

Konsta Peiponen

**TEKOÄLY VALMISTAVAN
TEOLLISUUDEN
KONENÄKÖSOVELLUKSISSA**

Kandidaatintyö
Tekniikan ja luonnontieteiden tiedekunta
Tarkastaja: Yliopistotutkija Eeva Järvenpää
Joulukuu 2020

TIIVISTELMÄ

Konsta Peiponen: Tekoäly valmistavan teollisuuden konenäkösovelluksissa
Kandidaatintyö
Tampereen yliopisto
Konetekniikan tutkinto-ohjelma
Joulukuu 2020

Valmistavan teollisuuden tuotantojärjestelmät ovat muuttumassa digitalisaation tuomien uusien menetelmien ansiosta. Tätä muutosta teollisuudessa kutsutaan teollisuus 4.0:ksi. Teollisuus 4.0 ideologia keskittyy tuotannon täyteen automatisoimiseen älykkään teknologian ja älykkäiden järjestelmien avulla. Osittain tätä tuotannon automatisoimista on edistämässä konenäkö ja sen sovellukset tuotannon eri tehtävissä. Konenäköjärjestelmiä on hyödynnetty teollisuudessa jo pitkään, mutta tekoälyn avulla järjestelmiin saadaan lisää ulottuvuuksia ja pystytään suorittamaan yhä monimutkaisempia tehtäviä.

Tutkielmassa tutkitaan kirjallisuuskatsauksen muodossa konenäköä ja tekoälyä erillisinä käsitteinä, sekä yhtenä kokonaisuutena. Tutkielman päätavoitteena on tuoda esille, miten erilaisia tekoälyä sisältäviä konenäkösovelluksia on hyödynnetty ja mitä hyötyä tekoälyn avulla kyseisissä sovelluksissa on saavutettu.

Tekoälyn ja konenäön tarkastelu erillisinä käsitteinä on hyvin kriittinen osa tutkielmaa. Ymmärtämällä mitä tekoäly on ja mitä konenäkö on, on mahdollista ymmärtää myös niistä muodostettuja kokonaisuuksia. Nämä kokonaisuudet, eli konenäköjärjestelmät, joissa on hyödynnetty tekoälyä, ovat koko työn keskeisin asia. Tekoälyä hyödyntämällä konenäköjärjestelmistä tulee näennäisesti älykkäitä ja niiden avulla on mahdollista suorittaa tehtäviä, joiden suorittamiseen on aiemmin tarvittu ihminen. Tutkielmassa tuodaan esille konkreettisten esimerkkien kautta, kuinka tekoälyn avulla päästään tarkempiin tuloksiin tuotannon erilaisissa tehtävissä.

Avainsanat: Tekoäly, konenäkö, valmistava teollisuus.

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

SISÄLLYSLUETTELO

1. JOHDANTO	1
1.1 Tutkimuksen tavoite ja tutkimusongelma.....	1
1.2 Tutkimusmenetelmä ja työn rakenne.....	2
2. TEKOÄLY	4
2.1 Tekoälyn historia.....	4
2.2 Tekoälyn määritelmä.....	6
2.3 Tekoälyteknologia	7
2.3.1 Koneoppiminen.....	7
2.3.2 Neuroverkot ja syväoppiminen	9
3. KONENÄKÖ	12
3.1 Konenäköjärjestelmä.....	12
3.2 Konenäön hyödyntämät ohjelmat ja algoritmit.....	14
4. TEKOÄLYÄ SISÄLTÄVIÄ KONENÄKÖSOVELLUKSIA	16
4.1 Kappaleen asennon, orientaation sekä materiaalin tunnistus	16
4.2 Laaduntarkkailu & kappaleen analysointi	19
4.3 Laitetason ohjausjärjestelmät	20
5. YHTEENVETO & JOHTOPÄÄTÖKSET	22
LÄHTEET	24

KUVALUETTELO

<i>Kuva 1. Tutkimuskysymyksen havainnollistus</i>	2
<i>Kuva 2. Tekoälyn historia, muokattu alaluvun 2.1 lähteistä</i>	6
<i>Kuva 3. Koneoppimisen osa-alueet, muokattu lähteistä (Ailisto et al. 2018, s. 15; Lehto et al. 2018, s. 14)</i>	8
<i>Kuva 4. Neuroverkon rakenne, muokattu lähteestä (Lehto et al. 2018, s. 21)</i>	10
<i>Kuva 5. Esimerkki neuronista, muokattu lähteestä (Ertel 2011, s. 224)</i>	10
<i>Kuva 6. Konenäköjärjestelmän tyypillinen rakenne (Steger et al. 2018, s.1)</i>	13
<i>Kuva 7. Konenäköalgoritmien tehtävät kuvankäsittelyprosessin eri vaiheissa, muokattu lähteestä (Liu et al. 2015, s. 15, Taipale 2020 mukaan, s. 30)</i>	15
<i>Kuva 8. Esimerkkejä kappaleen tunnistamiseen liittyvistä tehtävistä, muokattu lähteestä (Golnabi & Asadpour 2007)</i>	17
<i>Kuva 9. Konenäköjärjestelmä (Penumuru et al. 2020)</i>	18
<i>Kuva 10. Esimerkkejä laaduntarkkailun ja kappaleen analysoinnin kohteista, muokattu lähteestä (Golnabi & Asadpour 2007)</i>	19
<i>Kuva 11. Robotin työtehtäviä valmistuksessa, muokattu lähteestä (Golnabi & Asadpour 2007)</i>	21

1. JOHDANTO

Valmistava teollisuus on jatkuvasti muuttumassa digitalisaation ja teknologian kehityksessä, jolloin puhutaankin teollisuuden neljännessä vallankumouksesta. Teollisuus 4.0 ideologia keskittyy valmistavan teollisen prosessin täydelliseen digitalisoimiseen (Geissbauer et al. 2016). Tämän teollisuuden läpikäymän murroksen vuoksi tekoäly (Artificial Intelligence) onkin hyvin merkittävässä roolissa teollisuuden prosesseissa tulevaisuudessa. Tekoälyn sovelluksien kehittyessä sitä todennäköisesti tullaan hyödyntämään monipuolisesti erilaisissa tehtävissä. Kehityksen myötä teollisuuden prosesseissa työnkuvat sekä tarvittava työvoima tulee muuttumaan, jolloin myös vaikutus yhteiskuntaan on väistämätön. Aiheen ajankohtaisuus tekee tutkielmasta merkittävän.

1.1 Tutkimuksen tavoite ja tutkimusongelma

Tässä kandidaatintutkielmassa tarkastellaan tekoälyä valmistavan teollisuuden konenäkösovelluksissa. Tekoäly ei ole tarkasti määritelty termi, ja hyvin usein se ymmärretään väärin. Tekoäly on kokoelma eri teknologioita ja sovelluksia, joiden tavoitteena on kyetä oppimaan ja tekemään päätöksiä ihmismielen kaltaisesti. Tekoälyn ymmärtämisen helpottamiseksi muun muassa artikkeleissa puhutaan usein yhdestä tietystä tekoälystä, vaikka aina kyseessä on jokin sovellus johonkin tiettyyn ongelmaan. Kone tai laite voi käyttäytyä kuten älykäs ihminen, mutta vielä ei ole kehitetty älyä, joka kykenisi täysin itsenäiseen ja oppivaiseen suoriutumiseen samalla tavalla kuten ihmisen aivot. Hyvin lähelle on kuitenkin päästy. Homo sapiens – viisas ihminen on syy sille, miksi aikojen alusta lähtien älykkyydellä on viitattu ihmiseen. Tämän vuoksi myös tekoälyn älykkyyttä määrittäessä testit ovat sisältäneet seuraavat neljä eri kategoriaa: ihmismäinen ajattelu, ihmismäinen käytös, järkevä ajattelu sekä järkevä käytös. (Russel & Norvig 2016, s.1–5)

Tekoäly on siis hyvin laaja yläkäsite ja se sisältää paljon alakäsitteitä sekä kategorioita. Tutkimuksen tavoitteena on tuoda esille mitä tekoäly on, ja miten se jakautuu erilaisiin osa-alueisiin, ja kuinka sitä hyödynnetään valmistavan teollisuuden prosesseissa. Tutkielman sovellusosio on rajattu tekoälyä sisältäviin konenäkösovelluksiin teollisuuden sovellusten laajuuden vuoksi.

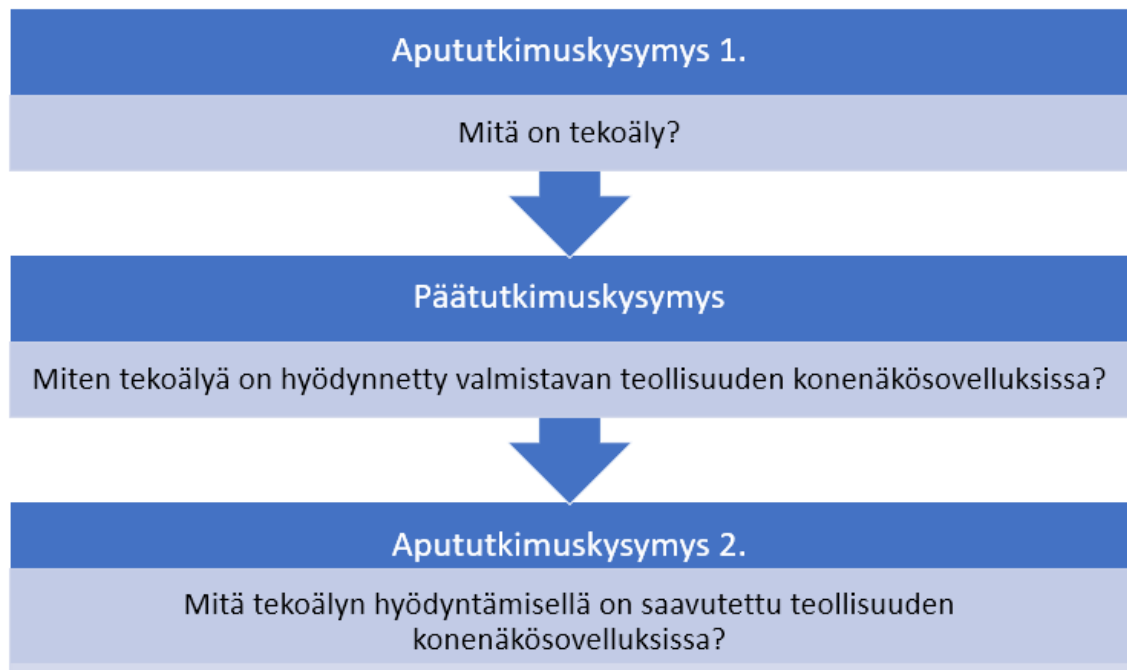
Konenäköjärjestelmät yleisesti ottaen ovat prosessointijärjestelmiä, jotka havainnoivat kuva- tai videomateriaalia ja tuottavat haluttua tietoa materiaalista. Tämä tieto voi olla esimerkiksi kappaleiden lukumäärä liukuhihnalla tai pintavikojen löytäminen tuotteesta.

Päätutkimuskysymys: Miten tekoälyä on hyödynnetty valmistavan teollisuuden konenäkösovelluksissa?

Apututkimuskysymys 1: Mitä on tekoäly?

Apututkimuskysymys 2: Mitä tekoälyn hyödyntämisellä on saavutettu teollisuuden konenäkösovelluksissa?

Kuvassa 1 havainnollistetaan päätutkimuskysymyksen ja apututkimuskysymysten relaatiota.



Kuva 1. Tutkimuskysymyksen havainnollistus

Apututkimuskysymys 1. on sijoitettu kuvassa päätutkimuskysymyksen yläpuolelle, koska ilman tekoälyn määrittelyä ei voida vastata päätutkimuskysymykseen. Apututkimuskysymyksen 2. avulla pyritään tuomaan esille tekoälyn tuomat hyödyt.

1.2 Tutkimusmenetelmä ja työn rakenne

Tutkimus toteutettiin kirjallisuuskatsauksena, jossa tutkittiin ammattilaisten teoksia ja julkaisuja aiheesta. Aineiston haku toteutettiin käyttämällä Tampereen yliopiston kirjaston hakupalveluita Andoria, Finnaa ja Scopusta, joiden apuna käytettiin myös Google Scholaria. Näiden palveluiden avulla oli helppo löytää materiaalia erilaisista lähteistä, joten

tutkimuksen aineistosta muodostui käytännössä automaattisesti monipuolinen kokonaisuus. Materiaalia etsiessä käytettiin esimerkiksi hakusanoja ”AI – Artificial intelligence”, ”Machine intelligence”, ”Computer vision”, ”Machine vision” sekä ”Manufacturing industry”, sillä aiheesta löytyi hyvin vähän tieteellisiä julkaisuja suomen kielellä. Tekoäly ja valmistava teollisuus ovat yksittäisinä käsitteinä hyvin laajoja aiheita, joten tutkimuksen rajaaminen oli välttämätöntä. Hakua rajattiin esimerkiksi yhdistelemällä termejä. Lisäksi tekoälyn jatkuvan kehityksen vuoksi, materiaalia etsiessä kiinnitettiin huomiota myös julkaisuajankohtaan. Kaikki ajantasainen tieto on kerätty alle 10 vuoden ikäisistä julkaisuista. Tekoälyn historiaa varten mukaan täytyi ottaa myös muutama vanhempi julkaisu.

Tutkimuksen rakenne sisältää johdannon lisäksi 4 lukua. Johdannon jälkeen luvut 2 ja 3 ovat kirjallisuuskatsausta. Tekoälyn teoreettista taustaa käsitellään luvussa 2. Luku 3 käsittelee tekoälyn hyödyntämisen mahdollisuuksia valmistavan teollisuuden konenäkösovelluksissa. Luvussa 4 on tarkoitus määritellä tekoälyn ja valmistavan teollisuuden konenäkösovellusten välinen yhteys sekä tuoda esille päätutkimuskysymykseen vastaus. Luvussa 5 esitellään tutkimuksen yhteenveto sekä johtopäätökset.

2. TEKOÄLY

Mitä on tekoäly tai milloin voidaan ajatella koneen olevan älykäs? Tekoäly ei suinkaan ole täysin uusi asia tässä maailmassa, vaan sen historia ulottuu jopa 1930-luvulle saakka. Jotta voidaan ymmärtää, mistä tekoälyssä on kyse, täytyy tarkastella ensin sen historiaa. Tässä luvussa määritellään, mitä tekoälyllä tarkoitetaan tässä tutkielmassa, ja lisäksi käsitellään eri tekoälyteknologioita.

2.1 Tekoälyn historia

On hyvin vaikea määritellä, milloin tekoälyn kehitys on alkanut, mutta yleisesti voidaan sanoa koneiden älykkyyden kehittämisen alkaneen 1930-luvulla, kun Alan Turing toi esille älykkäiden koneiden rajoitteita esittelemällä pysähtymisongelman. Turingin esittelemän pysähtymisongelman mukaan ei ole olemassa algoritmia, joka kykenisi pysäyttämään minkä tahansa ohjelman. Tämä ajatus loi pohjaa algoritmiajattelulle ja käynnisti tieteellisen murroksen koneiden älykkyyden kehittämisessä. 1940-luvulla McCullough ja Pitts onnistuivat mallintamaan neuroverkon ja löysivät yhteyden lauselogiikkaan. (Ertel 2011, s. 221)

McCulloughin ja Pittsin neuroverkkojen mallinnus loi pohjan neuroverkkotieteelle. Seuraava merkittävä edistysaskel koneen älykkyyden historiassa tuli 1950-luvulla, kun Alan Turing julkaisi teoksen *Computing Machinery and Intelligence*. Teoksessa tulee esille historian ensimmäinen älykkään koneen määritelmä. Huomioitavaa on, että tässä vaiheessa ei lainkaan puhuttu vielä koneen älykkyydestä termillä tekoäly. Turing piti lähtökohtana kysymystä ”Voiko kone ajatella?”. Turing muodosti testin, jonka tarkoituksena oli määritellä koneen älykkyys. Testiä kutsutaan Turingin testiksi. Testissä haastattelija haastattelee ihmistä ja konetta. Haastattelija ei näe haastateltavia, ja vastaukset annetaan muodossa kyllä tai ei kirjoitettuna. Haastattelun jälkeen, mikäli haastateltava ei osaa sanoa kumpi on kone, voidaan sanoa koneen olevan älykäs. (Turing 1950)

Kaikki tämä oli ainoastaan pohjaa tulevalle, ja vuonna 1956 John McCarthyn ja Marvin Minskyn pitämässä konferenssissa Dartmouthin yliopistossa esiteltiin termi tekoäly ensimmäistä kertaa (Ertel 2011, s. 6; Haenlein & Kaplan 2019). Tätä kahdeksanviikkoista konferenssia pidetään tekoälytutkimuksen lähtökohtana. Konferenssin aikana luotiin pohja hyvin usealle tekoälymallille. Seuraavien vuosikymmenten aikana koettiin onnistumisia tekoälyn osa-alueella. Esimerkiksi vuonna 1966 Joseph Wiezenbaum esitteli kielentunnistusohjelman ELIZAn. ELIZA kykeni muodostamaan keskustelua ihmisen

kanssa, ja lisäksi se oli ensimmäinen sovellus, joka kykeni yrittämään Turingin testiä. Tekoälylle ennustettiin suurta kehitystä. Vuonna 1970 Minsky väitti Life Magazine -lehden haastattelussa, että seuraavan 3–8 vuoden sisällä kehitetään kone, joka on yhtä älykäs kuin ihminen. (Haenlein & Kaplan 2019)

Näin ei kuitenkaan ollut, ja tekoälyn kehitys pysähtyi siihen, mistä se alkoikin. Äärimmäiset odotukset ja tutkijoiden optimismi ajoivat tekoälyn kehittäjät vaikeuksiin, kun he eivät pystyneetkään vastaamaan odotuksiin. Tekoälyn kehittämisen rahoituksia vähennettiin, ja alkoi niin sanottu tekoälyn talvi. (Haenlein & Kaplan 2019) Osittain tämä johtui siitä, että koneista yritettiin tehdä nimenomaan ihmisen kaltaisia. McCarthy oli yksi ainoista, joka ajatteli, ettei ihmismielen toiminta ole niin relevanttia tekoälyn kannalta. Syntyi kaksi eri koulukuntaa, joista perinteisempi ajattelutapa oli, että tekoälyn täytyi toimia kuten ihmismieli. Toinen koulukunta edusti vähemmistöä ja ajatteli päinvastoin. (Warwick 2012, s. 1–8)

Pikkuhiljaa 1980-luvun aikana McCarthyn ajattelutapa levisi ja uuden ajattelutavan mukana syntyi tilaa uudelle kehitykselle (Warwick 2012, s. 6–8). Vuonna 1986 tutkijat Sejnowski ja Rosenberg loivat neuroverkkojen avulla *NETtalk*-ohjelman, joka osasi puhua (Ertel 2011, s. 249).

1990-luvulla tekoäly kehittyi nopeasti, ja sitä olikin odotettu jo pitkään. Tällä vuosikymmenellä tekoälyä implementoitiin lukuisiin markkinoille suunnattuihin tuotteisiin ja palveluihin. Tällä vuosikymmenellä myös tietokone voitti ensimmäisen kerran ihmisen shakissa (Ailisto et al. 2018, s. 41). Lotfi Zadeh (1994) toi esille aiempaan tutkimukseen lisäten geneettisen ohjelmoinnin. Lisäksi 1999 Sony toi markkinoille ”AIBO”-robottikoiran, joka oli niin sanotusti ensimmäinen tekoälyä sisältävä lemmikki (Falcioni 1999). Tätä edellä käytyä tekoälyn historiaa havainnollistetaan kuvassa 2.

- **1930:** Turing - Pysähtymisongelma
- **1940:** McCullough & Pitts - Neuroverkot & yhteys lauselogiikkaan
- **1950:** Turing - Turingin testi, McCarthy & Minsk - Tekoäly termi
- **1960:** Wiezenbaum - ELIZA kielentunnistusohjelma
- **1970:** Tekoälyn talvi
- **1980:** McCarthyn ajattelutapa yleistyi, Sejnowski & Rosenberg - Neuroverkkoja hyödyntävä NETtalk
- **1990:** Zadeh - Geneettinen ohjelmointi, Sony – AIBO, Tietokone voitti ihmisen shakissa
- **2000 -> :** Palvelurobotit, autonomiset autot, tietokone voittaa ihmisen useissa eri peleissä, neuroverkkojen kehitys ja syväoppiminen ja lukuisat muut saavutukset

Kuva 2. Tekoälyn historia, muokattu alaluvun 2.1 lähteistä

Tekoälyn kasvu ja kehitys 2000-luvulta eteenpäin oli niin voimakasta, ettei tässä yhteydessä pystytä tarkastelemaan läheskään kaikkia merkityksellisiä saavutuksia tekoälyyn liittyen. Havainnollistamisen vuoksi tuodaan kuitenkin muutama esimerkki esille, jolloin tekoälyn kehityksessä on tapahtunut merkittäviä saavutuksia. 1999-luvun lopulta alkanut robotiikan kehityskausi jatkui 2000-luvulla, ja muun muassa palveluroboteista syntyi täysin uusi kehittyvä tekoälyn alalaji. Lisäksi autonomiset robotit yleistyivät lukuisilla eri aloilla hyvin useissa erilaisissa tehtävissä. (Ertel 2011, s. 11) Vuonna 2011 koettiin uusi merkittävä läpimurto, kun IBM:n kielentunnistamiseen ja muodostamiseen kehitetty ohjelma *Watson* voitti visailuohjelman *Jeopardyn* (Ailisto et al. 2018, s. 41; Ertel 2011, s. 11). Kaikki nämä ja lukuisat muutkin tekoälysaavutukset sijoittuvat viimeisten kahden vuosikymmenen ajalle.

2.2 Tekoälyn määritelmä

Tekoälylle ei ole olemassa yhtä tiettyä, tai oikeaa määritelmää, ja usein määritelmään vaikuttaa se, missä yhteydessä tekoälystä puhutaan. Ensimmäisen kerran tekoäly sai määritelmän vuonna 1955, kun McCarthy määritteli tekoälyn seuraavasti: tekoälyn tavoite on kehittää koneita, jotka käyttäytyvät kuten ne olisivat älykkäitä (Ertel 2011, s. 1). Kyseisen määritelmän ongelmana on kuitenkin tuolloin voimassa ollut ajatusmalli, jonka mukaan tekoälyllä pyritään ihmismäisyyteen. Tekoälyn tarkoitus on suorittaa tehtävä tehokkaasti, ja Elaine Rich määritteli tekoälyn tieteenalana, joka keskittyy selvittämään, miten koneet voivat tehdä tehtävän paremmin kuin ihmiset sillä hetkellä tekevät kyseisen tehtävän. (Ertel 2011, s. 2)

Britannica encyclopedia -tietosanakirjan määritelmän mukaan tekoäly on tietokoneen kyky suorittaa tehtäviä älykkäiden ihmisten kanssa. Tämä tarkoittaa sitä, että tietokone kykenee järjelemään asioita, päättämään sekä ymmärtämään asioiden tarkoituksia kuten ihmisetkin. (Artificial Intelligence 2020) Britannican määritelmä tuo esille tekoälyn eri ominaisuuksia, jotka kuvaavat erittäin hyvin, mitä tekoälyllä pyritään saavuttamaan. Tekoälyn avulla pyritään saavuttamaan siis näennäinen tietoisuuden taso, jolloin se pystyy ratkaisemaan sille määrättyjä tehtäviä. Hyvin usein nämä tehtävät ovat kuitenkin tarkoin rajattuja ja tietokoneen sisältämä tekoälyohjelma pystyy suorittamaan vain sen tietyn tehtävän.

Tässä kandidaatintutkielmassa tekoälystä puhuttaessa tarkoitetaan tietokoneohjelmaa tai -ohjelmien joukkoa, jotka suorittavat tehtävän tilanteen mukaan järkevällä tavalla, paremmalla tarkkuudella ja nopeammin kuin ihminen. Järkevä toiminta edellyttää tekoälyltä tiettyjä ominaisuuksia. Sen on osattava toimia erilaisissa ympäristöissä ja muuttuvissa tilanteissa ilman käyttäjän jatkuvaa avustamista. Tekoälyn täytyy siis kyetä kehittämään omaa toimintakykyään oppimisen kautta niin, että järjestelmä pystyy toimimaan järkevällä tavalla, vaikka tilanne muuttuisi ennakoimattomasti. (Ailisto et al. 2018, s. 47–48)

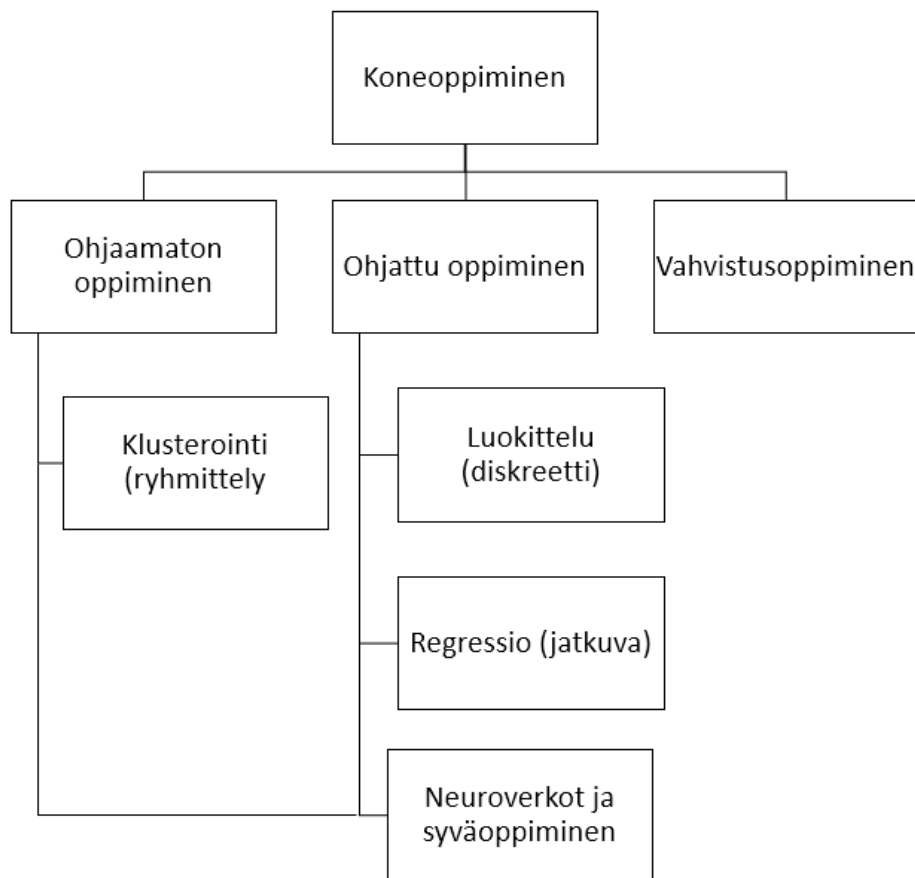
2.3 Tekoälyteknologia

Kuten aikaisemmin on mainittu, tekoäly ei ole yksi tietty teknologia, menetelmä tai ohjelma, vaan tekoäly jaetaan hyvin useisiin eri osa-alueisiin. Tekoälyteknologioita ovat esimerkiksi koneoppiminen, neuroverkot ja syväoppiminen, datatiede ja robotiikka. Lisäksi näitä eri teknologioita voidaan jakaa myös ratkaistavan tehtävän perusteella. Erilaisia tehtäviä, joissa käytetään tekoälyä, ovat esimerkiksi päättely- ja ongelmanratkaisutehtävät, suunnittelutehtävät, oppimistehtävät, kielentunnistustehtävät ja kuvantunnistustehtävät. Ratkaisevasti tehtävän suorittamiseen valittava teknologia riippuu datan määrästä, koosta ja tyypistä, sekä siitä, tarvitaanko tehtävässä kuinka oppivaista ohjelmaa. Lisäksi merkittävä tekijä on ratkaistavan tehtävän laajuus. Tässä luvussa käsitellään ainoastaan konenäön kannalta keskeisimpiä tekoälyteknologioita ja menetelmiä, joita ovat koneoppiminen sekä neuroverkot ja syväoppiminen. (Russel & Norvig 2016)

2.3.1 Koneoppiminen

Koneoppiminen on yksi tekoälyn keskeisistä osa-alueista, ja siinä käytetään usein hyödyksi tilastotieteen menetelmiä. Sen tarkoituksena on saada ohjelmisto parantamaan suorituskykyään tietyn tehtävän suorittamisessa, ilman eksplisiittistä ohjelmointia. (Nils-

son 1998, s. 1–3) Tarkoituksena on, että kone tai ohjelma oppii tunnistamaan, luokittelemaan ja ennustamaan asioita (Lehto et al. 2018, s. 13). Mukautumiskyvyn vuoksi ohjelma ei ole siis riippuvainen ihmisestä, kun syötteessä tapahtuu muutoksia. Ilman kykyä oppia ihmisen täytyisi muokata ohjelmaa joka kerta, kun syöte muuttuisi. Koneoppiminen voidaan jakaa kolmeen eri osa-alueeseen: ohjattuun, ohjaamattomaan sekä vahvistusoppimiseen. Tätä jaottelua on havainnollistettu kuvassa 3. Ohjatun oppimisen menetelmät voidaan jakaa edelleen kuvan 3 mukaan luokitteluun ja regressioon. Näiden lisäksi neuroverkot ja syväoppiminen kuuluu molempiin sekä ohjaamattomaan että ohjattuun oppimiseen. Neuroverkkoja ja syväoppimista käsitellään omassa alaluvussa 2.3.2.



Kuva 3. Koneoppimisen osa-alueet, muokattu lähteistä (Ailisto et al. 2018, s. 15; Lehto et al. 2018, s. 14)

Ohjattu oppiminen tapahtuu luokitellun aineiston avulla. Luokitellussa aineistossa on syöte- ja tavoitepareja, joiden avulla kone oppii tekemään luokittelun samankaltaiselle aineistolle. Opetusvaiheessa kerrotaan siis kunkin syöteen oikea tulos. (Ailisto et al. 2018, s. 14; Lehto et al. 2018, s. 13) ”Jos syötteet voidaan luokitella erilaisiin ryhmiin, niin kyse on luokittelusta, jos se on jatkuvaa, niin regressiosta”, toteavat Lehto et al.

(2018, s. 13). Edelleen ohjatun oppimisen luokittelu voidaan jaotella binääriseen luokitteluun, jolloin mahdollisia luokkia alkioille on kaksi, tai sitten luokitteluun useampaan luokkaan, jolloin mahdollisia luokkia on useampi kuin kaksi. Erilaisia luokittelualgoritmeja ovat muun muassa logistinen regressio, k:n lähimmän naapurin menetelmä, tukivektori-kone, naiivi Bayes-luokittelija ja päätöspuu. (Lehto et al. 2018, s. 14–15) Tämän työn kannalta ei ole kuitenkaan merkityksellistä käydä yksittäisten luokittelualgoritmien toimintaperiaatteita läpi.

Ohjaamaton oppiminen muistuttaa enemmän ihmisen oppimista, sillä ohjelma pyrkii itse ryhmittelemään eli klusteroimaan tapaukset niiden riippuvuuksien, suhteiden ja samankaltaisuuksiensa perusteella omiin luokkiinsa (Ailisto et al. 2018, Alpaydin 2016, s. 112–113; s. 15; Lehto et al. 2018, s. 13). Klusteroimisen toteuttamiselle on erilaisia menetelmiä, joita ovat esimerkiksi k-means-algoritmi, neuroverkkomenetelmät, latenttien muuttujien menetelmät sekä GAN-verkkomenetelmä (Ailisto et al. 2018, s. 15). Ohjaamattomassa oppimisessä on siis kyse siitä, että ohjelma osaa tunnistaa yhtäläisyyksiä datasta. Ohjatun oppimisen tapauksessa ohjelma olisi erikseen täytynyt opettaa esimerkkidatalla, jotta se osaisi tunnistaa datasta yhteneväisyyksiä.


Vahvistettu oppiminen perustuu agentin, eli oppijan tekemiin päätöksiin, sekä sen päätöksistä saatuihin palautteisiin. Ailisto et al. (2018) toteaa julkaisussaan: ”Toiminta ja oppiminen tapahtuvat ajassa, jolloin nykyinen tilanne perustuu aiempaan tilaan ja siinä tehtyihin ratkaisuihin. Vastaavasti tuleva tila riippuu ympäristöistä ja agentin ratkaisuista. Oppiminen kuvataan markovilaisena päätösprosessina (Markov Decision Process). Menetelmän juuret ovat käyttäytymispsykologiassa ja päätöksenteon teoriassa.” (Ailisto et al. 2018, s. 15)

2.3.2 Neuroverkot ja syväoppiminen

Neuroverkoja ja syväoppimista käsitellään erillisenä alalukuna sen laajuuden, ajankohtauuden sekä viimeaikaisen kehittymisen huiman nousun vuoksi. Helsingin yliopiston ja tietotekniikkayrityksen Reaktor järjestämän kurssin Elements of AI (Elements of AI 2020) mukaan syväoppiminen on tietyn tyyppinen koneoppimismenetelmä, jossa yksinkertaisista prosessointiyksiköistä koostuvia kerroksia yhdistetään verkostoksi. Tämä verkosto on neuroverkko ja sen sisältämät prosessointiyksiköt ovat neuroneita. Useista kerroksista muodostetun verkoston avulla pystytään suorittamaan hyvin vaativiakin tehtäviä, ja sen vuoksi niitä on hyödynnetty myös syväoppimisessä. Keinotekoiset neuroverkot muistuttavat ihmisen aivoissa sijaitsevia luonnollisia neuroverkoja, jotka käsittelevät sähköisiä signaaleja. Aivojen luonnolliset neuroverkot johdattivat tutkijat mallintamaan


keinotekoisia neuroverkkoja jo 1940-luvulla, mutta neuroverkkoja on onnistuttu hyödyntämään vasta 2010-luvulla. (Haenlein & Kaplan 2019) Tässä tutkielmassa neuroverkosta puhuttaessa tarkoitetaan aina keinotekoisia neuroverkkoja, ellei toisin mainita.

Neuroverkko rakentuu erilaisista kerroksista ja yksinkertaistettuna kerrokset ovat syötekerros, piilokerros sekä ulostulokerros (Lehto et al. 2018, s. 21; Ugur 2010). Näitä kerroksia sekä neuroverkon rakennetta havainnollistetaan kuvassa 4.



Kuva 4. Neuroverkon rakenne, muokattu lähteestä (Lehto et al. 2018, s. 21)

Syötteet x_1 ja x_2 kulkevat kolmen neuronikerroksen läpi ja verkon ulostulo y muodostuu näille syötteille tehdyistä laskutoimituksista. Se mitä verkon halutaan suorittavan, määrää miten nämä kerrokset ja erilaiset neuronit tulee järjestellä. Yksittäisen neuronin toimintaa havainnollistetaan kuvassa 5.



Kuva 5. Esimerkki neuronista, muokattu lähteestä (Ertel 2011, s. 224).

Neuroni vastaanottaa n määrän syötteitä ja syötteille lasketaan painotettu summa, jolloin saadaan ulostulo x_i . Lisäksi kahden erillisen neuronin välissä summa viedään aktivointifunktioon, joita ovat esimerkiksi sigmoid-funktio, hyperbolinen tangentti sekä ReLu-funktio. Nämä aktivointifunktiot muuttavat lineaarisen syötteen epälineaariseksi. Kerroksissa oleviin neuroneihin liittyy neuroneiden välillä olevia painoja sekä neuronikohtainen vakiotermi. Neuroneiden välillä oleva paino yksinkertaistettuna joko korostaa tai pienentää neuronilta lähtevän syötteen merkitystä. (Lehto et al. 2018, s. 21–29) Tämä on kuitenkin ainoastaan esimerkki neuroverkon perinteisestä rakenteesta. Tutkijat ovat kehittäneet useita erilaisia neuroverkkoja eri tarkoituksiin, joten ne myös rakentuvat erilaisista funktioista ja erilaisista rakenteista. Esimerkiksi FNN (Feedforward Neural Network) on neuroverkko, jossa verkkojen väliset yhteydet ei muodosta lenkkiä. Vastakohtana FNN verkolle on RNN (Recurrent Neural Network), jossa data kulkee syötteiden kautta takaisinpäin ja muodostaa ns. lenkin. (Schmidhuber 2015)

Neuroverkkoja on mahdollista opettaa ohjatusti, mutta ne voivat myös oppia ohjaamattomasti (Ugur 2010). Opettamistapa riippuu siitä mihin ohjelmalla pyritään. Ohjatun oppimisen tapauksessa opettaminen tapahtuu samalla tavoin kuten on mainittu luvussa 2.3.1, mutta nyt neuroverkkojen tapauksessa datan määrällä on suuri merkitys. Verkko voi ylioppia helposti, jos käytössä on liian vähän dataa. Ylioppimisesta seuraa, että verkko ei suoriudu tehtävistä halutulla tavalla, kun dataa on käytössä enemmän. Verkon opettaminen tapahtuu kuitenkin useimmiten iteratiivisesti. Verkon syötteellä tuottamaa tulosta verrataan virhefunktion avulla tavoitetulokseen. Tämä tarkoittaa sitä, että ulostulon ja halutun ulostulon erotusta verrataan keskenään. Opettamista kontrolloidaan minimoimalla virhefunktioita. Minimointi onnistuu esimerkiksi vastavirta-algoritmin avulla, jolloin piilokerroksen neuroneiden välisiä painokertoimia muutetaan. Vastavirta-algoritmin avulla löydetään siis virhefunktioiden minimointia vastaavat uudet painot neuroneille. (Schmidhuber 2015)

Neuroverkoista on tärkeä tuoda esille kaksi eri käsitettä: syvä neuroverkko (Deep Neural Networks, DNN) ja konvoluutioneuroverkko (Convolutional Neural Networks, CNN). Syvä neuroverkko koostuu hyvin useista kerroksista, kun taas yksinkertainen kuvassa 3 esiintyvä neuroverkko koostuu ainoastaan kolmesta kerroksesta. Konvoluutioneuroverkko on syvä neuroverkko, joka koostuu konvoluutio-operaatioita suorittavista kerroksista. Konvoluutio on matemaattinen operaatio kahden funktion välillä, jonka seurauksena syntyy uusi funktio. Esimerkiksi kuvankäsittelyssä konvoluutio-operaatiot auttavat tunnistamaan kuvasta kappaleen reunoja ja muotoja. Useita kerroksia yhdistelemällä on mahdollista tunnistaa kuvasta kappaleen omia muotoja, kuten eri syvyyksiä ja osien keskinäisiä riippuvuuksia. (Michelucci 2019)

3. KONENÄKÖ


Konenäkö on yksi valmistavan teollisuuden laajimmista sovelluskohteista esimerkiksi tarkkailussa, paikantamisessa ja kuvantamisessa. Etenkin laaduntarkkailussa konenäöllä on suuri merkitys. Tieteen nimissä konenäöstä puhuttaessa on kaksi eri koulukuntaa: toinen niistä käsittelee konenäköä teknisenä toteutuksena (Machine vision) ja toinen taas käsittelee konenäön matemaattista perustaa ja tietokoneohjelmia (Computer vision). Alaluvussa 3.1 käsitellään konenäköjärjestelmän teknistä toteutusta ja alaluvussa 3.2 käsitellään konenäköjärjestelmien matemaattista perustaa. Konenäkö on sanansa mukaisesti koneen kykyä nähdä ja havainnoida, ja se perustuu kuva- tai videomateriaalin perusteelliseen havainnoimiseen ja tulkitsemiseen. Näitä havaintoja ovat esimerkiksi kohteiden tunnistus, kohteen asento ja sijainti, pinnanlaadun tarkistus tai kohteissa tapahtuneet muutokset. Järjestelmän keskeisenä tehtävänä on myös osata tulkita näiden eri havaintojen merkitys. (Pietikäinen & Silvén 2019, s. 127)

3.1 Konenäköjärjestelmä

Jokainen valmistusprosessi on erilainen ja jokaisessa yksittäisessä prosessissa itsessään voi olla useita eri konenäköjärjestelmiä eri tehtäviä varten. Konenäkö on työkalu ainoastaan siihen tiettyyn tehtävään mihin se on luotu, eikä ainakaan vielä ole kehitetty konenäköä, joka onnistuisi suoriutumaan useista erilaisista tehtävistä. Pietikäisen ja Silvénin (2019, s. 127) mukaan pelkästään valaistuksen, katselusuunnan ja taustan muutokset sekä muut erilaiset vaihtelut toimintaympäristössä aiheuttavat suuria vaikeuksia kuvan näkymän tulkinnalle. Tästä syystä myös kokonaisen konenäköjärjestelmän täytyy olla tarkoin määritelty ja rakennettu juuri siihen kyseiseen tehtävään. (Pietikäinen & Silvén 2019)

Yksinkertainen konenäköjärjestelmä koostuu kuvan 4 mukaisista komponenteista. On hyvä huomioida, että kuvan 4 rakenne on kuitenkin vain esimerkki konenäköjärjestelmästä. Kuvan 4 esimerkissä jokin kappale (1) kulkeutuu kuljetinhihnalla eteenpäin. Kuvaa varten tarvitaan hyvät olosuhteet, jolloin kappaleen halutaan mahdollisesti olevan tiettyssä asennossa, sekä valaistuksen (3) täytyy olla hyvä. Kappaleen saavuttaessa tietyn kohdan esimerkiksi valosähköiseen ilmiöön perustuva anturi ilmoittaa kameralle (2) kuvan ottamisesta. Kameran linssin täytyy olla tarkoin valittu tai suunniteltu juuri kyseistä tapahtumaa varten. Kamera toimittaa kuvan tietokoneelle (5) kuvaa käsittelevän yksikön (6) läpi. Ohjain (7) järjestelee kuvan oikeaan paikkaan tietokoneen muistissa. Kun kuva on tietokoneella, kuvankäsittelyohjelma tarkastaa sen ja toimittaa lopputuloksen (9).

Tämä tulos toimitetaan signaalin yksinkertaistavan komponentin (10) kautta ohjainyksikölle (11). Ohjainyksikkö toimii signaalin perusteella ja antaa käskyn edelleen toimilaitteelle (13), joka ohjaa esimerkiksi virheelliset kappaleet pois linjastolta. Ohjainyksikön ja toimilaitteen välinen kommunikaatio toimii tiedonsiirtokomponentin (12) avulla. (Steger et al. 2018, s. 2)



Kuva 6. Konenäköjärjestelmän tyypillinen rakenne (Steger et al. 2018, s.1)

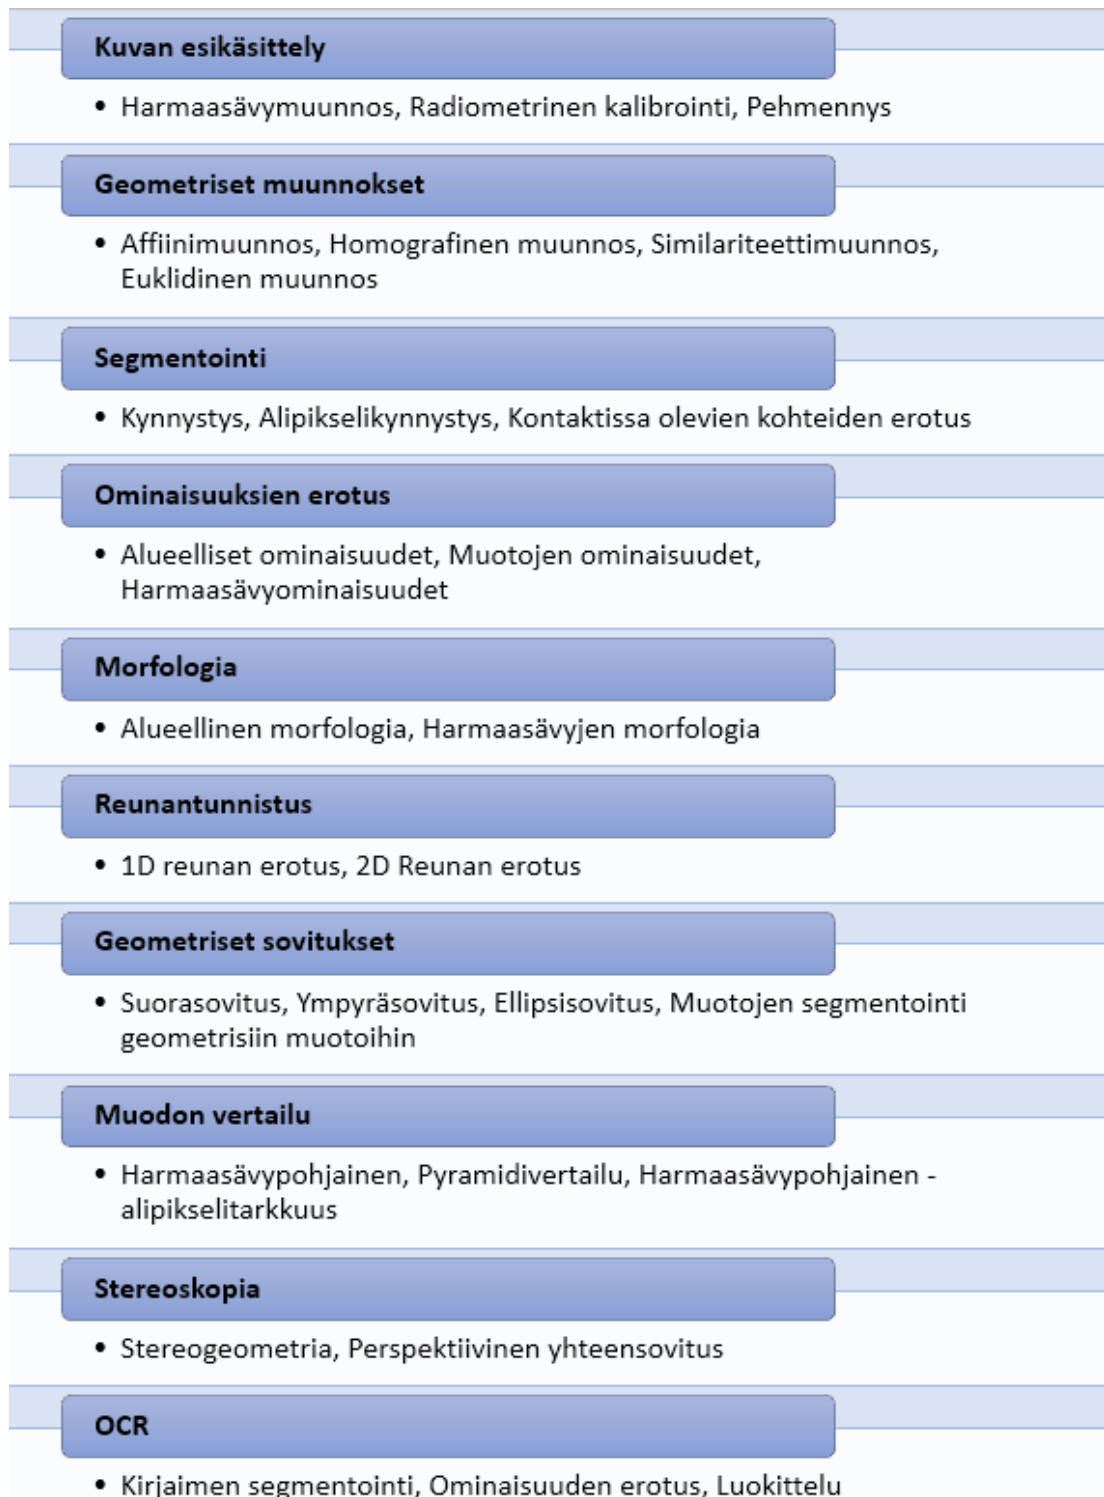
Konenäköjärjestelmä voidaan jakaa viiteen eri osaan: valaistus, linssi, anturointi, kuva-prosessointi ja kommunikointi. Oikean tyyppisellä valaistuksella kuvattavasta kappaleesta tuodaan haluttuja piirteitä näkyviin. Jotta tämä onnistuu, täytyy tietää miten kappale heijastaa valoa ja mikä valon aallonpituus toimii parhaiten. Valon tyypin ja aallonpituuden lisäksi valo täytyy suunnata oikein, jotta halutut piirteet tulevat kappaleesta esiin. (Steger et al. 2018, s. 5) Valon säteet heijastuvat kappaleesta ja ohjautuvat linssin läpi kuva-anturille. Linssin tyypin avulla voidaan määrittää, kuinka tarkka kuva halutaan (Steger et al. 2018, s.18).

Kameran sisällä kuva-anturi vastaanottaa kappaleen muodon optisesti linssiltä, ja kuva-anturin tehtävä on muuntaa muoto tietokoneen ymmärtämäksi elektroniseksi signaaliksi (Batchelor 2012, s. 358). Kuva-anturilla on siis tärkeä rooli koko järjestelmän kannalta. Kuva-anturi on valoherkkä kenno, joka vastaanottaa kappaleesta tulevat valonsäteet ja muuttaa ne tietyn suuruiseksi sähkövarauksiksi. Antureita on pääasiassa kahdenlaisia: CCD (Charge-Coupled Device) ja CMOS (Complementary Metal Oxide Semiconductor) (Steger et al. 2018, s. 42). CCD-kennon pinnalla on fotodiodeja, jotka reagoivat valoon

valon voimakkuuden perusteella. Näiden tietyn tyyppisten diodien ominaisuuksien ansiosta, kappaleen muoto saadaan muutettua tietokoneen luettavaksi dataksi (Batchelor 2012, s. 360–370). CMOS-kenno toimii samojen periaatteiden mukaisesti kuin CCD-kenno, mutta se on kehitetty nopeammaksi ja vähemmän virtaa kuluttavaksi. Näiden kennojen yksityiskohtainen toimintokuvaus ei kuitenkaan ole työn kannalta merkityksellistä. Kennolta kuva etenee kuvan prosessointiin, jossa kuvankäsittelyohjelma käsittelee kuvan ja antaa tietoa siitä. Viimeisenä on kommunikointi kaikkien komponenttien välillä. Kameralta kuva välitetään analogisena tai digitaalisena signaalina tietokoneelle. Tietokone luo signaalien avulla matriisin kuvan arvoista. Matriisi voi sisältää joko harmaita tai värillisiä arvoja. (Steger et al. 2018, s. 56)

3.2 Konenäön hyödyntämät ohjelmat ja algoritmit

Konenäön ja tekoälyn suhde on äärimmäisen tärkeää ymmärtää. Konenäkö on moneen kykenevä työkalu, mutta tekoälyä se ei ole. Sen sijaan konenäkö hyödyntää tekoälyä. Tyypillisesti konenäköjärjestelmä sisältää useita erilaisia algoritmeja kuvan prosessoinnin eri vaiheissa. Steger et al. tulkitsee kirjassaan ”Machine vision algorithms and applications” (2018, s. 97), että ilman silmiä emme näe. Ja jos meillä on silmät, mutta ei aivoja, emme näe silloinkaan. Tarvitsemme siis molempia, kuvaa tunnistavia sensoreita, sekä kuvaa prosessoivia ohjelmia ja algoritmeja, yhtä paljon (Steger et al. 2018, s. 97). Kuvassa 7 tuodaan esille algoritmien tehtäviä kuvankäsittelyprosessin eri vaiheissa.



Kuva 7. Konenäköalgoritmien tehtävät kuvankäsittelyprosessin eri vaiheissa, muokattu lähteestä (Liu et al. 2015, s. 15, Taipale 2020 mukaan, s. 30)

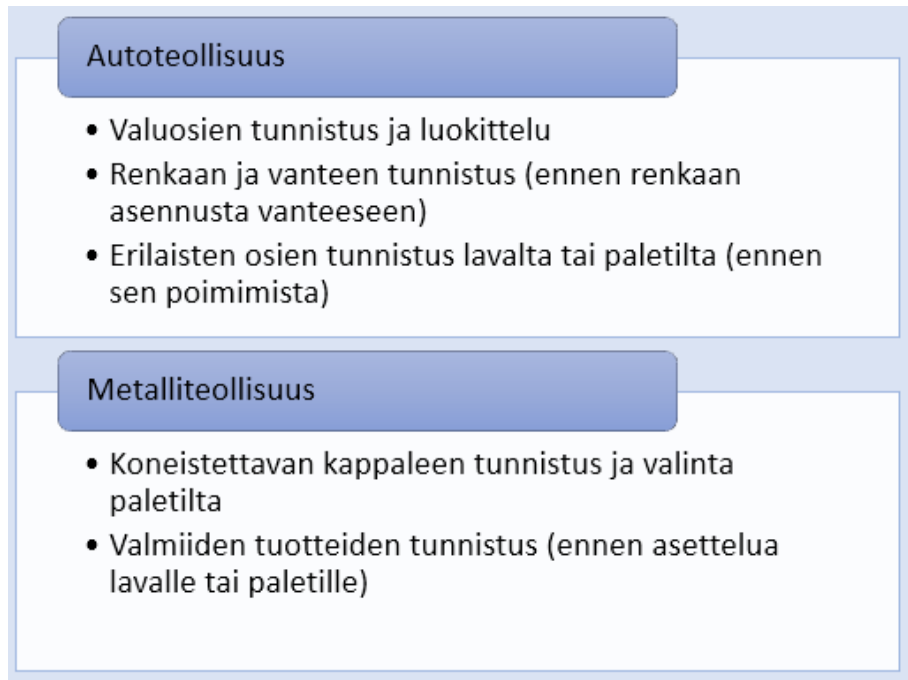
Kuten edellisessä luvussa on mainittu, konenäköjärjestelmä täytyy kehittää yksityiskohdaisesti suoritettavaa tehtävää varten, tällöin myös algoritmien yhteydessä täytyy huomioida tehtäväkohtainen spesifisyys. Usein tarvitsee luoda myös täysin uusia algoritmeja, jos vanhat saatavilla olevat algoritmit eivät sovellu tehtävään. (Davies 2005, s. 12–13)

4. TEKOÄLYÄ SISÄLTÄVIÄ KONENÄKÖSOVELLUKSIA

Valmistavassa teollisuudessa konenäköä käytetään useimmiten sovelluksiin, joiden tavoitteena on tunnistaa kappale, kontrolloida prosessia tai ohjata esimerkiksi robottia tai mekaanisia järjestelmiä. Tuotannon automatisoimisen kannalta merkittävimmissä roolissa on automaattinen tarkkailu konenäköä hyödyntäen (Automated visual inspection – AVI). AVIn tarkoituksena on varmistaa, että kappale valmistuu vaatimusten mukaisesti ja täyttää vaadittavat standardit. Lisäksi AVIa voidaan käyttää mittauksissa, komponenttien säätämisessä sekä laaduntarkkailussa. Tuotannon joustavuuden kannalta merkittävimpiä työkaluja ovat prosessin kontrolloimiseen ja järjestelmien tai robottien ohjaamiseen käytetyt konenäkösovellukset. (Golnabi & Asadpour 2007) Kaikki kyseiset eri tehtävät toimivat kuitenkin hyvin pitkälti yhdessä ja eri toimenpiteet ovat riippuvaisia toisistaan. Käytännössä tämä tarkoittaa sitä, että esimerkiksi kappale täytyy tunnistaa ennen kuin sille voidaan tehdä mitään. Tässä luvussa tuodaan esille valmistavan teollisuuden eri osa-alueiden konenäön sovelluskohteita sekä viimeisimpiä tekoälyä hyödyntäviä konenäkösovelluksia.

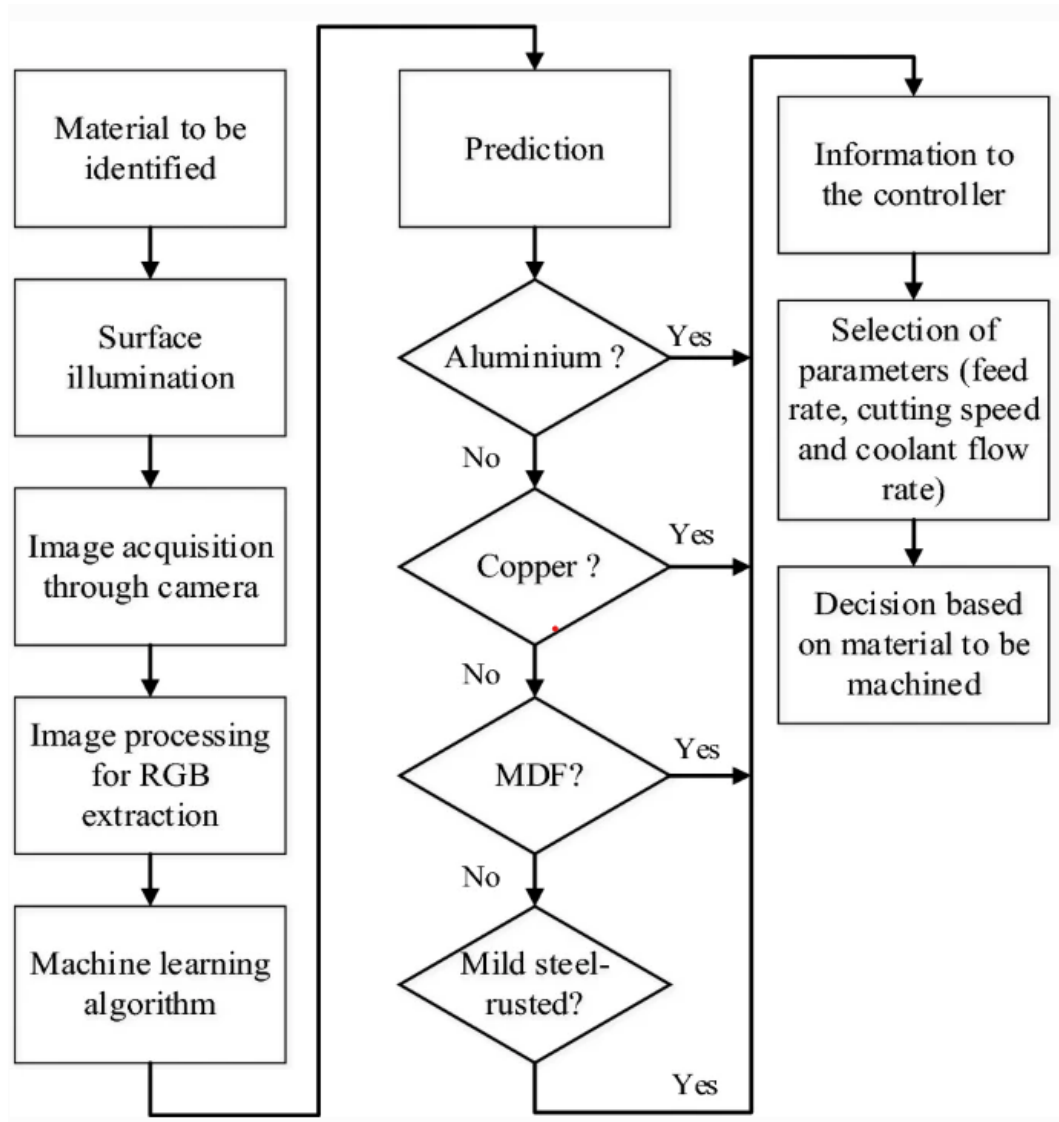
4.1 Kappaleen asennon, orientaation sekä materiaalin tunnistus

Kappaleen tunnistus ja luokittelu on yksi merkittävimmistä joustavan tuotannon konenäköjärjestelmän tehtävistä. Etenkin tuotannossa, missä kappaleen paikka ja orientaatio ei ole ennalta määritettävissä, ilman kappaleen tunnistusta tai luokittelua ei päästä eteenpäin esimerkiksi kappaleen asennukseen kokoonpanoon. Kuvassa 8 tuodaan esille tehtäviä erilaisista kappaleen tunnistustehtävistä.



Kuva 8. Esimerkkejä kappaleen tunnistamiseen liittyvistä tehtävistä, muokattu lähteestä (Golnabi & Asadpour 2007)

Penumuru et al. (2020) toteuttivat tutkimuksen, jonka tavoitteena oli konenäköjärjestelmä, joka tunnistaisi materiaalin ja näin ollen osaisi valita oikeat työkalut sen työstämiseen. Tutkimuksessa he käyttivät alumiinia, kuparia, puuta sekä pehmeää terästä. Materiaalin tunnistusta varten he käyttivät konenäköjärjestelmää ja koneoppimisalgoritmia, jonka avulla kone oppi tunnistamaan materiaaleja. Kuvassa 9 havainnollistetaan tutkimuksessa käytetyn konenäköjärjestelmän algoritmin tiedonkulkua.

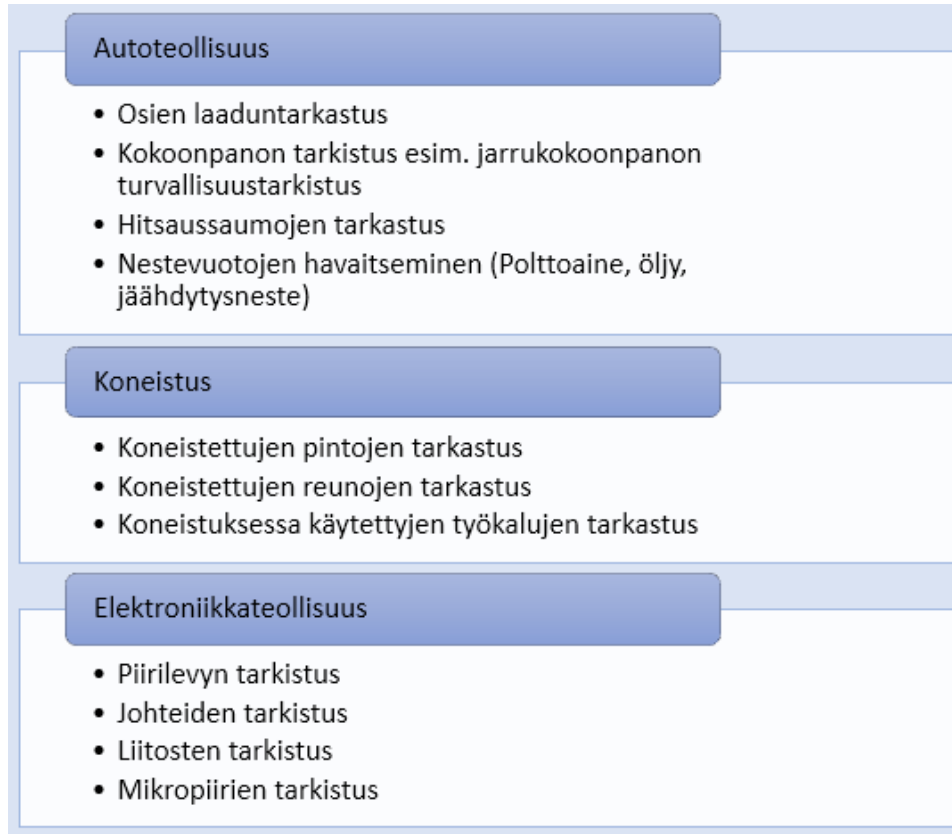


Kuva 9. Konenäköjärjestelmä (Penumuru et al. 2020)

Kuvan 9 mukaan konenäköjärjestelmän oli tarkoituksena tunnistaa kappaleen materiaali ja valita materiaalille sopivat työstömenetelmät. Koneoppimisalgoritmin opettamisessa he käyttivät 2491 näytettä, ja ohjelma testattiin 1068 näytteellä. Kyseisten lukujen avulla he saavuttivat 100 % tarkkuuden materiaalin tunnistukselle, joka kuitenkin rajoittuu täsmälleen samoihin olosuhteisiin. Voidaan siis todeta, että tekoälyn, tässä tapauksessa koneoppimisalgoritmin, käyttämisellä saavutetaan materiaalin tunnistuksessa perusteellisen hyviä tuloksia. Lisäksi Penumuru et al. (2020) toteavat, että ohjelmaa pystyy käyttämään erilaisiin olosuhteisiin vain pienin muutoksin, jonka vuoksi sen implementointi eri tarkoituksiin ei ole hankalaa.

4.2 Laaduntarkkailu & kappaleen analysointi

Laaduntarkkailussa ja kappaleen analysoinnissa keskitytään kappaleen laadun varmistamiseen sekä siihen onko valmistettu kappale vaatimusten mukainen esimerkiksi mittasuhteiltaan (Golnabi & Asadpour 2007). Kuvassa 10 esitellään esimerkkejä mihin konenäköä käytetään laaduntarkkailussa ja kappaleen analysoinnissa.



Kuva 10. Esimerkkejä laaduntarkkailun ja kappaleen analysoinnin kohteista, muokattu lähteestä (Golnabi & Asadpour 2007)

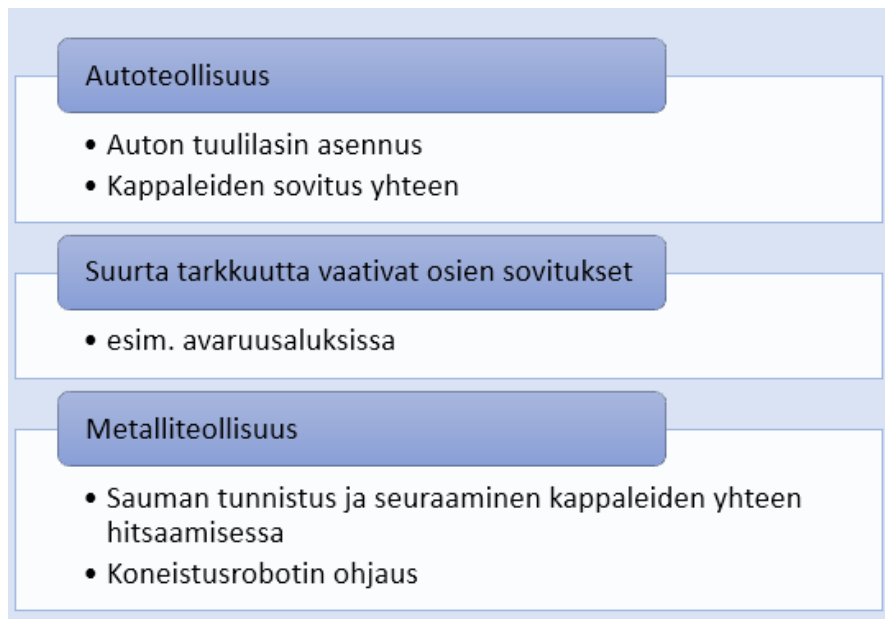
Kappaleen analysoinnissa on kyse esimerkiksi kappaleen mittaamisesta, ja konenäön avulla on päästy hyvinkin tarkkoihin mittatuloksiin. Konenäön etuna on se, että sen avulla pystytään mittaamaan sellaisissa olosuhteissa, jossa ihminen ei pysty. Esimerkiksi ahtaissa olosuhteissa. (Fu et al. 2006, s. 1127–1128) Quan et al. on esitellyt konenäköjärjestelmän, joka kykenee mittaamaan etäisyyksiä 1.3 % tarkkuudella (katso Fu et al. 2006, s. 1128). Mittausten lisäksi konenäön avulla on hyvin käytännöllistä seurata käytettävän koneen komponentin kuntoa, esimerkiksi työstökoneen terän kuntoa. Ong et al. (2019) tuovat artikkelissaan esille tutkimuksen neuroverkkoja hyödyntävästä konenäkösovelluksesta, jonka avulla voidaan tarkkailla CNC työstökoneen terän kuntoa. Tutkimuksessa vertailtiin neuroverkkoihin perustuvaa ja puhtaasti tilastotieteeseen perustuvaa terän

analysointityökalua. Neuroverkkoja käyttävän algoritmin avulla oli päästy 10 % tarkempaan tulokseen kuin tilastotieteeseen perustuvalla ohjelmalla, jonka vuoksi tutkimus osoittaa myös sen, että kyseisellä menetelmällä on potentiaalia tulevaisuuden teollisuudessa. (Ong et al. 2019)

Laaduntarkkailussa konenäön hyötyjä ovat tarkkuus, nopeus, toistettavuus ja 100 % kattavuus tuotteiden tarkastuksessa. Tämän toteuttaminen manuaalisesti ihmisillä olisi aikaa vievää ja kallista, eikä myöskään järkevää. (Anand 2020, s. 87) Esimerkiksi neuroverkkoja hyödyntämällä laaduntarkkailussa voidaan päästä jopa 100 % tarkkuuteen, johon ihminen ei koskaan pystyisi. Sun et al. (2016) toteuttivat tutkimuksen, jossa neuroverkkoja hyödyntävän konenäköjärjestelmän avulla pyrittiin tarkastamaan lämpösulakkeiden valmistusvirheitä. Tutkimustulokset osoittivat, että neuroverkkoja hyödyntävään konenäköön perustuva laaduntarkastus ylitti 100 % tarkkuuteen. Sun et al. (2016) toteavat, että kyseinen järjestelmä ei ainoastaan vähennä kuluja, vaan kasvattaa myös laaduntarkkailun luotettavuutta ja nopeutta. (Sun et al. 2016)

4.3 Laitetason ohjausjärjestelmät

Konenäköjärjestelmien käyttö laitetason ohjauksessa mahdollistaa paremman kontrollin, analyysin sekä reaaliaikaisen seuraamisen. Reaaliaikainen seuraaminen ja kontrollointi on merkityksellistä etenkin esimerkiksi metalliteollisuudessa ja eri alojen kokoonpanolinjastoilla. Valmistuksen tukena tuotannossa käytetään esimerkiksi robotteja, jotka toimivat konkreettisesti tuotannon tehtävissä. Mikäli kappaleiden koordinaatit ja orientaatiot eivät ole tarkoin määritetty, näiden robottien ohjaus perustuu usein täysin konenäköjärjestelmään, joka tulkitsee ja havaitsee. (Golnabi & Asadpour 2007) Kuvassa 11 tuodaan esille robottien erilaisia konenäköön perustuvia työtehtäviä.



Kuva 11. Robotin työtehtäviä valmistuksessa, muokattu lähteestä (Golnabi & Asadpour 2007)

Aviles-Viñas et al. (2016) tuo artikkelissaan esille teollisuusrobotin mahdollisuuksia opetella hitsaamaan hyödyntämällä neuroverkkoja ja konenäköä. Heidän tutkimustuloksensa osoittivat, että kun robotin konenäköjärjestelmän sisältämä neuroverkko oli opetettu mallidatan avulla, robotti osasi ehdottaa oikeanlaista hitsausaamaa ilman mitään tietoa vaadituista hitsausarvoista. He toteuttivat tietokoneella harjoituksen muodossa robotille oppimistapahtuman, joka kesti ainoastaan 4 minuuttia. Opitun tiedon avulla robotin sisältämä neuroverkko kykeni saavuttamaan jopa 95 % tarkkuuden ennustettavuudessa. Loppuun he totesivat, että vaikka oppimistapahtumat robotiikassa ovat hyvin kompleksisia tehtäviä, he kuitenkin onnistuivat tutkimuksen avulla todistamaan, kuinka teollisuusrobotti kykenee oppimaan oikeat hitsausparametrit ilman aiempaa tietoa asiasta. (Aviles-Viñas et al. 2016)

5. YHTEENVETO & JOHTOPÄÄTÖKSET

Kandidaatintutkielman tavoitteena oli tuoda kirjallisuuskatsauksen muodossa esille, miten tekoälyä on hyödynnetty valmistavan teollisuuden konenäkösovelluksissa. Tämän saavuttamiseksi teoriaosuudessa käsiteltiin tekoälyä ja konenäköä yksittäisinä käsitteinä, jotta tutkielman seuraavissa luvuissa pystyttiin käsittelemään niiden välistä suhdetta sekä keskinäistä riippuvuutta.

Tekoäly itsessään on hyvin laaja, sekä jopa abstrakti aihe sen useiden erilaisten määritelmien vuoksi. Tämän vuoksi sen määrittely työtä varten oli äärimmäisen tärkeää. Tässä tutkielmassa tekoälyllä tarkoitettiin yksinkertaistettuna tietokoneohjelmaa tai -algoritmia, joka suorittaa ohjelman järkevällä tavalla sekä paremmalla tarkkuudella ja nopeammin kuin ihminen.

Konenäkö on tehokas työkalu esimerkiksi havainnoimiseen, ohjaamisen avustukseen sekä paikantamiseen. Konenäköjärjestelmän avulla pystytään korvaamaan ihminen esimerkiksi laaduntarkkailun tehtävissä, jolloin vältetään virheitä ja konenäön avulla saavutetaan 100 % kattavuus tuotteiden tarkastuksessa. Konenäkö on siis työkalu, joka korvaa ihmisen tarkkailijana.

Yhdistämällä konenäön ja tekoälyn konenäköjärjestelmiin saadaan täysin uusi ulottuvuus. Tekoälyohjelmat eli tietokoneohjelmat tai -algoritmit toteuttavat laskentaa konenäön avulla kerätylle datalle. Ilman tekoälyä konenäkö on ainoastaan tarkkailija, joka kerää dataa. Tekoälyn avulla konenäköjärjestelmästä tulee tarkkailija, joka osaa myös tulkita dataa sekä muodostaa sen perusteella johtopäätöksiä. Konenäköjärjestelmässä tekoälyn rooli on siis olla järjestelmän näennäiset aivot. Ilman tekoälyä järjestelmän aivoina ei voida suorittaa niin monimutkaisia tehtäviä kuin haluttaisiin.

Tutkielman luvussa 4 tuotiin esille esimerkkejä valmistavan teollisuuden konenäkösovelluksista, joissa on hyödynnetty tekoälyä. Esimerkeissä tekoälyn ja konenäön avulla on muodostettu oppiva materiaalin tunnistamiseen keskittyvä konenäköjärjestelmä, CNC-työstökoneen terän kuntoa analysoiva konenäköjärjestelmä, lämpösulakkeiden valmistusvirheitä tunnistava konenäköjärjestelmä sekä oppiva hitsausrobotti.

Materiaalin tunnistamiseen kehitetyssä konenäköjärjestelmässä oli hyödynnetty koneoppimisalgoritmia. Algoritmin avulla järjestelmä tunnisti materiaalin sekä valitsi siihen sopivat työstömenetelmät ja -välineet. Järjestelmä saavutti 100 % tarkkuuden tunnistuksessa, ja on tutkijoiden mukaan myös helposti implementoitavissa erilaisiin kokonaisuuksiin.

siin. Tällaisen järjestelmän avulla saadaan esimerkiksi sellaiseen tuotantoon joustavuutta, jossa käytetään paljon erilaisia materiaaleja ja tuotetaan erilaisia tuotteita. Järjestelmän avulla tuotantoa ei tarvitse ajoittaa erilaisten materiaalien mukaan, eli ei haittaa, jos linjastolla on peräkkäin kahta erilaista materiaalia.

CNC-työstökoneen terän kuntoa analysoivan konenäköjärjestelmän analyysi perustuu neuroverkkoihin. Neuroverkkojen avulla konenäköjärjestelmä tulkitsee, onko työstökoneen terä vielä käyttökelpoinen seuraavassa työstössä. Tutkimuksessa neuroverkkojen avulla oli päästy 10 % tarkempaan tulokseen kuin puhtaasti tilastotieteeseen perustuvan ohjelman avulla. Tarkempien tuloksien avulla terän vikaantumisen todennäköisyys pienenee, jolloin myös laatu paranee, kun ei synny terän vikaantumisen vuoksi viallisia tuotteita.

Lämpösulakkeiden valmistusvirheitä tunnistavan järjestelmän tapauksessa hyödynnettiin neuroverkkoja ja saavutettiin 100 % tarkkuus laaduntarkistuksessa. Järjestelmän avulla on siis mahdollista säästää kuluja, nopeuttaa tarkistusta sekä kasvattaa sen luotettavuutta.

Oppiva teollisuushitsausrobotti käyttää oppimisessa neuroverkkoja ja oppii opetusdatan avulla. Robotti kykeni oppimisen ansioista muodostamaan oikeanlaisen hitsausnaaman ilman minkäänlaista tietoa kyseisen sauman hitsaamisen vaadittavista hitsausarvoista. Tällaisen robotin avulla valmistavassa teollisuudessa hitsausrobottien voidaan soveltaa vaativimpiin tehtäviin, joissa vaaditaan useita erilaisia hitsausnaamoja.

Tekoälyn hyödyntämisellä konenäköjärjestelmissä saavutetaan siis tietynlainen tietoisuuden aste, jolloin tarvitaan huomattavasti vähemmän operaattoreita kontrolloimaan laitteita tai tekemään laskutoimenpiteitä. Tämä edelleen tarkoittaa sitä, että tuotanto on helpompi automatisoida ja tulevaisuuden valmistavan teollisuuden tuotantojärjestelmistä tulee yhä enenevässä määrin täysin tai ainakin osittain automatisoituja.

LÄHTEET

- Ailisto, H., Heikkilä, E., Helaakoksi, H., Neuvonen, A. & Seppälä, T. (2018). Tekoälyn kokonaiskuva ja osaamiskartoitus, Valtioneuvoston kanslia: Valtioneuvoston selvitys- ja tutkimustoiminta. Saatavissa: <https://julkaisut.valtioneuvosto.fi/bitstream/handle/10024/160925/46-2018-Tekoaly%20kokonaiskuva.pdf>
- Alpaydin, E. (2016). Machine learning: The new Ai. The MIT Press.
- Anand, S. & Priya, L. (2020). A Guide for Machine Vision in Quality Control. Chapman and Hall/CRC
- Artificial intelligence. (2020). Encyclopedia Britannica.
- Aviles-Viñas, J., Rios-Cabrera, R. & Lopez-Juarez, I. (2016). On-line learning of welding bead geometry in industrial robots. Industrial Journal of Advanced Manufacturing Technology. Vol.83(1–4), s. 217–231.
- Batchelor, B. G. (2012). Machine Vision Handbook. Springer London.
- Davies, E. R. (2005). Machine Vision: Theory, Algorithms, Practicalities. Morgan Kaufmann.
- Elhoone, H., Zhang, T., Anwar, M. & Desai, S. (2020). Cyber-based design for additive manufacturing using artificial neural networks for Industry 4.0. International Journal of Production Research. s. 2841–2861
- Ertel, W. (2011). Introduction to Artificial Intelligence. Springer London.
- Falcioni, J. G. (1999). Editorial: Mechanical Doohickies. American Society of Mechanical Engineers. Vol.121(12).
- Fu, L., Zhang, Y., Huang, Q. & Chen, X. (2016). Research and application of machine vision in intelligent manufacturing. Chinese Control and Decision Conference (CCDC), Yinchuan. s. 1126–1131.
- Geissbauer, R., Vedso, J. & Schrauf, S. (2016). Industry 4.0: Building the digital enterprise. PWC. Saatavissa: <https://www.pwc.com/gx/en/industries/industries-4.0/landing-page/industry-4.0-building-your-digital-enterprise-april-2016.pdf>
- Golnabi, H. & Asadpour, A. (2007). Design and application of industrial machine vision systems. Robotics and computer-integrated manufacturing. Vol.23(6), s. 630–637.
- Haenlein, M. & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. California management review. Vol.61(4), s. 5–14.
- Lehto, M., Neittaanmäki, P., Nyrhinen, R., Ojalainen, A., Pölönen, I., Rautiainen, I., Ruohonen, T., Tuominen, H., Vähäkainuu, P., Äyrämö, S. & Äyrämö, S.-M. (2018). Jyväskylän yliopisto. Tekoälyn perusteita ja sovelluksia. <https://helituominen.files.wordpress.com/2018/09/kirja1809.pdf>
- Michelucci, U. (2019). Fundamentals of Convolutional Neural Networks in: Advanced Applied Deep Learning. Apress. Saatavissa: https://doi.org/10.1007/978-1-4842-4976-5_3
- Nilsson, N. (1998). Introduction to machine learning. Stanford University. Saatavissa: <https://ai.stanford.edu/~nilsson/MLBOOK.pdf>

Ong, P., Lee, W. K. & Lau, R. J. H. (2019). Tool condition monitoring in CNC end milling using wavelet neural network based on machine vision. *International Journal of Advanced Manufacturing Technology*. Vol.104(1–4), s. 1369–1379.

Penumuru, D.P., Muthuswamy, S. & Karumbu, P. (2020). Identification and classification of materials using machine vision and machine learning in the context of industry 4.0. *Journal of Intelligent Manufacturing*. Vol.31, s. 1229–1241.

Pietikäinen, M. & Silvén, O. (2019). *Tekoälyn haasteet: Koneoppimisesta ja konenäöstä tunneteknologiaan. Koneäön ja signaalianalyysin keskus, Oulun yliopisto. Saatavissa: <http://urn.fi/urn:isbn:9789526224824>*

Russel, S. & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach, Global Edition*. Pearson Education Limited.

Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. *Neural networks*. Vol.61, s. 85–117.

Steger, C., Ulrich, M. & Wiedemann, C. (2018). *Machine vision algorithms and applications*. Wiley-VCH.

Sun, T., Tien, F., Tien, F. & Kuo, R. (2016). Automated thermal fuse inspection using machine vision and artificial neural networks, *Journal of Intelligent Manufacturing*, vol.27(3), s. 639-651.

Taipale, T. (2020). *Viivakooditarrojen automatisoitu laadunvarmistus. Opinnäytetyö. Seinäjoen ammattikorkeakoulu, Tekniikan yksikkö. Saatavissa: <http://urn.fi/URN:NBN:fi:amk-202005016753>*

Turing, A. (1950). Computing Machinery and Intelligence. *Mind*. Vol.59(236), s. 433–460.

Ugur, K. (2010). A web-based tool for teaching neural network concepts. *Computer applications in engineering education*. Vol.18(3), s. 449–457.

Warwick, K. (2012). *Artificial Intelligence: The Basics*. Taylor & Francis Group.

Zadeh, L. A. (1994). Fuzzy logic, neural networks, and soft computing. *Communications of the ACM*. Vol.37 (3), s. 77–84.