

Alexi Pauku

KONEOPPIMISEN SOVELLUKSET IN- TERNET OF THINGS -POHJAISEN TUO- TANTOJÄRJESTELMÄDATAN ANALY- SOINNISSA

Kandidaatintyö
Tekniikan ja luonnontieteiden tiedekunta
Tarkastaja: Henri Vainio
Joulukuu 2023

TIIVISTELMÄ

Alexi Pauku: Koneoppimisen sovellukset Internet of things -pohjaisen tuotantojärjestelmädatan analysoinnissa

Kandidaatintyö

Tampereen yliopisto

Konetekniikka

12/2023

Tämä kandidaatintyö käsittelee koneoppimisen sovelluksia IoT-pohjaisen tuotantojärjestelmädatan analysoinnissa. Työn aihe tarjoaa mahdollisuuksia muun muassa energiankulutuksen ja materiaalin käytön hillitsemiseen sekä työntekijöiden turvallisuuteen ja mukavuuteen ja on siksi erittäin ajankohtainen. Työ toteutettiin kirjallisuusselvityksenä ja sen aihe on rajattu lähinnä materiaalinhallintajärjestelmiin.

Työn teoriaosuudessa esitellään kaksi tapaa jakaa koneoppiminen osa-alueisiin: jako global ja local learningiin sekä valvottuun ja valvomattomaan oppimiseen ja vahvistusoppimiseen. Samassa osuudessa esitellään myös Internet of Thingsiä sekä tuotantojärjestelmän osa-alueita. Työssä esitellään myös varsinaisia sovelluksia työn aiheelle. Nämä on jaettu kahteen kappaleeseen riippuen niiden käyttöönoton asteesta. Nykyisin käytössä olevista sovelluksista työssä nousee esiin vihivaunut. Tulevaisuuden ennusteissa taas ennakoiva kunnonvalvonta tulee leviämään entistä laajemmalle.

Avainsanat: Koneoppiminen, ennakoiva kunnonvalvonta, IoT, vihivaunut.

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

ABSTRACT

Aleksi Paukku: Machine learning applications in analysis of IoT based production system data

Bachelor's thesis
Tampere University
Mechanical engineering
12/2023

This thesis deals with the applications of machine learning in the analysis of IoT-based manufacturing system data. The topic of the thesis offers makes it possible to lower energy consumption and reduce material use as well as increase the safety and comfort of employees. The thesis was carried out as a literature review and its topic is mainly limited to material handling systems.

In the theory chapter two ways of dividing machine learning into sub-sections are presented: the division into global and local learning and the division into supervised, unsupervised and reinforcement learning. Internet of Things and parts of the production system are also presented. The thesis also presents actual applications for the topic of the work. These are divided into two paragraphs depending on the degree of their implementation. Among the applications currently in use automatic guided vehicles or AGVs stand out. In future forecasts, on the other hand, predictive maintenance will become even more widespread.

Keywords: Machine learning, IoT, predictive maintenance, automatic guided vehicles.

The originality of this thesis has been checked using the Turnitin OriginalityCheck service.

ALKUSANAT

Tämä kandidaatintutkielma käsittelee useaa nykyhetken ja tulevaisuuden tuotannossa tärkeää ja laajan mielenkiinnon aiheena olevaa aihetta. Internet of Things sekä koneoppiminen näkyvät myös kuluttajille työn aiheen ulkopuolella. Työ on toteutettu kirjallisuusselvityksenä.

Haluan kiittää Henri Vainiota työn ohjaamisesta ja Juho Kumaraa vertaistuesta venyneen työn loppuun saattamisessa. Kiitos myös Janne Juoksukankaalle ja Liisa Ikkala-Toiviaiselle neuvoista myöhästyneen työn kanssa toimimisesta.

Tampereella, 14.12.2023

SISÄLLYSLUETTELO

1. JOHDANTO	1
2. TEORIAA	3
2.1 Internet of things	3
2.2 Koneoppiminen	5
2.2.1 Global ja local learning	5
2.2.2 Valvottu ja valvoton oppiminen sekä vahvistusoppiminen	7
2.3 Kone- ja tuotantojärjestelmät	9
3. NYKYHETKEN SOVELLUKSIA	12
3.1 Materiaalinhallintajärjestelmät	12
3.1.1 Vihivaunut	12
3.1.2 Muut materiaalinhallintajärjestelmät	14
4. TEOREETTISET SOVELLUKSET	17
4.1 Ennakoiva kunnonvalvonta	17
4.2 Digitalisoitu valmistus	18
4.2.1 Industrie 4.0	18
5. SOVELLUSTEN KÄYTTÖÖNOTON HAASTEITA	19
5.1 Teknologian rajoitukset	19
5.2 Psykologiset ja sosiaaliset syyt	19
5.3 Lainsäädäntö	20
6. YHTEENVETO	22
LÄHTEET	23

LYHENTEET JA MERKINNÄT

AGV	Automated Guided Vehicle, vihivaunun englanninkielinen nimitys
AMR	Autonomous Mobile Robot, nimitys itsestään ajaville roboteille
ANN	Artificial neural network, keinotekoinen neuroverkko
CBM	Condition-based maintenance, kuntoon perustuva huolto
CER	Cost estimating relationship
CMMS	Control, Maintenance and technical Management System
DIAS	Distributed Intelligent Actuators and Sensors
IoT	Internet of Things, esineiden Internet
MHS	Material Handling System, järjestelmä materiaalin kuljettamiseen, usein tuotantojärjestelmän sisäisesti.
MTBF	Mean Time Between Failure
MTTF	Mean Time To Failure
Wi-Fi	Wireless Fidelity, langattomien tiedonsiirtoprotokollien perhe, jonka toiminta perustuu radioaaltoihin.
WiVi	Wireless Vision, 2,4 GHz Wi-Fi -signaaliin perustuva sovellus esineiden havainnointiin esimerkiksi seinän tai muun esteen läpi.

1. JOHDANTO

Tässä työssä käsitellään koneoppimisen sovelluksia Internet of Things -pohjaisen konejärjestelmädatan käsittelyssä tuotantotekniikan näkökulmasta rajattuna erityisesti materiaalinhallintajärjestelmiin. Mahdollisia tutkimuskysymyksiä ovat ainakin seuraavat: Miten koneoppiminen ja IoT näkyvät nykyään materiaalinhallinajärjestelmissä? Entä tulevaisuudessa? Mikä kehitystä mahdollisesti jarruttaa? Muita kysymyksiä ovat muun muassa, mitä voi automatisoida tai mitä ylipäättään kannattaa automatisoida? Näitä kannattaa pohtia, sillä työn aihe on noussut viime aikoina tärkeäksi Internetin ja erityisesti tiedonsiirtonopeuksien kasvaessa. Lisäksi aihe sivuaa älykästä tehdasta (*smart factory*), joka sekin on tulevaisuuden kannalta merkittävä aihe.

Työssä tutustutaan aiheen nykyhetkeen sekä hieman myös lähitulevaisuuden ennustuksiin, ja käsitellään tärkeimpiä sovelluksia. Työn kannalta oleellisia termejä ovat Internet of things, koneoppiminen sekä konejärjestelmät, jotka on esitelty kappaleissa 2.1, 2.2 ja 2.3. Työn aiheeseen liittyy vahvasti myös niin sanottu Big Data, joka tarkoittaa suurien tietomäärien kerääntymistä. Myös digitaalinen kaksonen (*digital twin*), tehtaan tai muun järjestelmän digitaalinen kopio, on tärkeä osa työn ainetta. Viimeisenä lukuna työssä on yhteenveto.

Viime aikoina ympäristöön liittyvät kysymykset ovat nousseet tärkeiksi, ja Galin et al. mukaan ihmiskunta tarvitsisi 1,7-kertaisesti Maapallon tarjonnan verran resursseja ylläpitääkseen nykyisen kulutuksen [21]. Esimerkiksi International Energy Agency World Energy Outlook 2023 -selvityksen mukaan 38 prosenttia Maapallon energiankulutuksesta ja 47 prosenttia hiilidioksidipäästöistä vuonna 2022 aiheutui tuotannosta [22]. Näin ollen automaation avulla saavutettava energian säästö voi auttaa suurelta osin hillitsemään energiankulutusta ja vähentämään päästöjä ja näin ollen hidastamaan muun muassa ilmaston lämpenemistä. Toinen ympäristön kannalta tärkeä etu on materiaalin tarkempi hyödyntäminen ja tuotantojätteen vähentäminen: esimerkiksi metalliteollisuudessa pitkälle viety automaatio mahdollistaa materiaalin, esimerkiksi teräslevyn, tehokkaamman hyödyntämisen ja näin ollen auttaa minimoimaan hukan. Tämä tietysti parantaa myös tuottavuutta.

Lisäksi pitkälle kehittynyt automaatio auttaa parantamaan työpaikkojen turvallisuutta ja mielekkyyttä: vaaralliset tai muuten epämiellyttävät työvaiheet voidaan auto-

matisoida. Tässäkin koneoppimisen ja IoT:n sovellukset ovat avuksi, ja teknologian kehityksen myötä niitä voidaan hyödyntää entistä monimutkaisempiin ja vaikeampiin vaiheisiin.

2. TEORIAA

Viime vuosien aikana Internet of thingsin sekä koneoppimisen erilaiset sovellukset ovat yleistyneet huomattavasti sekä tuotantotekniikan alalla että muualla. Tärkeitä termejä ovat muun muassa koneoppiminen, Internet of things sekä kone- ja tuotantojärjestelmät. Internet of things mahdollistaa esineiden, kuten työn kannalta oleellisten työstökoneiden ja materiaalinhallintajärjestelmien kytkemisen Internetiin muun muassa tiedon keräämiseksi. Koneoppiminen näyttäytyy kuluttajille taas erityisesti niin sanottuna tekoälynä tai keskustelubottina, kuten Rasmussenin et al. mukaan viime aikoina suosiota saavuttanut ChatGPT [23]. Työn kannalta oleellisempia käyttötarkoituksia ovat muun muassa erilaiset optimointitehtävät muun muassa materiaalivirroille. Konejärjestelmä taas on koneiden muodostama kokonaisuus, kun taas tuotantojärjestelmään voidaan katsoa koneiden lisäksi muun muassa työntekijät, työkalut sekä kokoonpano. Tässä työssä käsitellään koneoppimisen sovelluksia Internet of things – pohjaisen konejärjestelmädatan analysoinnissa erityisesti tuotantotekniikan näkökulmasta.

2.1 Internet of things

Internet of things on järjestelmä, joka mahdollistaa laitteiden liittämisen toisiinsa sekä laajempiin tietoverkkoihin Internetin välityksellä, joka voidaan toteuttaa langallisesti tai langattomasti esimerkiksi WiFi-sovelluksilla. Tämä mahdollistaa esimerkiksi entistä laajemman datan hankkimisen ja pidemmälle viedyn automaation. Suomen kielellä käytetään joskus nimitystä esineiden Internet, mutta tämä ei ole vakiintunut nimitys. Myös lyhenne IoT on laajassa käytössä kansainvälisestikin.

Internet of thingsin alaluokka Industrial Internet of things eli IIoT on tämän kandidaatintyön kannalta erityisen kiinnostava. Malakutin et al. mukaan IIoT voidaan jakaa kolmeen kerrokseen, joita ovat application eli sovellus, platform eli alusta sekä asset. Assetit ovat esimerkiksi IIoT-järjestelmän toimilaitteita kuten moottoreita. Useimmiten assetit ovat laitteiston fyysisiä osia, mutta esimerkiksi manipulaattoria ohjaavaa ohjelmistoa pidetään myös assetina [13].

Alusta tarkoittaa tässä yhteydessä sovellukseen sitomattomia komponentteja, kuten tietorakenteita tai pilvipalveluita. Vaikka suurin osa alustan komponenteista on

ohjelmiston sisäisiä, voidaan joitain laitteiston osiakin, kuten portteja, pitää Malakutin et al. mukaan alustaan kuuluvina osina. Sovellus taas tarkoittaa Malakutin et al. mukaan tarkemmin määriteltyä tehtävää, kuten esimerkiksi ennakoivaa kunnonvalvontaa, josta kerrotaan tarkemmin kappaleessa 3.2. IIoT:ssa sovellukset edustavat usein Malakutin et al. mukaan alaluokkaa engineering tools, joka mahdollistaa muun muassa laitteiden sijainnin selvittämisen ja niiden asetusten muuttamisen [13]. Alla olevassa taulukossa (1) on esitetty IoT:n kerrokset, kerrokseen kuuluvat tehtävät, vaihtoehtoisia toteutustapoja näille tehtäville ja näiden ominaisuuksia sekä esimerkkejä teknologioista, joilla nämä voidaan toteuttaa.

Kerros	Tehtävä	Vaihtoehtoisia toteutustapoja	Ominaisuuksia	Esimerkkejä teknologiasta
Asset (esimerkiksi toimilaite)	Tietorakenteiden koostumus ja rakenne	Standardoitu	Hyvä yhteentoimivuus, heikko toiminnallinen soveltuvuus	FDI, AutomationML, PLCOpen
		Sovelluskohtainen	Heikko yhteentoimivuus, hyvä toiminnallinen soveltuvuus	Yrityksen sisäiset ratkaisut
		Karkea	Heikko yhteentoimivuus	OPC UA DI
		Datan lisääminen semanttisesti	Hyvä yhteentoimivuus	ecl@ss, CDD, OWL
	Tiedonhankinta	Manuaalinen	Heikko tehokkuus ja huollettavuus	Teollisuuden engineering tools -sovellukset
		(ainakin osittain) automaattinen	Hyvä tehokkuus ja huollettavuus	mDNS, UPnP, DHCP
	Tietorakenteiden sijainti	Sulautettu	Hyvä yhteentoimivuus, heikko turvallisuus. Suorituskyky sovelluksesta riippuen hyvä tai heikko.	Sulautettu OPC UA -palvelin
		Edge	Hyvä yhteentoimivuus ja turvallisuus, heikko suorituskyky	Keräytetty OPC UA -palvelin
		Pilvipalvelut	Hyvä yhteentoimivuus ja turvallisuus, heikko suorituskyky	SQL, WebAPI, GraphDb, DocumentDB
	Platform (alusta)	Datan tallentaminen kiinteistön sisäisesti	Manuaalinen datan konfiguraatio	Heikko huollettavuus ja tehokkuus
Automaattinen datan konfiguraatio			Hyvä huollettavuus ja tehokkuus	UPnP, mDNS
Pilvipäätteiden määrittely		Manuaalinen pilvipäätteiden määrittely	Heikko huollettavuus, tehokkuus sekä saatavuus	Liitettävyyden engineering tools -sovellukset
		Automaattinen pilvipäätteiden määrittely	Hyvä huollettavuus, tehokkuus sekä saatavuus	Azure DPS, AWS
Kommunikaatio Edgeen		Yleinen protokollatuki	Hyvä huollettavuus ja yhteentoimivuus, heikko yhteensopivuus ja tehokkuus	OPC UA, oneM2m
		Verkkotunnukseen sidottu protokolla	Hyvä yhteensopivuus, heikko yhteentoimivuus, huollettavuus sekä suorituskyky	Haaroin Dockerissa
Kommunikaatio pilvipalveluun		Viestipohjainen kommunikaatio	Hyvä skaalautuvuus ja suorituskyky	MQTT, AMQP
		Transaktiopohjainen kommunikaatio	Heikko skaalautuvuus ja suorituskyky	AWS CloudFront, Azure Service Fabric
Käyttöliittymätason yhteentoimivuus		Standardisoitu	Hyvä yhteentoimivuus, heikko toiminnallinen soveltuvuus	MIMOSA
		Sovelluskohtainen	Heikko yhteentoimivuus, hyvä toiminnallinen soveltuvuus	REST/Swagger, OPC UA
Tietorakenteiden yhteentoimivuus	Yleinen malli	Hyvä yhteentoimivuus, heikko toiminnallinen soveltuvuus	OPC UA	
	Vertaiskartoitus	Heikko yhteentoimivuus, hyvä toiminnallinen soveltuvuus	Mukautettu palvelu	
Application (sovellus)	Käyttäjäkokeemus ja liikkuvuus	PC-pohjainen käyttöliittymä	Hyvä käytettävyys sekä toiminnallinen soveltuvuus, heikko asennettavuus	Microsoft WPF, QT, GTK
		Web-pohjainen käyttöliittymä	Heikko käytettävyys ja toiminnallinen soveltuvuus, hyvä asennettavuus	AngularJS, BackboneJS, React
		Mobiilipohjainen käyttöliittymä	Heikko käytettävyys ja toiminnallinen soveltuvuus, hyvä asennettavuus	ReactNative, Xamarin
	Avoimet datamallit	Standardisoitu	Hyvä yhteentoimivuus	AutomationML, PLCOpen, Collada, IEC61499, ecl@ss
		Sovelluskohtainen	Heikko yhteentoimivuus	Company-specific
	Konfiguraatio-mahdollisuudet	Manuaalinen	Heikko tehokkuus ja huollettavuus, hyvä toiminnallinen soveltuvuus	Teollisuuden engineering tools -sovellukset
		(ainakin osittain) automaattinen	Hyvä tehokkuus ja huollettavuus, heikko toiminnallinen soveltuvuus	mDNS, UPnP, DHCP

Taulukko 1. *Taulukossa on esitetty IoT:n ohjelmistoarkkitehtuuri ja esimerkkejä sen kerroksille kuuluvista tehtävistä, vaihtoehtoista näiden tehtävien toteuttamiseen, näiden vaihtoehtojen hyvät ja huonot puolet sekä esimerkkejä kunkin toteuttamisen teknologioista. Tämän taulukon kaikki sovellukset edustavat engineering tools -alaluokkaa. Muokattu lähteestä [13].*

2.2 Koneoppiminen

Machine learning eli koneoppiminen on osa tekoälyä, ja kuvaa nimensä mukaisesti järjestelmän kykyä oppia itsenäisesti. Big data tarkoittaa Mohantyn mukaan ilmiötä, jossa dataa kerääntyy tarkoituksella tai tarkoituksettomasti suuria määriä. Kone- ja tuotantojärjestelmädata, jota työssä käsitellään, sopii esimerkiksi big datasta. Datan mahdollisia lähteitä on useita, joista työn kannalta oleellisimpia IoT:hen liittyvät sensorit sekä koneiden tekemät mittaukset. Myös datan analyysin keinoja on useita, työn kannalta tärkeimpänä koneoppiminen [8].

Koneoppimisen jaottelu osa-alueisiin voidaan tehdä monella tapaa. Huangin et al. (2008) mukaan se voidaan jakaa kahteen osaan, joita ovat global sekä local learning. Tärkeimpänä erona näillä on datan käyttö, joka local learningissa on hyvinkin rajattua ja halutun tiedon oleellisimpiin osiin keskittyntä. Global learningia käytettäessä dataa taas hyödynnetään laajalti ja joskus käytetään jopa kaikkea saatavilla olevaa dataa. Local learning tarjoaa global learningiin verrattuna paremman suorituskyvyn ja matemaattisen ennustettavuuden, mutta häviää global learningille datan monipuolisuudessa. Global learning voidaan edelleen jakaa useaan osaan, joita ovat esimerkiksi conditional ja non-parametric learning, Bayesian average learning sekä maximum likelihood learning. Global ja local learningin yhdistelmää kutsutaan nimellä hybrid learning [2]. Sen sijaan M. Bertolini et al. kirjoittavat (2021, sivulla 3) toisenlaisesta jaottelusta, jossa osa-alueita ovat valvottu sekä valvomaton oppiminen ja vahvistusoppiminen. Valvottu oppiminen (*supervised learning*) perustuu ennakointiin, ja koostuu erilaisista algoritmeista. Valvomaton oppiminen (*unsupervised learning*) perustuu sen sijaan datassa esiintyvien samanlaisina toistuvien kaavojen havaitsemiseen. Vahvistusoppiminen (*reinforcement learning*) taas perustuu interaktiivisuuteen järjestelmän ja sen ympäristön välillä [20]. Vahvistusoppiminen on nykyhetken koneoppimisessa suuressa roolissa, ja Rasmussenin et al. mukaan muun muassa ChatGPT on koulutettu juuri tätä koneoppimisen osa-aluetta hyödyntäen [23].

2.2.1 Global ja local learning

Global learningia käytettäessä kartoitusfunktio voidaan määritellä seuraavasti:

$$c = \arg \max p(c_k | D, z) = \arg \max \int p(c_k, \theta | D, z) d\theta \quad (1)$$

Bayesin teoreemaa soveltamalla saadaan kaava muotoon:

$$p(c_k | D, z) = \frac{p(c_k, z | D, \theta) p(\theta | D)}{\sum_{c_k} \int p(c_k, z | D, \theta) p(\theta | D) d\theta} \quad (2)$$

Koska nimittäjällä ei käytännössä ole vaikutusta, voidaan kaavaa approksimoida seuraavasti:

$$c = \arg \max \int p(c_k, z | D, \theta) p(\theta | D) d\theta \quad (3)$$

Parametreistä θ ja D sekä niiden käytöstä riippuen käytetään jotain seuraavista global learningin alaluokista:

- Generatiivinen oppiminen (*generative learning*)
- Suurimman todennäköisyyden oppiminen (*maximum likelihood learning*)
- Maximum A posterior learning
- Suurimpaan ehtoon perustuva oppiminen (*maximum conditional learning*)
- Bayesin keskiarvoon perustuva oppiminen (*Bayesian average learning*)
- Parametritön oppiminen (*non-parametric learning*)
- Virheen minimointiin pyrkivä oppiminen (*Minimum error minimax probability machine*) [2]

Alla olevassa taulukossa (2) on esitetty koneoppimisen luokat global, local ja hybrid learning sekä niiden osa-alueet. Edelleen on esitetty näiden osa-alueiden sovelluksia.

Global Learning	Generative Classifiers	Bayesian Average Learning	Bayesian Point Machine
			Maximum Entropy Discrimination
		Conditional Learning	
		Maximum Likelihood Learning	Minimax Probability Machine
	Non-parametric Learning		
	Minimum Error Minimax Probability Machine	Minimax Probability Machine	
		Biased Minimax Probability Machine	
Fisher Discriminant Analysis			
Local Learning	Discriminant Learning	Support Vector Machines	
		Neuroverkot	
		Gabriel Graph	
Hybrid Learning	Max-Min Margin Machine	Support Vector Machines	
		Minimax Probability Machine	

Taulukko 2. Taulukossa on esitetty koneoppimisen luokat local, global ja hybrid learning ja edelleen näiden osa-alueet. Muokattu sivulta 14 lähteestä [2].

2.2.2 Valvottu ja valvoton oppiminen sekä vahvistusoppiminen

Valvotun oppimisen algoritmeista Bertolini et al. nostaa esiin muun muassa neuroverkot ja päätöspuut. Yhteistä näille kaikille on valvotun oppimisen tarkoitus pyrkiä arvioimaan haluttua suuretta mahdollisimman tarkasti. Tämä tehdään luomalla tietojoukko ja tämän jälkeen jakamalla se opettaviin (*training*) ja testaaviin (*testing*) alkioihin. Opettavia alkioita käytetään ennalta määritellyn hävikkifunktion minimoin-

tiin. Tämä tehdään yleisesti iteroimalla. Testaavia alkioita taas käytetään mallin tarkkuuden määrittämiseen. Tämä onnistuu, koska niitä ei käytetty opetusvaiheessa.

Valvomaton oppiminen, kuten jo aiemmin todettu, pyrkii ennustamisen sijaan löytämään datasta erilaisia samanlaisia toistuvia kaavoja. Valvomaton oppiminen on erityisen hyödyllistä niin kutsutun perustotuuden (*ground truth*) puuttuessa. Tällainen tilanne on esimerkiksi silloin, jos järjestelmän niin sanottu outputvektori puuttuu.

Valvomaton oppiminen voidaan edelleen jakaa kolmeen osa-alueeseen, joita ovat klusterianalyysi (*clustering*), tiheysanalyysi (*density estimation*) sekä dimension redusointi (*dimensionality reduction*). Klusterianalyysissä alkiot jaotellaan ryhmiin niin, että jokaisen ryhmän alkiot ovat keskenään enemmän samanlaisia kuin ryhmän ulkopuoliset alkiot. Nimensä klusterianalyysi on saanut ryhmien nimityksestä klusteri. Tiheysanalyysi taas käsittää useita työkaluja muun muassa vinouden havaitsemiseen. Yksinkertaisimmillaan nämä työkalut ovat esimerkiksi histogrammeja, monimutkaisempia taas ovat muun muassa Parzenin ikkuna sekä vektorin kvantisointi. Osa-alueista dimension redusointi on tämän opinnäytetyön aiheen kannalta kiinnostavin, sillä sitä käytetään muun muassa big datan analysointiin. Tässä se onkin erityisen kätevä, sillä se kykenee tiivistämään dataa muuttamatta sen sisältämää tietoa. Dimension redusoinnin työkaluja ovat muun muassa pääkomponenttianalyysi (*Principal components analysis, PCA*) ja erilaiset neuroverkkoihin perustuvat sovellukset. Dimension redusointi pyrkii esittämään datasta vain ne alkiot, joiden avulla datan tärkeimmät piirteet voidaan esittää ilman informaation hukkaamista.

Vahvistusoppiminen eroaa selvästi muista koneoppimisen osa-alueista, sillä se perustuu järjestelmän ja ympäristön vuorovaikutukseen. Vahvistusoppiminen ei tarvitse aiempaa dataa toimiakseen, vaan tavoitteena on järjestelmän itsenäinen oppiminen perustuen palkitsemiseen järjestelmän tehdessä oikean päätöksen. Vahvistusoppiminen perustuu suureen määrään toistoja ja palkitsemisen johdosta järjestelmä oppii toimimaan halutulla tavalla. Tästä on juonnettu myös vahvistusoppimisen toinen nimi, trial-and-error-oppiminen. Vahvistusoppimisen algoritmeja on muun muassa Q-learning, jossa järjestelmä oppii tekojensa painoarvon. Vahvistusoppiminen voidaan myös yhdistää valvotun tai valvomattoman oppimisen algoritmeihin oppimisen tehostamiseksi. Mikäli tässä käytetään neuroverkkoja, kutsutaan tätä nimellä syvä vahvistusoppiminen (*Deep Reinforcement Learning, DRL*). DRL-

työkaluista esimerkiksi double Q-learning perustuu Q-learningin ja neuroverkkoihin perustuvien algoritmien yhteistyöhön [20].

2.3 Kone- ja tuotantojärjestelmät

Konejärjestelmällä tarkoitetaan usean koneen muodostamaa kokonaisuutta. Koska työtä käsitellään tuotantotekniikan näkökulmasta, on konejärjestelmä esimerkiksi tehdas, tuotantolinja tai niiden osa. Tällöin voidaan käyttää myös nimitystä tuotantojärjestelmä. Tuotantojärjestelmään voidaan katsoa myös kuuluvan muita toimijoita, kuten myyntiä, suunnittelua ja kuljetusta. Kone- tai tuotantojärjestelmädata on siis tämän kokonaisuuden hallintaan ja/tai toimintaan liittyvää dataa. Tätä dataa voidaan kerätä esimerkiksi sensorien avulla, jotka voidaan sijoittaa muun muassa koneisiin, komponentteihin, materiaaleihin tai tuotteisiin. Dataa voidaan yksinkertaisesti kerätä myös palautteena työntekijöiltä tai sidosryhmiltä kuten asiakkailta.

Tuotantojärjestelmän tärkeimmät osat ovat koneet, työkalut ja kiinnittimet, kokoonpano, materiaalinhallintajärjestelmä, työntekijät sekä tietokonejärjestelmät. Koneet voidaan jakaa karkeasti kolmeen eri ryhmään: käsikäyttöisiin, jotka vaativat jatkuvaa työntekijän läsnäoloa, puoliautomaattisiin, jotka kykenevät tekemään osan työvaiheesta itsenäisesti, sekä täysin automaattisiin, jotka kykenevät tekemään usean työjakson peräkkäin ilman ihmisen avustusta. Puoliautomaattisia koneita ovat muun muassa numeeriseen ohjaukseen (*Computerized Numerical Control, CNC*) perustuvat koneet, esimerkiksi koneistuskeskukset, jotka tarvitsevat työntekijän lataamaan ja purkamaan koneen ennen työvaihetta ja sen jälkeen [5]. Useimmiten CNC-järjestelmien ohjaus perustuu nykyään PC-arkkitehtuuriin. Kuvassa 1 on esitetty hyvin tyypillinen Windows XP-pohjaisen CNC-järjestelmän, Jingdiao JD50:n, ohjauspaneeli. Uusimmat vastaavat ohjauspaneelit on muotoiltu ergonomisemmin työn mukavuuden ja turvallisuuden vuoksi. Erilaisten Windows-versioiden ohella myös useat versiot Linuxista ovat yleisiä käyttöjärjestelmiä CNC-ohjaukseen perustuville koneille.



Kuva 1. Kiinalaisen Beijing Jingdiao valmistaman Jingdiao JD50 -CNC-järjestelmän ohjauspaneeli koneistuskeskuksen ohjaamiseen. Kuvassa erottuvat hyvin muun muassa punainen hätäpysäytyslaite sekä sen alapuolella mustat kiertonupit karan pyörimis- ja syöttönopeuden säätämiseen. Kuvassa erottuu myös niin ikään musta käsipyörä, jota voidaan käyttää muun muassa karan sijainnin hienosäätöön. Wikimedia Commons, Jingdiao JD50 Control System.png, lisensoitu Creative Commons Nimeä-JaaSamoin 4.0 Kansainvälinen -lisenssillä, käyttäjältä HafeezJD. Saatavissa: https://commons.wikimedia.org/wiki/File:Jingdiao_JD50_Control_System.png

Myös kokoonpano voidaan karkeasti jakaa kolmeen osa-alueeseen. Nämä ovat manuaalinen eli työntekijän suorittama kokoonpano, automatisoitu eli juuri kokoonpanoa varten suunniteltujen laitteiden suorittama kokoonpano ja robotisoitu eli niimensä mukaisesti yhden tai useamman robotin suorittama kokoonpano [5]. Materiaalinhallintajärjestelmät (*Material Handling System*, MHS) taas ovat järjestelmiä, jotka mahdollistavat materiaalivirrat. Ne voivat perustua muun muassa liukuhihnoin, vihivaunuihin tai työntekijöiden ajamiin trukkeihin. Myös vihivaunujen ohella muut robotit, kuten manipulaattorit, saatetaan lukea materiaalinhallintajärjestelmiin riippuen niiden käyttötarkoituksesta. Materiaalinhallintajärjestelmän valinta riippuu hyvin paljon tuotannon tyypistä, erityisesti tuotantoerien koosta.

Tietokonejärjestelmät ovat myös modernin tuotannon kannalta hyvin tärkeä osa tuotantojärjestelmää. Ne kytkeytyvätkin jokaiseen muuhun osa-alueeseen hyvin vahvasti. Esimerkiksi tietokoneavusteinen suunnittelu ja valmistus (*Computer Aided Design* sekä – *Manufacturing*, CAD ja CAM) ovat laajasti käytössä suuressa osassa valmistavaa teollisuutta. Tietokonejärjestelmää tarvitaan myös robotisoitujen työvaiheiden toteuttamiseen. Näitä saattavat olla esimerkiksi hitsaus tai maalaus. Myös materiaalinhallintajärjestelmä vaatii toimiakseen tietokonejärjestelmää, jos se on toteutettu vihivaunuilla tai liukuhihnalla. Tietokonejärjestelmä tarjoaa myös apua trukkeihin perustuvassa sovelluksessa, esimerkiksi tarjoamalla työntekijälle ilmoituksen valmiista työvaiheesta, jolloin trukkia ajava työntekijä pääsee siirtämään kappaleen uudelle työasemalle. Tietokonejärjestelmä on myös todella suuressa roolissa tämän työn aiheessa, eli IoT:n ja koneoppimisen integroimisessa tuotantojärjestelmiin.

3. NYKYHETKEN SOVELLUKSIA

Nämä ovat sovelluksia, jotka ovat laajemmassakin kuin tutkimuskäytössä. Yleisimmät sovellukset ovat erilaisia materiaalinhallintajärjestelmiä. Lisäksi yksi yleinen sovelluskohde on Internet of Things – ICIOT 2020 -konferenssiohjelman mukaan kokenäköön tai niin kutsuttuun WiVi – eli wireless vision -teknologiaan pohjautuva tunnistusmekanismi esimerkiksi tuotteille. WiVi mahdollistaa muun muassa tuotteiden javainnoinnin joidenkin sellaisten materiaalien läpi, joiden läpi perinteision kokenäön sovellusten avulla ei nähdä [17]. Koneoppimisen ansiosta järjestelmä oppii tunnistamaan virheelliset tuotteet, mikä helpottaa ja nopeuttaa niiden hylkäämistä. Lisäksi IoT-sovelluksia ja koneoppimista on mahdollista hyödyntää myös tuotannon suunnittelussa ja erityisesti tuotannon ajoittamisessa. Esimerkiksi lastuavassa työstössä mahdollisuudet korostuvat työkalujen paikoin nopean kuluman takia. Työstö voidaan suunnitella työkalun kulumisen huomioon ottaen esimerkiksi työstettävän kappaleen mitoituksessa tai työstöjärjestyksessä.

3.1 Materiaalinhallintajärjestelmät

Materiaalinhallintajärjestelmät (*material handling system*, MHS) ovat järjestelmiä, jotka mahdollistavat materiaalivirrat esimerkiksi koneiden välillä tai varastointiin. Myös materiaalinhallintajärjestelmän toiminta voi perustua IoT:n lisäksi koneoppimiseen. Liukuhihnatuotanto (*traditional manufacturing*) sekä solutuotanto (*cellular manufacturing*) vaativat keskenään hieman erilaisia materiaalinhallintajärjestelmiä: esimerkiksi vihivaunut sopivat hyvin solutuotantoon helpon uudelleen järjestelemisen vuoksi, mutta liukuhihnatuotantoon ne ovat Ullrichin mukaan useimmiten tarpeettoman monimutkaisia, ja perinteinen liukuhihnaan perustuva materiaalinhallintajärjestelmä on parempi vaihtoehto [9].

3.1.1 Vihivaunut

Kirjallisuudessa esimerkiksi Fazlollahtabar ja Saidi-Mehrabad kirjoittavat sivuilla 41-44 vihivaunujen, eli itsestään ajavien, usein trukkimallisten, kappaleiden kuljettamiseen tarkoitettujen ajoneuvojen olevan joustavin tapa toteuttaa materiaalivirrat tuotantajärjestelmän sisäisesti [6]. Toinen yleinen tapa toteuttaa vihivaunun rakenne

on matala vihivaunu, joka kantaa kuormaa päällään. Jotkut kirjoittajat, kuten Melo ja Corneal kuitenkin käyttävät pisimmälle kehittyneistä sovelluksista nimitystä Autonomous Mobile Robot eli AMR [19]. Fazlollahtabar ja Saidi-Mehrabad kertovat sivuilla 98-111 vihivaunujen ohjaamisen mahdollisesti perustuvan neuroverkkoihin, jotka pyrkivät jäljittelemään ihmisen aivojen toimintaa. Tämä sovellus voi perustua sumeaan logiikkaan (*fuzzy logic*), joka tarkoittaa tapaa ratkaista ongelmia sääntöpohjaisesti matemaattisten mallien sijaan. Sumea logiikka toimii myös datalla, joka on epätarkkaa tai puutteellista, jolloin se sopii hyvin vihivaunun tai muun itsestään ohjautuvan ajoneuvon ohjauksen järjestämiseen. Tämä mekanismi on verrattavissa ihmisaivojen toimintaan, mutta toimii paljon nopeammin [6].

Ullrich kirjoittaa vihivaunujen käyttöönoton alkaneen jo 1950-luvulla, ja näiden varhaisten sovellusten perustuneen esimerkiksi mekaanisiin kytkimiin puskureissa sekä lattiaan sijoitetun magneettisen linjan seuraamiseen. Muutamaa vuotta myöhemmin Englannissa kehitetty sovellus perustui magneettisen linjan sijaan lattiaan piirrettyyn, värilliseen viivaan, jota vihivaunu kykeni seuraamaan optisten sensorien ansiosta. 1960-luvulla transistorin yleistyminen syrjäytti elektroniputket ja helpotti autonomisen ajamisen toteuttamista. 1970-luvulla vihivaunut alkoivat jo perustua yksinkertaisiin tietokoneisiin, ja sensorteknologian kehitys kasvatti vihivaunujen suosiota. 1990-luvulta alkaen sovellukset saattoivat perustua jo normaaleihin PC-tietokoneisiin, joka sekin laski niiden hintaa. Myös sensori- ja moottoriteknologian kehitys entisestään mahdollisti entistä monimutkaisemmat sovellukset [9]. IoT ja koneoppiminen ovat kuitenkin vihivaunujen osalta melko uusia sovelluksia.



Kuva 2. JBT:n valmistama trukkimallinen vihivaunu. Kuvasta erottuvat vihivaunulle tyypilliset turvallisuusvarusteet, kuten varoitusvalot ja hätäpysäytyslaite. Wikimedia Commons, Agv.forktruck2.jpg, public domain, vapaasti yleisessä käytössä, käyttäjältä AutoGuidedVehicles. Saatavissa: <https://upload.wikimedia.org/wikipedia/commons/6/62/Agv.forktruck2.jpg>

Ullrichin mukaan vihivaunu voidaan manuaalisesti ajattaa uuden reitin läpi, jolloin se oppii tämän reitin. Vaihtoehtoisesti tiedot voidaan myös ladata esimerkiksi verkosta. Vihivaunujen reitin optimointi koneoppimisen avulla on myös tässä järjestelmässä mahdollinen sovellus [9].

3.1.2 Muut materiaalinhallintajärjestelmät

Neumann esittelee Merkuryevin et al. teoksen kappaleessa 10 vihivaunujen ohella myös muita materiaalinhallintajärjestelmiä. Yksi perinteinen tapa toteuttaa materiaalivirta on liukuhihnaan ja erilaisiin robotteihin, yleisesti manipulaattoreihin, perustuva sovellus. Neumannin mukaan robotit huolehtivat usein tässäkin sovelluksessa materiaalien purkamisesta ja tuotteiden pakkaamisesta. Näistä Neumann käyttää nimitystä depalletising tai palletising robot.

Kuormia liikutellaan yleisesti kuormalavoilla. Neumannin mukaan nämä ovat standardimitoitettuja, esimerkiksi niin sanottuja eurolavoja, jotka ovat kooltaan 800 x

1200 mm. Eurolavojen käyttö on erityisen edullista juuri standardoinnin vuoksi, ja esimerkiksi asiakasyritys ei tarvitse varsinaista materiaalinhallintajärjestelmää trukin lisäksi kuorman purkamiseen. Liikutteluun käytetään liukuhihnojen ohella kääntölavoja, jotka mahdollistavat jyrkät käännökset. Vihivaunujakin voidaan käyttää, näistä Neumann käyttää tässä sovelluksessa nimitystä sukkula. IoT-sovelluksia käytetään esimerkiksi ilmoittamaan sukkuloille paketin olevan valmis noudettavaksi. Myös muiden järjestelmän osien valmisteluun paketin vastaanottamiseen käytetään usein IoT-sovelluksia, kuten RFID-siruja. Vastaava sovellus on myös mahdollista toteuttaa esimerkiksi trukeilla, jolloin ilmoituksen saa sukkulan sijaan työntekijä.

Korkean standardisoinnin vuoksi tällaisessa järjestelmässä koneoppimisen soveltaminen on usein melko vähäistä. Sitä voidaan kuitenkin käyttää ruuhkien välttämiseen: usein järjestelmissä on kohtia, johon kerääntyy useita paketteja samanaikaisesti. Neumannin mukaan kääntöpöydät ovat usein tällaisia, sillä 90 ° kääntymiseen kuluu aikaa esimerkkilaitteelta kuusi sekuntia. Koneoppimisen avulla järjestelmä voidaan esimerkiksi opettaa käsittelemään paketit parhaassa mahdollisessa järjestyksessä, ja näin ollen minimoida hukka-aika. Koneoppimista voidaan myös hyödyntää jo suunnitteluvaiheessa: olemassa olevista materiaalinhallintajärjestelmistä voidaan kerätä dataa, kuten läpimenoaika ja järjestelmän sijoittelu. Koneoppimisen avulla voidaan uuden materiaalinhallintajärjestelmän suunnittelu automatisoida näitä tietoja hyväksi käyttäen esimerkiksi digitaalista kaksosta [3].

Myös pystysuorat hissijärjestelmät (*vertical lift module*, VLM) kuuluvat materiaalinhallintajärjestelmiin. Niitä käytetään varastoimaan muun muassa komponentteja, keskeneräisiä tuotteita tai työkaluja. Ne koostuvat hyllyistä sekä itse hissistä, joka liikkuu sovelluksesta riippuen joko ainoastaan pystysuorassa tai tämän lisäksi vaakasuorassa. VLM-järjestelmät on helppo yhdistää sekä liukuhihnoihin että vihivaunujen tai trukkien lastausasemiin. Järjestelmät soveltuvat materiaalin painosta ja sovelluksesta riippuen myös työntekijöiden manuaalisesti käytettäväksi, ja tällöin niiden etuna on muun muassa ergonomisuus. Toinen merkittävä järjestelmän tarjoama etu on tilankäyttö, ja esimerkiksi Shelving + Rack Systems, Inc.-yrityksen tarjoama sovellus vapauttaa yrityksen mukaan jopa 85 % tilaa perinteiseen varastointiin verrattuna. Sovellukset myös parantavat varastoinnin tehokkuutta. Yritys tarjoaa sovellukselleen myös esimerkiksi IoT-pohjaisia ominaisuuksia, kuten reaaliaikaisen sisällön ja käyttöasteen valvonnan. Koneoppimista yritys hyödyntää muun muassa ennakoivassa kunnonvalvonnassa, käyttöasteen ennakoinnissa ja varastoinnin optimoinnissa. Yrityksen mukaan järjestelmä kykenee myös muun muassa siirtele-

mään itsenäisti varastoituja kappaleita järjestelmän sisäisesti varastoinnin optimoinnin yhteydessä [24].

4. TEOREETTISET SOVELLUKSET

Tässä kappaleessa käsitellään sovelluksia, jotka eivät ole päätyneet laajempaan käyttöön. Näitä sovelluksia, jotka olisivat ainakin jollain tasolla mahdollisia toteuttaa nykYTEKNOLOGIALLA, mutta tätä ei syystä tai toisesta ole tehty, on paljon. Syynä on useimmiten korkea hinta, pienet hyödyt, monimutkaisuus tai näiden yhdistelmä. Nämä taas johtuvat erilaisista teknologian, lainsäädännön sekä yhteiskunnan aiheuttamista rajoitteista, joita on pohdittu tarkemmin kappaleessa 5. Yhteistä kaikille näille sovelluksille on korkea digitalisaation aste ja mahdollisesti tarve uudistaa suurinta osaa, ellei koko järjestelmää, niiden käyttöönoton mahdollistamiseksi.

4.1 Ennakoiva kunnonvalvonta

Yksi todennäköisesti tulevaisuudessa yleistyvä sovellus on ennakoiva kunnonvalvonta, (*predictive maintenance*). Ennakoivaa kunnonvalvontaa voidaan pitää kuntoon perustuvan huollon (*condition based maintenance*, CBM) seuraavana kehitysaskeleena, sillä se yhdistää CBM:n automaation elementtejä. Esimerkiksi Shelving + Rack Systems, Inc käyttää muun muassa jo nyt ennakoivaa kunnonvalvontaa VLM-järjestelmissään [24]. Tzafestas (1999) kirjoittaa kappaleessa 13 ennakoivan kunnonvalvonnan eroavan ajastetusta huollosta siten, että kun ajastettu huolto suunnitellaan MTTF:n sekä MTBF:n avulla, eli ennustamalla seuraava vikaantumisen vikaantumishistorian sekä vastaavien sovellusten perusteella, perustuu ennakoiva kunnonvalvonta haurastumisen tarkkailuun, ennustamiseen sekä diagnooseihin. Ennakoivan kunnonvalvonnan avulla on mahdollista välttää osien turhaa vaihtamista ja ehkäistä vikaantumista ennen ajastetun huollon ajankohtaa. Sekä tarpeeton osien vaihtaminen että laitteen pitäminen toimettomana rikkoutumisen takia aiheuttaa yritykselle kuluja. Integroidun CMMS:n sekä DIASin avulla voidaan helpommin integroida ennakoiva kunnonvalvonta osaksi tuotantojärjestelmää [1].

Kehityksestä huolimatta ennakoiva kunnonvalvonta ei ole vielä kovin laajalle levinnyt sovellus. Masoni et al. ennustavat etäyhteyden kautta tapahtuvan kunnonvalvonnan, englanniksi *remote maintenance*, olevan tulevaisuudessa tärkeä osa tuotantojärjestelmien kunnossapitoa. *Remote maintenance* kuuluu osana *Industrie 4.0*:a, josta kerrotaan tarkemmin kappaleessa 4.2.1. *Remote maintenance* voidaan

toteuttaa muun muassa virtuaalitodellisuuden (*virtual reality*, VR) tai lisätyn todellisuuden (*augmented reality*, AR) avulla [12].

4.2 Digitalisoitu valmistus

U. Reisingerin mukaan digitalisoitu valmistus, englanniksi *digitalized manufacturing*, on kehittynyt viime aikoina nopeasti pitkälle kehittyneen tietotekniikan sekä sen verkostoitumisen seurauksena. Se on synnyttänyt monia tavoitteita, joista Reisingerin mukaan tärkeimpiä ovat saksalainen *Industrie 4.0*, jota kansainvälisesti kutsutaan myös englanninkielisellä nimellä *Industry 4.0*, kiinalainen *Made in China 2015* sekä yhdysvaltalainen *Industrial Internet Consortium*. Reisinger kirjoittaa erityisesti hitsauksessa ja metalliteollisuudessa käynnissä olevasta muutoksesta: tuotteet ovat pelkän sarjatuotannon sijaan ainutlaatuisempia ja asiakkaan käyttötarkoitukseen ja suunnitelmiin paremmin sopivia [15]. Lisäksi asiakkaat haluavat itse tuotteen lisäksi esimerkiksi erilaisia digitaalisia palveluja, ja myös itse tuotteen voi myydä palveluna. Tätä kutsutaan yksinkertaisesti nimellä tuote palveluna (*product as service*).

4.2.1 Industrie 4.0

Beierin et al. mukaan *Industrie 4.0* on alueellinen nimitys, joka on käytössä esimerkiksi Saksassa. Sen sijaan Yhdysvalloissa käytetään nimitystä *Industrial Internet (of Things)* eli IIoT. Kuitenkin Saksan ollessa aatteen synnyinmaa, on *Industrie 4.0* kansainvälisesti tunnetuin nimitys. *Industrie 4.0* määrittellään Reisingerin teoksessa haluksi yhdistää digitaalisesti kaikki valmistuksen elementit, kuten komponentit, laitteet, järjestelmät, logistiikan ja valmistukseen liittyvät palvelut. Näin ollen *Industrie 4.0*:n tärkeitä osa-alueita ovat IoT sekä pilvipohjaiset palvelut. Myös kyberfysiset järjestelmät (*Cyber-physical systems*, CPS), ja tämän kandidaatintyön kannalta erityisesti niiden alaluokka kyberfysiset tuotantojärjestelmät CPPS (*cyber-physical production system*, CPPS) ovat tärkeitä. Nämä ovat mekatronisia järjestelmiä, eli niissä esiintyy mekaniikkaa, elektroniikkaa sekä tietotekniikkaa. Lisäksi erityisesti myös CPPS-järjestelmät koostuvat joustavista, autonomisista ja itsensä konfiguroivista CPS-yksiköistä, jotka kommunikoivat keskenään mahdollistaen näin päätöksenteon prosessiin liittyen [15]. Sandler kirjoittaa sivulla 41 robottien kouluttamisen koneoppimisen avulla olevan kuitenkin toistaiseksi liian kallista ja monimutkaista perinteiseen ohjelmointiin verrattuna [14].

5. SOVELLUSTEN KÄYTTÖÖNOTON HAASTEITA

Vaikka koneoppimisen sovellusten käytön verrattain vähäinen käyttöönotto tuotannossa on yleisimmin seurausta teknologian rajoitteista, on lisäksi monia muun muassa yhteiskuntaan perustuvia syitä. Yksi suuri hidaste sovellusten käyttöönottoon on psykologinen: Bibal, A. et al. (2020) mukaan (sivulla 8) useat ihmiset luottavat enemmän muihin ihmisiin kuin tekoälyyn [16]. Thomas D. Grant ja Damon J. Wischik kirjoittavat sivuilla 25–26 usein syynä olevan myös lainsäädännön, joka hidastaa pitkälle automatisoitujen sovellusten käyttöönottoa [18].

5.1 Teknologian rajoitukset

Suurin osa teknologian aiheuttamista rajoituksista sovellusten käyttöönotossa liittyy käyttöönoton korkeaan hintaan. Tämä johtuu puolestaan tarpeesta uudistaa usein koko järjestelmä, jotta sovellusten käyttö olisi mahdollista. Mohantyn mukaan yksi big datan ja näin ollen myös sekä koneoppimisen että IoT:n ongelma on datan tallennus: mekaaniset kiintolevyt rajoittavat erityisesti tiedonsiirtonopeuksia, joten SSD- eli puolijohdelevyt, ehkä tulevaisuudessa myös faasimuutosmuisti ovat nopeutensa ansiosta parempia vaihtoehtoja. Puolijohdelevyjen hinta ja faasimuutosmuistin huono saatavuus kuitenkin rajoittavat niiden käyttöönottoa. Datan nopeaa käyttöä rajoittavat myös huonosti optimoidut tietorakenteet [8].

Mohanty kirjoittaa myös datan käsittelyssä käytettävän DRAM-siruja, jotka tarvitsevat jatkuvasti sähköä toimiakseen, ja näin ollen niiden olevan herkkiä poikkeamille sähkönsyötössä sekä aiheuttavan suuren energiankulutuksen. Lisäksi paikoin heikosti toteutettu standardisointi vaikeuttaa eri järjestelmien yhteiskäyttöä [8].

5.2 Psykologiset ja sosiaaliset syyt

Yksi tärkeä hidaste pitkälle kehittyneen automaation käyttöönottoon tuotantotekniikassa on Kvalnesin mukaan huoli työllisyydestä: tekoälyyn pohjautuvat sovellukset ovat usein halvempia kuin työntekijät ja mahdollistavat korkeampilaatuisten tuotteiden valmistuksen [7]. Näin ollen nämä sovellukset syrjäyttävät ainakin osan työntekijöistä. Kuitenkin Tzafestas (2016) mukaan nykyään ajatellaan automaation syn-

nyttävän uusia, mielekkäämpiä työpaikkoja ja näin ollen työllisyyskysymyksen merkityksen voidaan katsoa pienentyneen viime vuosina. Automaation nähdään myös parantaneen työpaikkojen turvallisuutta ja tuottavuutta sekä mahdollistaneen muun muassa invalidien työskentelemisen tai etätyöskentelyn. Tästä päästään kuitenkin toiseen Tzafestasin esiin tuomaan ongelmaan: automaatio on useimmille vielä melko vieras käsite, ja tarvittavan koulutuksen omaavia henkilöitä ei paikoin ole tarpeeksi. Lisäksi jo kappaleessa 5.1 mainittu standardisoinnin puute vaikuttaa myös ihmisten toimintaan laitteiden kanssa: erilaiset järjestelmät saattavat vaatia aivan erilaisen koulutuksen ja usein järjestelmän uudistuessa tai vaihtuessa joudutaan koko henkilöstö kouluttamaan uudelleen [11]. Tätä vastaan voidaan taistella muun muassa lainsäädännöllä, esimerkiksi hätä-seis-painike on useissa maissa pakollinen varuste, ja laki määrää sen ulkonäöstä ja toiminnasta. Esimerkiksi Suomessa asetuksen 12.6.2008/400 mukaan painikkeen on ”oltava varustettu selvästi tunnistettavilla ja näkyvillä ohjaimilla, jotka ovat nopeasti käytettävissä”, ”pysäytettävä vaarallinen prosessi mahdollisimman nopeasti aiheuttamatta muita riskejä” sekä ”tarvittaessa käynnistettävä tiettyjä suojausliikkeitä tai sallittava niiden käynnistäminen.” [3]

Kvalnes kirjoittaa myös utilitaristisesta etiikasta, englaniksi *Utilitarian ethics*, joka tarkoittaa Joakim Sandbergin mukaan näkemystä, jossa teon positiiviset sekä negatiiviset seuraukset punnitaan keskenään [7]. Jo aiemmin mainittu luottamus on lisäksi yksi tärkeä hidaste sovellusten käyttöönottoon.

Ramaswamy ja Joshi kirjoittavat erilaisista turvallisuusuhista, joista kyberturvallisuus ja yksityisyys on monelle tärkeä: koneoppimiseen liittyvä datan kerääminen saattaa altistaa ihmisten yksityisyyden ohjelmiston kehittäjän omiin tarkoituksiin tai kyberriskuille. Kyberriskut luovat turvallisuusuhan myös itse konejärjestelmälle [4]. Lisäksi tunnettu fyysikko Stephen Hawking on Sendlerin mukaan ilmaissut huolensa tekoälyn kehityksessä, josta asiantuntijat ovat samaa mieltä, ja Sandler kirjoittaa tästä teoksensa sivulla 41: Hawkingin mukaan tekoäly voi kehittyä ihmisen arvoiseksi ja jopa ohittaa ihmisen tämän kehityksen ollessa rajoitettu hitaan biologisen evoluution vuoksi [14].

5.3 Lainsäädäntö

Yleinen ongelma teknologian kehityksessä on aina ollut lainsäädäntö, joka muuttuu hitaasti eikä pysy teknologian muutoksen perässä. Grantin ja Wischikin mukaan lainsäädäntö ei välttämättä kykene ennustamaan tekoälyn käytön sovelluksia tulevaisuudessa. Näin ollen uusia sovelluksia esiteltäessä lainsäädäntöä täytyy paikoin

muuttaa, joka osaltaan hidastaa niiden käyttöönottoa [18]. Lisäksi tekoälyyn liittyvä lainsäädäntö on usein monimutkaista: Danaherin mukaan esimerkiksi ihmisen tai omaisuuden vahingoittuessa tekoälyn toiminnan tai sen virheen seurauksena syyllisen määrittäminen on usein vaikeaa. Erityisesti koneoppimisen kanssa tämä ongelma korostuu, sillä perinteisellä ohjelmoinnilla toteutetun laitteen toiminnan merkitys on suhteellisen vähäinen. Danaherin mukaan tekoäly voi olla kausaalisessa vastuussa onnettomuudesta, mutta moraalisen hahmotuskyvyn puutteen takia laillisessa ja moraalisisessa vastuussa on aina ihminen. Näin ollen joissain tapauksissa voidaan myös päätyä tilanteeseen, jossa syyllisen löytäminen on vaikeaa tai jopa mahdotonta. Tästä ongelmasta Danaher käyttää nimitystä *retribution gap*. Pahimmassa tapauksessa tästä voi seurata jopa luottamuksen romahtaminen lainsäädäntöön. Yhdeksi ratkaisuksi ongelmaan Danaher ehdottaa vakuutusmaksuja, joilla maksetaan tekoälyn aiheuttamien onnettomuuksien uhrien korvaukset. Tämä ei kuitenkaan poista ongelmaa laillisen syyllisen löytymisestä tai mahdollisesti virheellisesti jaetuista tuomioista [10].

6. YHTEENVETO

IoT:n sekä koneoppimisen rooli on viime vuosina kasvanut sekä tuotannossa että yleisesti yhteiskunnassa ja ihmisten elämässä huomattavasti, ja tulevaisuudessa tämä kasvu tulee varmasti vielä nopeutumaan. Tämä kehitys on parantanut tuottavuutta sekä työntekijöiden oloja esimerkiksi työturvallisuuden ja työn mielekkyyden saralla. Kehitys auttaa myös hallitsemaan tuotannon aiheuttamaa kuormaa ympäristölle ja pienentämään kuluja.

Teknologioiden käyttöönoton suurin este on niiden korkea hinta, joka johtuu muun muassa tarpeesta uudistaa paikoin koko järjestelmä sovelluksen käyttöönottamiseksi. Lisäksi big data aiheuttaa tarpeen suurille tallennustiloille ja korkeille tiedonsiirtonopeuksille. Suurimpia haasteita itse teknologian lisäksi ovat ihmisten asenteissa: monet kokevat kehittyneen automaation olevan yhä uhka omalle työllisyydelleen. Tekoälyn kehittyessä myös siihen liittyvän lainsäädännön on kehitettävä ennen kuin uusimmat sovellukset voidaan ottaa laajasti käyttöön. Lainsäädäntö muuttuu hitaasti, mikä onkin myös aiemmin jarruttanut teknologian sovellusten käyttöönottoa.

Nykyään yleisimpiä sovelluksia ovat materiaalinhallintajärjestelmät, erityisesti viihvaunut. IoT-sovelluksia ja koneoppimista käytetään niissä nykyään muun muassa varastoinnin tai materiaalivirtojen seuraamiseen sekä optimointiin. Tärkeä sovellus on myös tärkeän datan erottelu muusta big data -ilmiön johdosta.

Tulevaisuudessa ennakoivan kunnonvalvonnan voi odottaa leviävän ja kehittyvän entisestään. Lisäksi tulevaisuudessa myös muu digitalisoitu valmistus tulee todennäköisesti kasvattamaan suosiotaan. Digitaalinen kaksonen tulee olemaan yhä suuremmassa osassa tuotantolinjojen suunnittelussa, ja sen suunnittelussa voidaan hyödyntää muun muassa laajennetun todellisuuden sekä virtuaalitodellisuuden sovelluksia. Industrie 4.0 ja digitalisoitu valmistus aiheuttavat myös pyrkimyksen kaikkien valmistamisen osa-alueiden yhdistämiseen digitaalisesti. Jo alkanut valmistuksen muutos perinteisestä sarjatuotannosta kohti tarkemmin räätälöityjä tuotteita kohtaan tulee kiihdyttämään vauhtiaan ja menemään yhä pidemmälle. Lisäksi yritykset tulevat hankkimaan tuotteen yhä useammin palveluna.

LÄHTEET

- [1] Tzafestas, S. G. (1999), *Advances in Manufacturing, Decision, Control and Information Technology*, Springer-Verlag London.
- [2] Huang, K., Yang, H., King, I. & Lyu, M. (2008). *Machine Learning, Modeling Data Locally and Globally*, Springer, Berlin, Heidelberg.
- [3] Valtioneuvoston asetus koneiden turvallisuudesta, 12.6.2008/400. Saatavissa: <https://www.finlex.fi/fi/laki/ajantasa/2008/20080400>.
- [4] Ramaswamy S., Joshi H. (2009) *Automation and Ethics*. In: Nof S. (eds) *Springer Handbook of Automation*. Springer Handbooks. Springer, Berlin, Heidelberg.
- [5] Caggiano, A. (2014). *Manufacturing System*. Teoksessa: Laperrière, L., Reinhart, G. (eds) *CIRP Encyclopedia of Production Engineering*. Springer, Berlin, Heidelberg. Saatavissa: https://doi-org.libproxy.tuni.fi/10.1007/978-3-642-20617-7_6562.
- [6] Fazlollahtabar, H. & Saidi-Mehrabad, M. (2015). *Autonomous Guided Vehicles Methods and Models for Optimal Path Planning*, Springer International Publishing.
- [7] Kvalnes, Ø. (2015). *Moral Reasoning at Work: Rethinking Ethics in Organizations*, Palgrave Macmillan, London.
- [8] Mohanty, H., Bhuyan, P. & Chenthati, D. (2015). *Big Data*, Springer India.
- [9] Ullrich, G. (2015). *Automated Guided Vehicle Systems: A Primer with Practical Applications*, Springer, Berlin, Heidelberg.
- [10] Danaher, J. (2016). *Robots, law and the retribution gap*. Saatavissa: <https://link-springer-com.libproxy.tuni.fi/content/pdf/10.1007/s10676-016-9403-3.pdf>.
- [11] Tzafestas, S. G. (2016). *Roboethics, A Navigating Overview*, Springer International Publishing Switzerland.
- [12] Masoni, R., Ferrise, F., Bordegoni, M., Gattullo, M., Uva, A. E., Fiorentino, M., Carrabba, E. & Di Donato, M. (2017). *Supporting Remote Maintenance in Industry 4.0 through Augmented Reality*, *Procedia Manufacturing*, Volume 11, sivut 1296-1302. Saatavissa: <https://www.sciencedirect.com/science/article/pii/S2351978917304651>.
- [13] Malakuti, S., Goldschmidt, T. & Koziolok, H. (2018). *A Catalogue of Architectural Decisions for Designing IIoT Systems*. Teoksessa: Cuesta, C., Garlan, D., Pérez, J. (eds) *Software Architecture. ECSA 2018. Lecture Notes in Computer Science*, vol 11048. Springer, Cham.

- [14] Sendler, U. (2018). *The Internet of Things, Industrie 4.0 Unleashed*. Springer Vieweg Berlin, Heidelberg.
- [15] Reisinger, U., Mann, S., Middeldorf, K. & Sharma, R. (2019). Connected, digitalized welding production—Industrie 4.0 in gas metal arc welding, *teoksessa Welding in the World* 63, sivut 1121-1131. Saatavissa: <https://link.springer.com/article/10.1007/s40194-019-00723-2#citeas>.
- [16] Bibal, A., Lognoul, M., de Streel, A. & Frénay, B. (2020). *Legal requirements on explainability in machine learning*, Springer Nature.
- [17] Samanta, S., Singhar, S. S., Gandomi, A. H., Ramasubbareddy, S & Sankar, S. (2020) *A WiVi Based IoT Framework for Detection of Human Trafficking Victims Kept in Hideouts*. *Teoksessa Song, W., Lee, K., Yan, Z., Zhang, L.-J. & Chen, H. (2020) Internet of Things – ICIoT 2020*, sivut 96-107, Springer. Saatavissa: <https://link.springer.com/content/pdf/10.1007/978-3-030-59615-6.pdf>
- [18] Grant, T. D., Wischik, D. J. (2020). *On the path to AI, Law’s prophecies and the conceptual foundations of the machine learning age*, Palgrave Macmillan, Cham.
- [19] Kazakov, D., Erten, C. (2020). *Inductive Logic Programming, 29th International Conference, ILP 2019, Plovdiv, Bulgaria, September 3–5, 2019, Proceedings*, Springer International Publishing.
- [20] Bertolini, M., Mezzogori, D., Neroni, M. & Zammori, F. (2021). *Machine Learning for industrial applications: A comprehensive literature review, Expert Systems with Applications, Volume 175*, kirjallisuusselvitys. Saatavissa: <https://www.sciencedirect.com/science/article/pii/S095741742100261X>.
- [21] Gal, B., Gallina, V., Szaller, Á. & Schlund, S. (2022). *Optimization of a Remanufacturing Production Planning System with the Help of Artificial Intelligence*. Sivut 77. Saatavissa: <https://link.springer-com.libproxy.tuni.fi/book/10.1007/978-3-031-28839-5>.
- [22] International Energy Agency (2023). *World Energy Outlook 2023*, selvitys. Saatavissa: <https://www.iea.org/reports/world-energy-outlook-2023>.
- [23] Rasmussen, M.L.R., Larsen, A.-C., Subhi, Y. & Potapenko, I. (2023). *Artificial intelligence-based ChatGPT chatbot responses for patient and parent questions on vernal keratoconjunctivitis*. Saatavissa: <https://link.springer-com.libproxy.tuni.fi/article/10.1007/s00417-023-06078-1>.
- [24] Shelving + Rack Systems, inc. (2023). *A Guide to Understanding Vertical Lift Modules*, blogikirjoitus. Saatavissa: <https://www.srs-i.com/blog/a-guide-to-understanding-vertical-lift-modules/>.