anomaly detection” OR ”production planning” OR ”production scheduling”) AND (review OR survey OR framework)	104 (3)	Lazzaro et al. 2024 Manta-Costa et al. 2024 Ördek et al. 2024
"machine learning” OR ”artificial intelligence” AND ("industry 4.0" OR manufacturing OR industrial) OR factory OR factories AND ("economic impact" OR "return on investment" OR "ROI" OR "financial analysis" OR ”mone*” OR "business case" OR "cost-benefit" OR ”best practice*”)	110 (3)	Awaisi et al. 2024 Cannas et al. 2024 Rakholia et al. 2024

Kaikille hauille tehtiin lisäksi seuraavat rajaukset:

Vuosi: 2024–2025

Kieli: Englanti

Tyyppi: Artikkeli