



**TURUN  
YLIOPISTO**  
Kauppakorkeakoulu

# **Tekoälyn hyödyt vastuullisessa toimitusketjujen johtamisessa**

Toimitusketjujen johtaminen  
kandidaatintutkielma

Laatija:  
Aapo Valtonen

Ohjaaja:  
TkT Riikka Kaipia

28.4.2025  
Turku

Turun yliopiston laatujärjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -järjestelmällä.

## Kandidaatintutkielma

**Oppiaine:** Toimitusketjujen johtaminen

**Tekijä:** Aapo Valtonen

**Otsikko:** Tekoälyn hyödyt vastuullisessa toimitusketjujen johtamisessa

**Ohjaaja:** TKT Riikka Kaipia

**Sivumäärä:** 39 sivua

**Päivämäärä:** 28.4.2025

Toimitusketjujen johtamisessa vastuullisuutta vaaditaan niin lainsäädännöltä, kuluttajilta kuin muilta sidosryhmiltäkin. Vastuullisuudesta puhuttaessa nostetaan esiin usein ainoastaan ympäristöön liittyvä vastuullisuus, mutta myös sosiaaliset ja taloudelliset vastuullisuuden ulottuvuudet tulee ottaa päätöksenteossa huomioon. Tekoäly on kasvava trendi kaikilla toimialoilla, minkä takia sen hyödyt pitää osata valjastaa vastuullisuuden edistämiseksi myös toimitusketjujen johtamisessa. Yritysten päätöksentekijät tarvitsevat siis parempaa ymmärrystä siitä, miten tekoälyteknologioita voidaan käyttää vastuullisesti toimitusketjujen johtamisen kannalta.

Tässä kandidaatintutkielmassa käsitellään viiden eri tekoälyteknologian – koneoppimisen, syväoppimisen, agenttipohjaisten järjestelmien, luonnollisen kielen käsittelyn ja geneettisen algoritmin – sovelluksia toimitusketjujen johtamisessa. Tutkielmassa esitellään myös vastuullista toimitusketjujen johtamista ympäristöllisen, taloudellisen ja sosiaalisen vastuullisuuden näkökulmasta. Jokaisessa vastuullisuuden kategoriassa esitetään keskeisiä indikaattoreita, joita voidaan ottaa päätöksenteossa huomioon. Lopuksi tutkielmassa käsitellyt tekoälyteknologiat luokitellaan indikaattoreiden pohjalta vastuullisuuden eri osa-alueisiin, mikä tarjoaa kokonais kuvan tekoälyn potentiaalista vastuullisen toimitusketjun tavoittelussa.

Tutkielman tuloksista voidaan todeta, että tekoälyn sovellukset toimitusketjujen johtamisessa ovat laajoja, ja tekoälyä on käytetty esimerkiksi kysynnän ennustamiseen, riskienhallintaan ja logistiikkaan liittyvissä monimutkaisissa optimointiongelmissa. Käsitellyistä teknologioista ainoastaan luonnollisen kielen käsittely ja geneettiset algoritmit esiintyivät kirjallisuudessa kaikissa kolmessa vastuullisuuden osa-alueessa. Sosiaalinen vastuullisuus on vastuullisuuden osa-alueista vähiten tutkittu, eikä tekoälyn konkreettisia sovelluksia ole vielä hyödynnetty laajamittaisesti sen edistämiseen.

**Avainsanat:** tekoäly, koneoppiminen, syväoppiminen, agenttipohjaiset järjestelmät, luonnollisen kielen käsittely, geneettinen algoritmi, vastuullinen toimitusketjujen johtaminen

# SISÄLLYS

<b>1</b>	<b>Johdanto</b>	<b>6</b>
1.1	Tausta	6
1.2	Tutkimuksen tavoite ja tutkimuskysymykset	7
<b>2</b>	<b>Tekoäly toimitusketjujen johtamisessa</b>	<b>9</b>
2.1	Tekoälyn käsitteet	9
2.1.1	Tekoäly	9
2.1.2	Neuroverkot	11
2.1.3	Koneoppiminen	12
2.1.4	Syväoppiminen	13
2.2	Eri tekoälyteknologiat toimitusketjujen johtamisessa	14
2.2.1	Koneoppimisen sovellukset	15
2.2.2	Syväoppimisen sovellukset	17
2.2.3	Agenttipohjaiset järjestelmät	18
2.2.4	Luonnollisen kielen käsittely	19
2.2.5	Geneettinen algoritmi	20
<b>3</b>	<b>Vastuullinen toimitusketjujen johtaminen</b>	<b>22</b>
3.1	Ympäristöllinen vastuullisuus	22
3.2	Sosiaalinen vastuullisuus	24
3.3	Taloudellinen vastuullisuus	25
<b>4</b>	<b>Tekoälyn hyödyt toimitusketjujen vastuullisuudessa</b>	<b>27</b>
4.1	Tekoälyn tuomia mahdollisuuksia vastuullisuuteen	27
4.2	Eri tekoälyteknologiat vastuullisuuden eri osa-alueilla	27
<b>5</b>	<b>Yhteenveto ja johtopäätökset</b>	<b>31</b>
	<b>Lähteet</b>	<b>33</b>

## KUVIOT

Kuvio 1 Tekoälykäsitteiden hierarkia (mukaillen Kreutzer & Sirrenberg, 2020, s. 4)	10
Kuvio 2 Keinotekoisien neuroverkon eri tasot (mukaillen Kreutzer & Sirrenberg, 2020, s. 5; Raj & Kos, 2025)	11

## TAULUKOT

Taulukko 1 Vastuullisen toimitusketjun strateginen viitekehys (mukaillen Kleindorfer ym., 2005, s. 485)	23
Taulukko 2 Sosiaalisen vastuullisuuden indikaattorit (Bhinge ym., 2015 <sup>a</sup> ja Mujkić ym., 2018 <sup>b</sup> pohjalta)	25
Taulukko 3 Tekoälyteknologiat vastuullisuuden eri osa-alueilla	30

# 1 Johdanto

## 1.1 Tausta

Toimitusketjut ovat nykyään globaaleja ja kompleksisia, minkä myötä niiden vastuullinen johtaminen on entistä vaikeampaa (Gardner ym., 2019). Tuotteiden valmistamisen ja liikuttamisen laajat ympäristövaikutukset ovat luoneet tarpeen vastuullisille toimitusketjuille (Naz ym., 2022). Yritysten on tasapainoteltava eri sidosryhmien odotusten välillä, sillä esimerkiksi sijoittajat, lainsäätäjät ja kuluttajat vaativat yhä enemmän vastuullisuutta. Yritykset siis kohtaavat kilpailullisia, hallinnollisia ja sosiaalisia paineita tuoda vastuullisia toimintatapoja yrityksen päivittäisiin operaatioihin (Naz ym., 2022). Toimitusketjun vastuullisuuden lisääminen antaa yrityksille mahdollisuuden parantaa koko yrityksen vastuullisuutta, sillä harvoin suurimmat negatiiviset ympäristövaikutukset syntyvät yrityksen ydinliiketoiminnasta, vaan nimenomaan jostakin toimitusketjun osasta (Maghsoudi ym., 2023).

Tekoäly on viime vuosien aikana ollut puheenaiheena niin akateemisissa tutkimuksissa kuin yritysten päätöksenteossakin. Tekoälyn potentiaali toimitusketjujen vastuullisuuden edistämässä on nostettu esiin monissa akateemisissa tutkimuksissa. Tekoälyn sovellukset voivat muun muassa auttaa toimitusketjun jäljitettävyydessä ja ongelmien tunnistamisessa (Sanders ym., 2019) sekä jätteen vähentämisessä ja resurssien optimoinnissa (Yadav ym., 2024; Zhang ym., 2021). Organisaatioissa on ymmärretty, että erilaisia tekoälypohjaisia ratkaisuja kannattaa ottaa käyttöön toimitusketjun eri osa-alueille helpottamaan päätöksentekoa. Erilaisia tekoälymetodeja on hyödynnetty viime vuosikymmenten aikana etenkin kysynnän ennustamisessa, riskienhallinnassa, varastohallinnassa ja vastuullisessa toimitusketjujen johtamisessa (Pournader ym., 2021).

Ennen ChatGPT:n julkaisua joulukuun ensimmäisenä päivänä vuonna 2021 tekoälyn käyttö toimitusketjuissa keskittyi lähinnä big datan ja koneoppimisen eri sovelluksiin (Kamble ym., 2021), joita osasivat käyttää lähinnä tekoälyinsinöörit ja muuten asiaan vihkiytyneet. OpenAI:n, eli ChatGPT:n kehittäjän, aloittaman trendin myötä tekoäly on nykyään kuitenkin entistä helpommin käytettävissä ilman minkäänlaista kouluttautumista, minkä myötä sen hyödyt voidaan ottaa yrityksessä käyttöön selkeästi aiempaa laajemmin (Hendriksen, 2023).

Accenturen julkaisemassa raportissa ”Technology Vision 2025 – AI: A Declaration of Autonomy” käsitellään teknologian nykyisiä ja tulevia trendejä. Raportti on ilmestynyt vuosittain jo 25 vuoden ajan, ja vuonna 2025 sen tulokset perustuvat analyysiin, jossa on hyödynnetty tekstianalyysiä ja kielimalleja tunnistamaan keskeisiä kehityssuuntia esimerkiksi akateemisen kirjallisuuden ja

sijoitustrendien pohjalta. Tämän lisäksi raportti pohjautuu asiantuntijahaastatteluihin sekä yli 4000 johtajan maailmanlaajuiseen kyselyyn, joka toteutettiin 21 toimialalla ja 28 maassa vuoden 2024 lopussa. Raportin keskeinen anti on selvä: tekoäly on tulossa kovaa vauhtia tehostamaan ja muuttamaan työntekoa kaikilla toimialoilla ja yritysjohtajien pitää ottaa kehityssuunta tosissaan. Johtajakyselyyn vastanneista 96 % aikoo kolmen vuoden sisällä ottaa joko osittain, merkittävästi tai kokonaan käyttöön tekoälypohjaisia työkaluja automatisoimaan yrityksen toimintoja. Yhden mielenkiintoisen ennustuksen mukaan vuoteen 2030 mennessä yli puolet Fortune 500 -yrityksistä hyödyntää autonomisia toimitusketjun hallintajärjestelmiä. (Narain, 2025.) Vaikka kyseessä on vain ennustus, tekoälyn ja toimitusketjujen johtamisen kehityksen voidaan perustellusti katsoa suuntautuvan kohti yhä suurempaa automaatiota. Tekoälyn käytön yleistyminen avaa mahdollisuuksia lisätä toimitusketjujen vastuullisuutta, ja sitä vaaditaan muuttuvassa yhteiskunnassa jatkuvasti enemmän. Tämän takia näiden kahden aiheen yhdisteleminen ja tutkiminen on erittäin tärkeää sekä yksittäisen yrityksen että koko yhteiskunnankin näkökulmasta.

## 1.2 Tutkimuksen tavoite ja tutkimuskysymykset

Tämän kandidaatintutkielman tavoitteena on tutkia tekoälyn käyttöä toimitusketjun vastuullisuuden eri osa-alueilla, jotka ovat sosiaalinen, ympäristöllinen ja taloudellinen vastuu (Seuring & Müller, 2008). Tavoitteena ei ole keskittyä mihinkään tiettyyn teollisuudenalaan tai toimitusketjun osaan, vaan tutkia laajalla näkökulmalla tekoälyteknologioiden vaikutusta vastuulliseen toimitusketjujen johtamiseen.

Tekoälyteknologioiden sovelluksia toimitusketjujen johtamisessa on tieteellisessä tutkimuksessa tunnistettu noin 30 kappaletta (Bhattacharya ym., 2024; Helo & Hao, 2022; Min, 2010; Naz ym., 2022; Pournader ym., 2021; Toorajipour ym., 2021; Yadav ym., 2024). Tässä tutkielmassa käsitellään kuitenkin vain viittä tekoälyteknologiaa. Rajaus on tehty, jotta käsittelyssä pysyttäisiin kandidaatintutkielman laajuudessa ja koska kyseisiä teknologioita on tarkasteltu tieteellisessä tutkimuksessa nimenomaan toimitusketjujen johtamisen näkökulmasta. Tämän lisäksi tässä kandidaatintutkielmassa käsiteltävät tekoälyteknologiat ovat geneettistä algoritmia lukuun ottamatta koneoppimisen sovelluksia, minkä myötä jokaisen yksittäisen teknologian teknisiin ominaisuuksiin ei tarvitse syvällisemmin perehtyä, koska koneoppiminen tullaan kattavasti määrittelemään tekoälyä käsittelevässä luvussa.

Myös vastuullista toimitusketjujen johtamista tarkastellaan edellä mainittujen vastuullisuuden osa-alueiden eli ympäristöllisen, sosiaalisen ja taloudellisen vastuun kautta, ja jokaiselle osa-alueelle määritetään tieteellisen tutkimuksen pohjalta selkeät indikaattorit vastuullisuuden mittaamiseen.

Indikaattoreiden myötä voidaan perustella kunkin tekoälyteknologian sijoittamista vastuullisuuden eri osa-alueiden alle.

Tutkimuksen tärkein anti löytyy tekoälyn ja vastuullisen toimitusketjun liitoskohtaa käsittelevästä luvusta, jossa tarkoituksena on luokitella tekoälyteknologioita vastuullisen toimitusketjun kolmelle eri osa-alueelle. Vaikka tekoälyn soveltamista toimitusketjujen johtamiseen on käsitelty kirjallisuudessa, vain harvat tutkimukset ovat huomioineet vastuullisuusnäkökulman. Nykyiset kirjallisuuskatsaukset (esim. Naz ym., 2022; Yadav ym., 2024) viittaavat vastuullisuuden osa-alueisiin vain pintapuolisesti ilman tarkempaa analyysiä. Tutkimukseni tavoitteena on luoda selkeä luokittelu, joka auttaisi yrityksiä arvioimaan tekoälytyökalujen vaikutuksia vastuullisuuden eri osa-alueisiin. Tämän luokittelun kautta tutkimus pyrkii syntetisoimaan akateemisesta kirjallisuudesta löytyvää tietoa ja siten auttamaan yrityksiä strategisessa päätöksenteossa alati muuttuvassa ja voimakkaasti kilpailussa ympäristössä. Tutkielmassa on tarkoitus vastata kahteen tutkimuskysymykseen:

- Miten erilaisia tekoälyteknologioita voidaan käyttää toimitusketjujen johtamisessa?
- Miten tekoälyteknologiat voidaan luokitella vastuullisen toimitusketjun eri osa-alueille?

Tutkimus toteutetaan kirjallisuuskatsauksena. Kirjallisuuskatsaus on toteutettu avainsanahaulla erilaisista tietokannoista. Avainsanoina ovat toimineet esimerkiksi seuraavat: ”supply chain”, ”supply chain management”, ”sustainable supply chain management”, ”supply chain environmental sustainability”, ”artificial intelligence”, ”machine learning”, ”artificial intelligence applications” ja näiden hakusanojen yhdistelmät sekä sovellukset. Jokainen tutkielman rajaukseen soveltuva artikkeli on tarkastettu Julkaisuforumissa, ja mikäli artikkeli ei saavuta vähintään 1. tasoa, ei sitä ole tässä kandidaatintutkielmassa käytetty. Hakutietokantoina ovat toimineet suurimmalta osin Scopus ja Google Scholar. Kirjallisuuskatsauksen avulla voidaan muodostaa kattava kuva tekoälyn hyödyntämisestä vastuullisessa toimitusketjujen johtamisessa ja mahdollisesti ehdottaa uusia suuntia aiheen jatkotutkimusta varten.

## 2 Tekoäly toimitusketjujen johtamisessa

### 2.1 Tekoälyn käsitteet

#### 2.1.1 Tekoäly

Tekoälyn kehitys on kulkenut sykleissä noin 1950-luvulta alkaen aina tähän päivään asti. Voidaan katsoa, että tekoälyn kehityksessä on ollut kaksi selkeää ”tekoäly-talvea”, jolloin median ja yleisön kiinnostus tekoälysovelluksia kohtaan ei ole kohdannut teknologisten realiteettien kanssa, ja siksi sijoittajien kiinnostus tekoälyn kehittämistä kohtaan laskee (Muthukrishnan ym., 2020). 1990-luvun keskivaiheilta lähtien kiinnostus tekoälyn kehittämiseen lisääntyi tietokoneiden laskentatehon kasvun myötä, ja sillä tiellä alan kehitys on edelleen.

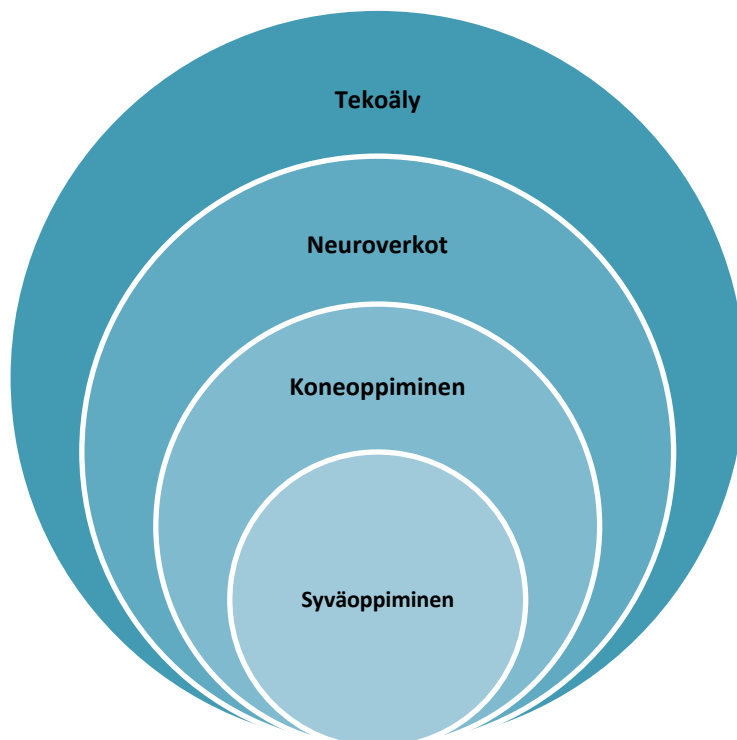
Matemaatikko Alan Turing esitti vuonna 1950 ensimmäistä kertaa kysymyksen siitä, pystyykö kone matkimaan ihmisen älykkyyttä. Turingin testissä ihminen käy keskustelua toisen ihmisen sekä koneen kanssa tietämättä, kumpi on kumpi. Mikäli ihminen ei pysty keskustelemalla erottamaan ihmistä koneesta, kyseisen koneen voidaan katsoa läpäisseen testin ja osoittaneen älykkyyttä. (Turing, 1950.) Turingin testin läpäisyä voidaankin pitää tekoälyn tavoitteena (Muthukrishnan ym., 2020), ja vaikka nykyään ymmärretään keskustelukyvykkyyden olevan vain yksi osa tekoälyä, ovat Turingin ajatukset tekoälyn historian kannalta merkittäviä.

Termin ”tekoäly” määritelmästä on monia eri tulkintoja. Yksinkertaisesti tekoäly voidaan määritellä koneen kyvyksi suorittaa aiemmin ihmisen suorittamia kognitiivisia tehtäviä, jotka sisältävät kyvyn tarkastella ympäristöä sekä perustella ja oppia itsenäisesti. Oppimisen myötä kone osaa myös löytää ratkaisuja ongelmiin ilman ohjausta. (Kreutzer & Sirrenberg, 2020, s. 3.) Toinen määritelmä keskittyy enemmän datalähtöisyyteen: tekoäly määritellään järjestelmän kykyä tulkita ulkoista dataa oikein, oppia datasta ja sitä kautta saavuttaa asetettuja tavoitteita joustavan sopeutumisen myötä (Kaplan & Haenlein, 2019). Määritelmien moninaisuudesta huolimatta yhdistävä ajatus on tietokoneiden lisääntynyt kyvykyys tehdä ihmisille tarkoitettuja tehtäviä yksittäisen työpaikan tai yleisesti koko yhteiskunnan näkökulmasta (Dwivedi ym., 2021).

Tekoälyä on määritelty monella eri tavalla painottaen eri asioita, mutta kaikista määritelmistä tulee ilmi yhteinen tavoite: tehdä koneesta ihminen. Kaplan & Haenlein (2019) esittelevät artikkelissaan tekoälyn jaottelun, jossa hahmotellaan tekoälyn inhimillistymisen astetta. Kirjoittajat jakavat tekoälyjärjestelmät vapaasti suomennettuna analyttiseksi tekoälyksi (engl. analytical AI), ihmisestä vaikutteita saaneeksi tekoälyksi (engl. human-inspired AI) ja ihmismäiseksi tekoälyksi (engl.

humanized AI). Analyttinen tekoäly käyttää ainoastaan kognitiivisia kyvykkyyksiä, kuten loogista ajattelua ja päättelyä, tehdessään päätöksiä. Tällainen tekoäly oppii menneistä kokemuksista ja soveltaa oppimaansa tulevaan. Suurin osa nykypäivän tekoälyteknologioista voidaan kategorisoida analyttiseksi tekoälyksi (Kaplan & Haenlein, 2019). Ihmisestä vaikutteita saanut tekoäly yhdistää kognitiiviset kyvykkyydet tunneälyyn, minkä myötä se osaa tunnistaa ja analysoida ihmisten tunteita ja ottaa ne huomioon päätöksenteossa. Ihmismäinen tekoäly sisältää edellisten lisäksi vielä sosiaalisen älykkyyden, eli se on itseään tiedostava (engl. self-aware) kommunikoidessaan ihmisten kanssa (Kaplan & Haenlein, 2019). Kysymys siitä, voiko tekoäly tiedostaa itsensä, on esimerkiksi taideyhteisössä ollut pohdinnan kohteena (Liu, 2023), mutta tekoälyn kehitys ei vielä ole saavuttanut ihmismäisen tekoälyn tasoa (Kaplan & Haenlein, 2019).

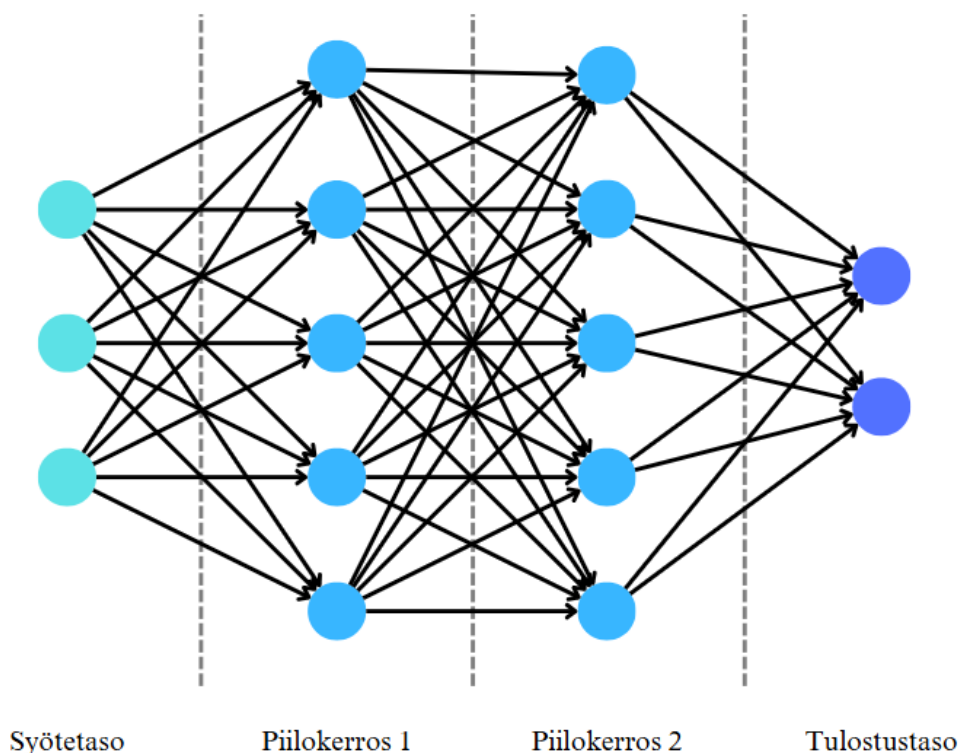
Kreutzer ja Sirrenberg (2020) lähestyvät kirjassaan tekoälyn vaikeasti hahmoteltavaa termistöä kuviolla, jossa tekoäly nähdään yläkäsitteenä, jonka sisään kuuluvat hierarkkisesti neuroverkot, koneoppiminen ja syväoppiminen. Tekoälyä käsittelevässä kirjallisuudessa termejä on jaoteltu eri tavoin. Esimerkiksi Muthukrishnan ym. (2020) on jättänyt hierarkiastaan pois neuroverkot ja sisällyttänyt ne syväoppimisen alle. Tässä tutkielmassa neuroverkot käsitellään kuitenkin erillisenä aiheena, mikä auttaa ymmärtämään paremmin sekä koneoppimista että syväoppimista. Alla oleva Kuvio 1, joka mukailee Kreutzerin ja Sirrenbergin (2020) kirjan esitystä, havainnollistaa tekoälykäsitteiden hierarkiaa.



Kuvio 1 Tekoälykäsitteiden hierarkia (mukaillen Kreutzer & Sirrenberg, 2020, s. 4)

## 2.1.2 Neuroverkot

Keinotekoiset neuroverkot ovat malleja, jotka matkivat aivojen biologista hermoverkkoa. Kuten ihmisen aivot, keinotekoiset neuroverkot koostuvat toisiinsa aivosynapsien mukaisesti kytketyistä neuronien kaltaisista laskentayksiköistä. (Tanaka ym., 2019.) Neuroverkoissa on yleensä monta eri tasoa, jotka keskustelevat keskenään (ks. Kuvio 2): syötetaso (engl. input layer) ottaa raakadataa vastaan ja välittää tiedon eteenpäin, piilokerrokset (engl. hidden layers) suorittavat varsinaisen laskennan raakadatan ja ennalta määrättyjen painotusten pohjalta ja tulostuskerros (engl. output layer) antaa lopputuloksen käsitellylle datalle (Kreutzer & Sirrenberg, 2020, s. 5; Raj & Kos, 2025; Schmidhuber, 2015).



Kuvio 2 Keinotekoisien neuroverkon eri tasot (mukaillen Kreutzer & Sirrenberg, 2020, s. 5; Raj & Kos, 2025)

Neuroverkot jaetaan kirjallisuudessa arkkitehtuurinsa mukaan kahteen eri tyyppiin: eteenpäin syöttäviin (engl. feedforward networks) ja toistuviin neuroverkkoihin (engl. recurrent networks). Yksinkertaistettuna näiden ero on se, että eteenpäin syöttävät neuroverkot käsittelevät dataa suoraviivaisesti ilman takaisinkytkentöjä, eli käsitelty tieto menee tasolta seuraavalle katsomatta taakseen, kun taas toistuvissa neuroverkoissa tieto voi liikkua tasojen välillä vapaasti. (Tanaka ym., 2019.) Jo 1990-luvulla nostettiin tieteellisessä kirjallisuudessa esiin eteenpäin syöttäviä neuroverkoja ja mainittiin isona etuna muun muassa niiden kestävyys (engl. robustness), eli kyky

säilyttää toimintakyky vioista ja häiriöistä huolimatta (Minai & Williams, 1994). Tällaista neuroverkkoa voidaan soveltaa esimerkiksi robotiikassa (Raj & Kos, 2025) ja yleisesti staattisen, ei-aika-perusteisen datan käsittelemisessä (Tanaka ym., 2019). Toistuvat neuroverkot taas soveltuvat dynaamisen eli aikaperusteisen datan käsittelyyn, mikä tekee mahdolliseksi esimerkiksi tekstin- ja puheentunnistuksen sekä ennustavan analytiikan (Barredo Arrieta ym., 2020; Tanaka ym., 2019).

### 2.1.3 Koneoppiminen

Yksi tekoälyn sovelluksista, koneoppiminen, perustuu algoritmeihin, jotka oppivat suoritettavasta tehtävästä koulutusdatan perusteella. Koneoppimismallien oppimisprosessiin voidaan tuoda mukaan myös olemassa olevaa asiantuntemusta koulutusdatan lisäksi. (Simeone, 2018.) Koneoppimisessa suuri määrä koulutusdataa opettaa koneita, eikä ohjelmoijien tarvitse puuttua oppimisprosessiin (Kreutzer & Sirrenberg, 2020, s. 6). Akateemisessa tutkimuksessa on yleisesti tunnistettu kolme eri koneoppimismetodia: valvottu oppiminen (engl. supervised learning), valvomaton oppiminen (engl. unsupervised learning) ja vahvistusoppiminen (engl. reinforcement learning) (Kaplan & Haenlein, 2019; Kreutzer & Sirrenberg, 2020, s. 6-7; Pournader ym., 2021; Simeone, 2018).

Valvotussa oppimisessa koulutusdata koostuu syötteen ja halutun tuloksen pareista (Kaplan & Haenlein, 2019; Simeone, 2018). Oppimismallin tavoitteena onkin opettaa algoritmia yhdistämään syötteet haluttuihin tuloksiin (Kreutzer & Sirrenberg, 2020, s. 6). Suurin osa koneoppimismalleista lukeutuu valvotun oppimisen alle (Simeone, 2018), ja esimerkiksi aiemmin tässä tutkielmassa esitetyt neuroverkot kuuluvat kyseiseen kategoriaan (Kaplan & Haenlein, 2019). Valvotussa oppimisessa järjestelmällä on siis halutut lopputulokset tiedossa, ja algoritmien on opittava tuottamaan nämä lopputulokset mahdollisimman tarkasti. Jos valvotun oppimisen pohjalta haluttaisiin opettaa algoritmia tunnistamaan koira, näytettäisiin sille massiiviset määrät erilaisia kuvia, joihin on liitetty tunnisteet ”koira” ja ”ei-koira”, ja esimerkkitiedon perusteella algoritmi mukauttaisi toimintaansa siten, että se tunnistaa malliin syötettävät uudet kuvat mahdollisimman tarkasti joko koiraksi tai ei-koiraksi.

Valvomattomassa oppimisessa tekoälyjärjestelmällä ei ole ennalta määriteltyjä tavoitearvoja, vaan algoritmin täytyy itse löytää samankaltaisuuksia ja kaavamaisuuksia annetusta koulutusdatasta (Kreutzer & Sirrenberg, 2020, s. 7). Lopputulos siis määräytyy algoritmin itsensä perusteella, mikä voi johtaa odottamattomiin tai yllättäviin tuloksiin ja sen myötä herättää epävarmuutta käyttäjissä. Koneoppimismalli käyttää esimerkiksi klusterointia (engl. cluster analysis) ryhmitelläkseen samankaltaisia elementtejä ilman ennalta määriteltyjä parametrejä. (Kaplan & Haenlein, 2019.) Käytännössä tämä voi tarkoittaa esimerkiksi dokumenttien ryhmittelyä aiheen perusteella (Simeone,

2018), Applen Siri-ääniassistenttia (Kaplan & Haenlein, 2019) tai sosiaalisen median käyttäjien profilointia heidän toimintansa perusteella (Kreutzer & Sirrenberg, 2020, s. 7).

Vahvistusoppiminen sijoittuu valvotun ja valvomattoman oppimisen väliin. Tässä metodissa koulutusprosessin alussa ei ole optimaalista ratkaisua, vaan koneoppimisalgoritmin pitää itse kokeilla eri vaihtoehtoja ja mukauttaa toimintaansa saamansa palauteen avulla (Kaplan & Haenlein, 2019; Kreutzer & Sirrenberg, 2020, s. 7; Simeone, 2018). Algoritmia käytetään etenkin tilanteissa, joissa harjoitusdata on rajallista ja ihanteellista lopputulosta on haastava määrittellä, tai tilanteissa, joissa oppiminen tapahtuu parhaiten ympäristön kanssa keskustelemalla (Kreutzer & Sirrenberg, 2020, s. 7). Vahvistusoppimista käyttävä algoritmi oppisi tunnistamaan koiran vastaanottamalla erilaisia kuvia ja päättämällä kokeilujen kautta, mitkä kuvista esittävät koiraa ja mitkä eivät. Jos algoritmi tunnistaa koiran oikein, se saa palkinnon, ja mikäli väärin, seuraa rangaistus. Vahvistusoppimista on käytetty myös esimerkiksi robotiikassa (Matsuo ym., 2022).

#### 2.1.4 Syväoppiminen

Syväoppiminen on koneoppimisen alalaji, joka mahdollistaa laajemman tietomateriaalin käsittelyn, tuottaa usein tarkempia lopputuloksia ja tarvitsee vähemmän ihmisten tekemää manuaalista datan esikäsitteilyä (Kreutzer & Sirrenberg, 2020, s. 8). Syväoppiminen ei niinkään vaadi mitään tiettyä koneoppimisen mallia, vaan sitä voidaan soveltaa useissa malleissa (Matsuo ym., 2022; Schmidhuber, 2015). Matsuo ym. (2022) mukaan syväoppimisen tavoitteena on löytää ongelman ratkaisemiseksi optimaalinen funktio. Syväoppiminen käyttää ”universaalista funktioaprosimaattoria” (s. 271) eri ongelmien ratkaisemiseen. Se sisältää suuren määrän erilaisia neuroverkkoja, jotka voivat kuvata minkä tahansa funktion valitulla tarkkuudella ja sitä kautta ratkaista määrätyn ongelman optimaalisella tavalla.

Syväoppimista käsiteltäessä pitää tuoda esiin neuroverkkojen koulutusmalleista takaisinkytkentä (engl. backpropagation), jossa neuroverkon edellisiä kerroksia tarkastellaan ja niiden painokertoimia säädetään niin, että laskenta tarkentuu kohti odotettua lopputulosta (Rumelhart ym., 1986). Tällainen menetelmä toimii sellaisenaan yksinkertaisempien neuroverkkojen kouluttamisessa, mutta syväoppimista käyttävien neuroverkkojen kanssa takaisinkytkentä tuo haasteita (Kohl & Miikkulainen, 2009; Schmidhuber, 2015). Kohlin ja Miikkulaisen (2009) mukaan suuri määrä laskentatasoja vaikeuttaa virhesignaalin oikeanlaista käsittelyä. He ehdottavat, että syväoppimismallit koulutettaisiin ensin valvomattoman oppimisen menetelmillä, mikä auttaisi asettamaan neuroverkon painojen lähtöarvot hyvään tasoon. Tämän myötä takaisinkytkentää voidaan helpommin käyttää neuroverkon jatkokoulutukseen.

Vuosituhanne vaihteen jälkeen jatkuvasti noussut laskentateho, muun muassa halvemmalla saataville tulleiden grafiikkaprosessorien (engl. Graphics Processing Unit / GPU) myötä, on kiihdyttänyt neuroverkkojen oppimista jopa 50-kertaisesti (Schmidhuber, 2015). Kehitys on luonnollisesti jatkunut edelleen, ja nykyään voidaan puhua jopa 1208-kertaisesta laskentanopeudesta verrattuna perinteiseen keskusprosessorilla (engl. Central Processing Unit / CPU) suoritettuun laskentaan (Landsmeer ym., 2024). Nykypäivänä syväoppimista hyödyntäviä algoritmeja voidaan käyttää esimerkiksi ajoneuvon kuljettajan aikomusten tunnistamiseen (Cheng ym., 2024) ja Alzheimerin taudin varhaiseen ja tehokkaaseen diagnosoimiseen (Farhatullah ym., 2025).

## 2.2 Eri tekoälyteknologiat toimitusketjujen johtamisessa

Mentzer ym. (2001) käsittelevät artikkelissaan toimitusketjujen johtamisen (engl. supply chain management / SCM) erilaisia määritelmiä ja yhdistelevät niitä tieteellisessä tutkimuksessa mainittujen määritelmien pohjalta kaikenkattavaksi määritelmäksi. Artikkelin mukaan toimitusketjujen johtaminen tarkoittaa ”yrityksen perinteisten liiketoimintatoimintojen sekä taktiikoiden järjestelmällistä ja strategista koordinoitua yrityksen sisällä sekä koko toimitusketjun yritysten välillä, tavoitteenaan parantaa sekä yksittäisten yritysten, että koko toimitusketjun pitkäaikaista suorituskykyä” (s. 18).

Tämän kandidaatintutkielman kohdealuetta varten on järkevää määritellä myös digitaalinen toimitusketju (engl. digital supply chain / DSC). Se määritellään älykkääksi teknologiseksi järjestelmäksi, joka perustuu laajamittaiseen datan käsittelyyn sekä erinomaiseen yhteistyöhön ja viestintään digitaalisen laitteiston (engl. hardware), ohjelmistojen (engl. software) ja verkkojen (engl. networks) välillä. Digitaalisen toimitusketjun tavoitteena on tukea ja synkronoida organisaatioiden välistä vuorovaikutusta tekemällä palveluista arvokkaampia, helpommin saavutettavia ja edullisempia, ja varmistamalla johdonmukaiset, ketterät ja tehokkaat lopputulokset. (Büyüközkan & Göçer, 2018, s. 165.)

Kuten johdannossa on mainittu, toimitusketjujen johtamiseen liittyviä tekoälyteknologioiden sovelluksia on tunnistettu noin 30 kappaletta, eikä niiden kaikkien esittely ole tässä tutkielmassa tarkoituksenmukaista. Tässä tutkielmassa käsitellään siis ainoastaan koneoppimista, syväoppimista, luonnollisen kielen käsittelyä, agenttipohjaista mallinnusta ja geneettistä algoritmia. Käsittely rajataan toimitusketjun johtamisen kannalta merkittävimpiin teknologioihin, jotka ovat suoraan tekoälypohjaisia teknologioita. Sen sijaan teknologiat, jotka ovat itsenäisesti olemassa ja voidaan integroida tekoälyn kanssa, on jätetty tutkielman ulkopuolelle. Tästä syystä esimerkiksi tekoälyä

hyödyntävä lohkoketju (engl. blockchain), tekoälypohjainen esineiden internet (engl. Internet of Things) ja ohjelmistorobotiikka (engl. robotic process automation / RPA) (ks. Yadav ym., 2024) on jätetty pois tutkielmasta. Seuraavaksi käsitellään viittä valikoitua tekoälyteknologiaa ja niiden sovelluksia toimitusketjujen johtamisessa. Tarkoituksena ei ole paneutua syvällisemmin tekoälyteknologioiden teknisiin ominaisuuksiin, sillä tekoäly on kattavasti selitetty edellisessä alaluvussa 2.1.

### 2.2.1 Koneoppimisen sovellukset

Koneoppiminen (engl. Machine Learning) voi auttaa ymmärtämään toimitusketjun eri yritysten motiiveja jakaa tärkeää tietoa toimitusketjussa ja tehdä yhteistyötä keskenään. Koneoppimisen avulla voidaan löytää keinoja parantaa yritysten välistä yhteistyötä. (Min, 2010.) Koneoppimisen roolia toimitusketjujen johtamisessa on tähän mennessä tutkittu ainakin seuraavilla toimitusketjun osa-alueilla: kysynnän ennustaminen, tuotannon suunnittelu ja hallinta, riskienhallinta sekä logistiikka (Long ym., 2025).

Kysynnän ennustaminen on toimitusketjun tehokkuuden kannalta tärkeää (Aamer ym., 2021; Feizabadi, 2022). Carbonneau ym. (2008) tutkivat koneoppimisen sovelluksia toimitusketjun kysynnän ennustamisessa ja vertailevat tuloksia perinteisiin ennustusmenetelmiin, kuten naivistiseen ennusteeseen, trendiin perustuvaan ennusteeseen ja liukuva keskiarvo -ennusteeseen. Tutkimuksessa käytettiin sekä simuloitua että oikeaa dataa. Tulokset ovat selkeitä: koneoppimisen sovellukset tuottavat tarkempia kysyntäennusteita verrattuna perinteisiin menetelmiin. Myös Feizabadin (2022) tutkimus, jossa vertailtiin koneoppimiseen pohjautuvia ennustusmenetelmiä perinteisiin menetelmiin terästeollisuuden yrityksen kysynnän ennustamisessa, osoittaa, että monimutkaisia riippuvuuksia hahmottavat mallit (koneoppiminen) suoriutuvat ennustamistehtävästä paremmin kuin perinteiset ennustamismallit. Parantunut kysynnän ennustamisen tarkkuus johtaa suoraan myös taloudellisen ja operatiivisen suorituskyvyn parannuksiin (Feizabadi, 2022).

Esimerkiksi Covid-19-pandemian aikana huomattiin, miten toimitusketjun häiriöt voivat vaikuttaa kaikkiin toimitusketjussa osallisena oleviin yrityksiin ja sitä kautta laajemmin koko yhteiskuntaan. Sen takia toimitusketjujen riskienhallinta on tärkeää. Riskienhallinta on jo vuosituhaten alussa määritelty Jüttnerin ym. (2003) artikkelissa seuraavasti: ”toimitusketjun riskien tunnistaminen ja hallinta yhteistyössä toimitusketjun osallisten kanssa, tavoitteena vähentää toimitusketjun haavoittuvuutta kokonaisuudessaan” (s. 201). Seuraavaksi käsitellään, miten koneoppimisen sovellukset voivat auttaa riskien tunnistamisessa, arvioimisessa, lieventämisessä ja seurannassa.

Koneoppimisen käyttämää matemaattista mallinnusta voidaan käyttää automatisoituun riskien tunnistamiseen. Riskien tunnistuksen jälkeen riskit arvioidaan, ja tähän prosessiin on yleensä tarvittu kauan alalla toimineita ammattilaisia, joiden arviot voivat olla objektiivisuuden kannalta arveluttavia. Tähän ongelmaan koneoppimisen sovellukset vastaavat objektiivisella, datan ja faktojen yhdistelyyn perustuvalla analyysillä. (Yang ym., 2023.) Kun riskit on tunnistettu ja arvioitu, aloitetaan riskien lieventäminen (engl. risk mitigation). Esimerkiksi lääketeollisuudessa yhtenä toimitusketjun riskinä voidaan pitää nettiapteekkien luotettavuutta. Tämän ongelman ratkaisuksi Zhao ym. (2020) kehittivät koneoppimisalgoritmin, joka onnistui tunnistamaan nettiapteekkien laillisuuden jopa 98,6 prosentin tarkkuudella. Näin tarkka tunnistaminen auttaa asiakkaita vastuullisten valintojen tekemisessä, ja algoritmi voidaan liittää esimerkiksi hakukoneisiin, jotta laittomat nettiapteekit saadaan suodatettua pois jo hakuvaiheessa. Riskien seurannassa koneoppiminen voi säästää henkilöstökuluissa, sillä se pystyy jatkuvaan valvontaan tiettyjen riskialttiiden tuotteiden seurannassa. Riskienhallinnan lisäksi koneoppiminen voi myös arvioida toimitusketjun eri osapuolia etukäteen, mikä vähentää toimitusketjun häiriöitä. (Yang ym., 2023.)

Tuotannon suunnittelu ja hallinta auttaa toimitusketjua toimimaan tehokkaasti ja optimoidusti. Koneoppimista voidaan käyttää tuotannon tarpeiden ennustamiseen ja aikataulujen optimoimiseen. Tämän lisäksi esimerkiksi ennakoiva kunnossapito hyödyntää koneoppimista analysoidakseen laitteiden kuntoa ja ennustaakseen huoltotarpeita. Koneoppimista voidaan käyttää myös laadunvalvontaan, jolloin mallit auttavat tunnistamaan laadulliset ongelmat ja niiden syyt, mikä suoraan parantaa tuotannon tehokkuutta ja vähentää hukkaa. (Usuga Cadavid ym., 2020.)

Singh ym. (2021) käsittelevät artikkelissaan koneoppimisen sovelluksia logistiikan ongelmien ratkaisemiseen. Artikkelin mukaan koneoppimisen eri algoritmeja on logistiikassa sovellettu ainakin kuljetusreittien optimointiin ja käänteiseen logistiikkaan, jonka tarkoituksena on saada tuotteista arvoa käänteisesti kulutuspisteestä takaisin lähtöpisteeseen esimerkiksi tuotepalautusten kautta (Singh ym., 2021). Tutkimuksen tuloksista huomataan myös, että valvottua oppimista käyttävät koneoppimisen mallit ovat yleisimpiä ratkaistaessa logistiikan haasteita, kuten kysynnän epävarmuutta ja kuljetusmuotojen yhdistämistä. Valvomaton oppimista käyttävät mallit ovat taas selkeästi harvinaisempia, sillä yleensä logistiikassa voidaan soveltaa esimerkiksi aikaisempia toimitusaikoja eli kouluttaa koneoppimisen malli valvotusti historiallista dataa käyttäen. Valvomaton oppiminen voi kuitenkin auttaa esimerkiksi asiakassegmentoinnissa, jossa koneoppimismallin pitää luokitella ja yhdistellä hajanaista dataa järkeväksi kokonaisuudeksi.

## 2.2.2 Syväoppimisen sovellukset

Syväoppiminen (engl. Deep Learning) on koneoppimisen alalaji. Syväoppimista on siis käytetty samantyyliisiin toimitusketjujen haasteisiin kuin koneoppimista, joten samankaltaisuuksia näiden mallien välillä löytyy varmasti. Yleisesti voi todeta, että koska syväoppimismallit voivat käyttää hyväkseen kaikkia koneoppimisen malleja, voidaan edellisessä alaluvussa käsiteltyjä toimitusketjun ongelmia ratkaista myös syväoppimisen malleilla. Tässä alaluvussa etsitään myös eroavaisuuksia koneoppimisen ja syväoppimisen välillä, ja selvennetään niitä toimitusketjujen johtamisen osa-alueita, joilla syväoppimisen sovellukset ovat toimineet parhaiten.

Palataan hetkeksi kuitenkin arvaamattoman kysynnän ennustamiseen. Nikolopoulos ym. (2021) tutkivat artikkelissaan päivittäistavara- ja elektroniikkatuotteiden ylikysynnän ennustamista Covid-19-pandemian aikana viiden eri maan (Saksa, Intia, Singapore, Iso-Britannia ja Yhdysvallat) datan pohjalta. Tutkimuksessa havaittiin, että heidän käyttämänsä syväoppimisalgoritmi LSTM (engl. Long-Short Term Memory) saavutti 100 prosentin peittoasteen (engl. cover rate) päivittäisessä datassa. Käytännössä se tarkoittaa sitä, että syväoppimisalgoritmi onnistui ennustamaan tuotteiden kysynnän niin tarkasti, että todelliset myyntimäärät osuivat aina ennustettuun vaihteluväliin. Tämä taas todistaa sen, että algoritmi pystyy käsittelemään kysynnän vaihteluita luotettavasti haastavassa pandemiatilanteessa ja siten auttamaan päätöksentekijöitä toimimaan järkevästi.

Samalla tavalla kuin koneoppiminen, pystyy syväoppiminenkin hahmottamaan monimutkaisia kokonaisuuksia ja yhdistelemään tietoa erilaisista lähteistä nopeasti ja tarkasti. Syväoppimista onkin käytetty esimerkiksi öljymarkkinan ennustamiseen Covid-19-pandemian aikana sosiaalisen median pohjalta. Ennustus kohdistui öljyn hintaan, tuotantoon, kulutukseen ja varastointiin, ja tuloksista voidaan todeta, että sosiaalisen median tiedot voivat parantaa ennusteiden tarkkuutta öljyn hinnan, tuotannon ja kulutuksen osalta. Varastoinnin ennustuksien tarkkuuteen sosiaalinen media ei kuitenkaan tuonut parannuksia. (Wu ym., 2021.) Hosseinnia Shavakin ja Ebrahimi Ghahnaviehin (2023) tekemä kirjallisuuskatsaus osoittaa, että nimenomaan ennustamiseen liittyvät sovellukset ovat parhaiten edustettuna syväoppimisen tutkimuksessa, sillä 17 tutkimusta 43:sta käsitteli jonkinlaista ennustamista (engl. forecasting). Vaikka ennustamiseen liittyvä mallinnus on syväoppimisen tutkimuksessa selkeästi suosituin, on muitakin malleja kehitetty onnistuneesti. Syväoppimisen mallit ovat esimerkiksi onnistuneet kartoittamaan monimutkaisia toimitusketjuja uutisartikkeleiden pohjalta apunaan luonnollisen kielen käsittely (ks. alaluku 2.2.5) (Wichmann ym., 2020) ja ratkaisemaan varastonhallinnan ongelmia (Gijsbrechts ym., 2022; Meisheri ym., 2022).

### 2.2.3 Agenttipohjaiset järjestelmät

Agenttipohjaiset järjestelmät (engl. Agent-Based Systems) tarkoittavat tekoälyjärjestelmiä, jotka ratkaisevat ongelmia jakamalla ratkaistavan ongelman pienemmiksi osaongelmiksi ja käyttävät keinotekoisia itsenäisiä olemuksia, eli agentteja, näiden pienempien ongelmien ratkaisuun. Nämä agentit oppivat ympäristöstään, osaavat käsitellä suuria määriä dataa, toimivat itsenäisesti ja pystyvät viestimään päätöksistään luonnollisella kielellä. (Min, 2010.) Agentit voivat toimia joko itsenäisesti tai osana suurempaa agenttien verkostoa. Sekä yksin että isommassa verkostossa toimivat agentit pohtivat päätöksenteossaan ympäröivää toimintaympäristöä. (Toorajipour ym., 2021.)

Xu ym. (2021) toteavat artikkelissaan, että agenttipohjaisten järjestelmien sovelluksia toimitusketjujen johtamisessa on tutkittu etenkin neljässä kategoriassa. Nämä kategoriat ovat järjestyksessä tutkituimmasta vähiten tutkittuun seuraavat: hajautetut agenttiarkkitehtuurit (engl. distributed agent architectures), viestintä ja neuvottelu (engl. communication and negotiation), oppiminen ja optimointi (engl. learning and optimization) ja logiikka ja päättely (engl. logic and reasoning). Hajautetut agenttiarkkitehtuurit voidaan muodostaa kahdella eri tavalla.

Toiminnallisessa hajautuksessa (engl. functional decomposition) agentit keskittyvät tiettyihin toimitusketjun tehtäviin, esimerkiksi kysynnän ennustamiseen tai ajojärjestelyyn. Toinen tapa järjestää hajautettu agenttiarkkitehtuuri on fyysinen hajautus (engl. physical decomposition), jossa agentit esittävät erilaisia yksiköitä, esimerkiksi maantieteellisiä sijainteja tai toimitusketjun eri organisaatioita. Suurin osa toimitusketjujen johtamisen näkökulmasta tutkituista agenttipohjaisista järjestelmistä käyttävät fyysistä hajautusta.

Agenttipohjaisten järjestelmien avulla voidaan siis simuloida toimitusketjun eri toimintoja, tehdä ennustuksia ja siten optimoida toimitusketjun toimintaa. Jo viime vuosituhaten puolella Swaminathan ym. (1998) onnistuivat useiden agenttien avulla simuloimaan toimitusketjun toimintaa ja helpottamaan toimitusketjun uudelleenjärjestelyssä (engl. supply chain re-engineering). Agenttien avulla onnistuttiin epävarmuuden edessä helpottamaan toimitusketjun eri komponenttien järjestelyä, ja agenttipohjainen simulaatio nopeutti toimitusketjumallien luomista. Liang ja Huang (2006) tutkivat agenttipohjaista kysynnän ennustamista monitasoisessa (engl. multi-echelon) toimitusketjussa. Simuloidussa toimitusketjussa on neljä tasoa: toimittaja (engl. supplier), valmistaja (engl. manufacturer), jakelija (engl. distributor) ja jälleenmyyjä (engl. retailer), jotka käyttävät toiminnassaan erilaisia varastonhallintajärjestelmiä. Agentit toimivat eri tasojen sisällä ja kommunikoivat keskenään optimoidakseen tilausmääriä ja siten tavoittelevat koko toimitusketjun

kustannusten minimoimista. Tutkimus osoittaa, että simuloimalla toimitusketjun eri tasoja voidaan optimoida tilausmääriä ja sitä kautta vähentää koko toimitusketjun kustannusta.

#### 2.2.4 Luonnollisen kielen käsittely

Luonnollisen kielen käsittely (engl. Natural Language Processing) tarkoittaa tekoälyjärjestelmää, joka suorittaa tehtäviä ihmiskielen ohjeiden mukaisesti. Näitä tehtäviä voivat olla esimerkiksi kääntäminen, luokittelu, tietojen poiminta, tekstin tuottaminen ja kysymys-vastaus-järjestelmä. (Pournader ym., 2021.) Nykyaikaiset luonnollisen kielen käsittelyn sovellukset pohjautuvat suurilta osin koneoppimiseen (Wichmann ym., 2018). Aiemmin yritysten päätöstenteossa on käytetty suurimmilta osin numeerista dataa, mutta luonnollisen kielen käsittelyn avulla voidaan käsitellä nopeasti ja tehokkaasti suuret määrät myös tekstimuodossa olevaa dataa.

Tekstimuodossa olevaa dataa voidaan käyttää esimerkiksi toimitusketjun riskien tunnistukseen. Sadeek ja Hanaoka (2023) arvioivat tutkimuksessaan luonnollisen kielen käsittelyn pohjalta toimitusketjun riskejä uutisten ja sosiaalisen median alustan Twitterin (nykyisen X:n) avulla. Analyysi keskittyy kahteen kriisitilanteeseen: Covid-19-pandemiaan sekä Ukrainan ja Venäjän väliseen sotaan. Tutkimuksen mukaan luonnollisen kielen käsittely voi havaita piileviä riskejä, kuten alueellisia toimitusketjuongelmia tai jännitteitä, ennen kuin ne realisoituvat. Yhtenä tutkimuksen mielenkiintoisena löydöksenä voidaan pitää sitä, että uutisista löydetty riskit keskittyivät lähinnä toimitusketjun ”tarjonta”-päähän, kun taas Twitteristä löydetty riskit liittyivät enemmän toimitusketjun ”kysyntä”-puoleen.

Aiemmassa syvädatan sovelluksia käsittelevässä alaluvussa (ks. alaluku 2.2.2) nostettiin esille syvädatan ja luonnollisen kielen käsittelyn yhdistäminen toimitusketjun kartoituksessa (Wichmann ym., 2020). Tämän tutkimuksen pohjana toimivassa Wichmannin ym. (2018) tutkimuksessa tarkastellaan luonnollisen kielen käsittelyn soveltamista toimitusketjukarttojen automaattiseen luomiseen. Toimitusketjun kartoitus on tärkeää, sillä toimitusketjujen monimutkaistumisen ja globalisoitumisen myötä yritykset menettävät näkyvyyttä toimitusketjunsä eri tasoihin, mikä vaikeuttaa riskienhallintaa ja tehokkuuden optimointia. Tutkimuksen mukaan luonnollisen kielen käsittely voi tukea toimitusketjun näkyvyyttä analysoimalla tekstidataa, kuten uutisartikkeleita ja muita verkkolähteitä. Luonnollisen kielen käsittelyn avulla toimitusketjukarttoja voidaan luoda automaattisesti, mikä voi auttaa yrityksiä löytämään uusia toimittajia.

## 2.2.5 Geneettinen algoritmi

Geneettinen algoritmi (engl. Genetic Algorithm) eroaa edellisistä menetelmistä siten, että se ei varsinaisesti opi datasta, vaan etsii parhaita ratkaisuja kokeilemalla. Geneettinen algoritmi kuuluu evoluutioalgoritmeihin ja etsii ratkaisuja ongelmiin samalla periaatteella kuin luonnonvalinta: parhaat ratkaisut selviävät ja kehittyvät ajan myötä. (Min, 2010.) Geneettistä algoritmia käytetään usein monimutkaisiin optimointiongelmiin. Mahdolliset ratkaisut koodataan numeerisiksi merkkijonoiksi eli kromosomeiksi, jotka luovat populaation, jota kehitetään usean kierroksen ajan esimerkiksi risteytyksen (engl. crossover), mutaation (engl. mutation) ja valinnan (engl. selection) kautta. (Min, 2010, s. 18.) Nazin ym. (2022) tuottama systemaattinen kirjallisuuskatsaus osoittaa, että etenkin vastuullisen toimitusketjun kohdalla geneettinen algoritmi on suosittu käsite, sillä 353 tutkitusta artikkelista 137:ssä oli käytetty avainsanaa ”geneettiset algoritmit” (engl. Genetic algorithms).

Logistiikassa optimointiongelmat voivat usein liittyä ajoneuvojen reitityksiin. Malmborg (1996) esittää ajoneuvojen aikataulutusergelmaan ratkaisun, jossa tavoitteena on minimoida asiakirjojen tai viestintämateriaalin (engl. correspondence) keräyksen ja toimituksen välinen viive eri työpisteiden välillä. Toisessa tutkimuksessa Göçmen ja Erol (2019) tutkivat ajoneuvoreitityksen optimointia geneettisen algoritmin avulla osana laajempaa intermodaalisen kuljetusverkoston optimointia. Tutkimuksessa geneettisen algoritmin avulla löydetään kustannustehokkaita ja mahdollisimman lyhyitä reittejä rekkakuljetuksille. Molempien tutkimusten tulokset osoittavat, että geneettistä algoritmia voidaan käyttää monimutkaisten optimointiongelmiin ratkaisuun.

Toinen tieteellisessä tutkimuksessa käsitelty logistinen optimointiongelma liittyy käänteiseen logistiikkaan (engl. reverse logistics). Geneettistä algoritmia on tälläkin saralla onnistuttu käyttämään ongelmien ratkaisuun. Min ym. (2006) esittävät tutkimuksessaan geneettistä algoritmia hyödyntävän ratkaisun tuotteiden palautuslogistiikkaan. Algoritmin tavoitteena on optimoida keskitettyjen palautuskeskusten (engl. centralized return centers) lukumäärät ja optimaaliset sijainnit mahdollisimman pienillä kustannuksilla. Zorbakhshnia ym. (2020) esittelevät tutkimuksessaan geneettistä algoritmia soveltavan monitavoitteisen optimointimallin käänteiseen logistiikkaan, joka ottaa huomioon myös vastuullisuuspuolen, sillä yksi tutkimuksen tavoitteista oli maksimoida sosiaalinen vastuullisuus esimerkiksi työolosuhteiden parantamisen ja työpaikkojen luomisen kautta. Muut tavoitteet optimointimallille ovat logistiikkakustannusten, kuten kuljetuskustannusten ja hiilidioksidipäästöjen, sekä palautuslogistiikan käsittelyajan minimoiminen.

Tutkimuksen tuloksista huomataan, että geneettinen algoritmi oli erityisen hyvä löytämään tasapainotettuja ratkaisuja edellä mainittujen tavoitteiden mukaisesti.

Geneettisen algoritmin käyttämistä vastuullisuuden tavoitteluun on tieteellisessä kirjallisuudessa tutkittu laajemminkin. NoParast ym. (2021) käsittelevät tutkimuksessaan betonivalmistuksen toimitusketjun kestävyysliittymiä haasteita, jotka ovat moniulotteisia ja vaikeasti hahmoteltavia. Tähän ongelmaan geneettinen algoritmi esittää laadukkaita aikataulusratkaisuja, joiden pohjalta tutkijat esittävät yhdeksi haasteiden ratkaisuksi kestävästä suljettua toimitusketjua (engl. sustainable closed-loop supply chain). Naderin ym. (2021) tutkimuksessa taas käsitellään toimitusketjun energiankulutuksen (engl. exergy) minimointia. Tässä tutkimuksessa geneettistä algoritmia käytetään optimoimaan kolme vastuullisuuden päätavoitetta, eli ympäristönsuojelu, taloudelliset säästöt ja sosiaaliset säästöt. Algoritmia sovelletaan elintarviketoimitusketjuun, ja tulokset osoittavat, että pienillä taloudellisilla myönnytyksillä saavutettiin 4,8 prosentin säästöt koko toimitusketjun energiankulutuksessa.

### 3 Vastuullinen toimitusketjujen johtaminen

Aiheen laajuuden takia vastuullisen toimitusketjujen johtamisen määritelmälle ei ole mitään selkeää konsensusta. Eniten viittauksia tieteellisessä tutkimuksessa Ahin & Searcyn (2013) mukaan on saanut Seuringin ja Müllerin (2008) antama määritelmä, jossa vastuullinen toimitusketjujen johtaminen (engl. sustainable supply chain management / SSCM) määritellään toimitusketjun hallinnaksi, jossa ohjataan materiaalin, tiedon ja pääoman virtoja sekä yritysten välistä yhteistyötä huomioimalla kestävän kehityksen taloudelliset, ympäristölliset ja sosiaaliset näkökulmat, sekä asiakkaiden ja sidosryhmien vaatimukset (s. 1700).

Ahi ja Searcy (2013) käsittelevät artikkelissaan vastuullisen toimitusketjun johtamisen erilaisia määritelmiä ja yhdistelevät niitä tieteellisessä tutkimuksessa mainittujen pohjalta kaikenkattavaksi määritelmäksi. Artikkelin mukaan vastuullinen toimitusketjujen johtaminen tarkoittaa koordinoitujen toimitusketjujen luomista, jossa taloudelliset, ympäristölliset ja sosiaaliset näkökulmat integroidaan vapaaehtoisesti keskeisiin organisaatioiden välisiin liiketoimintajärjestelmiin. Tavoitteena on hallita tehokkaasti materiaalin, tiedon ja pääoman virtoja, jotka liittyvät tuotteiden tai palveluiden hankintaan, tuotantoon ja jakeluun. Tämä toteutetaan sidosryhmien vaatimusten täyttämiseksi sekä organisaation kannattavuuden, kilpailukyvyyn ja resilienssin vahvistamiseksi sekä lyhyellä että pitkällä aikavälillä. (s. 339)

Kuten edellisistä määritelmistä huomataan, vastuullinen toimitusketjujen johtaminen on monimutkainen prosessi, jossa monet eri intressit kamppailevat keskenään optimaalisen lopputuloksen saavuttamiseksi. Vastuullisuus ei kuitenkaan ole valinta, vaan useat sidosryhmät, kuten esimerkiksi asiakkaat, sijoittajat, toimitusketjukumppanit ja lainsäätäjät vaativat yhä painokkaammin vastuullisia toimintatapoja koko toimitusketjun kontekstissa (Gualandris ym., 2015). Yhtenä vastuullisen toimitusketjun johtamisen haasteena voidaan pitää myös sitä, että rajoja näiden kolmen vastuullisuuden osa-alueen välillä on paikoitellen haastava vetää, sillä monilla päätöksillä on samanaikainen vaikutus useampaan vastuullisuuden osa-alueeseen (Hutchins & Sutherland, 2008). Seuraavissa alaluvuissa käsitellään aikaisemmin esitettyjä kolmea vastuullisuuden osa-aluetta toimitusketjujen johtamisen kannalta ja pyritään selkeästi määrittelemään niitä indikaattoreita, jotka kuuluvat kunkin vastuullisuuden osa-alueen alle.

#### 3.1 Ympäristöllinen vastuullisuus

Globaalin toimitusketjun jokaisella osalla on vaikutus ympäristöön. Toimitusketjun ympäristöllinen vastuullisuus (engl. environmental sustainability) perustuu toimitusketjun ympäristövaikutusten

tarkasteluun ja niihin reagoimiseen. (Bhinge ym., 2015.) Toimitusketjun ympäristövaikutusten määrittely on kuitenkin vaikeaa, eikä tieteellisessä tutkimuksessa ole saatu aikaan konsensusta siitä, mitä ympäristövaikutuksia tulee ottaa huomioon, kun minimoidaan toimitusketjun ympäristöhaittoja. Yleensä kyseeseen tuleekin useiden eri vaikutusten yhteensovittaminen ja optimoiminen mahdollisimman hyvien tulosten saavuttamiseksi. (Mujkić ym., 2018.)

Mujkić ym. (2018) käsittelevät tutkimuksessaan toimitusketjun vastuullisuuden indikaattoreita kirjallisuuskatsauksen muodossa. Ympäristön kannalta tutkituimpia indikaattoreita ovat hiilidioksidipäästöt (tai yleisemmin kasvihuonepäästöt), luonnonvarojen ehtyminen ja vedenkulutus, ekosysteemiin liittyvät vaikutukset, kuten ekosysteemin laatu ja saasteet, sekä ihmisten terveyteen liittyvät vaikutukset. Tutkimuksen tuloksista huomataan, että ympäristövaikutukset ovat laajoja ja sen takia myös vaikeasti mitattavissa.

Taulukko 1 Vastuullisen toimitusketjun strateginen viitekehys (mukaillen Kleindorfer ym., 2005, s. 485)

Strategiat	Sisäiset strategiat	Ulkoiset strategiat
Nykyiset strategiat	<ul style="list-style-type: none"> <li>- Jatkuvat prosessiparannukset kestävyuden näkökulmasta</li> <li>- Työntekijöiden osallistaminen</li> <li>- Jätteen vähentäminen</li> <li>- Energian säästö</li> <li>- Päästöjen hallinta</li> </ul>	<ul style="list-style-type: none"> <li>- Laajennettujen toimitusketjujen parantaminen</li> <li>- Hankintaketjun analysointi ja materiaalien sekä prosessien valinnan optimointi</li> <li>- Suljetun kierron toimitusketjujen (engl. closed-loop supply chains) tavoittelu uudelleenvalmistusta ja turvallista hävittämistä varten</li> </ul>
Tulevaisuuden strategiat	<ul style="list-style-type: none"> <li>- Saastuttavien kemikaalien talteenotto valmistuksessa</li> <li>- Uusiutumattomien raaka-aineiden korvaaminen</li> <li>- Tuotteiden uudelleensuunnittelu siten, että vähennetään materiaalien ja energian kulutusta</li> </ul>	<ul style="list-style-type: none"> <li>- Ydinosaamisen kehittäminen tuotteissa, prosesseissa ja toimitusketjuissa pitkän aikavälin kestävyuden varmistamiseksi</li> <li>- Kestävyttä tukevien strategioiden edistäminen</li> </ul>

Kleindorfer ym. (2005) tarjoavat tutkimuksessaan neliosaisen strategiaviitekehysten tämän laajan kokonaisuuden hallintaan. Viitekehys ottaa huomioon osittain myös sosiaalisen vastuullisuuden piirteitä, mutta keskittyy pääasiassa ympäristölliseen vastuuseen. Yllä on esitetty taulukkomuodossa viitekehysten sisältö. Taulukosta 1 havaitaan, että jo vuonna 2005 on tunnistettu toimitusketjujen johtamisen kannalta merkittävimpiä strategioita ympäristö vastuullisuuden tavoittelussa.

Viitekehysten sisällössä on selkeitä yhteneväisyyksiä Mujkićin ym. (2018) esittämiin keskeisiin ympäristöllisen vastuullisuuden indikaattoreihin. Taulukossa sisäisillä strategioilla viitataan niihin toimiin, joita toimitusketjun osana toimiva yritys voi sisäisesti tehdä, kun taas ulkoiset strategiat viittaavat niihin toimiin, joita yritys voi tehdä yhteistyössä toimitusketjun eri yritysten kanssa (Kleindorfer ym., 2005).

### 3.2 Sosiaalinen vastuullisuus

Vastuullisuuden kolmesta ”pilarista” sosiaalista vastuullisuutta (engl. social sustainability) on tutkittu tieteellisessä tutkimuksessa vähiten (Bhinge ym., 2015; Hutchins & Sutherland, 2008; Mujkić ym., 2018). Tämä voi johtua siitä, että sosiaalisen vastuullisuuden määrittely on vaikeaa aiheen laajuuden takia (Hutchins & Sutherland, 2008; Mujkić ym., 2018). Pelkistetysti määriteltynä sosiaalinen vastuullisuus tarkastelee ihmisten, yhteisöjen, kuluttajien ja muiden sidosryhmien terveyttä, turvallisuutta ja hyviä elinolosuhteita (Bhinge ym., 2015).

Mujkićin ym. (2018) tutkimuksessa sosiaalisen vastuullisuuden indikaattoreita mainitaan kahdeksan kappaletta, joista eniten huomiota tieteellisessä tutkimuksessa ovat saaneet työllisyys (engl. employment), työterveys ja -turvallisuus (engl. occupational health and safety) ja luodut työpaikat (engl. jobs created). Tämän lisäksi sosiaaliseen vastuullisuuteen voidaan tutkimuksen perusteella lukea yhdistymisvapaus, neuvotteluoikeus, paikallisyhteisöt, ruoan ja energian (resurssien) välinen kilpailu (engl. food to energy competition), sekä sosiaaliset etuudet. Bhinge ym. (2015) nostavat omassa tutkimuksessaan esille yhteensä 31 sosiaalisen vastuullisuuden mittaria ja tuovat esille perinteisten indikaattorien lisäksi enemmän juuri kulttuurista ja eettistä puolta, kuten kulttuuriperintö, alkuperäiskansojen oikeudet, reilu kilpailu, reilu palkka, lapsityövoima, sukupuolten välinen tasa-arvo ja korruption ehkäisy.

Kun sosiaalisesta vastuullisuudesta puhutaan, painotetaan usein ihmisten terveyttä ja turvallisuutta ja saatetaan unohtaa päätösten vaikutukset kulttuuriin ja eettisiin puoliin (Hutchins & Sutherland, 2008). Jaotellaan seuraavaksi edellisessä kappaleessa mainitut kahden eri tutkimuksen antamat indikaattorit Hutchinsin ja Sutherlandin (2008) artikkelissa esitetyn väitteen pohjalta kolmeen eri

kategoriaan, jotka ovat: työelämän indikaattorit, kulttuuriset indikaattorit, ja eettiset indikaattorit. Alla tässä kandidaatintutkielmassa käytettävä jaottelu sosiaalisen vastuullisuuden eri mittareista.

Taulukko 2 Sosiaalisen vastuullisuuden indikaattorit (Bhinge ym., 2015<sup>a</sup> ja Mujkić ym., 2018<sup>b</sup> pohjalta)

Työelämän indikaattorit	<ul style="list-style-type: none"> <li>• Työllisyys <sup>a, b</sup></li> <li>• Luodut työpaikat <sup>b</sup></li> <li>• Työterveys ja -turvallisuus <sup>b</sup></li> <li>• Yhdistymisvapaus <sup>a, b</sup></li> <li>• Neuvotteluoikeus <sup>b</sup></li> <li>• Sosiaaliset etuudet <sup>a, b</sup></li> <li>• Reilu palkka <sup>a</sup></li> </ul>
Kulttuuriset indikaattorit	<ul style="list-style-type: none"> <li>• Paikallisyhteisöt <sup>a, b</sup></li> <li>• Kulttuuriperintö <sup>a</sup></li> <li>• Alkuperäiskansojen oikeudet <sup>a</sup></li> </ul>
Eettiset indikaattorit	<ul style="list-style-type: none"> <li>• Ruoan ja energian välinen kilpailu <sup>b</sup></li> <li>• Reilu kilpailu <sup>a</sup></li> <li>• Lapsityövoima <sup>a</sup></li> <li>• Sukupuolten välinen tasa-arvo <sup>a</sup></li> <li>• Korruption ehkäisy <sup>a</sup></li> </ul>

### 3.3 Taloudellinen vastuullisuus

Toimitusketjun taloudellinen vastuu (engl. economic sustainability) liittyy liiketoiminnan kustannuksiin ja taloudelliseen vakauteen (Bhinge ym., 2015). Perinteisesti yrityksessä päätökset on tehty taloudellisen vastuullisuuden ehdoilla, ja esimerkiksi kehittyvissä maissa taloudelliset hyödyt saattavat mennä ympäristövaikutusten edelle (Hutchins & Sutherland, 2008).

Taloudellisissa päätöksissä esiin nostetaan usein päätöksenteon tasot ja puhutaan strategisista, taktisista ja operatiivisista päätöksistä (Gunasekaran ym., 2001; Tajbakhsh & Hassini, 2015). Toimitusketjujen johtamisessa strategiset päätökset ovat pitkän aikavälin päätöksiä, jotka voivat liittyä esimerkiksi tehtaiden sijainteihin tai toimittajien valintaan. Taktiset päätökset taas liittyvät esimerkiksi logistiikkaan tai tuotannon järjestelyihin keskipitkällä aikavälillä, kun taas operatiiviset päätökset kattavat lyhyen aikavälin päätöksiä esimerkiksi kysynnän täyttämiseen tai materiaalivirtoihin liittyen. (Mujkić ym., 2018; Tajbakhsh & Hassini, 2015.)

Gunasekaran ym. (2001) ja Tajbakhsh ja Hassini (2015) ovat käsitelleet taloudellisen vastuun indikaattoreita tutkimuksissaan, ja Mujkićin ym. (2018) kirjallisuuskatsauksessa taloudelliset indikaattorit on jaettu edellisten päätöksentekotasojen alle. Strateginen päätöksenteko pitää sisällään voitot, kassavirran, toimitusajan, asiakastyytyväisyyden, liiketoiminnan volyymin ja budjettivarianssin. Taktinen päätöksenteko pitää sisällään kokonaiskustannukset, kapasiteetin käyttöasteen ja tuotannon tehokkuuden. Viimeisenä on operatiivinen päätöksenteko, johon kuuluvat kysynnän epävarmuus, tuotteen laatu ja viallisten tuotteiden prosenttiosuus. Edellä mainituista indikaattoreista selkeästi eniten on tutkittu toimitusketjun kokonaiskustannuksia, ja sen jälkeen tutkituimpia indikaattoreita ovat voitot, kassavirta, toimitusaika ja kysynnän epävarmuus. Toimitusketjujen johtamisen kannalta on mielenkiintoista se, miten kokonaiskustannusten vähentämistä pidetään niin isossa arvossa, eikä lähtökohtana ole voittojen maksimoiminen, vaikka sitä voidaan yleisesti pitää liiketoiminnan tavoitteena. (Mujkić ym., 2018.)

## 4 Tekoälyn hyödyt toimitusketjujen vastuullisuudessa

### 4.1 Tekoälyn tuomia mahdollisuuksia vastuullisuuteen

Yritykset kohtaavat laajoja hallinnollisia, kilpailullisia ja sosiaalisia paineita tuoda vastuullisia toimintatapoja toimitusketjujen johtamiseen (Naz ym., 2022). Tekoälyn tarjoama automaatio optimoi toimitusketjuprosesseja ja näin vähentää toimitusketjun energiankulutusta ja hävikkiä (Yadav ym., 2024). Tekoäly auttaa reaaliaikaisessa päätöksenteossa ja pitää yllä toimitusketjujen resilienssiä muutosten edessä. Tekoälyn tekemä logistiikkaan liittyvä optimointi pienentää polttoaineen kulutusta ja päästöjä, jolloin tavaroiden liikuttamisen hiilijalanjälki pienenee. (Yadav ym., 2024.)

Tekoälyn sovellusten kyky tehdä ennustuksia esimerkiksi varastonhallintaan ja kysyntään liittyen vähentää ylimääräistä varastoa ja ylituotantoa (Yadav ym., 2024), millä on taas vaikutus toimitusketjun taloudelliseen ja ympäristölliseen vastuullisuuteen. Tästä esimerkkinä on saksalainen verkkokauppa Otto, jonka käyttämä tekoälyjärjestelmä pystyy ennustamaan tulevan 30 päivän myynnit 90 prosentin tarkkuudella, ja jo vuonna 2017 tilasi 200 000 tuotetta kuukaudessa automaattisesti (Dauvergne, 2022). Tekoälypohjaisten strategioiden liittäminen yrityksen nykyisiin toimitusketjun johtamisen järjestelmiin lisää toimitusketjun kykyä toimia sosiaalisen, ympäristöllisen ja taloudellisen vastuullisuuden mukaisesti (Yadav ym., 2024).

### 4.2 Eri tekoälyteknologiat vastuullisuuden eri osa-alueilla

Kuten luvussa 2.2. on eritelty, toimitusketjujen johtamisessa voi hyödyntää erilaisia tekoälysovelluksia monella eri tavalla. Tässä luvussa kerrataan lyhyesti kunkin tekoälyteknologian sovellukset ja luokitellaan kyseisten sovellusten sekä edellisessä luvussa käsiteltyjen vastuullisuuden indikaattorien perusteella tekoälyteknologiat vastuullisuuden eri kategorioihin. Tavoitteena on selkeästi perustellen yhdistää tekoälyteknologioiden tarjoamia toimitusketjun parannuksia niitä parannuksia vastaaviin vastuullisuuden indikaattoreihin, ja näin todeta tietyn tekoälyteknologian edesauttavan nimenomaan tiettyä vastuullisuuden osa-alueita. Luvun lopusta löytyy taulukko, johon on koottu käsittelyn tulokset yksinkertaistetusti.

Koneoppimista on toimitusketjujen johtamisen saralla käytetty ainakin kysynnän ennustamiseen (Carbonneau ym., 2008; Feizabadi, 2022) ja riskienhallintaan (Yang ym., 2023; Zhao ym., 2020). Tämän lisäksi tuotannon suunnitteluun ja hallintaan liittyen on käsitelty tuotannon tarpeiden ennustaminen, aikataulujen optimointi, ennakoiva kunnossapito ja laadunvalvonta (Usuga Cadavid

ym., 2020). Logistiikan osalta koneoppimista on sovellettu kuljetusreittien optimointiin, käänteiseen logistiikkaan ja kuljetusmuotojen yhdistelyyn. Tämän lisäksi erillisenä sovellusalueena on käsitelty koneoppimisen soveltamista asiakassegmentointiin. (Singh ym., 2021.) Kysynnän ennustamisen parannuksilla on vaikutus etenkin taloudellisiin ja ympäristöllisiin mittareihin, ja esimerkiksi Feizabadin (2022) tutkimuksen tuloksissa puhutaan taloudellisen ja operatiivisen suorituskyvyn parantumisesta. Samoin riskienhallinnassa (ks. Yang ym., 2023; Zhao ym., 2020) keskitytään pitkälti taloudellisten menetysten välttämiseen eikä pohdita sosiaalisia tai edes ympäristöllisiä vaikutuksia. Tuotannon suunnitteluun ja hallintaan liittyvissä sovelluksissa (ks. Usuga Cadavid ym., 2020) tuloksena saadaan lisättyä tuotannon tehokkuutta, joka vaikuttaa eniten taloudelliseen vastuullisuuteen, ja vähennettyä hukkaa, jolla on suurin vaikutus ympäristölliseen vastuullisuuteen. Samoin Singhin ym. (2021) esittämät sovellukset logistiikan optimointiin liittyen, kuten kuljetusreittien optimointi ja käänteinen logistiikka, vaikuttavat lähinnä ympäristölliseen vastuullisuuteen päästöjen vähenemisen kautta ja taloudelliseen vastuullisuuteen käänteisen logistiikan myötä saadun arvonalautuksen kautta. Yhteenvetona voidaan todeta, että koneoppimiseen pohjautuvia tekoälysovelluksia käytetään etenkin ympäristöllisen ja taloudellisen vastuullisuuden tavoittelussa.

Syväoppimisen sovellukset toimitusketjujen johtamisessa ovat pitkälti keskittyneet kysynnän ennustamiseen (Hosseinnia Shavaki & Ebrahimi Ghahnavieh, 2023; Nikolopoulos ym., 2021). Tämän lisäksi syväoppimista on sovellettu varastonhallintaan (Gijsbrechts ym., 2022; Meisheri ym., 2022), laajojen toimitusketjujen kartoitukseen (Wichmann ym., 2020) ja hyödykkeiden (esim. öljyn) markkinoiden seuraamiseen ja ennustamiseen (Wu ym., 2021). Myös syväoppimisen kohdalla voidaan todeta, että kysynnän tarkemmalla ennustamisella tavoitellaan lähinnä ympäristöllisiä ja taloudellisia hyötyjä. Esimerkiksi Hosseinnia Shavakin ja Ebrahimi Ghahnaviehin (2023) tutkimuksessa puhutaan kysynnän ennustamisen vaikutuksesta jätteiden määrään, mikä liittyy ympäristöllisen vastuullisuuden indikaattoreista luonnonvarojen eheytymiseen ja saasteisiin (Mujkić ym., 2018). Varastonhallintaan liittyvät taloudellisten indikaattoreiden puolelta kapasiteetin käyttöaste sekä kokonaiskustannukset (Mujkić ym., 2018). Wichmann ym. (2020) mainitsevat tutkimuksessaan, että toimitusketjujen kartoituksella on vaikutusta vastuullisuuteen (engl. sustainability), mutta keskittyvät tutkimuksessaan näkyvyyden ja sitä kautta hallittavuuden parantamiseen. Toki nämä tekijät voivat epäsuorasti lisätä vastuullisuutta. Syväoppimisen osalta voidaan todeta, että nykyiset syväoppimiseen pohjaavat tekoälyteknologiat ovat hyödyllisiä taloudellisen ja ympäristöllisen vastuullisuuden tavoittelussa.

Agenttipohjaisia järjestelmiä on käytetty toimitusketjun mallinnukseen ja sitä kautta muutosten vaikutuksien arvioimiseen (Swaminathan ym., 1998). Tämäkin tekoälyteknologia sopii kysynnän ennustamiseen, joka voidaan tehdä simuloimalla toimitusketjua agenttipohjaisesti (Liang & Huang, 2006). Agenttipohjaisten järjestelmien tarjoama toimitusketjun mallinnus liittyy lähinnä taloudellisiin tavoitteisiin, eikä kahdesta tutkimuksesta (ks. Liang & Huang, 2006; Swaminathan ym., 1998) ole havaittavissa viitteitä ympäristöllisen tai sosiaalisen vastuullisuuden tavoittelusta. Swaminathan ym. (1998) keskittyvät tutkimuksessaan toimitusketjun uudelleenkonfigurointiin ja saivat agenttipohjaisen järjestelmän myötä nopeutettua konfiguroinnin suunnittelua, millä on taloudellista vaikutusta. Liangin ja Huangin (2006) tutkimuksessa taas erikseen painotetaan sitä, että toimitusketjun simuloinnin tavoitteena on kustannusten minimoiminen. Tutkimustulos ei poista sitä mahdollisuutta, että agenttipohjaisia järjestelmiä voitaisiin käyttää myös ympäristöllisen ja sosiaalisen vastuullisuuden tavoitteluun, mutta tällä hetkellä pääpaino on taloudellisen vastuullisuuden tavoittelussa.

Luonnollisen kielen käsittelyä on käytetty riskien tunnistamiseen (Sadeek & Hanaoka, 2023) ja toimitusketjun kartoitukseen (Wichmann ym., 2018). Kuten syväoppimisen kohdalla jo mainittiin, Wichmann ym. (2018) tutkivat toimitusketjun kartoitusta resilienssin parantamisen kautta, eivätkä vastuullisuuden mainitsemisen lisäksi käsittele kartoituksen vaikutuksia vastuullisuuteen. Sadeek ja Hanaoka (2023) sen sijaan löysivät luonnollisen kielen käsittelyn avulla toimitusketjun riskejä sekä uutismediasta että Twitteristä (nykyinen X) kaikkiin vastuullisuuden osa-alueisiin liittyen. Sosiaalisen vastuullisuuden kannalta löytyi esimerkiksi seuraavat avainsanat (engl. topic words): työ (engl. labor), sota (engl. war), humanitaarinen (engl. humanitarian), ihmiset (engl. people) ja pelot (engl. fears). Taloudellisen vastuullisuuden kannalta taas löytyi muun muassa inflatio (engl. inflation), talous (engl. economy), tuotanto (engl. production), voitot (engl. profit) ja myynti (engl. sales). Viimeisenä ympäristöllisen vastuullisuuden kannalta löydettiin riskejä esimerkiksi päästöihin (engl. emissions), ilmastoon (engl. climate), polttoaineisiin (engl. fuel) ja raaka-aineisiin (engl. raw materials) liittyen. Kaikki nämä avainsanat resonoiivat vahvasti edellisessä luvussa esitettyjen vastuullisuuden indikaattoreiden kanssa, joten voidaan todeta, että luonnollisen kielen käsittelyä pystytään käyttämään toimitusketjujen johtamisessa kaikkien kolmen vastuullisuuden osa-alueen kehittämiseksi.

Geneettistä algoritmia on käytetty etenkin erilaisiin optimointiongelmiin toimitusketjun eri osa-alueilla, kuten ajoneuvojen aikataulutuksessa (Malmborg, 1996), ajoneuvoreitityksessä (Göçmen & Erol, 2019) ja käänteisessä logistiikassa (Min ym., 2006; Zorbakhshnia ym., 2020). Geneettistä algoritmia on käytetty myös monimutkaisten optimointiongelmiä ratkaisemaan, joissa tavoitteena on

optimoida vastuullisuuden eri osa-alueita keskenään (Naderi ym., 2021; NoParast ym., 2021). Malmborg (1996) ja Göçmen ja Erol (2019) keskittyvät tutkimuksissaan taloudellisten ja ympäristöllisten indikaattoreiden optimoimiseen, ja jälkimmäisessä tutkimuksessa nousee taloudellisista indikaattoreista esiin esimerkiksi kustannustehokkuus. Käänteiseen logistiikkaan liittyvässä tutkimuksessa Zarbakhshnia ym. (2020) tavoittelevat sosiaalista vastuullisuutta esimerkiksi työolosuhteiden parantamisen kautta, ja taloudellista sekä ympäristöllistä vastuullisuutta kuljetuskustannusten ja hiilidioksidipäästöjen minimoimisen kautta. NoParast ym. (2021) painottavat optimointia ympäristöllisen vastuullisuuden näkökulmista, kun taas Naderin ym. (2021) tutkimuksessa geneettinen algoritmi optimoi keskenään kolme vastuullisuuden osa-alueita. Yhteenvedon geneettistä algoritmia voidaan käyttää kaikkien kolmen vastuullisuuden osa-alueen optimoimiseen toimitusketjujen johtamisessa.

Taulukko 3 Tekoälyteknologiat vastuullisuuden eri osa-alueilla

Tekoälyteknologia	Toimitusketjun vastuullisuuden osa-alue		
	Ympäristöllinen	Sosiaalinen	Taloudellinen
<b>Koneoppiminen</b>	x		x
<b>Syväoppiminen</b>	x		x
<b>Agenttipohjaiset järjestelmät</b>			x
<b>Luonnollisen kielen käsittely</b>	x	x	x
<b>Geneettinen algoritmi</b>	x	x	x

## 5 Yhteenveto ja johtopäätökset

Tässä kandidaatintutkielmassa oli tavoitteena tutkia tekoälyn käyttöä toimitusketjun vastuullisuuden eri osa-alueilla, jotka ovat Seuringin ja Müllerin (2008) mukaan sosiaalinen, ympäristöllinen ja taloudellinen vastuu. Johdannon jälkeisessä toisessa luvussa käsiteltiin ensin tekoälyn käsitteet (luku 2.1) ja sen jälkeen luvussa 2.2 tekoälyn sovelluksia toimitusketjujen johtamisessa. Luvussa 3 esiteltiin vastuullisuuden käsitettä toimitusketjujen johtamisen kannalta ja määritettiin tietyt vastuullisuuden indikaattoreita. Viimeisessä käsittelyluvussa 4 yhdistettiin toimitusketjujen johtamisessa käytetyt tekoälyteknologiat vastuullisuuteen ja luokiteltiin tekoälyteknologiat luvussa 3 esitettyjen indikaattoreiden pohjalta vastuullisuuden osa-alueiden alle.

Tutkielmassa vastattiin kahteen tutkimuskysymykseen:

- Miten erilaisia tekoälyteknologioita voidaan käyttää toimitusketjujen johtamisessa?
- Miten tekoälyteknologiat voidaan luokitella vastuullisen toimitusketjun eri osa-alueille?

Tutkielmassa päätettiin keskittyä viiteen tekoälyteknologiaan, jotka olivat koneoppiminen, syväoppiminen, agenttipohjaiset järjestelmät, luonnollisen kielen käsittely ja geneettinen algoritmi. Rajaukseen päädyttiin, koska nämä teknologiat ovat geneettistä algoritmia lukuun ottamatta koneoppimisen sovelluksia ja jotta käsittelyssä pysyttäisiin kandidaatintutkielman kannalta sopivassa laajuudessa. Valitut viisi teknologiaa olivat myös nimenomaan toimitusketjujen johtamisen kannalta eniten tutkitut teknologiat.

Ensimmäisen tutkimuskysymyksen osalta voidaan todeta, että tekoälyn sovellusalueet toimitusketjujen johtamisessa ovat näinkin rajatusta käsittelystä huolimatta laaja-alaisia ja monimutkaisia. Koneoppimista on toimitusketjujen johtamisessa käytetty ainakin kysynnän ennustamiseen, tuotannon suunnitteluun ja hallintaan, riskienhallintaan ja logistiikan optimointiin. Syväoppimisen osalta merkittävin sovellusalue on kysynnän ennustaminen, mutta myös varastonhallinta ja esimerkiksi toimitusketjun kartoitus nousivat tutkielmassa esille. Agenttipohjaisia järjestelmiä on käytetty etenkin toimitusketjun mallinukseen ja erilaisten simulaatioiden tekemiseen. Luonnollisen kielen käsittely taas auttaa löytämään tekstipohjaisesta datasta esimerkiksi toimitusketjun riskejä. Geneettistä algoritmia on käytetty etenkin optimointiongelmien niin logistiikan osalta kuin laajemmissa monitahoisissa optimointiongelmassakin, joissa pitää painotella esimerkiksi vastuullisuuden eri osa-alueiden välillä.

Toisen tutkimuskysymyksen osalta huomattiin, että eri tekoälyteknologiat pystyttiin luokittelemaan vastuullisuuden eri osa-alueisiin ja että ainoastaan luonnollisen kielen käsittely ja geneettiset algoritmit soveltuvat kirjallisuuskatsauksen perusteella kaikkiin kolmeen kategoriaan.

Koneoppimista ja syväoppimista on lähinnä käytetty taloudellisen ja ympäristöllisen vastuullisuuden tavoitteluun, ja agenttipohjaisia järjestelmiä ainoastaan taloudellisen vastuullisuuden saralla.

Tutkielmani tuloksia arvioidessa on tärkeä muistaa, että kyseessä on suuresta lähdemateriaalista valikoitunut otos, eikä missään nimessä koko totuus. Aiheeseen liittyvä lähdekirjallisuus oli laajaa ja monialaista, ja tässä tutkielmassa rajattiin käsiteltäväksi vain ne näkökulmat, jotka parhaiten palvelivat asetettujen tutkimuskysymysten tarkastelua. Osa potentiaalisesti relevantista aineistosta on jäänyt pois puhtaasti lähdemateriaalin laajuuden takia, ja osa on rajattu pois Julkaisufoorumin luokitusten mukaisesti, mikäli lähdettä ei ole sieltä löytenyt tai se on ollut tasoa 0.

Johtopäätöksinä keskeisten tulosten pohjalta voidaan todeta, että vaikka tekoälyteknologiat tarjoavat laajoja mahdollisuuksia toimitusketjun vastuullisuuden parantamiseen, on niiden hyödyntäminen vastuullisuuden eri osa-alueilla suhteellisen epätasaista. Suurin osa tutkituista tekoälyteknologioista ei keskittynyt ollenkaan sosiaaliseen vastuullisuuteen, mikä saattaa johtua siitä, että sosiaalista vastuullisuutta on tutkittu vähiten ja siten sen parantaminen ei ole tieteellisessä tutkimuksessa tai yritysten päätöksenteossa ensiarvoisessa asemassa. Toisena syynä sosiaalisen vastuullisuuden laiminlyömiselle voi olla se, että sen mittaaminen on haastavaa. Ympäristöllinen puoli on otettu tutkimuksessa tällä hetkellä hyvin huomioon, ja trendi on varmasti tulevaisuutta ajatellen nouseva. Toimitusketjujen johtamisen kirjallisuudessa kriittisimpänä vastuullisuuden indikaattorina voidaan pitää taloudellisen vastuullisuuden alle kuuluvaa kokonaiskustannusta, joka on edelleen päätöksenteossa suurin vaikuttava tekijä.

Tulevassa tutkimuksessa olisi perusteltua keskittyä etenkin sosiaaliseen vastuullisuuteen, sillä kuten lähdekirjallisuudessakin on mainittu, sitä on tutkittu vähiten kolmesta vastuullisuuden osa-alueesta. Toinen esiin nouseva huomio on, että monet tässäkin tutkielmassa käsitellyt tutkimukset toteavat tekoälyn voivan auttaa vastuullisuuden tavoittelussa, mutta vielä enemmän tarvittaisiin tutkimuksia, jotka konkreettisesti kertoisivat niistä hyödyistä, joita tekoälyn sovellukset ovat toimitusketjun vastuullisen johtamisen kannalta tarjonneet. Viimeisenä, tässä tutkimuksessa on käytetty yhtä oppikirjaa lukuun ottamatta ainoastaan vapaasti luettavissa olevia journaaliartikkeleita, joten tuleva tutkimus voisi ottaa huomioon mahdollisesti myös muita akateemisia lähteitä, kuten konferenssijulkaisuja.

## Lähteet

- Aamer, A., Eka Yani, L., & Alan Priyatna, I. (2021). Data Analytics in the Supply Chain Management: Review of Machine Learning Applications in Demand Forecasting. *Operations and Supply Chain Management: An International Journal*, 14(1), 1–13. <https://doi.org/10.31387/oscm0440281>
- Ahi, P., & Searcy, C. (2013). A comparative literature analysis of definitions for green and sustainable supply chain management. *Journal of Cleaner Production*, 52, 329–341. <https://doi.org/10.1016/j.jclepro.2013.02.018>
- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Bhattacharya, S., Govindan, K., Ghosh Dastidar, S., & Sharma, P. (2024). Applications of artificial intelligence in closed-loop supply chains: Systematic literature review and future research agenda. *Transportation Research Part E: Logistics and Transportation Review*, 184, 103455. <https://doi.org/10.1016/j.tre.2024.103455>
- Bhinge, R., Moser, R., Moser, E., Lanza, G., & Dornfeld, D. (2015). Sustainability Optimization for Global Supply Chain Decision-making. *Procedia CIRP*, 26, 323–328. <https://doi.org/10.1016/j.procir.2014.07.105>
- Büyüközkan, G., & Göçer, F. (2018). Digital Supply Chain: Literature review and a proposed framework for future research. *Computers in Industry*, 97, 157–177. <https://doi.org/10.1016/j.compind.2018.02.010>
- Carbonneau, R., Laframboise, K., & Vahidov, R. (2008). Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, 184(3), 1140–1154. <https://doi.org/10.1016/j.ejor.2006.12.004>
- Cheng, K., Sun, D., Qin, D., Cai, J., & Chen, C. (2024). Deep learning approach for unified recognition of driver speed and lateral intentions using naturalistic driving data. *Neural Networks*, 179, 106569. <https://doi.org/10.1016/j.neunet.2024.106569>
- Dauvergne, P. (2022). Is artificial intelligence greening global supply chains? Exposing the political economy of environmental costs. *Review of International Political Economy*, 29(3), 696–718. <https://doi.org/10.1080/09692290.2020.1814381>

- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2021). Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- Farhatullah, Chen, X., Zeng, D., Ullah, R., Nawaz, R., Xu, J., & Arslan, T. (2025). A deep learning approach for non-invasive Alzheimer's monitoring using microwave radar data. *Neural Networks*, 181, 106778. <https://doi.org/10.1016/j.neunet.2024.106778>
- Feizabadi, J. (2022). Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications*, 25(2), 119–142. <https://doi.org/10.1080/13675567.2020.1803246>
- Gardner, T. A., Benzie, M., Börner, J., Dawkins, E., Fick, S., Garrett, R., Godar, J., Grimard, A., Lake, S., Larsen, R. K., Mardas, N., McDermott, C. L., Meyfroidt, P., Osbeck, M., Persson, M., Sembres, T., Suavet, C., Strassburg, B., Trevisan, A., ... Wolvekamp, P. (2019). Transparency and sustainability in global commodity supply chains. *World Development*, 121, 163–177. <https://doi.org/10.1016/j.worlddev.2018.05.025>
- Gijsbrechts, J., Boute, R. N., Van Mieghem, J. A., & Zhang, D. J. (2022). Can Deep Reinforcement Learning Improve Inventory Management? Performance on Lost Sales, Dual-Sourcing, and Multi-Echelon Problems. *M&SOM: Manufacturing & Service Operations Management*, 24(3), 1349–1368. <https://doi.org/10.1287/msom.2021.1064>
- Gualandris, J., Klassen, R. D., Vachon, S., & Kalchschmidt, M. (2015). Sustainable evaluation and verification in supply chains: Aligning and leveraging accountability to stakeholders. *Journal of Operations Management*, 38(1), 1–13. <https://doi.org/10.1016/j.jom.2015.06.002>
- Gunasekaran, A., Patel, C., & Tirtiroglu, E. (2001). Performance measures and metrics in a supply chain environment. *International Journal of Operations & Production Management*, 21(1/2), 71–87. <https://doi.org/10.1108/01443570110358468>
- Göçmen, E., & Erol, R. (2019). Transportation problems for intermodal networks: Mathematical models, exact and heuristic algorithms, and machine learning. *Expert Systems with Applications*, 135, 374–387. <https://doi.org/10.1016/j.eswa.2019.06.023>
- Helo, P., & Hao, Y. (2022). Artificial intelligence in operations management and supply chain management: An exploratory case study. *Production Planning & Control*, 33(16), 1573–1590. <https://doi.org/10.1080/09537287.2021.1882690>

- Hendriksen, C. (2023). Artificial intelligence for supply chain management: Disruptive innovation or innovative disruption? *Journal of Supply Chain Management*, 59(3), 65–76.  
<https://doi.org/10.1111/jscm.12304>
- Hosseinnia Shavaki, F., & Ebrahimi Ghahnavieh, A. (2023). Applications of deep learning into supply chain management: A systematic literature review and a framework for future research. *Artificial Intelligence Review*, 56(5), 4447–4489. <https://doi.org/10.1007/s10462-022-10289-z>
- Hutchins, M. J., & Sutherland, J. W. (2008). An exploration of measures of social sustainability and their application to supply chain decisions. *Journal of Cleaner Production*, 16(15), 1688–1698. <https://doi.org/10.1016/j.jclepro.2008.06.001>
- Jüttner, U., Peck, H., & Christopher, M. (2003). Supply chain risk management: Outlining an agenda for future research. *International Journal of Logistics Research and Applications*, 6(4), 197–210. <https://doi.org/10.1080/13675560310001627016>
- Kamble, S. S., Gunasekaran, A., Kumar, V., Belhadi, A., & Foropon, C. (2021). A machine learning based approach for predicting blockchain adoption in supply Chain. *Technological Forecasting and Social Change*, 163, 120465.  
<https://doi.org/10.1016/j.techfore.2020.120465>
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who’s the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15–25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Kleindorfer, P. R., Singhal, K., & Van Wassenhove, L. N. (2005). Sustainable Operations Management. *Production and Operations Management*, 14(4), 482–492.  
<https://doi.org/10.1111/j.1937-5956.2005.tb00235.x>
- Kohl, N., & Miikkulainen, R. (2009). Evolving neural networks for strategic decision-making problems. *Neural Networks*, 22(3), 326–337. <https://doi.org/10.1016/j.neunet.2009.03.001>
- Kreutzer, R. T., & Sirrenberg, M. (2020). *Understanding Artificial Intelligence: Fundamentals, Use Cases and Methods for a Corporate AI Journey*. Springer International Publishing.  
<https://doi.org/10.1007/978-3-030-25271-7>
- Landsmeer, L. P. L., Engelen, M. C. W., Miedema, R., & Strydis, C. (2024). Tricking AI chips into simulating the human brain: A detailed performance analysis. *Neurocomputing*, 598, 127953. <https://doi.org/10.1016/j.neucom.2024.127953>
- Liang, W.-Y., & Huang, C.-C. (2006). Agent-based demand forecast in multi-echelon supply chain. *Decision Support Systems*, 42(1), 390–407. <https://doi.org/10.1016/j.dss.2005.01.009>

- Liu, B. (2023). Arguments for the Rise of Artificial Intelligence Art: Does AI Art Have Creativity, Motivation, Self-awareness and Emotion? *Arte, Individuo y Sociedad*, 35(3), 811. <https://doi.org/10.5209/aris.83808>
- Long, Y., Kroeger, S., Zaeh, M. F., & Brintrup, A. (2025). Leveraging synthetic data to tackle machine learning challenges in supply chains: Challenges, methods, applications, and research opportunities. *International Journal of Production Research*, 1–22. <https://doi.org/10.1080/00207543.2024.2447927>
- Maghsoudi, M., Shokouhyar, S., Ataei, A., Ahmadi, S., & Shokoohyar, S. (2023). Co-authorship network analysis of AI applications in sustainable supply chains: Key players and themes. *Journal of Cleaner Production*, 422, 138472. <https://doi.org/10.1016/j.jclepro.2023.138472>
- Malmborg, C. J. (1996). A genetic algorithm for service level based vehicle scheduling. *European Journal of Operational Research*, 93(1), 121–134. [https://doi.org/10.1016/0377-2217\(95\)00185-9](https://doi.org/10.1016/0377-2217(95)00185-9)
- Matsuo, Y., LeCun, Y., Sahani, M., Precup, D., Silver, D., Sugiyama, M., Uchibe, E., & Morimoto, J. (2022). Deep learning, reinforcement learning, and world models. *Neural Networks*, 152, 267–275. <https://doi.org/10.1016/j.neunet.2022.03.037>
- Meisheri, H., Sultana, N. N., Baranwal, M., Baniwal, V., Nath, S., Verma, S., Ravindran, B., & Khadilkar, H. (2022). Scalable multi-product inventory control with lead time constraints using reinforcement learning. *Neural Computing and Applications*, 34(3), 1735–1757. <https://doi.org/10.1007/s00521-021-06129-w>
- Mentzer, J. T., DeWitt, W., Keebler, J. S., Min, S., Nix, N. W., Smith, C. D., & Zacharia, Z. G. (2001). DEFINING SUPPLY CHAIN MANAGEMENT. *Journal of Business Logistics*, 22(2), 1–25. <https://doi.org/10.1002/j.2158-1592.2001.tb00001.x>
- Min, H. (2010). Artificial intelligence in supply chain management: Theory and applications. *International Journal of Logistics Research and Applications*, 13(1), 13–39. <https://doi.org/10.1080/13675560902736537>
- Min, H., Jeung Ko, H., & Seong Ko, C. (2006). A genetic algorithm approach to developing the multi-echelon reverse logistics network for product returns. *Omega*, 34(1), 56–69. <https://doi.org/10.1016/j.omega.2004.07.025>
- Minai, A. A., & Williams, R. D. (1994). Perturbation response in feedforward networks. *Neural Networks*, 7(5), 783–796. [https://doi.org/10.1016/0893-6080\(94\)90100-7](https://doi.org/10.1016/0893-6080(94)90100-7)
- Mujkić, Z., Qorri, A., & Kraslawski, A. (2018). Sustainability and Optimization of Supply Chains: A Literature Review. *Operations and Supply Chain Management: An International Journal*, 11(4), 186–199. <https://doi.org/10.31387/oscm0350213>

- Muthukrishnan, N., Maleki, F., Ovens, K., Reinhold, C., Forghani, B., & Forghani, R. (2020). Brief History of Artificial Intelligence. *Neuroimaging Clinics of North America*, *30*(4), 393–399. <https://doi.org/10.1016/j.nic.2020.07.004>
- Naderi, R., Shafiei Nikabadi, M., Alem Tabriz, A., & Pishvaei, M. S. (2021). Supply chain sustainability improvement using exergy analysis. *Computers & Industrial Engineering*, *154*, 107142. <https://doi.org/10.1016/j.cie.2021.107142>
- Narain, K. (2025). *Technology Vision 2025*. Accenture. <https://www.accenture.com/us-en/insights/technology/technology-trends-2025>, luettu 8.2.2025
- Naz, F., Agrawal, R., Kumar, A., Gunasekaran, A., Majumdar, A., & Luthra, S. (2022). Reviewing the applications of artificial intelligence in sustainable supply chains: Exploring research propositions for future directions. *Business Strategy and the Environment*, *31*(5), 2400–2423. <https://doi.org/10.1002/bse.3034>
- Nikolopoulos, K., Punia, S., Schäfers, A., Tsinopoulos, C., & Vasilakis, C. (2021). Forecasting and planning during a pandemic: COVID-19 growth rates, supply chain disruptions, and governmental decisions. *European Journal of Operational Research*, *290*(1), 99–115. <https://doi.org/10.1016/j.ejor.2020.08.001>
- NoParast, M., Hematian, M., Ashrafian, A., Amiri, M. J. T., & AzariJafari, H. (2021). Development of a non-dominated sorting genetic algorithm for implementing circular economy strategies in the concrete industry. *Sustainable Production and Consumption*, *27*, 933–946. <https://doi.org/10.1016/j.spc.2021.02.009>
- Pournader, M., Ghaderi, H., Hassanzadegan, A., & Fahimnia, B. (2021). Artificial intelligence applications in supply chain management. *International Journal of Production Economics*, *241*, 108250. <https://doi.org/10.1016/j.ijpe.2021.108250>
- Raj, R., & Kos, A. (2025). An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions. *Sensors*, *25*(4), 1033. <https://doi.org/10.3390/s25041033>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*, 533–536. <https://doi-org.ezproxy.utu.fi/10.1038/323533a0>
- Sadeek, S. N., & Hanaoka, S. (2023). Assessment of text-generated supply chain risks considering news and social media during disruptive events. *Social Network Analysis and Mining*, *13*(1), 96. <https://doi.org/10.1007/s13278-023-01100-0>
- Sanders, N. R., Boone, T., Ganeshan, R., & Wood, J. D. (2019). Sustainable Supply Chains in the Age of AI and Digitization: Research Challenges and Opportunities. *Journal of Business Logistics*, *40*(3), 229–240. <https://doi.org/10.1111/jbl.12224>

- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, *61*, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Seuring, S., & Müller, M. (2008). From a literature review to a conceptual framework for sustainable supply chain management. *Journal of Cleaner Production*, *16*(15), 1699–1710. <https://doi.org/10.1016/j.jclepro.2008.04.020>
- Simeone, O. (2018). A Very Brief Introduction to Machine Learning With Applications to Communication Systems. *IEEE Transactions on Cognitive Communications and Networking*, *4*(4), 648–664. <https://doi.org/10.1109/TCCN.2018.2881442>
- Singh, A., Wiktorsson, M., & Hauge, J. B. (2021). Trends In Machine Learning To Solve Problems In Logistics. *Procedia CIRP*, *103*, 67–72. <https://doi.org/10.1016/j.procir.2021.10.010>
- Swaminathan, J. M., Smith, S. F., & Sadeh, N. M. (1998). Modeling Supply Chain Dynamics: A Multiagent Approach. *Decision Sciences*, *29*(3), 607–632. <https://doi.org/10.1111/j.1540-5915.1998.tb01356.x>
- Tajbakhsh, A., & Hassini, E. (2015). Performance measurement of sustainable supply chains: A review and research questions. *International Journal of Productivity and Performance Management*, *64*(6), 744–783. <https://doi.org/10.1108/IJPPM-03-2013-0056>
- Tanaka, G., Yamane, T., Héroux, J. B., Nakane, R., Kanazawa, N., Takeda, S., Numata, H., Nakano, D., & Hirose, A. (2019). Recent advances in physical reservoir computing: A review. *Neural Networks*, *115*, 100–123. <https://doi.org/10.1016/j.neunet.2019.03.005>
- Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P., & Fischl, M. (2021). Artificial intelligence in supply chain management: A systematic literature review. *Journal of Business Research*, *122*, 502–517. <https://doi.org/10.1016/j.jbusres.2020.09.009>
- Turing, A. (1950). Computing machinery and intelligence. *Mind*, *59*(236), 433–460.
- Usuga Cadavid, J. P., Lamouri, S., Grabot, B., Pellerin, R., & 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), 1531–1558. <https://doi.org/10.1007/s10845-019-01531-7>
- Wichmann, P., Brintrup, A., Baker, S., Woodall, P., & McFarlane, D. (2018). Towards automatically generating supply chain maps from natural language text. *IFAC-PapersOnLine*, *51*(11), 1726–1731. <https://doi.org/10.1016/j.ifacol.2018.08.207>
- Wichmann, P., Brintrup, A., Baker, S., Woodall, P., & McFarlane, D. (2020). Extracting supply chain maps from news articles using deep neural networks. *International Journal of Production Research*, *58*(17), 5320–5336. <https://doi.org/10.1080/00207543.2020.1720925>

- Wu, B., Wang, L., Wang, S., & Zeng, Y.-R. (2021). Forecasting the U.S. oil markets based on social media information during the COVID-19 pandemic. *Energy*, 226, 120403. <https://doi.org/10.1016/j.energy.2021.120403>
- Xu, L., Mak, S., & Brintrup, A. (2021). Will bots take over the supply chain? Revisiting agent-based supply chain automation. *International Journal of Production Economics*, 241, 108279. <https://doi.org/10.1016/j.ijpe.2021.108279>
- Yadav, A., Garg, R. K., & Sachdeva, A. (2024). Artificial intelligence applications for information management in sustainable supply chain management: A systematic review and future research agenda. *International Journal of Information Management Data Insights*, 4(2), 100292. <https://doi.org/10.1016/j.jjime.2024.100292>
- Yang, M., Lim, M. K., Qu, Y., Ni, D., & Xiao, Z. (2023). Supply chain risk management with machine learning technology: A literature review and future research directions. *Computers & Industrial Engineering*, 175, 108859. <https://doi.org/10.1016/j.cie.2022.108859>
- Zarbakshnia, N., Kannan, D., Kiani Mavi, R., & Soleimani, H. (2020). A novel sustainable multi-objective optimization model for forward and reverse logistics system under demand uncertainty. *Annals of Operations Research*, 295(2), 843–880. <https://doi.org/10.1007/s10479-020-03744-z>
- Zhang, X., Yu, Y., & Zhang, N. (2021). Sustainable supply chain management under big data: A bibliometric analysis. *Journal of Enterprise Information Management*, 34(1), 427–445. <https://doi.org/10.1108/JEIM-12-2019-0381>
- Zhao, H., Muthupandi, S., & Kumara, S. (2020). Managing Illicit Online Pharmacies: Web Analytics and Predictive Models Study. *Journal of Medical Internet Research*, 22(8), e17239. <https://doi.org/10.2196/17239>