

Janne Sarja

KONEOPPIMISEN HYÖDYNTÄMINEN YRITYKSEN LAADUNHALLINASSA

Johtamisen ja talouden tiedekunta
Kandidaatintyö
Huhtikuu 2019

TIIVISTELMÄ

Janne Sarja: Koneoppimisen hyödyntäminen yrityksen laadunhallinnassa
(Utilizing machine learning in company's quality management)

Tampereen yliopisto

Kandidaatintyö, 26 sivua

Maaliskuu 2019

Teknis-taloudellinen TkK-tutkinto-ohjelma

Pääaine: Tietojohtaminen

Tarkastaja: Jussi Myllärniemi

Avainsanat: koneoppiminen, laadunhallinta

Koneoppimista hyödynnetään nykypäivänä laajasti erilaisissa sovelluksissa. Koneoppiminen pyrkii rakentamaan älykkyyttä koneisiin. Tämän tutkimuksen pohjana on tutustua, kuinka yritykset pystyvät hyödyntämään koneoppimista omilla prosesseillaan. Yksi näistä prosesseista on laadunhallinta, joka on tärkeä osa yrityksen toimintaa. Laadunhallinnan tavoitteena on ylläpitää yrityksen prosessien ja tuotosten laatua. Laadunhallinta tuottaa paljon koneoppimiselle hyödyllistä dataa, mikä tekee laadunhallinnasta otollisen kohteen koneoppimisen hyödyntämiselle. Tutkimuksen aiheena on tutkia, millaisia koneoppimisen sovelluksia yritysten laadunhallinnassa voidaan käyttää.

Tämä kandidaatintyö on toteutettu kirjallisuuskatsauksena, jossa tutustutaan sekä koneoppimisen ja laadunhallinnan käsitteisiin yksittäin että näiden kahden käsitteen väliseen suhteeseen. Nämä kaksi käsitettä ovat tutkimuksen keskiössä, minkä lisäksi tutkimuksessa esitellään monia koneoppimisen menetelmiä sekä lähikäsitteitä, kuten tekoäly ja datatiede. Myös laadunhallintaa voidaan jaotella pienempiin osa-alueisiin, joissa koneoppimismenetelmiä voidaan hyödyntää. Tutkimuksessa esitellään esimerkiksi termit laadunvarmistus ja tilastollisen laadunvalvonta. Tutkimuksessa hyödynnetään erityisesti tieteellisiä artikkeleja, joissa tutkitaan koneoppimismenetelmien kehittämistä johonkin laadunhallinnan osa-alueeseen.

Tutkimuksen löydökset painottuivat erityisesti valmistavaan teollisuuteen, jossa pystytään hyödyntämään paljon tuotantolinjoilta sekä tuotetestauksesta saatavaa dataa. Vaikka tulokset painottuivat paljon valmistavan teollisuuden sovelluksiin, löydettiin myös muita sovellusaloja, kuten esimerkiksi sovellus, joka perustui asiakaspalautedataan palvelualalla. Tutkimuksen tulokset tarjoavat esimerkkejä siitä, kuinka yritykset voivat hyödyntää laadunhallinnan tuottamaa dataa paremmin ja kuinka koneoppimista voidaan hyödyntää laadunhallinnan ongelmien ratkaisemisessa.

ALKUSANAT

Tämä kandidaatintyö on tehty Tampereen yliopiston tietojohdamisen koulutusohjelmaan keväällä 2019. Koneoppiminen on itseäni kiinnostava ajankohtainen aihe, johon päätin yhdistää laadunhallinnan, sillä halusin oppia lisää tästä yrityksen osa-alueesta.

Haluan kiittää työni ohjaajaa ja tarkastajaa Jussi Myllärniemeä palautteesta ja kommentista työn aikana, sekä pienryhmääni hyvistä ideoista ja palautteesta.

Tampereella, 10.4.2019

Janne Sarja

SISÄLLYSLUETTELO

1.	JOHDANTO.....	1
1.1	Tutkimuksen tausta	1
1.2	Tutkimusongelma ja rajaus.....	2
1.3	Tutkimuksen rakenne.....	2
2.	TUTKIMUSMENETELMÄ JA TAVOITTEET.....	3
3.	KONEOPPIMINEN.....	5
3.1	Data ja algoritmit.....	5
3.2	Oppimisen alakentät	7
3.3	Toteutus	8
3.4	Lähikäsitteitä	9
4.	LAADUNHALLINTA.....	11
4.1	Laatu.....	11
4.2	Laadunhallinnan toteutus	12
4.3	Vaihtelu ja tilastollinen näkökulma.....	14
5.	KONEOPPIMISEN SOVELLUKSET LAADUNHALLINNASSA.....	16
5.1	Laatutekijöiden tunnistus	17
5.2	Sovellukset tilastollisessa laadunvalvonnassa.....	20
5.2.1	Valvontakaaviot	20
5.2.2	Hyväksymisotanta	21
6.	YHTEENVETO.....	23
6.1	Johtopäätökset	23
6.2	Jatkotutkimusmahdollisuudet ja tutkimuksen arviointi	24
	LÄHTEET	25

1. JOHDANTO

1.1 Tutkimuksen tausta

Moni teknologian käyttäjä voi törmätä koneoppimisen mahdollistamiin sovelluksiin päivittäin. Koneoppimiseen perustuvia sovelluksia ovat esimerkiksi kasvojen- ja puheentunnistus, roskapostin suodatus, sekä suoratoistopalveluiden sisältösuositukset (Gollapudi 2016, s. 15). Kuten myös edellisestä listauksesta voi huomata, usein koneoppimisen sovelluskohteista puhuttaessa esiin tulee pääasiassa kuluttajien käytössä olevia sovelluksia. Tämän vuoksi itseäni kiinnostaakin lähteä tutkimaan, kuinka koneoppimista voidaan hyödyntää yritysmaailmassa.

Yritysmaailmassa on suurta kysyntää kyvyllä löytää tärkeää tietoa suurista ja monimutkaisista datajoukoista. Tieto- ja ohjelmointiteknikan kehityksen, sekä informaation ja datan räjähdysmäisen kasvun seurauksena koneoppimisesta on kehittynyt tärkeä työkalu arvokkaan tiedon löytämiseen datasta. Niinpä myös organisaatiot ovat ymmärtäneet koneoppimisen tärkeän roolin datan jalostuksessa tietämykseksi. Koneoppiminen tarjoaa työkaluja trendien, kaavamaisuuksien ja vuorovaikutussuhteiden löytämiseksi datasta, mikä voi olla erittäin arvokasta yritysten liiketoiminnan kehitykselle. (Gollapudi 2016, s. vi, xi) Koneoppimisen avustuksella datan analysointia voidaan tehdä huomattavasti tehokkaammin kuin perinteisillä työkaluilla. Koneoppiminen tarjoaa hyödyllisen työkalun, jolla työntekoa voidaan tehostaa yrityksissä. Koneoppimisen nykymuodossa ihmisiä kuitenkin tarvitaan vielä tekemään johtopäätöksiä koneoppimisen tuloksista. Koneoppimisen hyödyntäminen voi säästää rahaa eliminoimalla yksinkertaiset ja puuduttavat työt. Samalla syntyy monipuolisempia ja kiinnostavampia työtehtäviä, jotka voivat hyödyttää yritystä uusilla tavoilla. (Mueller & Massaron 2016, s. 13, 27) Koneoppiminen voi siis luoda yritykselle lisäarvoa ja kilpailuetua jalostamalla uutta tietoa ja tehostamalla yrityksen toimintaa. Erityisesti itseäni kiinnostaa, kuinka koneoppimista voidaan hyödyntää yrityksissä datan analysointiin ja toiminnan tehostamiseen. Tämä näkökulma linkittää aiheen vahvasti myös tietojohtamisen kenttään.

Rose (2005, s. 41) esittää laadunhallinnan alaprosesseiksi laadun suunnittelun, -varmistuksen, -kontrolloinnin ja -parantamisen. Laadunhallinnan toteutuksen seurauksena syntyy paljon dataa esimerkiksi tuotteiden ja prosessien laadun tilasta. Tämä data kätkee sisälleen tietoa laatuun vaikuttavista tekijöistä ja niiden suhteista toisiinsa. Tämän tiedon löytämiseen kuitenkin tarvitaan usein älykkäitä informaation prosessointimetodeja. (Tsironis et al. 2005) Koneoppiminen vaikuttaa siis luonnolliselta työkalulta laadunhallinnan parissa työskenneltäessä.

1.2 Tutkimusongelma ja rajaus

Päättökysymys on määritelty muotoon: Millaisia mahdollisuuksia koneoppiminen tarjoaa yritysten laadunhallinnalle? Aiheessa keskeisenä teemana on siis tutustua koneoppimisen menetelmiin ja hyödyntämiseen. Toisena keskeisenä taustateemana on selvittää, mitä prosesseja laadunhallintaan kuuluu, kuinka laadunhallintaa ja sen työkaluja sovelletaan yrityksissä, ja mitä hyötyä laadunhallinnasta on.

Alatutkimuskysymyksiä ovat:

- Mitä koneoppiminen pitää sisällään?
- Mitä laadunhallinta on ja kuinka se näkyy yritysten toiminnassa?
- Mitä yhtäläisyyksiä on koneoppiminen ja laadunhallinnan välillä?

Alatutkimuskysymysten tavoitteena on kerätä taustatietoa ja johdatella kohti päättökysymystä.

1.3 Tutkimuksen rakenne

Tutkimuksen toisessa luvussa kuvataan tutkimusaineiston keräämistä sekä tutkimuksen tavoitteita. Kolmannessa luvussa tutustutaan koneoppimisen teorian perusteisiin. Luvussa selvennetään koneoppimisen käsitettä määrittelyn ja esimerkkien avulla. Tämän lisäksi luvussa tutustutaan syvemmin osa-alueisiin, joita tarvitaan koneoppimisen toteuttamisessa. Neljäs luku esittelee laadunhallintaa. Luvussa esitellään keskeisiä laadunhallinnan käsitteitä ja osa-alueita. Luku antaa myös kuvan siitä, kuinka laadunhallintaa voidaan toteuttaa yrityksissä ja mitä hyötyjä sillä voidaan saavuttaa. Viidennessä luvussa esitellään kirjallisuuden pohjalta laadunhallinnan tueksi kehitettyjä koneoppimissovelluksia. Luvussa pyritään esittelemään sovelluksia eri laadunhallinnan osa-alueilta. Viimeisessä eli kuudennessa luvussa esitetään kirjallisuuden pohjalta tehdyt johtopäätökset siitä, kuinka laajasti ja millä osa-alueilla koneoppimista hyödynnetään nykyisin laadunhallinnassa. Lisäksi luvussa esitellään mahdollisia jatkotutkimuskohteita sekä arvioidaan tutkimusta.

2. TUTKIMUSMENETELMÄ JA TAVOITTEET

Tässä tutkimuksessa tutkimusmenetelmänä käytetään kirjallisuustutkimusta. Kirjallisuutta haetaan pääasiassa Andor, Scopus ja Web of Science -järjestelmistä. Käytössä on myös helmenkalastusmenetelmä, jossa yhden lähteen lähdeluettelon avulla pyritään löytämään uusia lähteitä. Tämä menetelmä toimii esimerkiksi hyvänä keinona etsiä teoreettista taustatietoa. Aihepiirin käsitteitä käsittelevien tieteellisten artikkelien pohjustuksista ja teoriaosuuksista voi löytyä hyviä uusia lähteitä teoriaosuuteen. Teoreettista taustamateriaalia on löytynyt myös esimerkiksi pelkillä ”quality management”, ”quality control” ja ”quality assurance” hakusanoilla, kun hakua on rajattu tarpeeksi Andorissa. Hakutuloksia voidaan rajata esimerkiksi seuraavilla ehdoilla: hakusana esiintyy teoksen otsikossa, teos on kirja, saatavilla verkossa ja tieteenala on liiketalous. Tämänlaisella rajauksella saadaan hakusanalla ”quality management” 151 osumaa ja hakusanalla ”quality control” 49 osumaa. Yleisiä hakusanoja ja -lauseita, joita käytetään tiedonhaussa ovat:

- “machine learning” AND “quality management”
- “machine learning” AND “quality control”
- “machine learning” AND “quality assurance”
- “machine learning” AND “corporate applications”

Edellisessä listauksessa esiintyvien termien lisäksi esimerkiksi laadunvarmistuksesta löytyy paljon alakäsitteitä kuten ”sampling” tai ”Statistical process control”, joita voidaan yhdistää ”machine learning” termin kanssa. Myös ”machine learning” termi voidaan korvata hauissa jollakin yksityiskohtaisemmalla koneoppimisen alatermillä.

Tutkimusaineisto on suurimmilta osin englannin kielistä, joten tiedon etsintään käytettävät haut ovat suurimmaksi osin englannin kielisiä. Käsitteiden ja käännösten käsitteilyyn hyödynnetään lähtökohtaisesti MOT-sanakirjaa.

Viime aikoina olen huomannut, että koneoppimisesta ja tekoälystä vaikuttaa tulleen trendikkäitä termejä monilla aloilla. Uskoisin kuitenkin, että yritysten laadunhallinnassa koneoppimista ei vielä hyödynnetä täydellä potentiaalilla. Tutkimuksellani pyrin kasvattamaan omaa tietämystäni koneoppimisesta ja sen hyödynnyksestä etenkin yrityksissä. Lisätietoa pyrin myös saamaan yritysten laadunhallintaprosesseista ja siitä, kuinka koneoppimista voitaisiin hyödyntää niissä. Tutkimuksessa haluan koota yhteen eri tietolähteissä esiteltyjä koneoppimisen sovelluksia, joita voidaan käyttää yrityksen laadunhallinnan apuna. Tutkimuksen tavoitteena on siis esitellä keinoja koneoppimisen hyö-

dyntämiseen laadunhallinnassa ja näin ollen tuoda esille uusia sovelluksia, jotka voivat tuottaa lisäarvoa yritykselle.

3. KONEOPPIMINEN

Tekoäly ja koneoppiminen ovat ajankohtaisia ja suosittuja termejä nykypäivänä ja niiden suosio on kasvamassa edelleen. Koneoppimista ja tekoälyä käytetään nykyään lukuisissa sovelluksissa, ja monissa sovelluksissa ne toimivat niin hyvin, ettei niitä huomaa edes käyttävänsä. (Mueller & Massaron 2016, s. 9, 16) Mueller ja Massaron (2016, s. 38) korostavat koneoppimisen tarjoavan myös yritysmaailmalle tapoja asioiden tekemiseksi tehokkaammin. Koneoppiminen mahdollistaa asioiden tekemisen nopeammin, tarkemmin ja vähemmällä resursseilla, mikä johtaa organisaatioissa joustavuuteen ja suurempiin liiketoimintavoittoihin (Mueller & Massaron 2016, s. 38).

Gollapudi (2016, s. 3) määrittelee koneoppimisen mekanismiksi kaavamaisuuksien löytämiseksi sekä älykkyyden rakentamiseksi koneisiin niin, että ne pystyvät oppimaan. Koneoppimisessa on vahvoja tieteellisiä komponentteja, joiden kautta ihmiset voivat kehittää uusia konsepteja siitä, kuinka oppimis- ja ajatteluprosesseja voidaan toteuttaa koneilla. Koneoppiminen perustuu pitkälti matematiikan ja tilastotieteen menetelmiin, joita hyödyntämällä kone pystyy analysoimaan tietoa huomattavasti nopeammin ja tehokkaammin kuin ihminen. (Mueller & Massaron 2016, s. 10–24)

Koneoppimista hyödyntäviä sovelluksia on monissa paikoissa. Roskapostin tunnistus sähköpostisovelluksessa on yksi esimerkki koneoppimista hyödyntävästä sovelluksesta. Roskapostin tunnistuksessa kone pyrkii tunnistamaan sähköpostin sisällön ominaisuuksien perusteella, onko saapunut viesti roskapostia vai ei. Toinen yleinen koneoppimisen sovelluskohde on kuvien tunnistaminen. Kone voidaan harjoittaa tunnistamaan kuvan pikseleiden avulla esimerkiksi, mitä numeroa kuva esittää. (Gollapudi 2016, s. 14) Koneoppimista voidaan hyödyntää myös esimerkiksi asiakaspalvelussa. Monilla yrityksillä on käytössä asiakaspalvelurobotteja, jotka ovat oppineet vastaamaan yleisimpiin asiakaskysymyksiin. (Mueller & Massaron 2016, s. 17)

Vaikka nykyään koneoppimista hyödynnetään jo lukuisissa tuotteissa, sen käyttö ei ole vielä lähelläkään sen lopullista käyttöastetta. Koneoppimisessa käytettävät algoritmit ovat nykypäivänä vielä suhteellisen alkeellisia verrattuna siihen, mitä tutkijat ovat suunnitelleet käytettäväksi tulevaisuudessa. Myös datan määrä jatkaa kasvuaan, mikä tarjoaa uusia mahdollisuuksia tulevaisuudessa. (Mueller & Massaron 2016, s. 35)

3.1 Data ja algoritmit

Gollapudi (2016, s. 6) korostaa, että data on koneoppimisen pääasiallinen oppimismateriaali. Koneoppimiseen käytettävän datan muoto ja määrä voivat vaihdella tapauskohtai-

sesti (Gollapudi 2016, s. 6). Mueller ja Massaron (2016, s. 23) painottavat kuitenkin, että oppimiseen tarvitaan yleensä suuria määriä dataa, jotta datasta voidaan löytää luotettavasti kaavamaisuuksia. Pelkkä datan syöttäminen koneoppimisalgoritmiin ei kuitenkaan riitä takaamaan onnistuneita koneoppimistuloksia. Koneoppimisen keskiössä on datan tunteminen ja käyttäminen oikealla tavalla. Tämä vaatii oikean datan keräämistä, datan puhdistamista ja datan käsittelyä niin, että siitä löydetään avainominaisuuksia, joiden avulla koneoppimisalgoritmi voi löytää kaavamaisuuksia. (Gollapudi 2016, s. 4, 13)

Koneoppimiseen käytettävät datamäärät voivat ylittää jopa niin suuriksi, että niitä kutsutaan termillä big data. Suuren datamäärän lisäksi big datalle tyypillistä on datan monimutkaisuus sekä datan nopea liikkuminen ja määrän kasvu. Datan määrän takia big datan käsittely on erittäin vaikeata. Käsittelyssä on otettava huomioon datan säilytys ja liikuttelu, minkä seurauksena käsittelyyn käytettäviltä teknologioilta vaaditaan paljon. Big datalle ominainen piirre on myös se, että ihmiset eivät pysty visualisoimaan sitä ilman apua. Big data sisältää kuitenkin usein ihmisille hyödyllistä tietoa, ja koneoppiminen onkin yksi keino big datan sisällön ymmärtämiseen ja hahmottamiseen. (Mueller & Massaron 2016, s. 23–25)

Koneoppimisessa käytettävä data voi olla merkittyä tai merkitsemätöntä. Merkitsemätön data on usein raakadataa. Esimerkkejä merkitsemättömästä datasta voivat olla kuva, video tai twiitti. Merkitsemättömästä datasta tulee merkittyä dataa, kun sille annetaan jokin merkitys. Merkitys annetaan usein jonkin tunnisteiden avulla. Esimerkiksi kuvan tunniste voi kertoa, mitä kuva esittää, jolloin tunniste voisi olla vaikkapa puu, eläin tai rakennus. Usein tunnisteiden lisääminen merkitsemättömään dataan vaatii ihmisen apua. Tämän vuoksi merkityn datan hankinta on usein hankalampaa, aikaa vievämpää ja kalliimpaa kuin merkitsemättömän datan hankinta. (Gollapudi 2016, s. 8)

Toinen koneoppimisen tukipilari on algoritmien käyttö. Mueller ja Massaron (2016, s. 19) määrittelevät koneoppimisen keskipisteenä olevan algoritmit, joilla käsitellään dataa. Algoritmi on menetelmä tai kaava ongelman ratkaisemiseksi. Koneoppimisessa sovelluskohde vaikuttaa siihen, millaista algoritmia käytetään. Kuten datankin tapauksessa, tavoitteena on valita oikea algoritmi ongelman ratkaisemiseksi. Koneoppimisalgoritmi sisältää systemaattisen joukon operaatioita, joita suoritetaan datajoukolle. Tavoitteena on dataa käsittelemällä luoda lopputulos, joka ratkaisee ongelman. Algoritmi määrittää, kuinka kone tulkitsee dataa, joten käytössä oleva algoritmi vaikuttaa siihen, millaisia lopputuloksia koneoppiminen antaa. (Mueller & Massaron 2016, s. 19–30)

Koneoppimisessa algoritmeja harjoitetaan datan avulla, mikä muokkaa algoritmin näkemystä datasta. Usein koneoppimisessa lähtötilanteena on se, että tiedetään alkutilanne ja lopputilanne, mutta ei tiedetä, millaisen algoritmin tai funktion avulla päästään alkutilanteesta lopputilanteeseen. Harjoituksen tarkoituksena on tarjota erilaisia esimerkkejä, joissa algoritmille annetaan alkutilanteessa syöte ja tiedetty lopputulos. Syötteen avulla

algoritmi muokkaa näkemystään datasta ja näin pyrkii luomaan algoritmin, joka ratkaisee ongelman. (Mueller & Massaron 2016, s. 30, 32)

3.2 Oppimisen alakentät

Koneoppimisessa keskeisessä roolissa on oppimisongelman ratkaiseminen. Oppimisongelman ratkaiseminen perustuu siihen, että suoriutumisen määritellystä tehtävästä paranee ajan myötä, kun systeemi saa jonkinlaista harjoitusta. (Jordan & Mitchell 2015) Koneoppimisen kontekstissa oppimista voidaan jaotella alakenttiin. Algoritmeja voidaan luokitella näiden alakenttien perusteella. Erilaiset oppimistavat vaativat erilaisia algoritmeja ja toteutustapoja. (Gollapudi 2016, s. 21) Tässä kappaleessa tutustutaan erilaisiin oppimisen alakenttiin.

Ohjatussa oppimisessa harjoitusdata koostuu itse datan attribuuteista sekä ulostulon oikeasta vastauksesta, jolloin siis syötteenä on raakadataa ja ulostulona on datan tunnistus. Esimerkki ohjattuun oppimiseen perustuvasta algoritmista on luokittelualgoritmi, jossa syötteen avulla pyritään päättämään, mihin ennalta määriteltyyn luokkaan kyseinen datapiste kuuluu. (Louridas & Ebert 2016). Ohjattuun oppimiseen perustuvissa algoritmeissa keskitytään löytämään syötteen attribuuttien ja ulostulon attribuuttien välinen suhde. Kun algoritmia on harjoitettu tarpeeksi merkityllä datalla, algoritmi pystyy ennustamaan syötteen perusteella ulostulon vaihtoehtoja se olisi ennalta tiedossa. (Gollapudi 2016, s. 21)

Toinen koneoppimisessa käytettävä oppimismenetelmä on ohjaamaton oppiminen. Ohjaamattomassa oppimisessa harjoitusdata ei sisällä vastauksia halutusta lopputuloksesta, vaan koneen on pääteltävä ne itse. Esimerkki ohjaamattomaan oppimiseen perustuvasta algoritmista on klusterialgoritmi, jossa datapisteet pyritään jakamaan niiden samankaltaisuuden perusteella klustereihin eli ryhmiin, jotka eivät ole ennalta tiedossa. (Louridas & Ebert 2016) Ohjaamattoman oppimisen tavoitteena on löytää datasta rakenteita, jotka eivät olleet ennalta tiedossa. (Gollapudi 2016, s. 22)

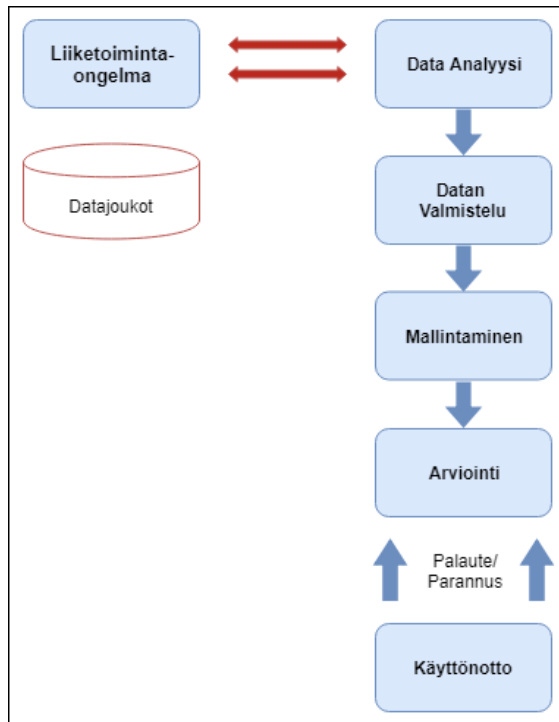
Muita koneoppimisen käytössä olevia oppimismenetelmiä ovat esimerkiksi vahvistusoppiminen ja syväoppiminen. Vahvistusoppimisessa pyritään ohjaamaan algoritmin toimintaa palkitsemalla niitä ratkaisuja, jotka ovat lähellä haluttuja tuloksia, jolloin algoritmi kehittyy askeleittain kohti optimaalista tulosta. Syväoppiminen on koneoppimisen alue, joka pyrkii yhtenäistämään koneoppimista tekoälyn kanssa. Syväoppimisessa keskiössä on keinotekoisien neuroverkkojen kehittäminen, jotka voivat toimia esimerkiksi merkittömällä datalla ja pienellä määrällä merkittävää dataa. (Gollapudi 2016, s. 22–23)

3.3 Toteutus

Gollapudi (2016, s. 9) esittelee kolme yleistä vaihetta koneoppimisen toteuttamiseksi: tehtävän määrittäminen, algoritmin valinta ja mallin muodostaminen. Tehtävä voidaan määrittää ongelmaksi, joka koneoppimisalgoritmeilla halutaan ratkaista. Tehtävän määrittämisen lisäksi on tärkeää myös miettiä, kuinka tehtävästä suoriutumista tullaan mittaamaan. Koneoppimisen kontekstissa suoriutuminen voidaan määrittää sen mukaan, kuinka laajasti tai luotettavasti ongelma on ratkaistu. Kun tehtävä on määritetty, voidaan siirtyä algoritmin valintaan. Algoritmeja on erilaisia, kuten jo aiemmin kävi ilmi, ja tärkeää on miettiä, mikä on tehtävään sopivin algoritmi. Algoritmin valinnan jälkeen koneoppimisprosessissa luodaan malli, joka kuvaa koneoppimissysteemiin syötettyä dataa. Malli on siis algoritmien ulostulo. (Gollapudi 2016, s. 9)

Louridas ja Ebert (2016) toteavat, että suurin osa koneoppimismenetelmistä perustuu algoritmin harjoittamiseen harjoitusdatalla, minkä jälkeen algoritmia voidaan käyttää käytännönongelman ratkaisemiseen, jossa käytössä on dataa, jota algoritmi ei ole nähnyt ennen. Myös Gollapudi (2016, s. 5) on samoilla linjoilla ja esittää, että mallin muodostus ja käyttöönotto toteutetaan yleensä kolmessa vaiheessa. Ensimmäisessä vaiheessa on algoritmin harjoittaminen. Seuraavana vaiheena on validointi- ja testausvaihe, jossa mitataan, kuinka hyvin algoritmin harjoitus onnistui. Tässä vaiheessa koneoppimisalgoritmeille annetaan dataa, jota se ei vielä harjoitusvaiheessa ole nähnyt ja mitataan sen jälkeen esimerkiksi mallin virheitä erilaisilla menetelmillä. Viimeisenä on vuorossa käyttöönotto eli sovellusvaihe, jossa mallia käytetään todellisten ongelmien ratkaisuun. (Gollapudi 2016, s. 5)

Kuvassa 1 esitetään Gollapudin (2016, s. 33) luoma malli koneoppimisprosessin elinkaaren etenemisestä ja arkkitehtuurista. Elinkaari alkaa ongelman määrittämisellä, johon sisältyy tavoitteen asetus sekä prosessin ja ennako-oletusten pohtiminen. Seuraavaksi mietitään, millainen oppimisongelma on kyseessä. Kun algoritmi ja malli on valittu kyseessä olevan ongelman pohjalta, valitaan seuraavassa elinkaaren vaiheessa, kuinka mallin tarkkuutta mitataan. Lopuksi ennen käyttöönottoa testataan, kuinka hyvin malli toimii uuden datan kanssa, jota malli ei ole aiemmin nähnyt. (Gollapudi 2016, s. 32–33)



Kuva 1 Koneoppimisprosessin elinkaaren arkkitehtuuri (Gollapudi 2016, s. 33)

Koneoppimisalgoritmit tarvitsevat usein myös paljon muistia ja laskentatehoa, joten myös tietotekniikan käyttöä on tärkeää suunnitella koneoppimisen toteutuksessa. Monissa koneoppimisen sovelluksissa ei ole aikaa odotella algoritmin tuottamia tuloksia kovinkaan pitkään. (Mueller & Massaron 2016, s. 14) Yleisiä koneoppimisessa käytettäviä ohjelmointikieliä ovat esimerkiksi Python ja R (Louridas & Ebert 2016).

3.4 Lähikäsitteitä

Tilastotiede on yksi keskeisistä työkaluista, joita koneoppimisessa hyödynnetään. (Mueller & Massaron 2016, s. 24) Thomas (2014, s. 1) määrittelee tilastotieteen systemaattiseksi ja tieteelliseksi datan tutkimukseksi, joka tarjoaa metodeja datan tuottamiseen ja ymmärtämiseen. Määritelmästä löytyy paljon yhteneväisyyksiä koneoppimisen kanssa ja tilastotiede onkin yksi yleisemmistä metodeista, joita käytetään koneoppimisalgoritmeissa, mutta ei kuitenkaan ainoa. (Mueller & Massaron 2016, s. 24)

Koneoppiminen nähdään tekoälyn alakenttänä. Tekoälyn avulla pyritään rakentamaan järjestelmiä, jotka matkivat ihmisten käytöstä. (Gollapudi 2016, s. 30) Koneoppimisella voidaan suorittaa tekoälyn oppimispuoli (Mueller & Massaron 2016 s. 13). Koneoppimisen erottaa kuitenkin tekoälystä esimerkiksi se, että koneoppimisessa keskitytään ratkaisemaan oppimisiongelma mahdollisimman tehokkaasti, jolloin ratkaisu ei aina välttämättä ole ihmisen toimintaa mukaileva. (Gollapudi 2016, s. 30–31)

Muita koneoppimiseen liitettyjä käsitteitä ovat tiedonlouhinta ja datatiede. Tiedonlouhinta pyrkii analysoimaan ja tuottamaan uutta ymmärrystä datasta koneoppimisen

tavoin. Koneoppimisen ja tiedonlouhinnan erona on se, että koneoppimisessa hyödynnetään aiempaa kokemusta ja tietoa, kun taas tiedonlouhinnan tavoitteena on löytää uutta tietoa datasta. Datatieteessä muutetaan dataa tuotteiksi. Datatieteessä sovelletaan analytiikkaa ja koneoppimista, joiden avulla voidaan tehdä päätelmiä datasta. Datatiede toimii yläkäsitteenä esimerkiksi koneoppimiselle ja tiedonlouhinnalle, jotka sisältyvät datatieteen piiriin. (Gollapudi 2016, s. 30, 32)

4. LAADUNHALLINTA

Laadunhallinnan periaatteet ovat levinneet 1980-luvulta lähtien laajasti yrityksiin ympäri maailmaa (Rahman 2004; Kim et al. 2012, s. 1). Kiinnostus laadunhallintaa kohtaan on kasvanut erityisesti valmistavassa teollisuudessa ja terveydenhoitoalalla (Nair 2006). Laatuohjelmia voidaan käyttää sekä valmistavan teollisuuden yrityksissä, että palvelualan yrityksissä, sillä laatuun vaikuttavaa variaatiota ilmaantuu sekä tuotteissa että prosesseissa. Koneoppimisen tavoin suuri osa laatuun ja laadunhallintaan liittyvistä työkaluista perustuu datan hyödyntämiseen. (Sahay 2015, s. ix)

Laadunhallinnan historia alkaa 1900-luvun alkupuolelta. Frederic Winslow Taylor oli ensimmäisiä pioneereja laadunhallinnan alalla. Hän esitteli maailmalle ajatusmallin, jossa keskittyminen siirtyi työntekijöistä koko prosessiin. Taylor painotti erityisesti suunnittelu- ja toteutusprosessien erottamista toisistaan. Laadunhallinta kehittyi lisää 1910-luvulla Fordin kokoonpanolinjan ja Walter Shewhartin variaatioon painottuvan ajattelumallin myötä. Shewhart kehitti myös tilastollisen prosessinohjauksen periaatteita. Toisen maailmansodan aikana keskittyminen siirtyi tarkastuksiin ja laaduntarkkailuun. 1950-luvulla Joseph Juran toi asiakaslähtöisen ajattelutavan laadunhallintaan ja Armand Feigenbaum esitteli total quality control -lähestymistavan, joka keskittyi laatuajattelun omaksumiseen koko organisaation laajuisesti. Laatuajattelun periaatteita omaksuttiin erityisesti Japanissa 1950-luvulta lähtien. 1980- ja 1990-luvuilla kehitettyjä laadunhallinnan lähestymistapoja ovat esimerkiksi Total quality management, Just-In-Time, lean ja Six Sigma. Nykypäivänä keskeisimpiä laadunhallinnan periaatteita ovat asiakaslähtöisyys, variaation ymmärtäminen, jatkuva parantaminen ja Six Sigma. (Rose 2005, s. 14–20; Sahay 2015, s. 16)

4.1 Laatu

Laadunhallinnan keskiössä on luonnollisesti laadun käsite. Kansainvälinen laadunhallinnan standardi ISO 9001 (2015) määrittelee laadun asteeksi, jolla joukko ominaisuuksia täyttää sille asetetut vaatimukset. Laatu voidaan tarkastella eri näkökulmista, jonka seurauksena, standardin määritelmästä huolimatta, laadulle ei ole yhtä yleisesti hyväksyttyä määritelmää. Erilaisten laatumääritelmien keskiössä on kuitenkin usein vaatimusten täyttäminen tai asiakastyytyväisyys. (Dale et al. 2016, s. 19–20) Laadun määritelmä riippuu myös perspektiivistä. Laatu voi esimerkiksi tarkoittaa eri asioita tuotetta suunnittelevan insinöörin ja tuotetta käyttävän asiakkaan näkökulmista. Asiakas olisi kuitenkin hyvä nähdä lopullisena arvon ja laadun määrittäjänä. (Sahay 2015, s. x) Esimerkiksi Mitra (2016, s. 8) määrittää laadun olevan tuotteen tai palvelun kyky saavuttaa tai ylit-

tää asiakkaan sille määrittämä käyttötarkoitus. Eri asiakkailla on erilaisia vaatimuksia, minkä seurauksena näkemys laadusta voi vaihdella myös asiakaskohtaisesti (Mitra 2016, s. 8).

Tärkeää on huomioida, että laatu on tulosta kovasta, harkitusta ja jatkuvasta työstä, joka alkaa suunnittelusta, sisältää laatuun vaikuttavien tekijöiden tunnistamisen ja huomioimisen, sekä soveltaa kurinalaisesti prosesseja ja työkaluja (Rose 2005, s. 6). Rose (2005, s. 23) määrittää koulutuksen olevan laadun perustana. Laatu tuotettaessa kaiken toiminnan tulisi perustua teoriaan ja tietoon. Myös johtaminen on keskeisessä asemassa laadun tuottamisessa. (Rose 2005, s. 23) Laadunhallinnan yhteydessä laatu voidaan jakaa kolmeen ulottuvuuteen: suunnitteluun, vaatimusten noudattamiseen ja suoriutumiseen (Mitra 2016, s. 10).

4.2 Laadunhallinnan toteutus

Laatuun ja laadunhallintaan panostaminen tarjoavat yrityksille erilaisia etuja. Globaaleilla ja kilpailullisilla markkinoilla asiakkaat odottavat ja vaativat jatkuvasti parempaa laatua. Laatu tarjoaa yrityksille mahdollisuuden kilpailla halpojen valmistusmaiden hintoja vastaan. Tutkimukset ovat osoittaneet, että asiakkaat ovat valmiita maksamaan enemmän hyvästä laadusta ja etenkin yritysten välisessä kaupassa laatu vaikuttaa ostopäätökseen enemmän kuin hinta. (Dale et al. 2016, s. 27; Kent 2016, s. 9) Parempi laatu ja luotettavuus tuotteissa ja palveluissa johtaa korkeampaan koettuun arvoon asiakkaan näkökulmasta, mikä voi johtaa suurempiin tuloihin ja parempaan kannattavuuteen (Sahay 2015, s. 1). Laadunhallinta voi johtaa lisääntyneiden tulojen lisäksi myös pienempiin kustannuksiin, mikä myös vaikuttaa positiivisesti yrityksen kannattavuuteen. Laatu ja siihen panostaminen johtavat siis liiketoiminta voittoihin ja parempaan kilpailukykyyn. (Rose 2005, s. 12) Huono laatu puolestaan voi johtaa asiakkaiden ja markkinaosuuden menettämiseen (Dale et al. 2016, s. 26). Kent (2016, s. 6) listaa laadunhallinnan tuomia etuja seuraavasti: paremmat tuotteet, parantunut asiakastyytyväisyys, enemmän myyntiä, kasvanut markkinaosuus, pienemmät kustannukset, parantuneet liiketoimintavoitot, vähemmän ongelmia ja parantunut työntekijöiden tyytyväisyys.

Laadunhallinnan onnistumiseen tarvitaan koko yrityksen laajuista panostusta ja laatuajattelun tulee vaikuttaa kaikkiin yrityksen toimintoihin. Esimerkiksi valmistavassa teollisuudessa laatuun liittyy paljon muutakin kuin pelkästään itse valmistettavan tuotteen laatu. Laatu muodostuu koko tuotteen elinkaaresta, johon liittyy esimerkiksi erilaiset palvelut ja kontaktit asiakkaan kanssa. (Kent 2016, s. 4, 13) Dale et al. (2016, s. 47) määrittelevät laadunhallinnan toteutuksen tärkeimmiksi elementeiksi toimitusjohtajan sitoutumisen ja johtamistaidot, organisaation ja suunnittelun, työkalut ja tekniikat, koulutuksen, sitoutumisen, tiimityön, sekä mittaamisen ja palautteen. Kent (2016, s. 7) puolestaan määrittelee laadun avaintekijöiksi organisaation, systeemit, työkalut ja kulttuurin. Tulososoittimet ovat myös tärkeä osa tehokkaan laadunhallinnan toteutusta. Mittaamisella voidaan seurata, kuinka hyvin laadunhallinnan implementointi on onnistunut.

Hyvät mittarit tarjoavat informaatiota myös alueista, joilla toimintaa voitaisiin parantaa entisestään. (Kent 2016, s. 16)

International Organization for Standardization (ISO) on standardoinut laadunhallintaa

ISO 9000 -perheeseen kuuluvilla standardeilla. ISO 9000:2015 -standardi määrittelee kriteereitä laadunhallintajärjestelmille. Standardissa laadunhallinta jaetaan seitsemään periaatteeseen: asiakaslähtöisyys, johtaminen, kaikkien osallistuminen, prosessikeskeisyys, jatkuva parantaminen, päätöksenteko ja suhteidenhallinta. (International Organization for Standardization 2015) ISO 9000 -standardit määrittelevät joukon ominaisuuksia, joiden tulisi olla osana organisaation laadunhallintaa. ISO 9000 -standardien toteutuksen onnistumisessa on tärkeää organisaation sitoutuminen ja panostaminen ohjelmaan (Dale et al. 2016, s. 190). Kent (2016, s. 3) tuo kuitenkin esille, että monissa yrityksissä standardin toteutus voi olla vain laatikkojen rastittelua, mikä ei oikeasti auta organisaation laadunhallintaa. ISO-9000 standardit eivät ole ainoa tapa toteuttaa laadunhallintaa organisaatioissa. Sertifikaatti voi kuitenkin viestiä asiakkaille yrityksen sitoutumisesta laatuun, ja jotkin asiakkaat voivat jopa vaatia sertifikaattia, jotta suostuvat tekemään yrityksen kanssa yhteistyötä. (Dale et al. 2016, s. 190)

Laadunhallintaa voidaan jaotella pienempiin osiin erilaisten alakäsitteiden avulla. Dale et al. (2016, s. 12) jakavat kirjassaan laadunhallinnan neljään osa-alueeseen: laadun kehitys, laatu liiketoiminta kontekstissa, laatusysteemit, -työkalut ja -tekniikat, sekä laadun ylläpito. Useat eri kirjallisuuslähteet nostavat johdonmukaisesti laadunvalvonnan ja laadunvarmistuksen keskeisiksi laadunhallinnan alakentiksi. Myös jatkuva parantaminen ja laadunhallinnan soveltaminen koko organisaation laajuisesti nousevat esille eri tavoin laadunhallintaa käsittelevässä kirjallisuudessa. (Dale et al. 2016; Kent 2016; Mitra 2016) Laadunhallintaa voidaan jakaa myös havaitseviin ja ennaltaehkäiseviin systeemeihin. Havaitsemisen tehtävänä on löytää vialliset lopputulokset ennen kuin ne pääsevät asiakkaalle. Ennaltaehkäisyn tavoitteena on puolestaan vähentää vikojen määrää lopputuloksessa. (Sahay 2015, s. 5)

Mitra (2016, s. 12) määrittelee laadunvalvonnan laadunhallinnan alajärjestelmäksi, joka ylläpitää haluttua laadun tasoa hyödyntämällä tuotteista tai palvelusta saatua palautetta ja suorittamalla korjaavia toimenpiteitä, jos palautteen perusteella löydetään poikkeavuuksia. Chorafas (2013, s. 24) tiivistää laadunvalvonnan olevan toimintaa, joka varmistaa, että lopputulos on määrittelyjen mukainen. Laadunvalvonta yhdistetään usein erityisesti tuotteiden valmistamiseen (Chorafas 2013, s. 24). Tuotteiden tarkastaminen voidaan nähdä laadunvalvonnan pohjana, mutta laadunvalvonta sisältää myös kehittyneempiä valvontatekniikoita, sekä reagoi saatuihin tuloksiin (Dale et al. 2016, s. 31). Laadunvalvonnassa voidaan hyödyntää esimerkiksi tilastotiedettä ja näytteidenottoa (Mitra 2016, s. 5).

Laadunvarmistuksen tehtävänä on varmistaa, että kaikkia laadunhallintaan liittyviä suunnitelmia noudatetaan (Mitra 2016, s. 13). Laadunvarmistus siis pyrkii ohjaamaan yritystä kohti jatkuvaa parantamista, joka perustuu suunnitteluun ja ongelmien ennaltaehkäisyyn (Dale et al. 2016, s. 33–34). Laadunvarmistuksen tavoitteena on ylläpitää systeemiä, joka seuraa jatkuvasti laadunhallinnan tehokkuutta yrityksessä (Mitra 2016, s. 13). Laadunvarmistus keskittyy enemmän ennaltaehkäisyyn, kun taas laadunvalvonta keskittyy enemmän havaitsemiseen. (Dale et al. 2016, s. 34)

Laadun yhteydessä nousee esille usein myös laadunhinnan käsite. Laadunhinta voi kuitenkin olla hämäävä käsite, sillä laatu tuo usein myös tuloja ja liiketoimintavoittoa yrityksille. Investoinnit laatuun voivat maksaa monissa tapauksissa itsensä takaisin jo vuoden sisällä ja tuoda tämän jälkeen lisävoittoja vielä pitkän aikaa. Yritys voi myös laskea kustannuksia pitkällä aikavälillä parantamalla prosessien ja systeemien laatua. (Kent 2016, s. 14–15) Phillip Crosbyn mukaan laadunhinta voidaan jakaa kahteen osaan: hyvän laadun tuottamisesta aiheutuviin kustannuksiin ja huonosta laadusta aiheutuviin kustannuksiin. Suuressa osassa laatuohjelmista tavoitteena on laskea huonosta laadusta aiheutuvia kustannuksia. (Sahay 2015, s. x, 4) Ennaltaehkäisevillä laatusysteemeillä voidaan laskea huonosta laadusta syntyviä kustannuksia. Ennaltaehkäisyyn panostamalla voidaankin laskea sekä havaitsemisesta että epäonnistumisista syntyviä kustannuksia. (Kent 2016, s. 14–15)

4.3 Vaihtelu ja tilastollinen näkökulma

Toistuva prosessi ei tuota ikinä tismalleen samanlaista lopputulosta. Tätä lopputulosten vaihtelua kutsutaan variaatioksi. Variaatio on erityisesti valmistusprosesseille tyypillinen luonteenpiirre. Variaatio eli vaihtelu vaikuttaa suuresti myös laatuun ja laadunhallintaan. (Rose 2005, s. 21) Esimerkkinä variaatiosta voidaan käyttää valmistuslinjaa, jossa tuotteen valmistamiseen kuluva aika on keskimäärin tasan neljä minuuttia. Variaation johdosta kaikkien tuotteiden valmistusaika ei kuitenkaan tule olemaan tasan neljää minuuttia, vaan valmistusajat tulevat vaihtelevaan neljän minuutin kummallakin puolella. (Sahay 2015, s. 12) Laadunhallinnan kannalta tärkeää on tunnistaa mahdolliset variaationaiheuttajat ja niiden vaikutukset. Laatua voidaan parantaa analysoimalla prosesseja ja suorittamalla korjaavia toimia variaation vähentämiseksi. Esimerkiksi Six Sigma on laajasti käytössä oleva laadunhallintaohjelma, joka pyrkii variaation vähentämiseen yrityksen prosesseissa. (Rose 2005, s. 21)

Tilastotiedettä hyödynnetään laadunhallinnassa laajasti. Moderni laadunvalvonta sisältää paljon erilaisia tilastotieteen menetelmiä (Mitra 2016, s. 4). Tilastollinen laadunvalvonta ja tilastollinen prosessienhallinta ovat tärkeitä laadunhallinnan osia, joiden tavoitteena on kerätä ja analysoida dataa, jonka avulla voidaan kehittää prosesseja. Koneoppimisen tavoin tilastollinen prosessienhallinta keskittyy datan ja tilastotieteen ympärille. (Asif et al. 2013) Sahay (2015, s. xi) esittelee muita vaihteluun ja tilastotieteeseen keskittyviä laatutyökaluja ja -ohjelmia, joita ovat esimerkiksi tilastollinen prosessienväl-

vonta, Six Sigma ja Total Quality Management. Myös nämä työkalut keskittyvät erityisesti vaihtelun vähentämiseen, datan hyödyntämiseen ja vaihtelun tutkimiseen tilastotieteen avulla (Sahay 2015, s. xi). Suosituimpia tilastollisen prosessin hallintatyökaluja ovat valvontakaaviot, joita kutsutaan myös Shewhartin-kaavioksi niiden kehittäjän Walter Shewhartin mukaan. Valvontakaaviot esittävät mitattuja laatuominaisuuksia graafisessa muodossa. Valvontakaaviot tarjoavat informaatiota prosessien ja tuotteiden laadusta. (Kahraman & Yanik 2016, s. 23–24)

Hyväksymisotanta on teollisuudessa paljon käytetty tilastollisen laadunvalvonnan lähestymistapa. Hyväksymisotanta on tuotetestausmenetelmä, jossa tuote-erästä valitaan satunnaisesti tietyn suuruinen otanta, jolle suoritetaan mittauksia, joiden tuloksia verrataan ennalta määriteltyihin rajoihin. Hyväksymisotannassa määritellään hyväksymisraja, joka kertoo, kuinka monta viallista tuotetta otannassa saa maksimissaan olla, jotta koko tuote-erä voidaan hyväksyä. Hyväksymisotanta on halvempi ja tehokkaampi vaihtoehto perinteiselle tarkastukselle, jossa kaikki tuotteet tarkastetaan. Hyväksymisotantaan kuuluu päätöksenteko siitä, kuinka monta tuotetta erästä valitaan testattavaan otantaan ja kuinka hyväksymisrajat asetetaan. (Kahraman & Yanik 2016, s. 179–180)

5. KONEOPPIMISEN SOVELLUKSET LAADUNHALLINASSA

Laadunhallinta tuottaa erittäin suuria datamääriä, joihin sisältyy tuotteiden ja prosessien statuksesta kertovaa dataa. Tämä data sisältää tietoa monista laatuun vaikuttavista tekijöistä ja näiden tekijöiden välisistä suhteista. Koneoppimismetodit tarjoavat keinoja tämän laatu-tietämyksen jalostamiseksi datasta. (Tsironis et al. 2005) Monet laadunhallintaan liittyvistä ongelmista ovat luonteeltaan monimutkaisia, sillä ne sisältävät monia muuttujia ja parametrejä. Lisäksi näihin ongelmiin liittyvä data on usein epämääräistä, epätarkkaa ja epätäydellistä. Koneoppiminen on yksi lupaavimmista keinoista ratkaista tämän tyyppisiä ongelmia. (Kahraman & Yanik 2016, s. vii). Tässä luvussa esitellään kirjallisuuslähteiden avulla jo kehitettyjä koneoppimissovelluksia, joilla pystytään vastaamaan joihinkin laadunhallinnan ongelmiin.

Tietokoneiden integrointi valmistuslinjoille on tarjonnut uusia mahdollisuuksia automatisoida laadunvalvontaa ja toteuttaa reaaliaikaista laadunseurantaa koneoppimisen avulla (Kahraman & Yanik 2016, s. 2). Laadunseuranta ja -tarkastaminen vaativat resursseja, minkä seurauksen paremman laadun ylläpitäminen tarkastusten avulla tarkoittaa prosessin tehokkuuden laskemista. Moderneilla teknologioilla, kuten koneoppimisella, voidaan parantaa laadun tuottamiseen liittyvää tehokkuutta. (Ko et al. 2017) Esimerkiksi konenäön ja laserskannauksen avulla voidaan tuottaa tehokkaasti prosessi- ja tuotedataa valmistuslinjoilta (Kahraman & Yanik 2016, s. 2). Koneoppimisella voidaan myös analysoida tilastollisen laadunvalvonnan tuottamaa dataa uusilla tavoilla, esimerkiksi tuottamalla uutta informaatiota valvontakaavioista. (Cheng & Cheng 2011; Salehi et al. 2012) Modernit teknologiat siis mahdollistavat nykypäivänä tehokkaan tiedon keräämisen valmistusprosesseista, joten tämä on yksi potentiaalinen osa-alue, jossa koneoppimisen hyödyntämistä voidaan tutkia.

Datan tuottamisen ja analysoinnin lisäksi koneoppimisen metodeja voidaan hyödyntää laadunhallintaan liittyvässä päätöksenteossa ja kehittämisessä (Kahraman & Yanik 2016, s. 2). Laadunhallinnassa ja laadun parantamisessa keskiössä ovat johtaminen ja päätöksenteko, jotka vaativat tuekseen informaatiota (Mitra 2016, s. 18–19). Monet laadunhallinnan työkalut pyrkivät auttamaan ja ohjaamaan laadun kehittämiseen liittyvässä päätöksenteossa. Koneoppimista voidaan hyödyntää myös tällä osa-alueella, joko päätöksiä tukevan datan keräämisessä tai itse päätöksenteossa. (Kahraman & Yanik 2016, s. 2) Koneoppimisen avulla pystytään esimerkiksi löytämään osa-alueita, joihin panostamalla yritys voi parantaa laatuaan ja näin ylläpitää jatkuvan parantamisen kulttuuria (Tsironis et al. 2005; Ko et al. 2017). Prosessien tutkiminen ja laadun kehittämiseen

liittyvä päätöksenteko vaikuttaa toiselta potentiaaliselta osa-alueelta, jossa koneoppimisen hyödyntämistä voidaan tutkia.

5.1 Laatutekijöiden tunnistus

Tässä alaluvussa pyritään esittelemään koneoppimissovelluksia, joissa keskiössä on tutkia yritysten prosesseja ja löytää kehityskohteita. Näiden sovellusten lopullisena tarkoituksena on tuottaa informaatiota laatuun liittyvän päätöksenteon tueksi.

Tuotteiden tarkastaminen suoritetaan usein asettamalla valmistuksen aikana tarkastuspisteitä, joissa tuotteen ominaisuuksia verrataan määriteltyihin rajoihin ja arvoihin. Perinteisestä laadun tarkastuksesta poiketen, myös jälkimarkkinointidatan seuraaminen on yksi tapa ylläpitää laatua. Jälkimarkkinointidata sisältää usein hyödyntämätöntä tietoa viallisten tuotteiden oireista, syistä ja korjaustoimenpiteistä. (Ko et al. 2017) Tämän vuoksi Ko et al. (2017) lähtivät suorittamaan tutkimusta, jonka tavoitteena on esitellä valmistus-, tarkastus- ja jälkimarkkinointidatan välisiä yhteyksiä koneoppimisen avulla. Eri datalähteitä yhdistelemällä pyritään löytämään yhteneväisyyksiä poikkeaville tai viallisille tuotteille. Tutkimuksessa jälkimarkkinointipalveluista saatava data yhdistetään tuotteen valmistus- ja tarkastusdataan. Koneoppimisen avulla voidaan analysoida tuotteen eri ominaisuuksia ja niiden välisiä yhteyksiä sekä löytää poikkeaviin ja viallisiin tuotteisiin vaikuttavia tekijöitä. Koneoppimisen avulla voidaan myös tutkia valmistushistorian ja asiakkaan kokeman laadun välistä suhdetta. Artikkelissa esitelty malli pyrkii vähentämään jälkimarkkinoinnin ja erityisesti korjausten aiheuttamia kustannuksia yritykselle. (Ko et al. 2017)

Ko et al. (2017) suorittamassa tutkimuksessa tavoitteena on soveltaa esiteltyä mallia epänormaalien moottorien tunnistamiseen. Epänormaaleja moottoreita ovat moottorit, joita ollaan jouduttu korjaamaan jälkimarkkinointipalveluissa moottorin takuuajana. Tutkimuksen koneoppimisalgoritmina käytetään anomaly detection -algoritmeja eli poikkeavuuksia tunnistavia algoritmeja. Moottoreita luokiteltaessa viallisia moottoreita on huomattavasti vähemmän kuin toimivia, jolloin voidaan ilmaista, että luokat ovat epätasapainossa, sillä toiseen luokkaan kuuluu huomattavasti enemmän moottoreita. Poikkeavuuksia tunnistavat algoritmit toimivat epätasapainoisten luokkien kohdalla perinteisiä luokittelualgoritmeja paremmin. Koneoppimisen muodostaman mallin avulla moottoreiden viallisuutta pystytään paremmin arvioimaan jo ennen asiakkaalle lähettämistä. Tutkimuksen tulokset osoittavat, että kyseisen mallin avulla pystytään vähentämään asiakkaalle lähetettävien viallisten moottorien määrää. Luonnollisesti algoritmit eivät pysty täydellisesti löytämään kaikkia viallisia moottoreita ja joitakin toimivia moottoreita voidaan määritellä viallisiksi. Algoritmeja säätämällä voidaan tunnistaa enemmän viallisia moottoreita, mutta seurauksena myös enemmän mahdollisesti toimivia moottoreita luokitellaan viallisiksi. Yrityksen päättäjät voivatkin siis itse miettiä,

mikä on yritykselle järkevin vaihtoehto: päästää enemmän huonompi laatuista tuotteita läpi ja vähentää valmiiden moottorien hylkäämisestä aiheutuvia kustannuksia vai minimoida huonolaatuisten moottorien määrä, mutta kasvattaa moottorien hylkäämisestä johtuvia kustannuksia. (Ko et al. 2017) Ko et al. (2017) painottavat, että myös muita laadunhallinnan metodeja tarvitaan laadunhallinnan onnistumiseen, jolloin koneoppiminen ja perinteiset laadunhallinnan työkalut täydentävät toisiaan.

Xu et al. (2018) tutkivat koneoppimisen hyödyntämistä autoteollisuuden laadunhallinnassa ja laatuongelmien ratkaisemisessa. Sekä laadunhallinta että laatuongelmien ratkaiseminen ovat kriittisiä osa-alueita autoteollisuudessa menestymiseksi. Laatuongelmien ratkaisemiseen kuuluu ongelman määrittäminen, analysointi, syyn tunnistus ja mittaaminen. Reaaliaikainen ja historiallinen data tuovat paljon arvoa ongelmanratkaisuprosessille, mutta näitä ei vielä käytetä täydellä potentiaalilla. (Xu et al. 2018)

Jotkin laadunhallinnan tietojärjestelmät ovat lisänneet hakutoimintoja historiallisen datan selaamiseen ja hyödyntämiseen. Uuden laatuongelman syntyessä järjestelmän käyttäjä voi etsiä ongelmaan liittyvää tietoa järjestelmästä hakusanojen avulla. Järjestelmien ongelmana on kuitenkin se, että ne eivät löydä tarpeellisella tarkkuudella merkityksellistä tietoa hakusanojen perusteella, mikä tekee tiedonhausta epätehokasta. (Xu et al. 2018) Xu et al. (2018) lähtevätkin artikkelissaan tutkimaan kehittyneemmän tietojärjestelmän toteutusta, joka tapahtuu kolmessa osassa. Ensiksi tietojärjestelmän osana on prosessi, joka pyrkii yhdistämään sanallisia vikaraportteja eri komponentteihin ja vikatyyppeihin. Seuraavaksi artikkelissa pyritään muodostamaan kalanruotokaavion, joka auttaa ongelmien juurisyiden löytämisessä. Kalanruotokaavio muodostetaan historiallisen datan perusteella. Kolmantena osana artikkeli pyrkii muodostamaan tietojärjestelmän, joka toimii hakukoneen sijaan enemmän kysymys ja vastaus -järjestelmänä. (Xu et al. 2018)

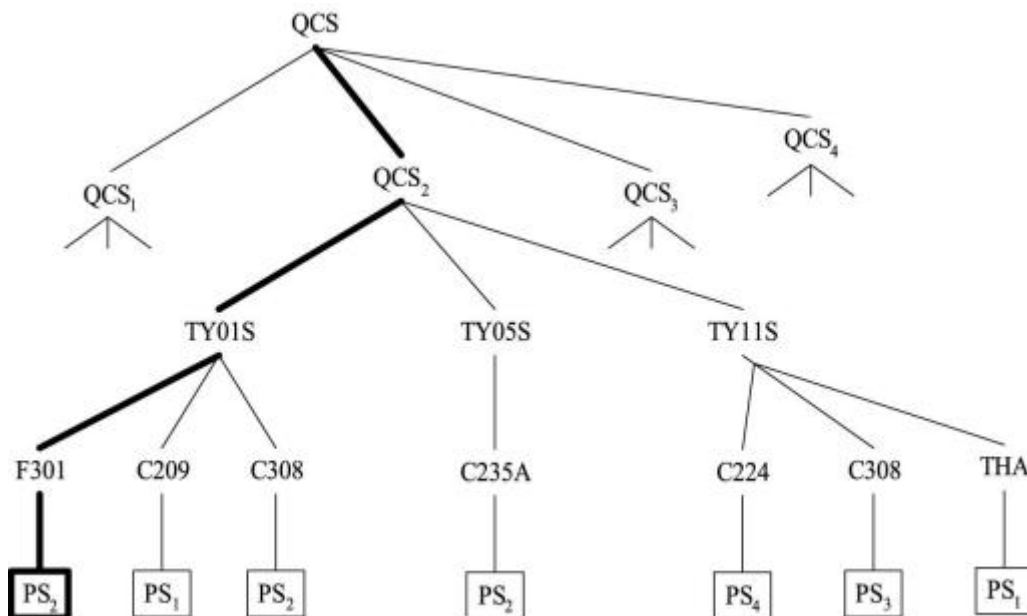
Tekstimuodossa oleva laatu data muutetaan käytännöllisempään muotoon erilaisten tekstin- ja tiedonlouhinta-algoritmien avulla. Prosessin tavoitteena on muuttaa laadunhallintaan liittyvää raakadataa paremmin jäsennellyksi tiedoksi, jolla voidaan ratkaista laatuongelmia. Kalanruotokaavion muodostamiseen käytetään Support Vector Machine (SVM) koneoppimisalgoritmia. SVM on luokittelualgoritmi, jonka tarkoitus on jaotella dataa ennalta määriteltyihin luokkiin. Kalanruotokaavion tapauksessa ongelmia pyritään jaottelemaan viiteen eri juurisyyluokkaan. Kalanruotokaavion avulla tietojärjestelmän käyttäjä voidaan ohjata oikean juurisyyn luo ongelman perusteella. (Xu et al. 2018)

Tsironis et al. (2005) kirjoittaman artikkelin tutkimuksessa perehdytään siihen, kuinka koneoppimista voidaan hyödyntää asiantuntijoiden päätöksenteossa mallintamalla tuotteiden laatutekijöiden kaavamaisuuksia, jotka esiintyvät valmistusvaiheessa. Tutkimuksessa hyödynnetään induktiivista koneoppimisalgoritmia nimeltään päätöksentekopuu (Tsironis et al. 2005). Päätöksentekopuut ovat yksiä tehokkaimmista ja käytetyimmistä koneoppimistekniikoista. Päätöksentekopuut muodostavat datasta sääntöjä, joita voidaan käyttää luokitteluun ja ennustamiseen. Säännöt muodostuvat ehtolauseista, joiden

perusteella päätellään lopputulos. Päätöksentekopuut ilmaisevat nämä säännöt yksinkertaisessa ja ihmisen ymmärrykselle luontaisessa muodossa. (Gollapudi 2016, s. 160)

Päätöksentekopuualgoritmin soveltamista kokeillaan todellisessa teollisuusympäristössä, jossa valmistetaan ISDN-modeemeja. Tutkimuksessa koneoppimisalgoritmeissa käytetään valmistuksen aikana kerättyä tuotteiden laatu- ja viallisuusdataa. Tutkimuksen kohdeprosessi on puoliautomaattinen valmistusprosessi, joka sisältää neljä laaduntarkastuspistettä, neljä valmistuspistettä, kaksi kokoamispistettä, yhden pakkauspisteen, sekä yhden korjauspisteen. Kaksi ensimmäistä tarkastuspistettä sisältävät visuaalista tarkastelua. Kolmannella tarkastuspisteellä testataan tuotteen virtalähdettä. Viimeisellä tarkastuspisteellä testataan tuotteen kestävyyttä sekä testataan lukuisia muita tuotteen ominaisuuksia. Päätöksentekopuualgoritmissa pyritään löytämään valmistuspisteiden ja viallisten tuotteiden välisiä suhteita. Koneoppimisalgoritmia käytettiin päätöksentekopuun muodostamiseen. (Tsironis et al. 2005)

Tsironis et al. (2005) suorittamassa tutkimuksessa muodostettiin päätöksentekopuu, jonka lehdet vastasivat aina yhtä neljästä valmistuspisteestä. Puun avulla voidaan selvittää vikaan vaikuttanut valmistuspiste valitsemalla jokaisessa haarautumiskohdassa vian havainnut tarkastuspiste, vikaa kuvaava vikakoodi tai valmistuslaitteen sarjanumero. Tällöin voidaan liikkua puussa lehteen asti, jolloin saadaan tietää, mikä valmistuspiste oli vastuussa kyseisestä viasta. Kuvassa 2 demonstroidaan puussa liikkumista. (Tsironis et al. 2005)



Kuva 2 Kuva esittää osaa päätöksentekopuusta. Lyhenne QCS tarkoittaa tarkastuspistettä ja PS tarkoittaa valmistuspistettä. Muut lyhenteet kuvaavat vikakoodeja ja valmistuslaitetta. (Tsironis et al. 2005)

Valmistusinsinöörit tutkivat päätöksentekopuun tuottamia sääntöjä, minkä perusteella määritettiin, että tuotetuista säännöistä 80% oli täysin luotettavia. Tutkimus osoitti, että päätöksentekopuulla voidaan löytää tehokkaasti vian aiheuttanut valmistuspiste tuotteen valmistusdatan perusteella. (Tsironis et al. 2005)

Valmistavan teollisuuden lisäksi koneoppimista on hyödynnetty myös palvelualoilla. Verkkokomenttien kerääminen on suosittu ja tehokas tapa kerätä käyttäjäpalautetta laadun parantamiseksi. Verkkokomenttien luotettava analysointi voi kuitenkin olla haastavaa. Haasteita tuovat esimerkiksi se, kuinka vähemmän luotettavia kommentteja tulisi käyttää, kuinka voidaan löytää laatuviikoja kommenttien perusteella ja kuinka löytää järkeviä parannuskohteita kommenttien perusteella. (Wei et al. 2015) Wei et al. (2015) tutkivat näiden haasteiden ratkaisemista koneoppimisen avulla. Tutkimuksessa tutkittiin koneoppimisen hyödyntämistä hotellin saamien verkkokomenttien analysoinnissa. Tutkimuksen tulokset osoittivat, että valittu lähestymistapa tarjoaa tehokkaan tavan arvioida hotellin palvelun tasoa sekä löytää järkeviä parannuskohteita verkkokomenttien perusteella. Tutkimuksen tulokset osoittivat, että valittu lähestymistapa tarjoaa tehokkaan tavan arvioida hotellin palvelun tasoa sekä löytää järkeviä parannuskohteita verkkokomenttien perusteella. (Wei et al. 2015)

5.2 Sovellukset tilastollisessa laadunvalvonnassa

Tässä alaluvussa esitellään sovelluksia, jotka linkittyvät tilastolliseen laadunvalvontaan. Valvontakaaviot ja hyväksymisotanta ovat potentiaalisia tutkimuskohteita koneoppimisen hyödyntämiselle, sillä molemmissa hyödynnetään tuotetestauksesta saatavaa dataa (Kahraman & Yanik 2016, s. 23–24, 179).

5.2.1 Valvontakaaviot

Moderneiden mittauslaitteiden ja tietokoneiden käytön myötä on nykypäivänä tyypillistä seurata tuotantolinjoilla useita toisistaan riippuvia laatupiirteitä samanaikaisesti (Cheng & Cheng 2011). Valvontakaaviot ovat käytetyimpiä tilastollisen prosessinohjauksen työkaluja, joilla pyritään tunnistamaan epänormaalia variaatiota mittaustuloksissa. Usean muuttujan valvontakaavioiden heikkous on se, että ne tunnistavat epänormaalit tapahtumat, mutta eivät pysty määrittämään tarkasti, mitkä muuttujat tai muuttujajoukot ovat aiheuttaneet epänormaalin signaalin. Ongelman ratkaisemiseksi useissa tutkimuksissa ollaan tutkittu, kuinka erilaisia kaavamaisuuksia ja muuttujien välisiä suhteita voidaan löytää valvontakaavioista. Koneoppimisen metodit ja erityiset neuroverkot ovat osoittautuneet lupaaviksi teknologiksi valvontakaavioiden analysoinnissa. (Cheng & Cheng 2011; Salehi et al. 2012)

Neuroverkkoihin perustuvat algoritmit pyrkivät matkimaan ihmisen aivojen toimintaa. Neuroverkot koostuvat neuroneista, jotka kommunikoivat keskenään. Neuroverkot koostuvat useista neuroneista, jotka saavat numeraalisia syötteitä joko toisilta neuroneil-

ta tai algoritmin alkuperäisiltä syötteiltä. Syötteiden avulla neuroni laskee uuden ulostuloarvon, joka voidaan lähettää joko muihin neuroneihin tai algoritmin lopulliseen ulostuloon. Kun dataa siirretään neuronien välillä, saa se aina jonkin painoarvon eli numeerollisen kertoimen. (Gollapudi 2016, s. 310–313) Neuroverkkojen harjoittaminen perustuu siihen, että näitä neuronien välisiä painoarvoja pyritään säätämään niin, että neuroverkon suoriutuminen sille määritellyssä tehtävässä paranee (Liu et al. 2017).

Monet tutkimukset ovat osoittaneet, että neuroverkkoihin perustuvilla teknologioilla voidaan löytää kaavamaisuuksia tehokkaammin kuin tavanomaisilla metodeilla. Neuroverkot soveltuvat hyvin käytettäväksi myös reaaliajassa. Näistä syistä johtuen neuroverkot vaikuttavat lupaavilta ja tehokkailta työkaluilta, joita voidaan käyttää datan analysointiin valmistavan teollisuuden laadunvarmistus sovelluksissa. (Salehi et al. 2012) Salehi et al. (2012) nostavat esille myös, että neuroverkot pystyvät myös toimimaan vaihtelevan laatusella datalla, mikä tekee niistä sopivan lähestymistavan valvontakaavioiden kaavamaisuuksien löytämiseen. Cheng & Cheng (2011) esittelevät puolestaan kolme syytä, miksi neuroverkot soveltuvat erityisen hyvin valvontakaavioiden tulkitsemiseen. Ensinnäkin neuroverkot pystyvät luomaan omat tulkintamallit datasta sen sijaan, että käyttäisivät perinteisiä todennäköisyysjakaumia kaavioiden prosessointiin. Toinen syy on, että neuroverkot pystyvät käsittelemään useita sekä toisistaan riippuvia että riippumattomia datapisteitä. Kolmanneksi neuroverkot pystyvät luomaan hyvin tarkkoja malleja, kun dataa on riittävä määrä. (Cheng & Cheng 2011)

Salehi et al. (2012) ovat tutkineet kaksivaiheisen koneoppimismallin soveltamista valvontakaavioiden tulkitsemiseen. Mallin ensimmäisessä osassa käytetään SVM algoritmia luokittelemaan kaavioiden kuvioita normaaleihin ja epänormaaleihin kuvioihin. Mallin toisessa osassa käytetään neuroverkkoja, joiden avulla voidaan huomata keskiarvon ja varianssin muutoksia sekä selvittämään muutosten suuruus jokaiselle laatumuuttujalle. (Salehi et al. 2012) Cheng & Cheng (2011) puolestaan esittelevät neuroverkon käyttöön perustuvan seurantamallin, jolla pyritään huomaamaan varianssin muutoksia kahden muuttujan valvontakaavioissa. Lähestymistavassa neuroverkkoalgoritmilta annetaan syötteeksi tietty määrä peräkkäisten mittauspisteiden tuloksia ja neuroverkko pyrkii määrittämään, tapahtuuko tällä välillä muutoksia varianssissa. (Cheng & Cheng 2011)

5.2.2 Hyväksymisotanta

Toinen yleinen tilastolliseen laadunvalvontaan liittyvä tutkimuskenttä on ollut hyväksymisotantaa otoksien optimaalisen koon määrittäminen. Sundaram ja Deepa (2012) tutkivat geneettisen koneoppimisalgoritmin hyödyntämistä tuplaotantasuunnitelman optimaalisen otantakoon ja hyväksymisrajan määrittämisessä. Geneettiset algoritmit pyrkivät löytämään optimaalisimpia kombinaatioita ja perustuvat evoluutioteorian näkemykseen luonnonvalinnasta ja geeneistä. Geneettisissä algoritmeissa sopivimpia löydettyjä ratkaisuja muokataan yhdistelyn ja mutaatioiden avulla uusiksi ratkaisuksi ja uusista rat-

kaisuista valitaan iteratiivisesti jälleen sopivimmat yksilöt jatkojalostukseen. (Sundaram & Deepa 2012)

Perinteisesti hyväksymisotanta on perustunut siihen, että tuotantoerästä valitaan kerran satunnainen otanta testattavaksi, minkä perusteella päätetään hyväksytäänkö vai hylätäänkö kyseinen erä. Tupla- ja moniotantasuunnitelmat ovat suunniteltu antamaan kyseenalaisille erille lisämahdollisuus. Jos ensimmäinen otos tuottaa rajamailla olevan tuloksen, voidaan tuplaotannassa ottaa uusi otos erästä, jolla hyväksymisotanta suoritetaan. (Sundaram & Deepa 2012) Sundaramin ja Deepan (2012) tutkimuksessa geneettiset algoritmit onnistuivat hyvin määrittelemään optimaalisia kokoja otannalle ja rajoja erän hyväksymiselle.

6. YHTEENVETO

6.1 Johtopäätökset

Laadunhallintaa on harjoitettu yrityksissä jo pidemmän aikaa 1900-luvun alkupuolelta lähtien. Laadunhallinta on kehittynyt vuosien saatossa, minkä seurauksena ollaan kehitetty paljon uusia metodeja ja työkaluja laadunhallinnan eri osa-alueille. Nykypäivänä monissa yrityksissä laadunhallinta perustuu edelleen perinteiseen tilastolliseen laadun-tarkkailuun, joka keskittyy tarkastusten ja testauksen ympärille. Tilastollisen laadun-tarkkailun työkaluja ovat esimerkiksi hyväksymisotanta ja valvontakaaviot. Perinteisempien työkalujen lisäksi viime vuosina on kehittynyt myös uusia laadunhallinnan lähestymistapoja, kuten Six Sigma ja Total quality management. Tässä kirjallisuustutkimuksessa tutkittiin koneoppimisen ja älykkäiden metodien hyödyntämistä laadunhallinnassa, mikä voi olla yksi mahdollinen tulevaisuuden kehityssuunta laadunhallinnan kentässä. Kirjallisuustutkimuksen tulosten perusteella voidaan todeta, että koneoppimisen sovelluksia hyödynnetään jo nyt yritysten laadunhallinnassa ja koneoppimisen käytöllä on paljon potentiaalia laadunhallinnan sovelluksissa.

Laadunhallinnassa keskeisiä osa-alueita ovat esimerkiksi jatkuva kehittäminen, laadunvalvonta, laadunvarmistus ja kokonaisvaltaisuus. Erityisesti jatkuvan kehittämisen sekä laadunvalvonnan osa-alueilla on ongelmia, joita voidaan ratkaista koneoppimisen avulla. Jatkuvaan kehittämiseen tarvitaan päätöksentekoa tukevaa tietoa potentiaalisista kehityskohteista. Koneoppimisen avulla voidaan tuottaa tämänlaista dataa esimerkiksi tutkimalla yrityksen prosesseja tai yrityksen saamaa palautetta. Laadunvalvonnassa puolestaan koneoppimista voidaan hyödyntää tuottamalla lisä tietämystä laadunvalvonnan tuottamasta datasta.

Kirjallisuuden perusteella suuri osa koneoppimisen sovelluskohteista keskittyvät nykyisin tuotteiden testausdatan hyödyntämiseen. Nämä sovelluskohteet voidaan jakaa karkeasti kahteen ryhmään. Ensimmäiseen ryhmään kuuluvat reaaliaikaiseen valmistuksen seurantaan perustuvat sovellukset. Näissä sovelluksissa pyritään huomaamaan prosesseissa tai tuotteissa tapahtuvaa laadun vaihtelua. Tämän lähestymistavan avulla voidaan esimerkiksi suorittaa välittömiä korjaustoimenpiteitä tai estää huonolaatuisten tuotteiden pääsyä asiakkaille asti. Toiseen ryhmään kuuluvien sovellusten painotus on puolestaan juurisyiden löytämisessä. Näissä sovelluksissa pyritään tutkimaan laatua laajemmin ja pidemmällä aikavälillä. Tällä tavoin pystytään löytämään tärkeimpiä laatuun vaikuttavia tekijöitä. Tähän ryhmään kuuluvilla sovelluksilla voidaan tukea laatuun liittyvää päätöksentekoa ja edesauttaa jatkuvaa laadun kehittämistä.

Kirjallisuustutkimuksessa löydettiin sekä päätöksentekoa että havainnointia tukevia koneoppimismetodeja. Löydetyt ratkaisut painoutuivat paljon valmistavaan teollisuuteen, minkä seurauksena esimerkiksi palvelualoihin liittyvät sovellukset jäivät pienemmälle huomiolle. Valmistavan teollisuuden kehyksestä johtuen suuri osa koneoppimissovelluksista painoutuivat valmistuslinjojen ja tuotetestauksen tuottamaan dataan, jolloin jälleen esimerkiksi asiakas- tai liiketoimintadataan perustuvat sovellukset jäivät pienemmälle huomiolle.

6.2 Jatkotutkimusmahdollisuudet ja tutkimuksen arviointi

Kuten todettua, tässä työssä esitellyt ratkaisut painoutuivat paljon valmistavan teollisuuden alalle, joten syvällisempää jatkotutkimusta voitaisiin tehdä siitä, millä eri tavoin koneoppimista voitaisiin hyödyntää esimerkiksi palvelualalla tai tietotyöhön painottuvalla alalla. Toinen jatkotutkimuksen kohde voisi olla tutkia lisää, kuinka liiketoiminta- ja asiakasdataa voitaisiin hyödyntää koneoppimisen avulla enemmän laadunhallinnassa. Kolmas mahdollinen jatkotutkimussuunta voisi olla tutkia, kuinka koneoppimista voidaan hyödyntää uusien laadunhallintaprosessien ja tuotteiden kehityksessä, sillä nykyiset löydökset käsittelevät pääasiassa olemassa olevien prosessien ja tuotteiden kehittämistä.

Tutkimuksessa pystyttiin vastaamaan päätutkimuskysymykseen nostamalla esille esimerkkejä erilaisista koneoppimisen tarjoamista mahdollisuuksista laadunhallinnalle. Esitellyt sovellukset toivat suhteellisen onnistuneesti esille erilaisia sovelluskohteita, vaikka kuten todettua monet sovellukset keskittyivät valmistavaan teollisuuteen. Eri työn osissa on myös pyritty vastaamaan alatutkimuskysymyksiin. Työssä pyrittiin hyödyntämään erityisesti koneoppimisen osalta mahdollisimman tuoreita lähteitä. Myös tässä onnistuttiin tyydyttävästi ja suurin osa lähteistä on 2010-luvulta. Sovelluksia käsittelevä kirjallisuus ei vaikuttanut olevan vielä kovinkaan laajaa ja monet sovellukset voivat olla myös yrityssalaisuuksia. Uskoisin kuitenkin, että työn antama kuva koneoppimisen hyödyntämisestä laadunhallinnan prosesseissa on vähintäänkin suuntaa antava.

LÄHTEET

- Asif, M., de Vries, H. J. & Ahmad, N. (2013). Knowledge creation through quality management, *Total Quality Management & Business Excellence*, Vol. 24(5/6), pp. 664–677.
- Cheng, C.-S. & Cheng, H.-P. (2011). Using neural networks to detect the bivariate process variance shifts pattern, *Computers & Industrial Engineering*, Vol. 60(2), pp. 269–278.
- Chorafas, D. N. (2013). *Quality control applications*, London; New York: Springer Verlag.
- Dale, B. G., Bamford, D. & van der Wiele, T. (2016). *Managing Quality: An Essential Guide and Resource Gateway*, Chicester, UNITED KINGDOM: John Wiley & Sons, Incorporated.
- Gollapudi, S. (2016). *Practical Machine Learning*, Birmingham, UNITED KINGDOM: Packt Publishing Ltd.
- International Organization for Standardization (2015). ISO 9001 Quality management. Saatavissa (viitattu 23.1.2019): <https://www.iso.org/files/live/sites/isoorg/files/archive/pdf/en/pub100080.pdf>
- Jordan, M. I. & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects, *Science*, Vol. 349(6245), pp. 255–260.
- Kahraman, C. & Yanik, S. (Eds.) (2016). *Intelligent decision making in quality management: theory and applications*, Cham: Springer.
- Kent, R. (2016). *Quality Management in Plastics Processing - Strategies, Targets, Techniques and Tools*, Elsevier.
- Kim, D.-Y., Kumar, V. & Kumar, U. (2012). Relationship between quality management practices and innovation, *Journal of Operations Management*, Vol. 30(4), pp. 295–315.
- Ko, T., Lee, J. H., Cho, H., Cho, S., Lee, W. & Lee, M. (2017). Machine learning-based anomaly detection via integration of manufacturing, inspection and after-sales service data, *Industrial Management & Data Systems; Wembley*, Vol. 117(5), pp. 927–945.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y. & Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications, *Neurocomputing*, Vol. 234, pp. 11–26.
- Louridas, P. & Ebert, C. (2016). Machine Learning, *IEEE Software*, Vol. 33(5), pp. 110–115.
- Mitra, A. (2016). *Fundamentals of Quality Control and Improvement*, New York, UNITED STATES: John Wiley & Sons, Incorporated.

- Mueller, J. P. & Massaron, L. (2016). *Machine Learning for Dummies*, Hoboken, UNITED STATES: John Wiley & Sons, Incorporated.
- Nair, A. (2006). Meta-analysis of the relationship between quality management practices and firm performance—implications for quality management theory development, *Journal of Operations Management*, Vol. 24(6), pp. 948–975.
- Rahman, S.-U. (2004). The Future of TQM is Past. Can TQM be Resurrected?, *Total Quality Management & Business Excellence*, Vol. 15(4), pp. 411–422.
- Rose, K. H. (2005). *Project Quality Management: Why, What and How*, Boca Raton, UNITED STATES: J. Ross Publishing, Incorporated.
- Sahay, A. (2015). *Managing and Improving Quality: Integrating Quality, Statistical Methods and Process Control*, New York, UNITED STATES: Business Expert Press.
- Salehi, M., Kazemzadeh, R. B. & Salmasnia, A. (2012). On line detection of mean and variance shift using neural networks and support vector machine in multivariate processes, *Applied Soft Computing*, Vol. 12(9), pp. 2973–2984.
- Sundaram, S. & Deepa, S. P. (2012). Determination of Optimal Double Sampling Plan using Genetic Algorithm, *Pakistan Journal of Statistics and Operation Research*, Vol. 8(2), pp. 195–203.
- Thomas, S. (2014). *Basic Statistics*, New Delhi, INDIA: Alpha Science International.
- Tsironis, L., Bilalis, N. & Moustakis, V. (2005). Using machine learning to support quality management: Framework and experimental investigation, *The TQM Magazine*, Vol. 17(3), pp. 237–248.
- Wei, X., Luo, X., Li, Q., Zhang, J. & Xu, Z. (2015). Online Comment-Based Hotel Quality Automatic Assessment Using Improved Fuzzy Comprehensive Evaluation and Fuzzy Cognitive Map, *IEEE Transactions on Fuzzy Systems*, Vol. 23(1), pp. 72–84.
- Xu, Z., Dang, Y. & Munro, P. (2018). Knowledge-driven intelligent quality problem-solving system in the automotive industry, *Advanced Engineering Informatics*, Vol. 38, pp. 441–457.