

Joonas Kakkuri

# NEUROVERKKOJEN HYÖDYNTÄMINEN TEOLLISUUDEN DIGITALISOITUMI- SESSA

Tekniikan ja luonnontieteiden tiedekunta  
Kandidaatintyö  
Elokuu 2020

## Tiivistelmä

Joonas Kakkuri: Neuroverkot teollisuuden digitalisoitumisen työkaluna  
Digitalizing industry with neural networks  
Tampereen yliopisto  
Tietojohdamisen tutkinto-ohjelma  
Elokuu 2020

---

Digitalisaatio on yksi 2000-luvun suurista teollisuuden vaikuttavista tekijöistä. Se on merkittävä kehityskohta niin yrityksen kilpailukykyyn, talouden kuin turvallisuudenkin näkökulmasta. Yritykset etsivät jatkuvasti uusia keinoja kehittää tietojärjestelmiään ja digitaalisia resursseja. Neuroverkot toimivat yhtenä vaihtoehtona teollisten prosessien digitalisoinnin työkaluksi. Niiden avulla voidaan ohjelmallisesti analysoida asioita, jotka aikaisemmin ovat olleet vaikeita tai jopa mahdottomia tehtäviä. Suurimpia harppauksia neuroverkoilla on saatu aikaan kuvan, äänen ja videon analysoinnissa ja tunnistuksessa.

Kirjallisuuskatsauksessa neuroverkoille todettiin paljon käyttökohteita, sillä nykyisellään teollisuudessa moni prosessi suoritetaan ihmisen tekemän työn kautta. Yleisesti teollisuudessa käyttökohteet sijoittuvat tuotannon valvontaan sekä tuotantolaitoksen toiminnan kehittämiseen. Tuotantokoneista ja -laitteista saatavaa tietoa neuroverkkojen avulla analysoidaan voidaan koko tuotantolaitoksen toimintaa ohjata ohjelmallisesti. Nykyisellä teknologialla neuroverkkojen ja älykkäiden tuotantolaitosten suunnittelu ja rakentaminen on kuitenkin kallista, mikä hidastaa yritykset digitalisoitumista.

Neuroverkoilla voidaan kuitenkin pienentää tuotannon kustannuksia. Neuroverkko pystyy työskentelemään jatkuvasti ja toistamaan samaa toimintaa väsymättä, mutta aina yksinkertaisiin tehtäviin soveltuvia ratkaisuja ei ole yleisesti saatavilla. Tämän vuoksi neuroverkkojen kehitys ja käyttöönotto tulisi aloittaa mahdollisimman yksinkertaisista ongelmista. Tällä hetkellä teollisuudessa neuroverkkoja hyödynnetään ennakoivassa vikadiagnostiikassa tuotantolaitteiden huollon ohella, tuotteen laadun tunnistuksessa sekä muissa yksinkertaisissa tehtävissä ihmisen korvaajana tai apuna. Neuroverkoilla voi olla tulevaisuutta ajatellen suurikin vaikutus taloudellisesti ja toiminnallisesti. Teollisuudessa käytettävien laitteiden tiedon kerääminen on kasvanut huomattavasti sensoritekniikan kehittyessä ja laitevalmistajat ovat huomanneet tiedon merkityksen. Suurella tiedon määrällä ja pilvilaskennalla pystytään ratkaisemaan yksi neuroverkkojen kehitykseen liittyvistä ongelmista, joka puolestaan saattaa vauhdittaa älykkäiden tuotantolaitosten kehittämistä.

Avainsanat: Neuroverkot, Digitalisaatio, Teollisuus 4.0.

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

# ALKUSANAT

Tämä kandidaatintyö on laadittu Tampereen yliopiston tietojohdamisen koulutusohjelmaan kesällä 2020. Tutkimuksen aihe on valittu harrastuneisuuden ja oman mielenkiinnon perusteella. Kandidaatintyö on toteutettu kirjallisuustutkimuksena perehtymällä pintapuolisesti neuroverkkojen toimintana ja käyttökohteisiin sekä teollisuuden digitalisointumiseen.

Haluan kiittää avovaimoani Saanaa kehittävästä palautteesta. Kiitos myös kandidaatintyön ohjaajille sekä kaikille, jotka antoivat palautetta ja kommentteja työstäni.

Tampereella, 2.8.2020

Joonas Kakkuri

# SISÄLLYSLUETTELO

1. JOHDANTO .....	1
1.1 Tutkimuksen tausta .....	1
1.2 Tutkimusongelma ja aiheen rajaus .....	2
1.3 Tutkimuksen rakenne .....	3
2. TUTKIMUKSEN TOTEUTUS .....	4
2.1 Tutkimusmenetelmä .....	4
2.2 Tutkimusaineisto .....	5
3. NEUROVERKOT .....	6
3.1 Eteenpäin kytketty verkko .....	7
3.2 Oppimisprosessi .....	8
3.2.1 Ohjattu oppiminen .....	9
3.2.2 Ohjaamaton oppiminen .....	10
3.3 Konvolutionaalinen neuroverkko .....	10
4. TEOLLISUUSDEN DIGITALISAATIO .....	12
4.1 Kyber-fyysinen järjestelmä .....	12
4.2 Neuroverkkojen hyödyntäminen teollisuudessa .....	15
4.3 Neuroverkkojen käyttökohteet teollisuudessa .....	16
5. YHTEENVETO .....	18
LÄHTEET .....	20

## LYHENTEET JA MERKINNÄT

CPS	Cyber-physical system. Kyber-fyysinen järjestelmä
MLP	Multi-layer-perceptron. Neuroverkon yksinkertaisin malli
Teollisuus 4.0	Teollisuuden 4. vallankumous, jonka keskiössä ovat yrityksen digitaaliset tarpeet

# 1. JOHDANTO

## 1.1 Tutkimuksen tausta

Tietokoneen kyky tehdä päätöksiä, tunnistaa ja luokitella asioita aikaisemman tiedon perusteella on etenkin 2010-luvulta alkaen kokenut suuria harppauksia eteenpäin. Kuvan, videon ja äänen prosessointi sekä erilaiset suositusalgoritmit ovat esimerkkejä tekoälyn käytännönsovelluksista. Ihmisen älykkyyttä ja ajattelun mallintamista on tutkittu jo 1990-luvulla, mutta vasta viime aikoina erilaiset tekoälyratkaisut ovat tulleet laajemmin esille tietokoneiden laskentatehon kasvaessa.

Teolliset prosessit ovat riippuvaisia työntekijöistään monilta osin, sillä yksinkertaiseenkin työhön on aina tarvittu ihmisen työpanos. Entä jos ihmisen loogista ajattelua pystyisi mallintamaan koneellisesti myös teollisessa tuotannossa? Teollisten robottien ja koneiden reaaliaikainen valvonta sekä huolto takaa tuotannon joustavan toiminnan ja vähentää yllättäviä tuotannon keskeytyksiä (Lee et al. 2019). Tästä hyötyisivät eniten yksinkertaista ja toistuvaa työtä tekevät prosessit, etenkin sellaiset, joissa prosessin tarkoituksena on luokittelu jonkin ominaisuuden perusteella.

Tekoäly ja koneoppiminen ovat eräitä tämän hetken kuumimmista teknologisista aiheista. Neuroverkot ovat tällä hetkellä yksi johtavista tekoälyn sovelluksista. Neuroverkkoa käyttävä tekoäly on pystynyt voittamaan ihmisen shakissa (Bratko, 2018) ja monissa muissa strategiapeleissä, mikä osoittaa, että strategista päätöksentekoa on mahdollista mallintaa myös tietokoneohjelmalla jopa ihmistä huomattavasti tehokkaammaksi ja tarkemmaksi. Neuroverkkoja käytetään myös esimerkiksi erilaisissa konenäkö- sekä kuvankäsittelyongelmissa.

Yleisesti ottaen neuroverkkojen mallintaminen ja hyödyntäminen perustuu jonkin asteiseen luokitteluun (Krizhevsky, 2012). Shakissa luokitellaan jokainen siirto itselle edulliseksi tai haitalliseksi, kuvantunnistuksessa tietty pikselien joukko luokitellaan tunnistettavaksi objektiksi, videon kohdalla toistetaan kuvantunnistus monia kertoja sekunnissa sekä suosittelualgoritmi pyrkii luokittelemaan suosituksia käyttäjän aikaisempien toimintojen perusteella.

Tässä työssä tutkitaan kirjallisuuskatsauksena, miten neuroverkkoja voidaan hyödyntää teollisuuden digitalisaation työkaluna. Työssä tutkitaan neuroverkkojen ominaisuuksia sekä tämän hetken neuroverkkoratkaisuja, joita teollisuudessa voidaan käyttää hyväksi.

Keskeistä on myös löytää pääpiirteittäin teollisuuden digitalisoitumisen haasteita ja tarjota näihin haasteisiin ratkaisua neuroverkkojen avulla.

## 1.2 Tutkimusongelma ja aiheen rajaus

Aiheena on neuroverkkojen hyödyntäminen teollisuuden digitalisoitumisessa. Aihe on rajattu käsittelemään ensisijaisesti suuria tuotantolaitoksia. Digitalisaatio ja analytiikka ovat jo pitkään olleet merkittävässä asemassa yritysten liiketoiminnassa ja Lee (at al. 2019) uskoo tämän olevan entistäkin merkittävämpää tulevaisuudessa. Tämän vuoksi myös uudet teknologiset ratkaisut kuten neuroverkot ja tekoäly ovat merkittävässä osassa yritysten tulevaisuuden toimintaa. Tutkimuksessa ei ole otettu huomioon neuroverkkototeutuksen aiheuttamia kustannuksia, sillä kustannukset saattavat vaihdella suurestikin eri ohjelmistoyritysten välillä eikä vakiintunutta hintaa neuroverkkojen kehitykselle ole saatavissa.

Neuroverkkojen hyödyntämisellä voidaan ratkaista moniakkin asioita, mitkä aikaisemmin olivat täysin mahdottomia. Esimerkiksi virheellisen tuotteen tunnistaminen on ihmiselle helppoa, mutta tietokoneelle se on aikaisemmin ollut mahdoton tehtävä. Nykyisin kuitenkin yksinkertainen kuvantunnistus pystytään tekemään lähes ihmisen tarkkuudella (Krishevsky, 2012).

Neuroverkoilla on mahdollisesti siis merkittäviä taloudellisia hyötyjä yrityksille, jos ne pystytään hyödyntämään oikein. Tämän pohjalta päätutkimusongelmaksi muodostui:

- Miten neuroverkkoja voidaan hyödyntää tiedon jalostuksessa?

Päätutkimuskysymyksen tukena käytetään alatutkimuskysymyksiä:

- Miten digitalisoituminen on vaikuttanut teollisuudessa?
- Millaista dataa teollisuudesta on saatavilla?
- Millaisia ongelmia neuroverkoilla voidaan ratkaista?

Näiden kysymyksen pohjalta pyritään ainakin yleisellä tasolla selvittämään neuroverkkojen hyödyntämisen etuja ja vaatimuksia. Tämän pohjalta voidaan pohtia, miten neuroverkkojen hyödyntäminen tulisi aloittaa ja millaisessa tilanteessa neuroverkon käyttö on mahdollista ja kannattavaa.

### **1.3 Tutkimuksen rakenne**

Seuraavassa luvussa esitellään tutkimusmenetelmä ja tutkimusaineistoa. Luvussa kolme käsitellään neuroverkkojen rakennetta, tyyppejä sekä neuroverkkojen kehittämiseen liittyviä strategioita. Luvussa neljä käydään läpi teollisuuden digitalisoitumista sekä neuroverkkojen liittämistä tuotantolaitoksen eri tasoille. Samassa luvussa käsitellään myös neuroverkkojen käyttökohteita ja vaatimuksia. Viimeinen luku vetää tulokset yhteen ja esittää kirjallisuuskatsauksen arvioinnin sekä jatkotutkimustarpeet.



## 2. TUTKIMUKSEN TOTEUTUS

### 2.1 Tutkimusmenetelmä

Tutkimus suoritetaan kirjallisuuskatsauksena. Aineisto koostuu pääosin vertaisarvioituista artikkeleista sekä tieteellisistä julkaisuista. Lähdemateriaalin keräämisessä keskityttiin vahvasti julkaisuajankohtaan sekä viittausten määrään ja lähdemateriaalin kasamisessa pyrittiin hyödyntämään mahdollisimman uusia sekä tunnettuja julkaisuja. Etenkin neuroverkkoihin liittyvät artikkelit ovat kehittyneet suuresti lähiaikoina ja suurin osa käsitteli erilaisia kuvantunnistuksen käyttökohteita. Lähteet ovat suurimmalta osin englanninkielisiä, sillä Suomen ulkopuolella aihetta on tutkittu huomattavasti enemmän. Myös aiheen tyyppin vuoksi osa suomalaisista tutkimuksista on tehty englannin kielellä. Lähdemateriaalin avulla kerättiin katsaus aiheesta tehtyjen tutkimusten pohjalta.

Aineisto haettiin pääosin Computer science database-tietokannasta. Apuna käytettiin myös Andor sekä Scopus tietokantoja. Taulukossa 1 on esitelty käytettyjä hakulauseita.

**Taulukko 1:** Käytetyt hakulauseet

Hakulause	Andor	Computer science database	Scopus
"Industry 4.0" AND "development"	42 415	2309	3134
"Industry 4.0" AND "neural network*"	1741	242	296
"Convolutional neural network*" AND "implementation"	19145	3271	2368
"Neural network" AND "learning"	579 469	47 904	166 189
"Industry 4.0" AND "digitalization"	9122	376	732

Tuloksista valittiin julkaisut tekijöiden sekä otsikon perusteella. Lisäksi tuloksia rajattiin julkaisuvuoden mukaan uusimpiin tutkimuksiin, jolla saatiin tulosten määrää rajattua sopivan kokoiseksi. Vertaisarvioituja lähteitä käytettiin ensisijaisesti, jotta aineiston laatu ja tutkimuksen tulos olisi mahdollisimman hyvä.

## 2.2 Tutkimusaineisto

Tutkimusaineisto koostui pääosin tieteellisistä artikkeleista sekä verkossa julkaistuista kirjoista. Krishevsky (et al. 2012) on tutkinut laajasti neuroverkkojen kuvantunnistuksen mahdollisuuksia ja tuloksia. Lee (et al. 2018, 2019) on tutkinut laajasti tekoälyn hyödyntämisen keinoja teollisuudessa etenkin tuotannon näkökulmasta. Klumpp (2018) puolestaan on tutkinut kyberfyysisiä järjestelmiä, eli laitteiden ja tietojärjestelmien yhteen liittämisen tuomia mahdollisuuksia. Taulukkoon 2 on kerätty tämän tutkimuksen kannalta merkittävin tutkimusaineisto.

**Taulukko 2:** Tärkein tutkimusaineisto

Kirjoittajat	Julkaisun tyyppi	Kuvaus
Krizhevsky et al. (2012)	Tieteellinen artikkeli	Julkaisun tutkimuksessa tutkittiin neuroverkkojen kuvantunnistuksen tarkkuutta suurella datamäärällä.
Lee et al. (2018)	Kirja	Kirjassa tutkitaan tekoälyn merkitystä tulevaisuuden teollisuudessa.
Klumpp (2018)	Tieteellinen artikkeli	Mitä tekoälyn liittäminen fyysisiin teollisuuden laitteisiin tarkoittaa ja mitä se käytännössä vaatii.

Neuroverkkoja on tutkinut myös Zakarian (et al. 2014), joka käy artikkelissaan läpi neuroverkkojen toimintaa ja oppimisen eri keinoja. Neuroverkkojen hyödyntämistä on tutkinut Shiqi (et al. 2016) kuvan luokittelun sekä Wu ja Zhao (2018) ennakoivan viantunnistuksen näkökulmasta. Lee (et al. 2019) puolestaan tutkii tekoälyn hyödyntämistä teollisuudessa tiedon analysoinnin näkökulmasta ja Romero (et al. 2020) älykkäiden teollisuuslaitosten rakennetta ja toimintaa.

### 3. NEUROVERKOT

Neuroverkot ovat yksi koneoppimisen alalaji. Neuroverkoille on ominaista, että niiden toimintaa ei ohjelmoida etukäteen, vaan ne pystyvät annetun datan perusteella itse ohjautumaan kohti uudenlaisia tilanteita. Neuroverkot ovat ohjelmallisesti mallinnettuja, rakenteeltaan ihmisen hermoverkostoa kuvastavia prosessointiparadigmoja (Zakaria et al, 2014) ja ovat yksi tekoälyn muoto. Neuroverkon perusajatuksena on matkia biologista aivotoimintaa ja tämän avulla pyrkiä havaitsemaan kaavoja sekä malleja, tekemään itsenäisiä päätöksiä sekä oppimaan aikaisemman tiedon perusteella uutta (Rawat et al. 2018). Yksi suurimpia neuroverkkojen ajureita on laskentatehon voimakas kasvu (Dharmajee & Ramana, 2019) sekä automaation ja robotiikan lisääntyminen teollisuudessa (Liyanage et al. 2007).

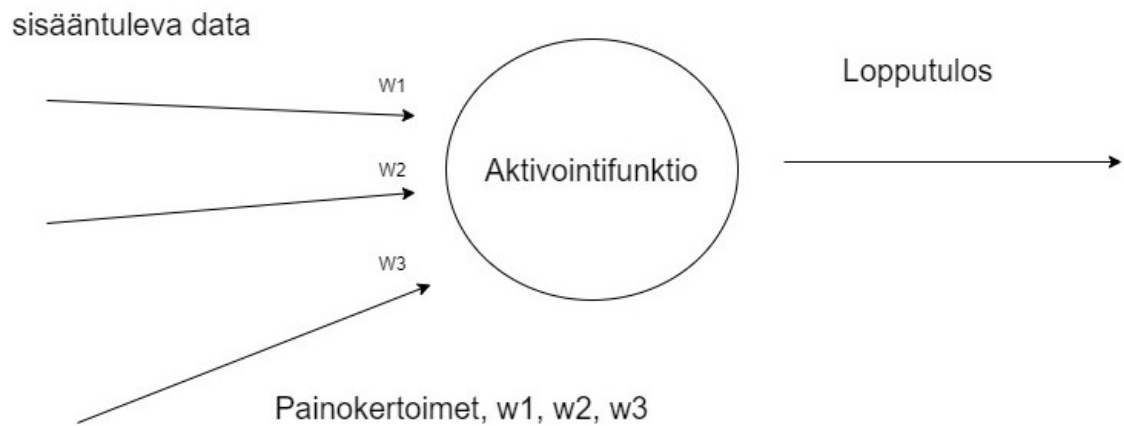
Neuroverkkojen rakenne vaihtelee käyttötarkoituksesta ja saatavilla olevasta laskentatehosta ja datasta riippuen paljonkin (Krizhevsky, 2012). Kuvankäsittelyyn käytettävä neuroverkko on rakenteeltaan hyvin erilainen kuin ennustamiseen tai luokitteluun käytettävä neuroverkko (Krizhevsky, 2012; Sim, Kim & Ahn. 2019). Zakarianin (et al. 2014) mukaan neuroverkkoja voidaan kuitenkin yleisellä tasolla jaotella kolmen ominaisuuden perusteella:

1. Verkossa olevien tasojen sekä niissä sijaitsevien neuronien määrän avulla.
2. Käytetyillä oppimismekanismeilla verkon painotusten päivittämisessä.
3. Jokaisessa tasossa käytettävällä aktivointifunktiolla

Neuroverkon peruselementti ja laskentayksikkö on keinotekoinen neuroni. Se vastaanottaa mielivaltaisen määrän sisään tulevaa dataa, asettaa jokaiselle erilliselle datapistteelle painokertoimen sekä lisää neuronille ominaisen lisän (bias). Neuroni muodostaa näiden lukujen perusteella painotetun yhteissumman kaavalla

$$f(x_1, x_2, \dots, x_{n-1}, x_{n-2}) = \varphi(\sum_{i=1}^N w_i \cdot x_i + \phi), \quad (1.)$$

joka syötetään aktivointifunktioon. Sisään tuleva data  $x_1, x_2, \dots, x_{n-1}, x_{n-2}$  kerrotaan neuronien välisillä painokertoimilla  $w_1, w_2, \dots, w_{n-1}, w_{n-2}$ . Tuloon lisätään vielä neuronille ominainen lisä  $\phi$ , lopputulos syötetään aktivointifunktioon  $\varphi$ , josta saadaan neuronin lopputulos (Zhou, 2019).



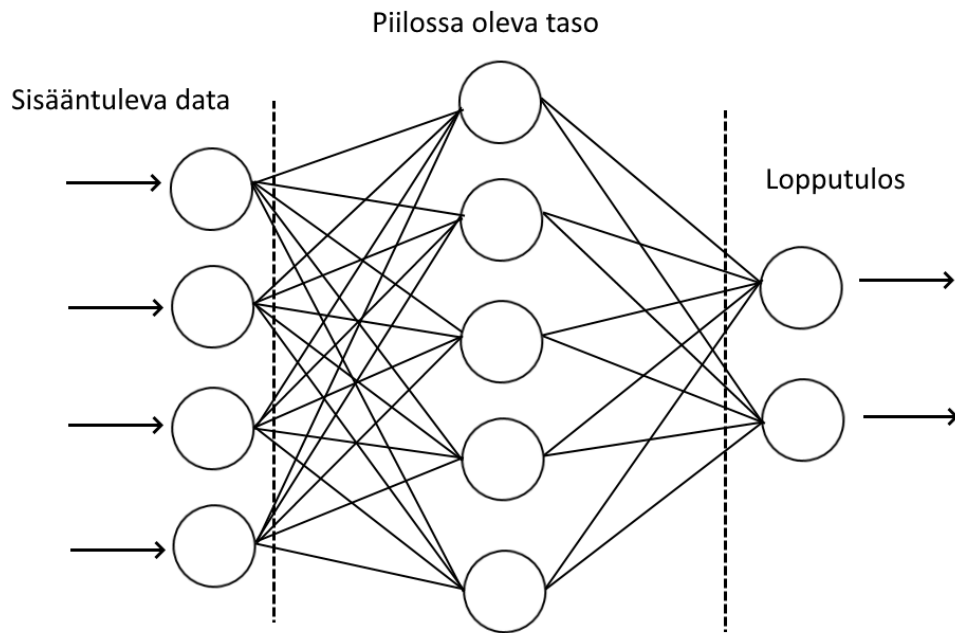
**Kuva 1: Keinotekoisen neuronin rakenne**

Aktivointifunktion tarkoituksena on erotella neuronien lopputulos toisistaan ja tällä tavoin tuottaa epälineaarisia lopputuloksia (Glorot & Bengio 2010). Käytettyjä aktivointifunktiota ovat esimerkiksi trigonometrinen funktioiden variaatiot sekä sigmoid-funktio. Tarkoituksena on siis luoda selkeämpiä eroja neuronin lopputuloksille, jotta itse verkon oppiminen olisi tehokkaampaa (Bawa & Kumar 2018). Aktivointifunktiolla on siinä mielessä suuri rooli, että sen pohjalta muodostuva lopputulos määrää koko neuroverkon oppimisprosessin nopeuden sekä tarkkuuden.

Tässä luvussa käsitellään tarkemmin neuroverkkojen rakennetta sekä erilaisia oppimismetodeja.

### 3.1 Eteenpäin kytketty verkko

Neuroverkko nimensä mukaan koostuu monesta yllä kuvatusta neuronista. Yleisimmin puhutaan eteenpäin kytketystä neuroverkosta (multi layer perceptron, MLP), joka koostuu sisääntulo-, piilo- sekä ulostulotasosta (kuva 2) (Zakarian et al. 2014). Piilossa olevat kerrokset ovat yksi merkittävä tekijä siirryttäessä yksinkertaisista ongelmanratkaisutilanteista monimutkaisiin etenkin suurella datamäärällä (Sathya & Abraham, 2013).

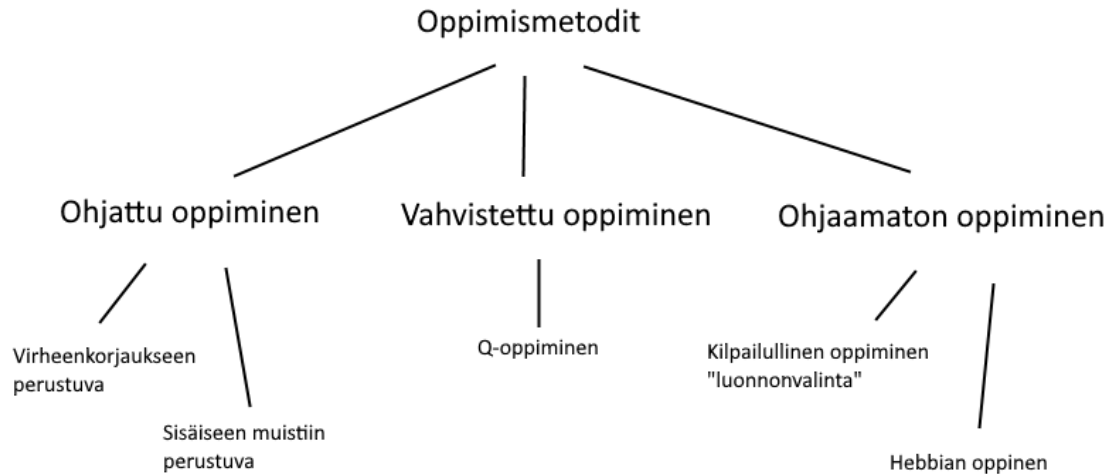


**Kuva 2: Yksinkertaisen MLP:n rakenne**

Tasojen rakenne sekä niiden väliset liitokset voivat vaihdella suurestikin erilaisten neuroverkkoarkkitehtuurien välillä. Kaikkien tasojen ei ole pakko olla liitoksissa toisiinsa. Joissain tilanteissa neuroverkon kehittyminen voi jopa estyä turhien liitosten vuoksi (Sat-hya & Abraham, 2013). Tämä siis tarkoittaa neuroverkon oppimisen hidastumista tai jopa pysähtymistä.

### 3.2 Oppimisprosessi

Yleisesti kaikille neuroverkoille käytetään yhtä tai useampaa oppimisstrategiaa. Karkeasti nämä voidaan jakaa kolmeen oppimisparadigmaan: ohjattu-, ohjaamaton- sekä vahvistettu oppiminen (kuva 3) (Zakarian et al, 2014. s. 34). Kukin näistä jakautuu vielä omiin alatyyleihinsä riippuen käytetyn neuroverkon rakenteesta sekä saatavilla olevasta datasta. Yleisesti kaikilla strategioilla on sama päämäärä: saavuttaa neuroverkon optimaalisin suorituskyky (Lappin & Shienbier, 2007).



**Kuva 3: Neuroverkon yleisimmät oppimisstrategiat (Sathya & Abraham, 2013).**

Yleisesti voidaan kuitenkin todeta selkeimmät erot oppimismetodien välillä. Käytetty oppimismetodi määrää hyvin pitkälle, millaiseen käyttötarkoitukseen neuroverkkoa voidaan käyttää (Toivanen 2013). Neuroverkkojen opettamiseen ja kehittämiseen on olemassa moniakin erilaisia strategioita. Tässä luvussa esitellään niistä kaksi yleisintä: ohjattu oppiminen sekä ohjaamaton oppiminen.

### 3.2.1 Ohjattu oppiminen

Ohjattu oppiminen voidaan mieltää yksinkertaisemmaksi oppimisen metodiksi. Sen perustana on, että alku- sekä lopputulos on tiedossa. Tämän tiedon pohjalta neuroverkolle suoritetaan kaksi vaihetta: eteen- ja taaksepäin läpäisy. Eteenpäin läpäisyn tarkoituksena on saada nykyinen neuroverkon tulos esille ja tämän jälkeen verrata sitä oikeaan lopputulokseen. (Sathya & Abraham, 2013). Neuroverkon sekä oikean tuloksen välille voidaan laskea virhe, joka kertoo neuroverkon tarkkuuden. Virheen perusteella neuroverkkoa voidaan neuronin tasolla säätää kohti oikeaa lopputulosta (Sathya & Abraham, 2013). Eli neuroverkon kertoimia säätämällä pyritään löytämään reitti oikeasta alkutilanteesta haluttuun lopputulokseen (Mishra & Gupta 2017).

Onnistuakseen ohjattu oppiminen vaatii paljon strukturoitua dataa, sillä neuroverkon lopputulos riippuu täysin datan oikeellisuuteen. Datan tarkka muoto onkin yksi ohjatun oppimisen haittapuolista, sillä monessa tapauksessa ei ole olemassa olevaa, otsikoitua dataa, jota voitaisiin käyttää neuroverkon opettamiseen.

Ohjattu oppiminen on oikean datan löydyttyä tehokas keino. McAllisterin (et. al 2018) tutkimuksen mukaan ohjattu oppiminen toi tarkimman lopputuloksen kuvantunnistustehävässä. Erityisesti kuvantunnistuksessa ohjattua oppimista on pystytty hyödyntämään

tehokkaammin, sillä luotettavaa ja otsikoitua dataa on yhä laajemmin saatavilla (Krishevsky, 2012).

### 3.2.2 Ohjaamaton oppiminen

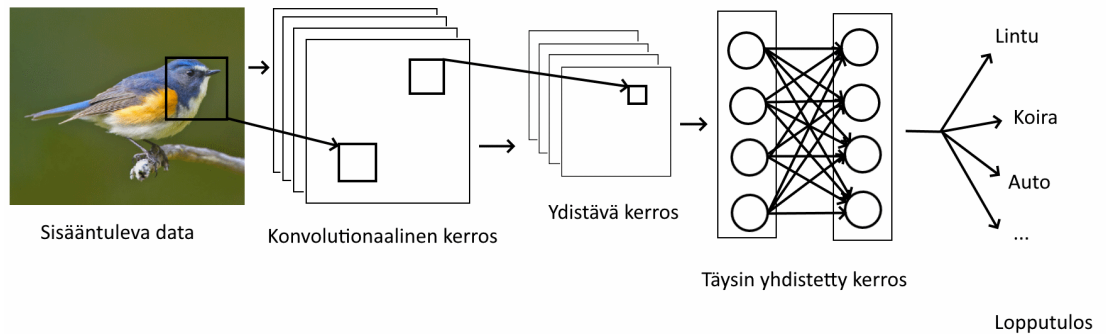
Ohjaamaton oppiminen tarjoaa suppeamman luokitteluskaalan verrattuna ohjattuun oppimiseen. Sen avulla kuitenkin pystytään käsittelemään myös strukturoimatonta dataa, jota monesti on saatavilla suuriakin määriä. (Pinho & Costa, 2018). Ohjaamattoman oppimisen toisena erona ohjattuun oppimiseen on, että data koostuu vain sisään tulevasta datasta (Lappin & Shieber, 2007), jolloin neuroverkon lopputulos saattaa vaihdella huomattavasti ennen sopivien painokertoimien löytämistä. Neuroverkon kehittäminen aloitetaan luomalla populaatio neuroverkkoja, jotka pyrkivät samaan lopputulokseen. Ohjaamaton oppiminen koostuu kolmesta vaiheesta: kilpailu, arviointi sekä sopeutuminen. Neuroverkot siis kilpailevat keskenään ja suorituksen jälkeen neuroverkkojen tulos arvioidaan. Parhaiten pärjävistä neuroverkoista yhdistetään uusi populaatio neuroverkkoja, jotka ovat sopeutuneet edellistä sukupolvea paremmin kyseessä olevaan tehtävään. (Sathya & Abraham, 2013). Kun toistokoe suoritetaan tarpeeksi monta kertaa, neuroverkkojen tuloksen varianssi pienenee ja neuroverkon tehokkuus ja käytettävyys koheenee.

Ohjaamattoman oppimisen tarkoituksena on kehittää uusia kaavoja sekä malleja yhdistämällä olemassa olevaa tietoa (Wolff, 2013). Ohjaamattoman oppimisen avulla voidaan etsiä piilossa olevaa tietoa, eli sellaista, jota ei vielä tiedetä. Big-data ja iot-laitteet tarjoavat ohjaamattomaan oppimiseen merkittävän pohjustuksen tiedon keräyksessä. Kuitenkin tällaisessa tapauksessa geneerinen ohjaamattoman oppimisen metodi neuroverkon kehittämisessä ei ole riittävä, sillä neuroverkon kehittyminen edes lähelle ihmisen ymmärrystä on pitkä ja vaativa prosessi (Marblestone et al. 2016). Ohjaamattoman oppimisen etuna kuitenkin on, että neuroverkon oppiminen ei välttämättä vaadi jatkuvaa ihmisen valvontaa, seuraamista ja hyvin valmisteltua dataa, vaan neuroverkko pystyy prosessoimaan dataa itsenäisemmin.

### 3.3 Konvolutionaalinen neuroverkko

Konvolutionaalinen neuroverkko on rakenteeltaan hyvin samanlainen eteenpäin kytketyn neuroverkon kanssa. Konvolutionaalisen neuroverkon on todettu olevan erityisen hyvä kuvantunnistuksessa (Krishevsky et al. 2012), äänen prosessoinnissa (Ossama et al. 2014) sekä luokittelutehtävissä (Shiqi et al. 2019). Rakenteeltaan konvolutionaalinen verkko muistuttaa eteenpäin kytkettyä verkkoa, mutta data kulkee tasojen välissä kon-

volutionaalisen tason läpi. Tämän kerroksen tarkoituksena on tunnistaa toistuvia kuvi-  
oita. Neuroverkko siis kykenee tunnistamaan toistuvia osia alkuperäisestä datasta ja näi-  
den osien perusteella sen tarkkuutta on pystytty nostamaan merkittävän suureksi (kuva  
4).



**Kuva 4: Konvolutionaalisen neuroverkon rakenne (Fu, 2016)**

Konvolutionaalista verkkoa voidaan käyttää luokitteluun, jossa sisään tulevasta datasta halutaan päätyä johonkin ennalta tiedossa olevaan lopputulokseen tai sen avulla voidaan tunnistaa kaavoja, esimerkiksi kuvan 3 linnusta voitaisiin tunnistaa vain linnun ääriiviiva (Fu, 2016).

Konvolutionaalisten neuroverkkojen suurinapa etuna muihin neuroverkkomalleihin on sen itsenäisyys. Koska sisään tuleva data on monesti konvolutionaalisen neuroverkon käyttötarkoituksissa kaksiulotteista, esimerkiksi kuvan tai videon pikselit, tarvittavan tiedon alkujalostamisen määrä on hyvin pieni. (Mishra & Gupta, 2017).



## 4. TEOLLISUUDEN DIGITALISAATIO

Teollisuus 4.0 vauhdittaa yritysten digitalisoitumista entisestään kohti tehokkaampaa tuotantoa sekä laadukkaan tuotteen nopeaa ja joustavaa valmistusta (Liyanage et al, 2007). Käytännössä tämä tarkoittaa teollisuuden tuotannosta saatavan tiedon tehokkaampaa keräämistä ja hyödyntämistä. Teollisuudesta saatavaa tietoa on nykyisin saatavilla huomattavasti enemmän, sillä laitevalmistajat ovat tunnistaneet erilaisten tiedon keräämiseen tarkoitettujen sensorien sekä data-analytiikan edut (Lee et al. 2019. s.30). Neuroverkot tarjoavat suuren datamäärän vuoksi merkittävän mahdollisuuden tiedon analysoinnin näkökulmasta, sillä ne vaativat monesti suuren määrän dataa, mutta käyttämällä suurempaa lähdedataa, tehokkaampia malleja sekä parempia tekniikoita ylimallintamisen (overfitting) estämiseksi, neuroverkosta voidaan kehittää yhteen käyttötarkoitukseen ihmisen älyä ja päätöksentekokykyä vastaava neuroverkko (Krizhevsky et al. 2012). Tätä tuotantokoneiden, tiedon ja tekoälyn kokonaisuutta sanotaan kyberfyysiseksi systeemiksi (cyber physical-system) (Klumpp, 2018).

Teollisuus sisältää paljon erilaisia toimintamalleja ja monimutkaisia prosesseja, mikä tarkoittaa, että ongelmien seuraaminen, löytäminen ja korjaaminen ei aina ole yksinkertaista. Digitalisaation sekä iot-laitteiden kehittymisen myötä ohjelmistot, infrastruktuuri sekä pilvilaskenta ovat osaltaan ratkaisseet teollisuuden perusongelmia (Zakaria et al, 2014), mutta kaikkia teollisuuden prosesseja ei ole pystytty ohjelmallisesti mallintamaan.

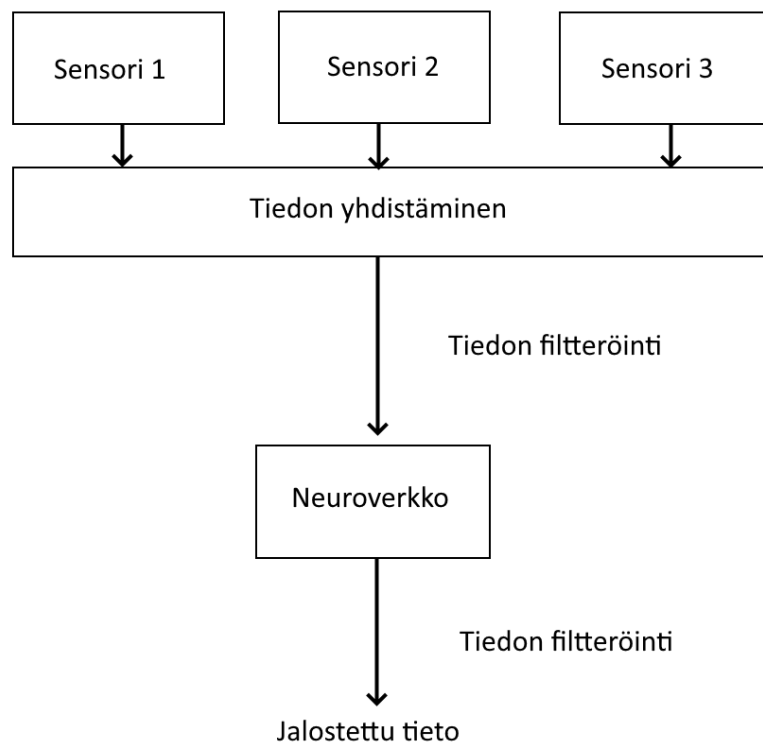
Tietojärjestelmien sekä tietoliikenteen kehittyessä yrityksen kustannuksia on pystytty laskemaan merkittävästi, sillä monia prosesseja on pystytty automatisoimaan (Klumpp, 2018). Myös prosessien valvontajärjestelmät ovat kehittyneet ja tuotannossa tapahtuvia virheitä pystytään paremmin estämään ja ennakoimaan data-analytiikan sekä tietojärjestelmien avulla (Romero et al. 2020). Neuroverkkoratkaisuilla on pystytty parantamaan muun muassa kyberturvallisuutta (Lee et al. 2018), kuvantunnistusta (Krishevsky et al, 2012; McAllister et al, 2019), tuotannon mallinnusta sekä kysynnän ennustamista (Obando, 2019). Tällä on voinut olla teollisuuden toiminta-alueen mukaan suuriakin vaikutuksia kustannusten hallinnassa. Tarkalla valvontajärjestelmällä voi olla positiivisia vaikutuksia myös työturvallisuuteen sekä tuotteiden laatuun.

### 4.1 Kyberfyysinen järjestelmä

Teollisuuteen tarkoitettujen laitteiden valmistajat ovat ajaneet teollisuuden digitalisoitumista eteenpäin esimerkiksi tarkemmalla sensoriteknologialla (Schütze et al. 2018).

Nämä tekijät mahdollistavat tarkemman, luotettavamman sekä reaaliaikaisemman datan keräämisen. Merkityksellisen datan keräyksen voimistuminen saattaa tuoda lisävauhtia myös neuroverkkojen kehitykseen, sillä relevantti ja oikea oppimisdata on tärkeää neuroverkon tehokkaan ja tarkan lopputuloksen kannalta (Zakaria et al. 2014).

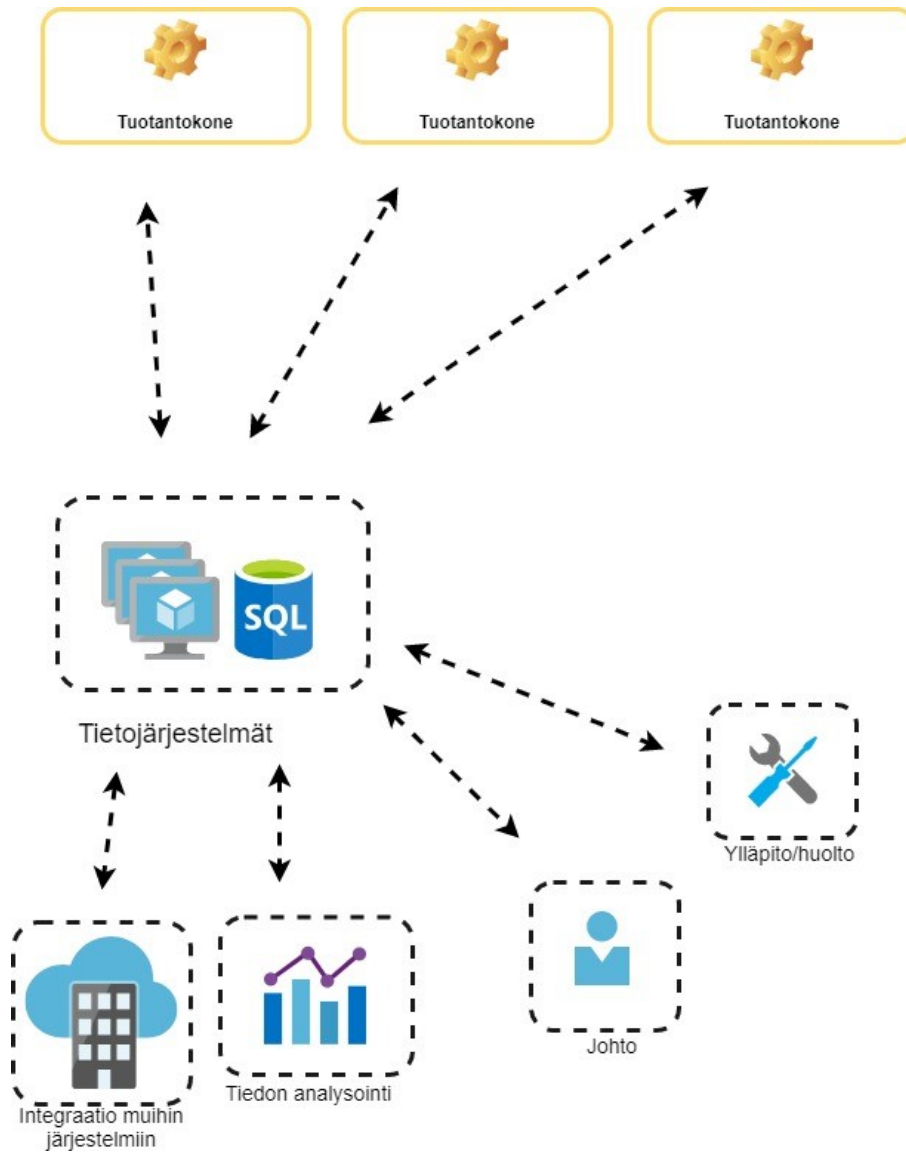
Kuvassa 4 on esitelty mahdollinen kyberfyysisen järjestelmän sensorin rakenne. Tieto kerätään sensoreista ja laitteista tietyn aikavälin sisällä, jonka jälkeen tiedosta muodostetaan yhtenäinen paketti. Tietopakettista voidaan tarvittaessa vielä rajata virhemittauksia ulos tarkemman tuloksen saamiseksi. Tämän jälkeen data lähetetään yleensä yrityksen omaan pilvipalveluun, jossa tieto analysoidaan ja jalostettu tieto lähetetään päättäjille tai automatisoituun hallintajärjestelmään, jossa ohjelmisto ja laitteet osaavat mukautua tiedon perusteella. (Castanõ et al. 2019).



**Kuva 5: Älykkään sensorin rakenne (Castanõ et al. 2019)**

Isommassa kuvassa monen laitteen kytkeminen yhteen yrityksen sisäisiin tietojärjestelmiin vaatii yhteisen tietokannan sekä langattoman yhteyden (Shin et al. 2018), joka muodostaa varsin suuren kokonaisuuden. Silti neuroverkkojen merkitys tiedon jalostamisessa myös tuotantolaitoksen tasolla on suuri, sillä niitä voidaan hyödyntää tuotantolaitteiden sekä koko tuotantojärjestelmän hallinnassa. Kuvassa 4 esitettiin neuroverkon hyödyntämistä tuotantolaitteen toiminnan ohella, kuvassa 5 puolestaan neuroverkkoa

voidaan hyödyntää tuotannosta saatavan tiedon analysoimiseen ja jatkojalostamiseen (Lee & Singh, 2019).



**Kuva 6: Älykkään tuotantolaitoksen rakenne (Shin et al. 2018)**

Isossa kuvassa neuroverkkoja voidaan hyödyntää ylläpidon, johdon päätöksenteon sekä tiedon analysoinnin tukena (Klumpp, 2018). Integraatio muihin järjestelmiin nousee merkittäväksi tekijäksi digitalisoitumisen näkökulmasta, sillä yrityksen kaikkien tuotantolaitteiden tiedon saattaminen yhteen voi tuoda esille uutta tietoa.

Nykyisellään neuroverkkoja käytetään lähinnä tuotantokoneiden toiminnan tukena ja joissain tilanneissa myös ennakoivan huoltotoimenpiteiden työkaluna (Liyanage et al, 2007). Tällä hetkellä digitalisoituminen ja älykkäiden tuotantolaitosten kehittyminen ottavat kuitenkin vielä alkuaskelia koko tuotantolaitoksen automatisoinnissa.

## 4.2 Neuroverkkojen hyödyntäminen teollisuudessa

2010-luvulla neuroverkkojen sekä tekoälyn avulla manuaalisten sekä operationaalisten prosessien automatisointia on pystytty kehittämään merkittävästi (Nascimento et al, 2018). Neuroverkkoratkaisuja on tutkittu muun muassa kyberturvallisuuden (Lee et al. 2018), kuvantunnistuksen (Krishevsky et al, 2012; McAllister et al, 2019) sekä tuotannon mallintamiseen sekä kysynnän ennustamiseen (Obando, 2019). Tarkasti määritellyjä teollisuuden käyttökohtia neuroverkoille on vaikea osoittaa, sillä yritysten tuotantolaitteisto ja prosessit ovat hyvin monimuotoisia. Yleisesti voidaan kuitenkin todeta, että neuroverkkojen avulla voidaan pienentää ihmisen tekemää työn määrää, vähentää valmistuksen kustannuksia sekä mahdollistaa tuotannon huolettomampi toiminta (Lee & Singh, 2019).

Tällä hetkellä neuroverkkojen ja syväoppimisen teknologia kehittyy ja yritysten odotukset neuroverkkojen tehokkuudesta ja hyödyllisyydestä kulkevat rinnakkain kehitystyön kanssa (Liyanage et al. 2007). Tämä voi siis tarkoittaa, että neuroverkkoratkaisuja tullaan ottamaan käyttöön yhä enenevässä määrin ja neuroverkkojen ominaisuudet kehittyvät. Neuroverkkoratkaisuilla haetaan pääsääntöisesti ratkaisuja kustannusten alentamiseen sekä liikevaihdon kasvuun (Klumpp 2018).

Monet neuroverkkojen sovellukset pyrkivät ratkaisemaan toiminnallisia päätöksiä, esimerkiksi laatuvarmistuksen tuotteiden tunnistaminen (Shangong et al. 2013). Tämän avulla virheelliset tuotteet voidaan havaita nopeasti ja niiden syntymistä voidaan ennaltaehkäistä tehokkaammin. Neuroverkkoja voidaan kuitenkin käyttää tuotannon ulkopuolella yrityksen muiden toimintojen tukena. Toistaiseksi strategisen päätöksenteon näkökulmasta uusien toimintamallien ja tapojen löytäminen neuroverkkojen avulla on jäänyt pienemmälle huomiolle. Tarkasti määritettävissä olevan ongelman sijaan neuroverkkoratkaisulla pyritään mallintamaan ihmisen strategista päätöksentekoa ja älykkyyttä yhdistämällä mahdollisimman monta laitetta samaan sisäiseen verkkoon ja tämän avulla tehdä korkeammalla tasolla päätöksiä (Klumpp 2018; Lee et al. 2019).

Teollisuudessa neuroverkkojen hyödyntäminen voi olla merkittävä osa liiketoiminnan kasvussa, sillä yritysten fokuksena on fyysisen tuotantoympäristön yhdistäminen digitaalisiin järjestelmiin. Tämän tarkoituksena on mahdollistaa älykkäiden järjestelmien ja laitteiden itsenäisempi toiminta. (Romero et al, 2020). Neuroverkkojen hyödyntäminen on järkevä ratkaisu, kun integroitavia laitteita on paljon. Tällöin tietovirta saattaa olla liian suuri ihmisen analysoitavaksi, etenkin reaaliaikaisissa prosesseissa. (Majdani et al. 2018).

### 4.3 Neuroverkkojen käyttökohteet teollisuudessa

Suuren datamäärän analysointiin tarvitaan uusia tehokkaampia työkaluja, jotta kerättyä dataa voidaan hyödyntää tehokkaammin. Sensoreiden ja muiden dataa keräävien laitteiden määrän kasvaessa, täytyy myös analytiikan työkaluja kehittää ja automatisoida (Schütze et al. 2018). Neuroverkot voivat tarjota yhden ratkaisun datamäärän analysointiin. Monet neuroverkkoihin sekä niiden hyödyntämiseen liittyvät tutkimukset keskittyvät joko tietyn ongelman ratkaisemiseen (Krizhevsky et al. 2012; Toivanen 2013; Schütze et al. 2018) tai täysin uuden ratkaisun löytämiseen, jota aikaisemmin ei ole ollut tiedossa (Baker et al, 2020; Taylor, 2015).

Ottaen huomioon tämän lähestymistavan, on syytä ymmärtää neuroverkkojen vahvuudet ja heikkoudet. Kuten aiemmin on todettu, neuroverkot ovat poikkeuksellisen hyviä luokitelutehtävissä (Krishevsky, 2012). Tämän vuoksi teollisuudessa on mahdollista korvata yksinkertaisia tunnistus, lajittelu sekä valvontatehtävissä ihmisen työ neuroverkkoratkaisulla. Todellisia käytännön käyttökohteita on vaikea arvioida tarkasti, sillä teollisuudessa yritysten välillä prosessit ja toiminnot vaihtelevat neuroverkkojen näkökulmasta merkittävän paljon. Samaa neuroverkkomallia ei voida siis käyttää universaalisti, vaan neuroverkko täytyy kouluttaa tiettyyn tehtävään (Zakarian et al. 2014).

Teollisuus 4.0:n sekä älykkäiden tuotantolaitosten tavoitteita ovat muun muassa: ihmisen tekemän työn vähentäminen, resurssien tehokkaampi hyödyntäminen sekä huoleton ja itsenäinen tuotanto (Lee et al. 2019). Neuroverkoilla on pystytty vastaamaan esimerkiksi huolettomamman tuotannon tavoitteeseen ennakoivalla huollolla (Tsehaye & Sisay, 2019). Neuroverkon avulla pystytään siis havaitsemaan tarve huoltotoimenpiteelle ja näin ollen ehkäisemään tuotannon keskeytyksiä (Riuttala, 2016). Keskeytysten havaitseminen ajoissa on tärkeää liiketoiminnan ja tuottavuuden kannalta, sillä lyhytkin keskeytys tuotannossa tuottaa yritykselle huomattavia kustannuksia (Tsehaye & Sisay, 2019).

Mikäli tuotantokoneiden dataa mitataan jo erilaisilla sensoreilla, voidaan vikatilanteita myös mallintaa ohjelmallisesti (Wu & Zhao, 2018). Tällöin vika voidaan havaita neuroverkon avulla ennen kuin vikatilanne aiheuttaa isompaa ongelmaa ja kustannuksia. Tällöin myös huoltotoimet voidaan aloittaa aikaisemmin ja tarvittavat toimenpiteet ovat tarkemmin tiedossa etukäteen (Wu & Zhao, 2018).

Myös tuotettavan tuotteen laatu ja asiakastyytyväisyys ovat merkittäviä tuotantoon vaikuttavia tekijöitä. Neuroverkkojen avulla voidaan valvoa tuotantoa tehokkaammin ja virheelliset tuotteet pystytään havaitsemaan myös suuresta massasta tarkemmin (Shangong et al. 2013).

Yrityksen sisäisten prosien digitalisoituessa ja kehittyessä syntyy hyödyllistä dataa, jota voitaisiin hyödyntää tuotannon ulkopuolella. Tuotannon ja tuotteiden seuraamisen yhteydessä voidaan suunnitella koko tuotantoketjun toimintaa. Neuroverkkoja sekä tuotannosta saatavaa tietoa hyödyntämällä voidaan yrityksen tuotantoketjun toimintaa parantaa. Neuroverkkojen hyödyntämisellä pyritään historiadataan pohjautuen tekemään tietoperusteisia päätöksiä ja muuttamaan toimintatapoja kohti tehokkaampaan resurssien käyttöä. (Lima-Junior & Carpinetti, 2019).

## 5. YHTEENVETO

### 5.1 Tulokset

Neuroverkot ovat yksi käytetyimpiä tekoälyn ja koneoppimisen sovelluksia teollisuudessa, mutta myös muilla toimialoilla. Neuroverkkojen suurin etu verrattuna ihmisen ajatteluun ja päätöksentekokykyyn on kyky suodattaa suuri määrä dataa pienessä ajassa. Neuroverkot ovat erityisen hyviä suorittamaan yhtä tiettyä tehtävää. Neuroverkkoja voidaan teollisuudessa hyödyntää esimerkiksi:

- Luokitteluun
  - Tuotteiden erottaminen toisistaan automaattisesti
  - Virheellisten tuotteiden löytäminen
- Ennakointi
  - Ennakoiva huolto ja työturvallisuuden parantaminen
  - Kysynnän ennakointi
- Analytiikka
  - Resurssien käytön optimointi

Teollisuuden käyttötarkoituksia on kuitenkin vaikea eritellä tarkemmin, sillä ongelmat ja haasteet ovat hyvin monimuotoisia eri teollisuuden laitoksissa. Tutkimustulokset siis tarjoavat neuroverkkoratkaisun korkealla tasolla ja ratkaisujen syvällisempi analyysi jätetään jatkotutkimustarpeeksi.

Neuroverkkojen yhtenä taustatekijänä on yritysten tarve parantaa kilpailukykyään ja pysyä mukana teollisuuden digitalisoitumisessa. Data-analytiikka, sensorit sekä erilaiset hallintajärjestelmät ovat esimerkkejä teollisuuden digitalisoitumisesta. Järjestelmien kehittyessä myös teollisuudesta saatavan tiedon määrä valvonnan ja mittaamisen vuoksi on kasvanut todella suureksi. Kilpailukykyä voidaan nykyisten keinojen lisäksi parantaa tehokkaammalla resurssien käytöllä ja tietoon perustuvalla toiminnalla. Neuroverkkojen tehtävä on tuoda aiemmin piilossa ollutta tietoa esille päätöksenteon tueksi.

Teollisuudesta saatavaa dataa on iot-laitteiden kehittyessä saatavilla entistäkin enemmän ja joissain tilanteissa tavanomainen data-analytiikka ei enää riitä tämän tehokkaa-

seen analysoimiseen. Esimerkkinä tästä on kuvantunnistus, jota ei perinteisin analysointityökalujen avulla voida tehdä, vaan se vaatii neuroverkkoja ja oikean oppimisstrategian neuroverkon kehittämiseen.

Teollisuudessa neuroverkkojen käyttötarkoitukset voidaan karkeasti jakaa kahteen osaan käyttötarkoituksen mukaan: toiminnalliseen ja operatiiviseen. Toiminnallisella käytöllä tarkoitetaan laitteiden ja tuotannon tehtävien valvontaa ja automatisointia, jota monesti suoritetaan tuotantolaitteiden tasolla. Operatiivinen käyttö puolesta viittaa yrityksen tietojärjestelmistä saatavan tiedon analysoimista ja tämän puolesta esimerkiksi kysynnän ennustamista ja koko tuotantoketjun hallintaan liittyvää automatisointia.

## **5.2 Tutkimuksen arviointi ja jatkotutkimustarpeet**

Tutkimuksella pystyttiin vastaamaan tutkimuskysymykseen odotetulla tavalla. Aiheesta on tehty jonkin verran tutkimusta muun muassa terveydenhuollon näkökulmasta ja tulokset ovat yhteneviä myös teollisuuden näkökulmasta. Keskeisimpänä asiana nousee esiin neuroverkkojen laaja käyttömahdollisuus. Niiden tekninen toteutus on mahdollista tehdä melko pienessäkin mittakaavassa tai liittää osaksi koko tuotantolaitoksen toimintaa. Neuroverkkojen todellinen hyötyä kustannusten alentamisessa ei voida vielä tarkasti arvioida, sillä yrityksen neuroverkkototeutuksista ei ole riittävästi tieteellistä tutkimusta. Neuroverkkojen kustannustehokkuuden selvittäminen jää siis tutkimustarpeeksi. Erilaisten neuroverkkoratkaisuiden toimivuuden ja tarkkuuden lisäksi voitaisiin siis tutkia myös sen tuomia hyötyjä liiketoiminnallisesta näkökulmasta.

Tutkimus toimii kuitenkin yhteenvetona nykyisistä neuroverkon toteutuksista ja tarjoaa lähtökohdan uuden neuroverkkoratkaisun kehittämiseen. Tätä voitaisiin hyödyntää yrityksen prosessien automatisoinnin suunnitteluvaiheessa. Jatkotutkimusta voitaisiin lähteä kehittämään ensin yksinkertaisen neuroverkkoratkaisun avulla, jolloin kustannukset pysyvät matalina. Tässä tutkimuksessa neuroverkkojen hyödyntämistä ja teollisuuden digitalisaation yhdistelmää tutkittiin vain pinnallisesti ja todellinen hyödyntäminen vaatii syvällisempää tutustumista aiheeseen.



# LÄHTEET

Baker, B., Kanitscheider, I., Markoc, T., Wu, Y., Powell, G., McGrew, B. & Mordatch, I. 2020. 'Emergent tool use from multi-agent autocurricula'. s. 9-10. <https://arxiv.org/abs/1909.07528>

Bawa, V. S. & Kumar, V. 2018. 'Linearized sigmoidal activation: A novel activation function with tractable non-linear characteristics to boost representation capability'. *Expert systems with applications*. Vol 120, no 15. s. 346-356. <https://doi.org/10.1016/j.eswa.2018.11.042>

Bratko, I. 2018. 'AlphaZero – what's missing?'. *Informatica*. Vol 42. no 1, <https://search-proquest-com.libproxy.tuni.fi/docview/2133770071?accountid=14242>

Castanõ, F., Beruvides, G., Haber, R. E. & Artuñedo, A. 2019. 'Obstacle recognition-based machine learning for on-chip LiDAR sensors in cyber-physical system'. *Sensors*. Vol 17, no 9. <http://dx.doi.org.libproxy.tuni.fi/10.3390/s17092109>

Dharmajee, R. & Ramana, K.V. 2019. 'Accelerating Training of Deep Neural Networks on GPU using CUDA'. *International Journal of Intelligent Systems and Applications*. vol. 10, no. 5, s. 18. <https://libproxy.tuni.fi/login?url=https://search-proquest-com.libproxy.tuni.fi/docview/2268345992?accountid=14242>

Fu, Y. 2016. 'Semantic segmentation of human faces using convolutional neural networks.' [https://andor.tuni.fi/permalink/358FIN\\_TAMPO/1j3mh4m/alma99111873224059](https://andor.tuni.fi/permalink/358FIN_TAMPO/1j3mh4m/alma99111873224059)

Glorot, X. & Bengio, Y. 2010. 'Understanding the difficulty of training deep feedforward neural networks'. *AISTATS*. Vol 9. s. 249-256. <http://proceedings.mlr.press/v9/glorot10a/glorot10a.pdf>

Krizhevsky A., Sutskever, I. & Hinton E. G. 2012. 'ImageNet Classification with Deep Convolutional Neural Networks'. <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>

Klumpp, M. 2018. 'Innovation Potentials and Pathways Merging AI, CPS, and IoT. Applied System Innovation'. *Applied system innovation*. Vol 1. no. 5. <https://doi.org/10.3390/asi1010005>.

Lappin, S., Shieber, S.M. 2007. 'Machine learning theory and practice as a source of insight into universal grammar'. *Journal of Linguistics*. Vol. 43, no 2, s. 393-427. <https://doi.org/10.1017/S0022226707004628>

Lee, J., Singh, J. 2019. 'Industrial AI: is it manufacturing's guiding light?' <https://doi.org/10.7945/tt9s-gz25>

Lee, J., Singh, J. & Azamfar, M. 2019 'Industrial Artificial Intelligence'. arXiv.org preprint arXiv:1908.02150

Lee, J., Hossein, D., Singh, J. 2018. 'Industrial artificial intelligence for industry 4.0-based manufacturing system.' *Manufacturing letters*. Vol 18. s. 20-23.

Lima-Junior, F. R. & Carpinetti, L. C. R. 2019. 'Predicting supply chain performance based on SCOR.sup. metrics and multilayer perceptron neural networks'. *International journal of production economics*. [Online] 212119-.

Liyanage, J., Lee, J., Ni, J. & Emmanouilidis, C. 2007. 'Integrated e-Maintenance and Intelligent Maintenance Systems', teoksessa Ben-Daya, M., Duffuaa, S. O., Raouf, A., Knezevic, J. & Ait-Kadi, D. (toim.) *Handbook of maintenance management and engineering*. Springer, London, s. 499-544. <https://doi.org/10.1007/978-1-84882-472-0>

Nascimento, A. M., Bellini, C. G. P. 2018. 'Artificial intelligence and industry 4.0: the next frontier in organizations.' *Brazilian administration review*. Vol 15, no 4. Rio de Janeiro

Majdani, F., Petrovski, A., Doolan, D. 2018. 'Evolving ANN-basen sensors for context-aware cyber physical systems of an offshore has turbine'. *Evolving systems*. Vol 9, no 2. s.119-133.  
Mishra, C. & Gupta, D.L. 2017. 'Deep Machine Learning and Neural Networks: An Overview'. *IAES International Journal of Artificial Intelligence*, Vol. 6, no 2. s. 66-73. <https://lib-proxy.tuni.fi/login?url=https://search-proquest-com.libproxy.tuni.fi/docview/1924958782?accountid=14242>

Marblestone, A.H., Wayne, G. & Kording, K.P. 2016. 'Toward an Integration of Deep Learning and Neuroscience'. *Frontiers in Computational Neuroscience*. Vol 10. s. 94. <https://doi.org/10.3389/fncom.2016.00094>

McAllister, P., Zheng, H., Bond, R. & Moorhead, A. 2018. 'Combining deep residual neural network features with supervised machine learning algorithms to classify diverse food image datasets'. *Computers in biology and medicine*, Vol. 95, s. 217-233. <https://lib-proxy.tuni.fi/login?url=https://search-proquest-com.libproxy.tuni.fi/docview/2017151995?accountid=14242>

Obando, A. 2019. 'Combined artificial intelligence modeling for production forecast in an oil field'. *CT&F – Ciencia, tecnologia future*. Vol 9, no 1. s. 27-35.

Ossama, A-H., Mohammed A-R., Jiang, H., Deng, L., Penn, G., Yu, D. 2014. 'Convolutional neural networks for speech recognition'. *IEEE/ACM Transactions on audio, speech and language processing (TASLP)*. Vol. 22, no 10. s. 1533-1545.

Pinho, E. & Costa, C. 2018. 'Unsupervised learning for concept detection in medical images: A comparative analysis'. *Applied Sciences*, Vol. 8, no 8. <http://dx.doi.org.lib-proxy.tuni.fi/10.3390/app8081213>

Rawat, A. S., Rana, A., Kumar, A., Bagawari, A. 2018. 'Application of multi-layer artificial neural network in the diagnosis system: A systematic review'. *Institute of advanced engineering and sciences*. Dehradun. Uttarakhand Technical University.

Riuttala, K. 2016. 'Ennustavan vikadiagnostiikan kehitys ja etäkunnonvalvonnan hyödyntäminen nrrmm-liiketoimintasegmentissä'. *Opinnäytetyö*. Tampereen ammattikorkeakoulu.

Romero, M., Guedria, W., Panetto, H., Barafort, B. 2020. 'Towards a characterization of smart systems: a systematic literature review'. *Computers in industry*. Vol. 120.

Saniuk, S., Saniuk, A., Cagánová, D. 2019 'Cyber industry networks as an environment of the industry 4.0 implementation'. <https://doi.org/10.1007/s11276-019-02079-3>

Sathya, R., Abraham, A. 2013. 'Comparison of supervised and unsupervised learning algorithms for pattern classification'. (*IJARAI*) *International journal of advanced research in artificial intelligence*. Vol 2, no 2.

Schütze, A., Helwig, N. & Schneider, T. 2018. 'Sensors 4.0 – smart sensors and measurement technology enable Industry 4.0'. *Journal of sensors and sensor systems*. Vol. 7, no 1, s. 359–371, <https://doi.org/10.5194/jsss-7-359-2018>,

Shangong, C., Bin, L., Xuesong, H. & Xiaohu, L. 2013. 'Automated inspection of engineering ceramic grinding surface damage based on image recognition'. *The international journal of advanced manufacturing technology*. Vol. 66. no 1-4. s 431-443. Heidelberg.

Shin, H-J., Cho, K-W., Oh, C-H. 2018. 'SVM-based dynamic reconfiguration CPS for manufacturing system in industry 4.0'. *Wireless communications & mobile computing*. Vol 2018. <https://doi.org/10.1155/2018/5795037>

Shiqi, Y., Sen, J., Chunyan, X. 2016. 'Convolutional neural networks for hyperspectral image classification'. *Neurocomputing*. Vol 2017. s. 88-98.

Sim, H.S., Kim, H.I. & Ahn, J.J. 2019. 'Is Deep Learning for Image Recognition Applicable to Stock Market Prediction?' *Complexity*, vol. 2019, s. 10. <https://lib-proxy.tuni.fi/login?url=https://search-proquest-com.libproxy.tuni.fi/docview/2187375918?accountid=14242>

Taylor, T. 2015. 'Requirements for open-ended evolution in natural and artificial systems.' arXiv preprint arXiv:1507.07403

Tsehaye, D., Sisay, G. 2019. 'Application of failure mode effect analysis (FMEA) for efficient and cost-effective manufacturing: a case study at Bahir dat textile share company'. *Journal of optimization in industrial engineering*. Vol. 12, no 1. s. 23-29.

Toivanen, P. 2013. 'MLP-verkon arkkitehtuurin optimointi geneettisellä algoritmilla'. Tampere: Tampereen yliopisto. [https://andor.tuni.fi/permalink/358FIN\\_TAMPO/1kfm-qvo/alma996077204205973](https://andor.tuni.fi/permalink/358FIN_TAMPO/1kfm-qvo/alma996077204205973)

Wolff, J.G. 2013. 'The SP Theory of Intelligence: An Overview'. *Information*, Vol. 4, no 3. s. 283-341. <https://doi.org/10.3390/info4030283>

Wu, H. & Zhao, J. 2018. 'Deep convolutional neural network model based chemical process fault diagnosis'. *Computers & chemical engineering*. [Online] 115185-197. <https://doi.org/10.1016/j.compchemeng.2018.04.009>

Zakaria, M., AL-Shebany, M. & Sarhan, S. 2014. 'Artificial Neural Network: A Brief Overview' teoksessa Mabrouka AL-Shebany et al. *International Journal of Engineering Research and Applications*. John Wiley & Sons, New Jersey, ISSN: 2248-9622, Vol. 4, no 2(Version 1), Helmikuu 2014, s. 7-12.

Zhou, Y. 2019. 'Sentiment classification with deep neural networks'. [https://andor.tuni.fi/permalink/358FIN\\_TAMPO/1j3mh4m/alma9911187894605973](https://andor.tuni.fi/permalink/358FIN_TAMPO/1j3mh4m/alma9911187894605973)