Tampereen yliopisto

PLITE
OPTIMAALISTA LISÄARVOA TEKNOLOGIASTA

Saku Pöysäri

KONEOPPIMINEN IHMISEN JA ROBOTIN YHTEISTYÖSSÄ

2025

PIRKANMAA COUNCIL OF TAMPERE REGION
ETELÄ-POHJANMAAN LIITTO Regional Council of South Ostrobothnia
Euroopan unionin osarahoittama

SISÄLLYSLUETTELO

1. JOHDANTO 1
2. IHMISEN JA ROBOTIN YHTEISTYÖ JA VUOROVAIKUTUS 3
3. KONEOPPIMISEN SOVELLUKSET IHMISEN JA ROBOTIN YHTEISTYÖSSÄ 9
4. CASE: PUHEOHJAUS 16
5. KONEOPPIMISEN HYÖDYNTÄMISEN RAJOITTEITA 19
6. YHTEENVETO 24
LÄHTEET 25
LIITE 1 – KONEOPPIMISEN SOVELLUKSIA ROBOTIIKASSA SEKÄ IHMISEN JA ROBOTIN YHTEISTYÖSSÄ 32

1. JOHDANTO

Nykyaikaiset tuotantolaitokset ovat yhä varsin jäykkiä rakenteiltaan, mikä tarkoittaa, että ne on optimoitu tiettyjen tuotteiden valmistukseen, eikä niitä voida helposti mukauttaa uusien tuotteiden tuotantoon ilman merkittäviä muutoksia nykyiseen järjestelmään (Arents & Greitans 2022). Tämä jäykkyys on ongelmallista nykypäivän nopeasti muuttuvilla markkinoilla, joissa epävarmuus ja vaihtelu ovat arkipäivää. Kuluttajat odottavat jatkuvasti uusia tuotteita nopeilla aikatauluilla, ja tämä asettaa yrityksille paineita kehittää tuotantoprosessejaan entistä joustavammiksi, älykkäämmiksi ja tehokkaammiksi. (Tliba et al. 2023) Tulevaisuuden tehdasympäristöiltä vaaditaan monikäyttöisyyttä ja kykyä mukautua nopeasti muuttuviin tarpeisiin – jopa lyhyellä aikavälillä (Evjemo et al. 2020).

Tässä kehityksessä teollisuusrobottien rooli on keskeinen, sillä ne tarjoavat mahdollisuuden lisätä tuotannon joustavuutta ja reagointikykyä muuttuvissa olosuhteissa (Bilancia et al. 2023). Valmistavan teollisuuden yritykset käyttävätkin teollisuusrobotteja toimintansa tehostamiseksi ja kasvattamiseksi kilpailukyvyn ylläpitämiseksi (Palčič & Prester 2024). Teollisuusrobottien ydinajatus on automatisoida tylsiä, likaisia ja vaarallisia tehtäviä (Sanneman et al. 2021). Tavoitteena on antaa joko fyysisesti tai kognitiivisesti raskaat ja toistuvat tehtävät roboteille suoritettavaksi, jolloin ihmiset vapautuvat mielekkäämpien, vaativimpien, näppäryyttä ja päätöksentekokykyä vaativien luovempien tehtävien suorittamiseen (Liu et al. 2024).

Viimeisen reilun vuosikymmenen aikana on noussut esille uusi tuotantoparadigma ihmisen ja robotin yhteistyöstä (engl. Human-Robot Collaboration, HRC), jossa robotit työskentelevät ihmisten rinnalla yhteisessä työtilassa vuorovaikutuksessa erilaisten tehtävien suorittamiseksi (Wang et al. 2024). Tavoitteena ei olekaan eriyttää robotteja ja ihmisiä toisistaan, vaan yhdistää automaation vahvuudet ihmistyöntekijöiden joustavuuteen sekä kognitiivisiin ja vuorovaikutustaitoihin tuotannon tehostamiseksi (Matheson et al. 2019).

Vaikka teollisuusrobotit joko yksistään tai yhdessä ihmisen kanssa työskennellessä pystyvätkin nostamaan tuottavuutta, ongelmana on, että robottisovellukset on edelleen suurimmilta osin suunniteltu ja ohjelmoitu vastaamaan tietyn tehtävän tarpeita (Sanneman et al. 2021). Tällaiset robotit eivät yleensä omaa älykkäitä toimintoja, eivätkä ne kykene sopeutumaan nopeasti muuttuviin olosuhteisiin tai oppimaan uusia tehtäviä itsenäisesti

(Arents & Greitans 2022). Tämä on osittain seurausta perinteisten suunnittelumenetelmien ja robottikeskeisten ohjelmointimenetelmien käytöstä (kuten mallipohjainen etäohjelmointi, opettamalla ohjelmointi robotin käsiohjaimella tai johdattamalla ohjelmointi robotin käsivarrella), joissa robottien liikeradat suunnitellaan ja määritellään ennalta kutakin tehtävää varten erikseen (Villagrossi et al. 2023). Robottien toiminta perinteisesti edellyttää tarkasti määriteltyä ympäristöä, jossa jokaisen robottisolun osan, laitteen ja tuotteen on oltava täsmälleen oikeassa paikassa. Mikäli järjestelmän komponentit tai valmistettava tuote vaihtuvat tai näiden sijainnit muuttuvat ennalta määrittelemättömästi, joudutaan joko muokkaamaan olemassa olevaa ohjelmaa manuaalisesti tai aloittamaan ohjelmointi alusta, mitkä pysäyttävät tuotannon ohjelmoinnin ajaksi. Tämä tekee ohjelmoinnista työlästä, monimutkaista ja altista virheille. (Pan et al. 2012)

Ratkaisuksi on muodostumassa tekoäly, jonka on todistettu tekevän tuotannosta joustavamman ja reagointikykyisemmän dynaamisesti muuttuvan tuotannon haasteiden ratkaisemiseksi (Bin Akhtar 2024). Tekoäly avaa uusia mahdollisuuksia teollisuusrobottisovellusten suunnitteluun, ohjelmointiin sekä ihmisen ja robotin yhteistyön mahdollistamiseen (Urrea & Kern 2025). Edistyneitä tekoälyyn pohjautuvia robottisovelluksia ei kuitenkaan vielä ole juurikaan markkinoilla kaupan hyllyltä ostettavissa, vaan nämä ovat tällä hetkellä pääsääntöisesti tutkimusvaiheessa tai ne on kehitetty yksittäisiä sovelluksia varten. Haasteena on, kuinka nämä teollisuusroboteille suunnitellut tekoälyratkaisut saadaan jalkautettua tuotantoon sujuvasti ja virheettömästi. Tämä on yksi syy siihen, miksi teollisuudessa ei vielä tunnisteta kaikkia tekoälyn mahdollistamia mahdollisuuksia robotiikassa. (Arents & Greitans 2022) Tekoälyä hyödyntävät robottisovellukset ovat kuitenkin nousemassa tulevina vuosina keskeiseen asemaan, sillä tuotannon joustavuus sekä monimutkaisten prosessien syvällinen ymmärrys nähdään ratkaisevina kilpailukyvyn kannalta (Riliwan et al. 2024).

Tässä selvityksessä tarkastellaan, kuinka tekoälyä voidaan hyödyntää ihmisen ja robotin yhteistyösovelluksissa. Aluksi käydään lävitse ihmisen ja robotin yhteistyön perusteita eri yhteistyömuotojen kautta, jonka jälkeen siirrytään tarkastelemaan käytännön tekoälyn sovelluksia ihmisen ja robotin yhteistyössä. Tarkemmin käsittelyyn otetaan robottien puheohjaus case-esimerkkinä. Selvityksen lopussa kartoitetaan nykyisiä haasteita, rajoitteita ja vielä ratkaisemattomia kysymyksiä, jotka ratkaisemalla saataisiin tekoälyratkaisut jalkautettua laajemmin teollisuuden käyttöön.

2. IHMISEN JA ROBOTIN YHTEISTYÖ JA VUOROVAIKUTUS

Robottien kanssa työskentelyn tulee olla turvallista operaattorille (Fahle et al. 2020), minkä takia edelleenkin tyydytään useimmiten turvallisuuden kannalta helpoimpaan ja yksinkertaisimpaan ratkaisuun, jossa roboteille osoitetaan tehtäviä, jotka ne voivat suorittaa itsenäisesti aidatulla työalueella erillään tuotannon työntekijöistä (Murashov et al. 2017, Robla-Gomez et al 2017). Jos asianmukaisia turvallisuusmekanismeja ei ole käytössä, työntekijöiden loukkaantumisriski on suuri, sillä useimmat teollisuusrobotit eivät ole tietoisia ympäristöstään (Arents et al. 2021). Nykypäivän tuotantoympäristössä on kuitenkin entistä enemmän tehtäviä, joissa tarvitaan toisaalta sekä robotin kestävyyttä ja toistonsietokykyä sekä ihmisten näppäryyttä ja päätöksentekokykyä (Liu et al. 2024).

Viimeisen reilun vuosikymmenen aikana ihmisen ja robotin yhteistyöhön on keskitetty enenevissä määrin enemmän huomiota toisaalta niin sanottujen yhteistyörobottien (engl. Collaborative Robots, Cobots) yleistymisen myötä (Knudsen & Kaivo-oja 2020) että myös Teollisuus 5.0 myötä, jossa asetetaan ihminen tuotannon keskiöön, priorisoiden työntekijän hyvinvointi sekä edistää kestävämpiä ja resilientimpiä tuotantojärjestelmiä (Alves et al. 2023). Ihmisen ja robotin yhteistyössä robotit ja ihmiset työskentelevät yhdessä tiiminä erilaisten tehtävien suorittamiseksi (Bauer et al. 2008). Tavoitteena ei olekaan eriyttää robotteja ja ihmisiä toisistaan, vaan yhdistää automaation vahvuudet ihmistyöntekijöiden joustavuuteen sekä kognitiivisiin ja vuorovaikutustaitoihin tuotannon tehostamiseksi (Matheson et al. 2019). Ihmisen ja robotin yhteistyö voikin olla perusteltua, jos prosessoitavissa osissa on vaihtelua esimerkiksi koissa ja muodoissa, kokoonpantavat osat vaativat peräkkäisiä toimia ihmiseltä ja robotilta tai jos kokoonpannaan suurempia osia yhdessä ihmisellä ja robotilla (Latokartano et al. 2023).

Perinteiset teollisuusrobotit kykenevät suorittamaan tehtäviä keskeytyksettä ja saavuttamaan tarkkuuden, nopeuden ja toistettavuuden tasoja, joita ihmiset eivät pysty saavuttamaan (Villani et al. 2018). Ne kuitenkin kärsivät monipuolisuuden puutteesta, eivätkä kykene tehokkaasti sopeutumaan muuttuviin työympäristöihin tai tuotannon muutoksiin, mikä on ensiarvoista pk-yrityksissä (Matheson et al. 2019). Ihmisillä sen sijaan on luontainen joustavuus ja kyky sopeutua odottamattomiin tilanteisiin sekä säilyttää vahva päätöksentekokyky myös dynaamisissa ja monimutkaisissa ympäristöissä (Villani et al. 2018).

Ihmisen ja robotin yhteiskäyttösovellukset yleistyvät erityisesti pk-yrityksissä (Matheson et al. 2019), joissa kevyiden yhteistyörobottien joustavuus ja helppokäyttöisyys ovat usein ratkaisevia valintakriteerejä robottia valittaessa (Inkuku et al. 2022). On todistettu, että ihmisen ja robotin yhteistyö voi merkittävästi kasvattaa tuotannon tehokkuutta myös pk-yrityksissä (Probst et al. 2015), mikä osaltaan kannustaa ihmisen ja robotin yhteistyön hyödyntämiseen.

On syytä muistaa, että ihmisen ja robotin yhteistyötä ei toteuteta pelkästään yhteistyöroboteilla, vaan myös tavanomaisilla perinteisimmillä teollisuusroboteilla kunhan on valittuna oikea yhteistyön muoto ja turvallinen toteutustapa ja soveltuvat turvalaitteistot (Matheson et al. 2019). On myös syytä huomioida, että päivittyneet teollisuusrobotiikan turvallisuusstandardit vuodelta 2025 (ISO 10218-1&2:2025) eivät enää tunnista termiä yhteistyörobotti, vaan puhutaan yhteistoiminnallisista sovelluksista, koska sovelluksesta tulee tehdä turvallinen ja tähän ei pystytä pelkästään ”luontaisesti turvallisilla” yhteistyöroboteilla. Tässä selvityksessä käytetään kuitenkin edelleen termiä yhteistyörobotti selkeyden vuoksi, koska suurin osa lähdemateriaalista on julkaistu ennen turvallisuusstandardien päivittymistä.

Yhteistyön tasot

Bauer et al. (2016) ovat esittäneet erinäisiä yhteistyön tasoja, joita on esitetty kuvassa 1. Nämä tasot ovat matalimmasta yhteistyön tasosta korkeimpaan: rinnakkaiselo, vuoroittainen yhteistyö, yhteistoiminta ja yhteistyö. Mitä korkeampi yhteistyön taso sitä korkeammat ovat vaatimukset robottisovelluksen sisäisille turvaominaisuuksille. (Latokartano et al. 2023)

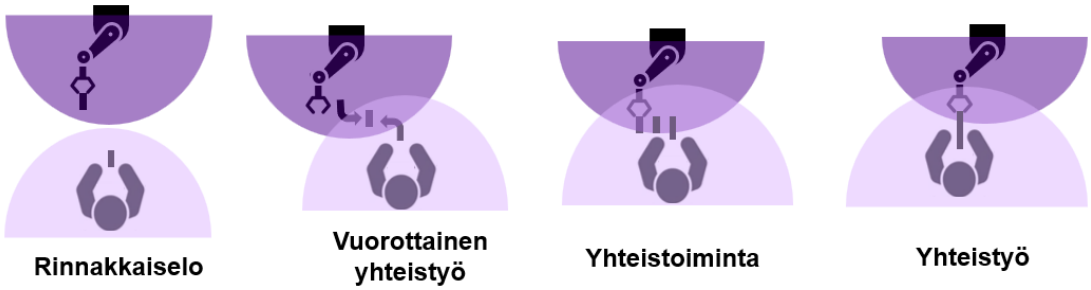

Kuva 1. *Ihmisen ja robotin yhteistyön tasot (mukaillen lähdettä Bauer et al. 2016).*

Useimmat yhteistyösovellukset ovat nykypäivänä rinnakkaiseloon tai vuorottaiseen yhteistyöhön perustuvia (Arents et al. 2021). Rinnakkaiselossa ihminen ja robotti ovat fyysisesti samassa tilassa, jossa robottia ei ole rajattu aidoilla, mutta näillä on erilliset työtilat eikä varsinaista yhteistyötä (Fischer et al. 2023). Aitojen puuttuminen kuitenkin helpottaa

ihmisen liikkumista solussa ja voi vapauttaa lattiatilaa (Gustavsson et al. 2023), kun fyysiset aidat korvataan turvaluokitelluilla antureilla ja skannereilla. Vuoroittaisessa yhteistyössä ihminen ja robotti jakavat saman työtilan, mutta työskentelevät siellä eri aikoina (Bauer et al. 2016). Turvaluokitelluilla antureilla ja skannereilla tunnistetaan ihmisen saapuminen ja poistuminen työalueelta. Käytännössä robotti pysähtyy turvallisesti ihmisen läsnä ollessa ja jatkaa toimintaansa vasta, kun tila on jälleen vapaa. (Latokartano et al. 2023)

Tulevaisuudessa yhteistyösovellukset tulevat olemaan entistä enemmän yhteistoimintaan ja yhteistyöhön perustuvia, joita ei vielä löydy juurikaan teollisuudesta (Latokartano et al. 2023). Yhteistoiminnassa ihminen ja robotti työskentelevät rinnakkain samassa työtilassa, mutta eri puolilla sitä eri tehtävissä tai eri kappaleilla (Bauer et al. 2016). Tässä mallissa robotin nopeus, voima ja liikkeet ovat rajoitettuja, ja sen on oltava helposti pysäytettävissä oletettavan törmäyksen sattuessa. Vain tähän tarkoitukseen suunnitellut robotit, jotka sisältävät voima- ja vääntöantureita, pysähtyvät automaattisesti kontaktin tapahtuessa. (Latokartano et al. 2023) Yhteistyössä ihminen ja robotti käsittelevät samanaikaisesti samaa kappaletta (Bauer et al. 2016). Tämä on teknisesti vaativin yhteistyön muoto, sillä robotti tarvitsee tilannetietoisuutta havainnoidakseen ympäristöään ja reagoidakseen ihmisen toimintaan reaaliaikaisesti. Robotti voi esimerkiksi muuttaa liikerataansa ihmisen liikkeiden mukaan. (Latokartano et al. 2023) Tässä kohdin tarvitaan erilaisia koneoppimisen menetelmiä, robotin tilannetietoisuuden kasvattamiseksi.

Keinot yhteistyön toteuttamiseen standardien perusteella

Edellä esitellyt ihmisen ja robotin yhteistyöntasot eivät ota varsinaisesti kantaa, kuinka turvallisuus tulisi toteuttaa. Tätä varten teollisuusrobotiikan turvallisuusstandardit (SFS EN ISO 10218-1&2: 2025) määrittävät kolme keinoa, joilla ihmisen ja robotin yhteistoiminta tulisi toteuttaa teollisuuden sovelluksissa (kts. kuva 2):

- Käsin ohjaaminen (engl. Hand-guided control, HGC)
- Nopeuden ja vähimmäisetäisyyden valvonta (engl. Speed and Separation Monitoring, SSM)
- Tehon ja voiman rajoittaminen (engl. Power and Force Limiting, PFL)

Standardin mukainen käsin ohjaaminen tarkoittaa pääsääntöisesti robotin ohjaamista tuotantoprosessin aikana automaattitilassa, mutta tätä voidaan käyttää myös manuaalitilassa, kun esimerkiksi robotille ollaan opettamassa paikoituspisteitä johdattamalla opettamalla (SFS EN ISO 10218-2: 2025). Robotti voi esimerkiksi kannatella kuormaa, jota ihminen ohjaa ja asettaa paikoilleen (Hietanen et al. 2020). Yhteistyöroboteilla käsin ohjaus voidaan toteuttaa ilman erillisiä laitteita voimantunnistuksen avulla, kun taas suuret

robotit vaativat erillisen ohjauslaitteen hätäpysäytys- ja sallintalaitteineen (Latokartano et al. 2023).

Nopeuden ja vähimmäisetäisyyden valvonnassa robotin toimintaa säädetään ihmisen etäisyyden perusteella: ihmisen ollessa kaukana robotti voi liikkua nopeammin ja ihmisen lähestyessä robotin nopeutta hidastetaan. Mikäli etäisyys alittaa sallitun rajan, robotti pysähtyy. (Byner et al. 2019) Turvallinen vähimmäisetäisyys määritetään huomioiden ihmisen ja robotin suhteellinen nopeus standardin mukaisesti (SFS EN ISO 10218-2: 2025).



Kuva 2. *Yhteistyön toteuttamisen vaihtoehdot vasemmalta oikealle: käsin ohjaaminen, nopeuden ja vähimmäisetäisyyden valvonta sekä tehon ja voiman rajoittaminen (mukaillen lähdettä Latokartano et al. 2023).*

Tehon ja voiman rajoittamisessa robotti on suunniteltava siten, että mahdollinen törmäys ihmiseen on vaaraton, joko rakenteellisilla tai ohjaukseen perustuvilla ratkaisuilla. Koska pelkät rakenteelliset keinot eivät useimmiten riitä, turvallisuus toteutetaan rajoittamalla robotin voimaa ja nopeutta ohjausteknisesti. (Latokartano et al. 2023) Rajoja valvotaan esimerkiksi servovirtojen mittauksella tai erillisillä voima-antureilla, ja valvonta toteutetaan erillään varsinaisesta robotin ohjelmasta (Aivaliotis et al. 2019). Suunnittelussa hyödynnetään standardissa SFS EN ISO 10218-2:2025 määritettyjä raja-arvoja törmäysvoimille.

Ihmisen ja robotin välisen kommunikoinnin keinot

Ihmisen ja robotin välinen vuorovaikutus ja kommunikointi muodostaa merkittävän haasteen tekoälytutkimuksen alalla. Perinteisiä tekoälymenetelmiä ei ole erityisesti suunniteltu käsittelemään fyysisessä maailmassa esiintyviä jatkuvasti muuttuvia, arvaamattomia ja osittain tuntemattomia ympäristöjä. Robotit ovat tyypillisesti rajoittuneet yksinkertaisten tehtävien suorittamiseen ja toistamiseen ennustettavissa olevissa tilanteissa, kuten pakkaamisessa ja hitsauksessa. Fyysisessä vuorovaikutuksessa ja ihmisten kanssa kommunikoinnissa robottien tulisi kuitenkin olla ymmärrystä, jonka avulla ne pystyvät toimimaan vaihtelevissa ja dynaamisissa tilanteissa. Tämän seurauksena robotiikan ala on siirtymässä alueille, joissa anturitiedon merkitys kasvaa jatkuvasti ja tekoälyn on osoitettava kykynsä ennakoida ja hallita laajaa kirjoa erilaisia tilanteita. (Dhanda et al. 2025)

Ihmisen ja robotin välinen yhteistyö perustuu tehokkaaseen kommunikaatioon, joka voidaan jakaa karkeasti kahteen pääluokkaan: kontaktilliseen kommunikaatioon ja kontaktittomaan kommunikaatioon. Kontaktillisessa eli fyysisessä yhteistyössä ihminen ja robotti ovat suorassa kosketuksessa, eli esimerkiksi yhdessä asentamassa osaa paikalleen kokoonpanossa, jolloin robotti mittaa vuorovaikutusvoimia ennakoidakseen ihmisen aikomuksia ja säätääkseen liikettään. Kontaktittomassa eli kosketuksettomassa yhteistyössä kommunikointi tapahtuu eleiden, puhekomentojen ja ihmisen liikeaikomusten ennustamisen avulla ilman tarkoituksellista fyysistä kontaktia. (Mukherjee et al. 2022) Eri kommunikointimuotojen yhdisteleminen tuo järjestelmiin redundanssia, mutta parantaa järjestelmien luotettavuutta ja häiriönsietokykyä teollisissa ympäristöissä, minkä takia näitä on testattu ihmisen ja robotin välisen kommunikoinnin ohella yhteistoiminnallisten solujen turvallistamisessa ja osapuolten aikomusten ennustamisessa. (Park et al. 2017, Plappert et al. 2018) Kontaktittomassa vuorovaikutuksessa korostuvat tämän selvityksen mukaan koneoppimisen menetelmät, joita hyödynnetään operaattorin eleiden havainnoinnissa, tunnistamisessa, luokittelussa, analysoinnissa sekä toimintojen suunnittelussa.

Tärkeimmät kontaktittomat kommunikoinnin keinot robotin ja ihmisen välillä ovat (Mukherjee et al. 2022):

- Käsieleet
- Puhekomennot
- Katse ja kasvojen ilmeet
- Semantiikka

Käsieleet ovat ihmisille luonnollinen ja tehokas viestintätapa, ja niitä voidaan hyödyntää myös ihmisen ja robotin väliseen kommunikointiin. Tyypillisesti robotti seuraa erilaisilla anturiratkaisuilla ihmisen käden asentoja ja liikkeitä ja tämän perusteella reagoi käyttäjän viesteihin (Ziaeefard & Bergevin 2015). Käsieleiden tunnistus perustuu anturidataan, joista käsien asennot pyritään havaitsemaan ja segmentoimaan sekä koneoppimismalleihin, kuten konvoluutioneuroverkkoihin (engl. Convolutional Neural Networkiin, CNN), jotka mahdollistavat nopean ja tarkan tilallisten ja ajallisten piirteiden tunnistuksen anturidatasta. Jatkuva tunnistus edellyttää eleiden ajallista seurantaa erilaisia koneoppimisen algoritmeja hyödyntäen, esimerkiksi dynaamisen aikasovittamisen avulla. (Li 2020) Eleiden luokittelussa on käytetty neuroverkkoja ja HMM-malleja (engl. Hidden Markov Model, piilotettu Markovin malli), joista osa on suunnattu erityisesti HRC-sovelluksiin (Mukherjee et al. 2022). Käsieleitä on sovellettu esimerkiksi robottien liikkeen matkimiseen, kokoonpanotehtäviin ja ihmisen ja robotin välisen vuorovaikutuksen parantamiseen (Du et al. 2014, Coupete et al. 2015). Haasteena ovat ennalta määrittelemättömät eleet, joita

on pyritty tunnistamaan generatiivisten mallien avulla (Simao et al. 2019). Tutkimukset osoittavat, että elepohjainen robotin ohjaus voi olla operaattorille yksinkertaisempaa ja nopeampaa kuin perinteisillä ohjauslaitteilla (käsiohjaimilla) toteutettuna (Nuzzi et al. 2021).

Käsieleiden ohella myös katsetta voidaan käyttää kommunikointiin tarjoten tietoa ihmisen huomion kohteesta (engl. Visual Focus of Attention, VFOA) ja tukee aikomusten ennustamista ja toimintojen vuorottelua yhteistyössä (Mukherjee et al. 2022). Silmänliikkeiden mittaaminen on usein kallista ja operaattoria häiritsevää, minkä vuoksi katsetta arvioidaan pään asennon ja kehon suuntauksen perusteella konevision avulla (Sheikhi & Odobez 2015). Turvallisuussyistä katseentunnistuksessa suositaan useita toisiaan tukevia lähteitä (Drawdy & Yanik 2015).

Puhe on toinen ihmiselle luontainen kommunikoinnin muoto ja erityisen intuitiivinen ja tehokas syötemuoto myös robotiikassa. Luonnollinen kieli mahdollistaa monimutkaisten ohjeiden ja parametrien ilmaisemisen. (Plappert et al. 2018) Robottien puheohjausta on hyödynnetty esimerkiksi hydraulimoottorin kokoonpanossa, jossa operaattori kertoo robotille mitä tämän tulee tehdä tai mitä työkaluja tämän tulee käyttää (Ojanen 2024). Puhetta ja liikettä yhdistäviä malleja on kehitetty mm. sekvenssistä sekvenssiin -oppimisen avulla, jolloin robotit kykenevät sekä kuvailemaan havaittua ihmisen liikettä että tuottamaan liikkeitä kielellisten kuvausten perusteella (Plappert et al. 2018). Puheen ja käsieleiden yhdistäminen parantaa merkittävästi tunnistustarkkuutta verrattuna yksittäisiin syötemuotoihin (Maurtua et al. 2018).

3. KONEOPPIMISEN SOVELLUKSET IHMISEN JA ROBOTIN YHTEISTYÖSSÄ

Tekoälyä voidaan määritellä useammalla eri tavalla, riippuen keneltä siitä kysytään. Yleisesti käytössä olevan määritelmän mukaan tekoäly on tietojenkäsittelyn ala, jonka tavoitteena on kehittää järjestelmiä suorittamaan tehtäviä, jotka normaalisti vaativat ihmisen älykkyyttä (Chartrand et al. 2017). Tekoälyn tehtävänä on toteuttaa käyttäjän antamia tehtäviä ja suorittaa näitä ennalta määriteltyjen sääntöjen ja algoritmien mukaisesti (Jakhar & Kaur 2020). Tässä selvityksessä tekoäly nähdään koneoppimisen (engl. Machine Learning, ML) ja syväoppimisen (engl. Deep Learning, DL) kautta, jotka ovat osa tekoälyäkontekstia. Koneoppimisessa järjestelmä parantaa toimintaansa datan ja kokemuksen perusteella, kun taas syväoppiminen on koneoppimisen alalaji, joka hyödyntää useampikerroksisia malleja ja kykenee automaattiseen piirteiden tunnistamiseen (Tarantino 2022).

Koneoppiminen perustuu algoritmeihin, jotka oppivat suurista tietomääristä tunnistamaan kaavoja ja tekemään ennusteita. Järjestelmä kehittää toimintaansa iteratiivisesti tulosten perusteella (Helm et al. 2020). Koneoppiminen jaetaan ohjattuun oppimiseen (engl. supervised learning, SL), ohjaamattomaan oppimiseen (engl. unsupervised learning, USL) ja vahvistusoppimiseen (engl. reinforcement learning, RL) (Baduge et al. 2022). Ohjatussa oppimisessa malli opetetaan ennalta määritellyn datan avulla, ja sitä käytetään esimerkiksi vikojen ja turvallisuusrikkomusten tunnistamiseen. Ohjaamattomassa oppimisessa malli tunnistaa rakenteita suoraan määrittelemättömästä datasta, minkä vuoksi se soveltuu massadatan käsittelyyn, kuten ryhmittelyyn ja ulottuvuuksien vähentämiseen. (Tarantino 2022) Vahvistusoppimisessa järjestelmä oppii vuorovaikutuksessa ympäristön kanssa palkkioiden avulla, ja sitä hyödynnetään erityisesti robotiikassa (Tomé De Andrade e Silva & Azevedo 2022). Koneoppimisen eri alalajien toimintaperiaatteet on kuvattu kuvassa 3 yksityiskohtaisemmin.

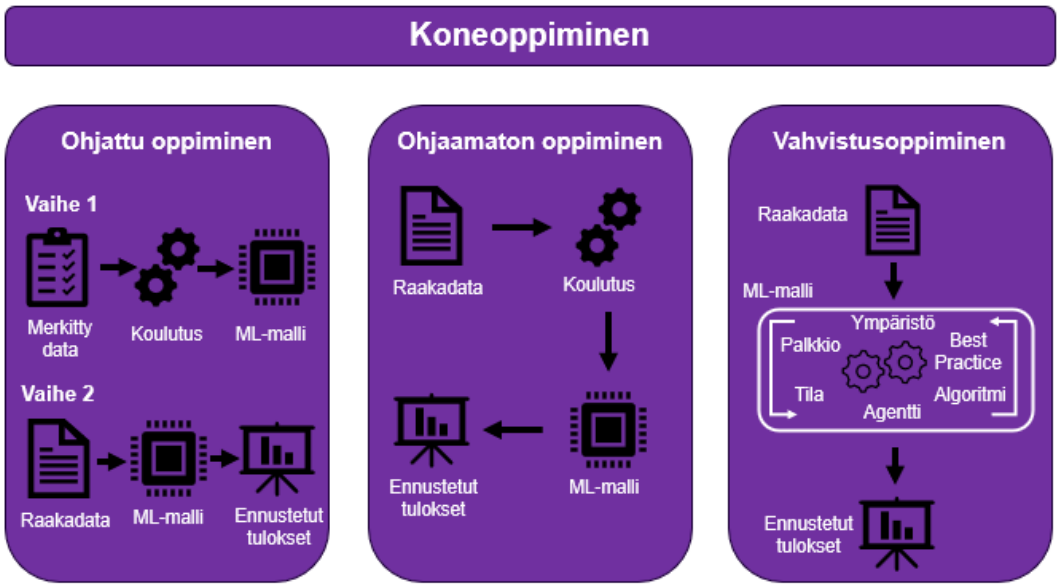

Kuva 3. *Koneoppimisen alalajit (mukaillen lähdettä Baduge et al. 2022).*

Tekoälyn sovelluskohteet valmistavassa teollisuudessa ovat laajat ja moninaiset. Erilaisia koneoppimisen algoritmeja käytetään esimerkiksi valmistusprosessien suunnittelussa, ennakoivassa kunnossapidossa, laadunvalvonnassa, prosessinohjauksessa ja optimoinnissa sekä logistiikassa vain muutamia mainiten (Fahle et al. 2020). Teollisuusrobotiikassa tekoälyä ja sen erinäisiä algoritmeja käytetään muun muassa optimoimaan kokonaisvaltaisesti robottisovellusten toimintaa parantamalla näiden tehokkuutta esimerkiksi tarkemmalla liikehallinnalla (Soori et al. 2023).

Jotta fyysinen yhteistyö ihmisen ja robotin välillä olisi sujuvaa ja intuitiivista, robotin täytyy pystyä tarkkailemaan ympäristöään, tunnistamaan sen nykytila ja päivittämään tätä tietoa jatkuvasti. Kun robotti saa tällaisen tiedon käyttöönsä, se voi oppia arvioimaan, mitä toimintoja sen odotetaan suorittavan ja miten ne kannattaa toteuttaa. (Ogenyi et al. 2021) Esimerkiksi tilanteessa, jossa robotti tekee kokoonpanoa yhdessä ihmisen kanssa, sen tulee tunnistaa kokoonpantavat esineet ja mahdolliset muut esineet työskentelyalueellaan, ennakoida ihmisen aikomukset ja sovittaa oma toimintansa suhteessa näihin esimerkiksi törmäyksien välttämiseksi tai laadukkaan kokoonpanon kannalta. Tällaiset kyvyt eivät ole valmiiksi ohjelmoituja robotille, vaan ne täytyy opettaa sopivien oppimismenetelmien avulla (Ogenyi et al. 2021).

Viime vuosina koneoppiminen on yleistynyt robottien opetuksessa, mikä on auttanut osittain ratkaisemaan monimutkaisuuteen ja laskentatehoon liittyviä haasteita, joita aiheutuu siitä, että jokainen yhteistyön vaihe pitäisi muuten ohjelmoida erikseen (Semeraro et al. 2023). Kun robotti on oppinut tehtävän, seuraava haaste on sen toteuttaminen mahdol-

lisimman tehokkaasti (Ogenyi et al. 2021). Hyvällä tehtäväsuunnittelulla ja toimivilla yhteistyöstrategioilla robotti voi kuitenkin työskennellä ihmisen kanssa tehokkaasti yhteisen tavoitteen saavuttamiseksi (Hernandez et al. 2017). Kilpailuhenkisen ja kustannustehokkaan teollisuuden luonteen vuoksi koneoppimiseen perustuvien järjestelmiä tarvitaan, koska tällaiset järjestelmät ovat tarkempia ja tehokkaampia kuin nykyisin käytössä olevat järjestelmät (Mukherjee et al. 2022).

Arinez et al. (2020) ovat kuvanneet kuvan 4 mukaisesti, kuinka tekoälyä voidaan hyödyntää ihmisen ja robotin yhteistyössä. Kuvasta ensinnäkin huomataan, että ihmisellä on kognitiivisia kyvykkyyksiä vaativia tehtäviä, kuten tehtävien suunnittelua ja allokointia ihmisen ja robotin välillä sekä ongelmanratkaisua ja päätöstentekoa, joihin robotit eivät perinteisesti kykene muuttuvassa tuotantoympäristössä. Huomataan, että ihminen on hyvin joustava ja mukautuva tuotannon resurssi, joka pystyy sopeutumaan muutoksiin. Sen sijaan robotilla on erinäisiä suorittamiseen liittyviä tehtäviä, kuten annettujen tehtävien suorittamista, liikeohjausta, kappaleidenkäsittelyä ja virheentunnistusta. Nämä ovat hyvin automatisoitavissa olevia, tarkkuutta ja toistoa vaativia tehtäviä, joissa robotit ovat vahvimmillaan.

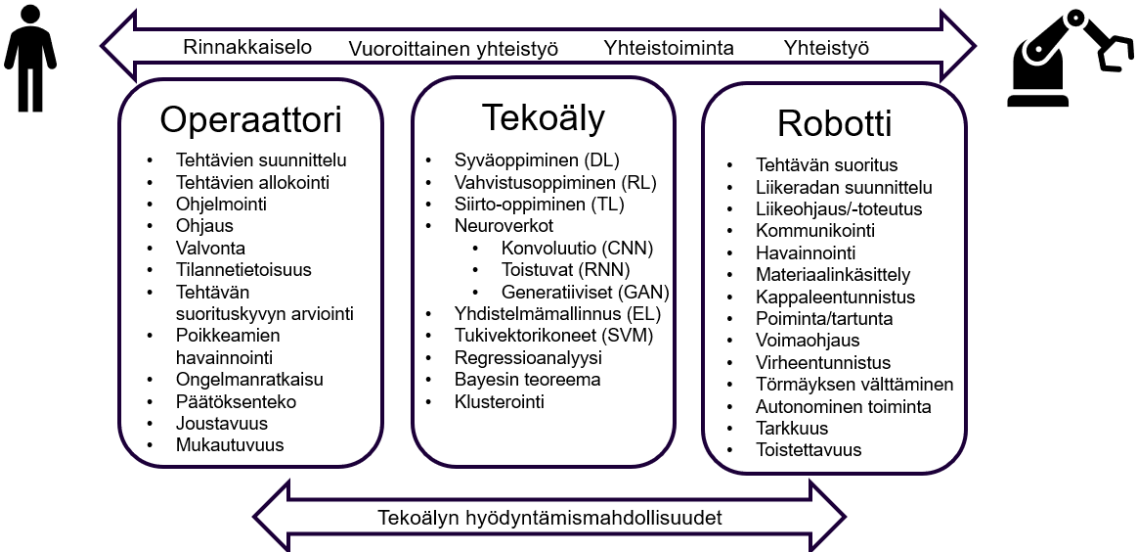

Kuva 4. *Tekoälyn hyödyntämismahdollisuudet ihmisen ja robotin yhteistyössä (mukaillen Arinez et al. 2020).*

Kuvan 4 keskellä on Arinez et al. (2020) näkemyksen mukaisesti tekoäly erilaisine menetelmineen, joita voidaan hyödyntää erilaisissa tuotannon tilanteissa. Tekoälyllä voidaan esimerkiksi siirtää tehtävien suunnittelua ja allokointia erilaisille koneoppimisen algoritmeille, jolloin tuotantoprosesseja voidaan tehostaa paremmalla tehtävänjaolla ihmisen ja robotin välillä. Sama toimii myös toiseen suuntaan: robotilta saatavaa virhedataa

voidaan analysoida ja jatkojalostaa operaattorille selkeämpään muotoon erilaisilla algoritmeilla, jonka pohjalta operaattori voi tehdä luotettavamman tiedon pohjalta päätöksiä toiminnan kehittämiseksi. Tämä mahdollistaa entistä laajemman ja syvemmän ihmisen ja robotin yhteistyön esimerkiksi mahdollistamalla joustavamman työnjaon ihmisen ja robotin välillä.

Seuraavassa osuudessa pureudutaan tarkemmin, miten tekoälyä ja koneoppimista voidaan hyödyntää ihmisen ja robotin yhteistyössä käytännönesimerkkien kautta. Tarkoituksena ei ole esittää kaiken kattavaa listausta eri käyttökohteista eikä käsitellä näitä kovin yksityiskohtaisesti, vaan nostaa ainoastaan poimintoja tuoreimmista tekoälyn ja koneoppimisen tutkimuksista ihmisen ja robotin yhteistyön alueelta.

Tekoälyn ja koneoppimisen sovellusesimerkit

Viimeisen reilun vuosikymmenen aikana useammat tutkijat ovat kehittäneet erilaisia koneoppimisen algoritmeja ja sovelluksia ihmisen ja robotin välisen yhteistyön kehittämiseksi. Näitä on listattuna erinäisiin kirjallisuusselvityksiin, joista ansioituneimpia ovat Liu et al. (2022), Mukherjee et al. (2022), Semeraro et al. (2023) ja Dhanda et al. (2025) kokoamat systemaattisen kirjallisuuskatsaukset tekoälystä ja koneoppimisesta yhteistoiminnallisissa robottisoluissa. Selvityksen lopussa oleva Liite 1 perustuu heidän tutkimuksiinsa ja analyyseihinsä listaten erilaisia koneoppimisen sovelluskohteita ja tutkimusaiheita ihmisen ja robotin yhteistyössä.

Seuraavaksi käydään lävitse muutamia Liitteen 1 koneoppimisen sovelluskohteita ihmisen ja robotin yhteistoiminnassa pääteemoittain. Suurin osa HRC-sovelluksista on kokoonpanotehtäviin liittyviä. Näin ollen tutkimuksissa korostuvat koneoppimisen algoritmit ihmisen toiminnan tunnistamiseen ja ennustamiseen, esineiden ojennukseen ja käsittelyyn, turvallisuuteen ja erilaisiin oppimisenmuotoihin. Esimerkiksi Tourlomousis et al. (2017) hyödynsivät erinäisiä koneoppimisen algoritmeja työpöydän kokoonpanossa.

Ihmisen toiminnan tunnistaminen ja ennustaminen

Ihmisen ja robotin yhteistyön edistämiseksi on kehitetty koneoppimiseen perustuvia järjestelmiä, joissa robotti pystyy tunnistamaan käyttäjän kulloinkin suorittaman tehtävän vaiheen. Tämän tiedon perusteella robotti mukauttaa toimintaansa ja tarjoaa tukea kyseiseen vaiheeseen liittyvien alitehtävien toteuttamisessa. (Dhanda et al. 2025). Esimerkiksi Vinanzi et al. (2020) kuvaavat tilanteen, jossa käyttäjä kokoaa muodon palikoista ja robotti viimeistelee rakenteen saatavilla olevan havainnointitiedon pohjalta. Toisessa esimerkissä Munzer et al. (2018) esittävät esimerkiksi kokoonpanosovelluksen, jossa robotti avustaa käyttäjää joko tulkitsemalla meneillään olevaa työvaihetta tai ennakoi-

malla ja valmistelemalla seuraavat työvaiheet. Liu et al. (2021b) kehittivät työssään vahvistusoppimiseen perustuvaa koulutusmenetelmää, joka huomioi ihmisen käyttäytymisen dynaamiset ja stokastiset ominaisuudet yhteistoiminnallisessa kokoonpanossa. Lopputuloksena he käyttivät kehittämäänsä menetelmää ihmisen ja robotin yhteistoiminnallisessa kokoonpanotehtävässä, osoittaen, että ehdotettu menetelmä kykenee ohjaamaan robottia edustavaa agenttia tekemään yhteistyötä operaattorin kanssa myös silloin, kun ihminen suorittaa työvaiheita satunnaisessa järjestyksessä (Liu et al. 2021b). Rahman et al. (2015) käyttivät luottamuspohjaista MPC:tä (engl. Trust-based Model Predictive Control, MPC) ihmisen ja robotin yhteistyökokoonpanon tehtävänjaon hallintaan tuotannossa. MPC:tä käytettiin minimoimaan ihmisen ja robotin nopeusvaihteluja ja kasvattamaan ihmisen ja robotin luottamusta toisiinsa (Rahman et al. 2015).

Esineiden luovutus ja käsittely ihmisen ja robotin välillä

Ihmisen ja robotin yhteistyön merkittävimpiä tehtäviä ovat esineiden luovutus toimijoiden välillä sekä esineiden käsittely, jossa ihminen ja robotti käsittelevät yhtäaikaisesti esinettä ilman siitä irrottamista (Dhanda et al. 2025). Molemmissa tapauksissa robotin on tulkittava tarkasti käyttäjän aikomukset ja odotukset esineitä siirrettäessä useiden vaihtoehtojen joukosta (Shukla et al. 2018). Yhteistyöroboteilta odotetaan kykyä päättää, milloin ne ottavat vuoronsa yhteistoiminnallisessa tehtävässä erilaisia syötteitä havainnoimalla (Mukherjee et al. 2022).

Esineiden luovuttamiseksi muun muassa Nikolaidis et al. (2015) ja Peternel et al. (2019) kehittivät tutkimuksissaan robottisovellukset, joissa robotit toimivat käyttäjää tukevassa roolissa pitämällä ja asettamalla esineitä käyttäjän aikomusten ja optimointiparametrien perusteella esimerkiksi kiillotus- ja poraustehtävissä. Vastaavasti Ojanen (2024) kehitti puheohjauksella toimivan kokoonpanosovelluksen, jossa robotti pystyy ojentamaan operaattorille työkalun operaattorin antaman audiokomennon perusteella. Zhou & Wachs (2018) kehittivät kognitiivisen vuoronottomallin, joka perustuu piikkipohjaiseen neuroverkkoon (engl. Spiking Neural Network, SNN) ja jonka avulla ennustetaan, milloin robotin tulisi ottaa vuoro analysoimalla ihmisen viestintäsyötteitä ja ennakoimalla hänen toimintaansa. Viitekehys validoitiin simuloidussa kirurgisessa toimenpiteessä, jossa robotti instrumenttihoitajana ennusti kirurgin aikomukset ja ojensi tarvittavat leikkausvälineet. (Zhou & Wachs. 2018)

Esineiden käsittelyssä Roveda et al. 2019 ja Sasagawa et al. 2020 kuvaavat järjestelmiä, joissa robotit tarjoavat käyttäjälähtöistä tukea tehtävissä, kuten ruokailuvälineiden pitä-

misessä tai ruoan annostelun koordinoinnissa. Teollisessa kontekstissa tätä on hyödyntänyt esimerkiksi Hietanen et al. (2020) tehtävässä, jossa ihminen ja yhteistyörobotti asentavat yhdessä akselia dieselmoottorikokoonpanossa.

Turvallisuuden parantaminen operaattorin liikkeentunnistuksella

Ihmisen ja robotin yhteistyössä on erityisen tärkeää pitää operaattori turvassa robotin kanssa työskennellessä (Fahle et al. 2020). Tekoälysovellukset avaavat uusia mahdollisuuksia tämän toteuttamiseen operaattorin liikkeentunnistuksella. Esimerkiksi Duckworth et al. (2019) käyttivät ensin valvomattoman oppimisen menetelmiä ihmisen liikkeiden muuntamiseen matalamman ulottuvuuden dataksi ja tämän jälkeen konvoluutioneuroverkkoa (engl. Convolutional Neural Network, CNN) ihmisen asentojen arviointiin, mitä puolestaan voidaan hyödyntää yhteistoiminnallisen robottisolun turvallisuuden edistämiseen vertaamalla ihmisen valvottuja ja valvomattomia lähestymistapoja robottisolussa.

Liu et al. (2017) käyttävät piilotettua Markovin mallia (engl. Hidden Markov Model, HMM) ihmisen liikkeiden ennustamiseen yhteistyöperusteisessa moottorin kokoonpanotilanteessa, neuroverkkopohjaisen ratkaisun sijaan. Dröder et al. (2018) loivat kokeellisen simulaatioalustan, jonka avulla voidaan tutkia, miten ihmiset ja robotit toimivat yhdessä. Alustassa robotti suunnittelee liikkumisreittinsä älykkäästi konvoluutioneuroverkko- ja klusterianalyysimenetelmien avulla, ja se tunnistaa ympäristön esineet neuroverkon avulla. Alustassa ei pyritä ennustamaan ihmisen liikkeitä, vaan arvioimaan turvallisia alueita, joilla robotti voi liikkua ilman vaaratilanteita. Lisäksi järjestelmä hyödyntää syvyystietoa, jotta ihmisen liikkeet voidaan mallintaa ja sijoittaa tarkasti ympäristöön (Lemmerz et al. 2019). Liu et al. (2021a) keskittyivät teollisen ihmisen ja robotin yhteistyön turvallisuusongelmaan ja käyttivät vahvistusoppimisen algoritmeja (engl. Deep Deterministic Policy Gradient , DDPG) sen ratkaisemiseksi. He ottivat ihmisen käden esteen havaintona ja tämän perusteella ohjasivat ja mukauttivat reaaliaikaisesti käsivarsirobotin liikerataa törmäysten välttämiseksi (Liu et al. 2021a).

Jäljittelyoppiminen robotiikassa

Wang et al. (2018) kehittivät tutkimuksessaan jäljittelyoppimista eli imitaatio-opetusta (engl. Imitation Learning). Menetelmän avulla yhteistyörobotti oppii ihmisen suorittamista demonstraatioista ja kykenee avustamaan ihmistä jaetuissa työtilanteissa. Lähestymistavassa ihminen voi ohjelmoida robottia luonnollisen kielen avulla omien työskentelymieltymyksiensä mukaisesti. Robotti oppii kokoonpanotehtäviä ihmisen demonstraatioiden perusteella hyödyntäen maksimi-entropiaan perustuvaa käänteistä vahvistusoppimista. Menetelmää testattiin konkreettisessa kokoonpanotehtävässä, ja oppimisprosessin aikana robotti päivittää tietämystään optimaalisen kokoonpanostrategian mukaisesti.

Yhteistyövaiheessa robotti käyttää oppimaansa tietoa avustaakseen aktiivisesti ihmistä yhteistoiminnallisessa kokoonpanotehtävässä. (Wang et al., 2018) Vastaavanlaista tutkimusta ovat tehneet Rozo et al. (2016), jotka tutkivat ihmisen ja robotin yhteistyötä nosto-, kuljetus- ja kokoonpanotehtävissä. He kehittivät imitaatio-opetukseen perustuvan menetelmän robotin liikkeen tuottamiseksi. (Rozo et al. 2016)

4. CASE: PUHEOHJAUS

Edeltävässä luvussa esiteltiin isommassa kuvassa erilaisia koneoppimisen sovelluksia ja menetelmiä, jotka mahdollistavat ihmisen ja robotin välisen yhteistyön. Tässä luvussa keskitytään tarkemmin yhteen koneoppimisen osa-alueeseen yhteistoiminnallisten robottisolujen toteutuksessa – robotin puheohjaukseen. Puheohjausta on käytetty menestyksekkäästi monissa ihmisen ja robotin yhteistyösovelluksissa, erityisesti kokoonpanotehtävissä (Ojanen 2024), mutta myös esimerkiksi hitsauksessa (Angleraud et al. 2021). Luvun ensisijaisena tavoitteena on kuvata yksityiskohtaisemmin, minkälaisia ominaisuuksia puheohjaukseen liittyy sekä kuinka puheohjaus toteutetaan ja millaisia eri vaiheita siihen kuuluu. Tarkoituksena on osoittaa, että koneoppimisen menetelmien hyödyntäminen ei ole aina kovin yksinkertaista.

Puheohjauksessa ihminen antaa robotille ohjeita, kuinka sen tulisi toimia. Ihmisen ja robotin yhteistyössä puheohjauksen yhtenä etuna on se, että se mahdollistaa ihmisen keskeytyksettömän työskentelyn molemmat kädet vapaina (Gustavsson et al. 2018), mikä ei ole mahdollista esimerkiksi robottien käsiohjaimien kautta kommunikoitaessa. Lisäksi sanallisella viestinnällä voidaan välittää enemmän tietoja ja komentoja kuin perinteisillä ohjausmenetelmillä (Ekrekli et al. 2023). Lisäksi ohjaus voi olla paljon dynaamisempaa, kun reaaliajassa pystytään antamaan ohjeita robotilla mitä sen tulisi tehdä.

Puheohjaus voi olla myös kaksisuuntaista: sen sijaan, että vain ihminen antaa komentoja robotille, niin myös robotti pystyy vastaamaan käyttäjälle (Salehzadeh et al. 2022). Robotti voi esimerkiksi antaa operaattorille ohjeita tehtävän suorittamiseen tai kertoa omista aikomuksistaan, jos ihmisellä ei ole esimerkiksi selvää käsitystä suoritettavasta tehtävästä (Devin & Alami 2016, Buisan et al. 2020). Robottien kommunikointi operaattoreille lisää luottamusta robotteihin (Zhu & Williams 2020) ja voi parantaa yhteistyön tehokkuutta ja sujuvuutta (Salehzadeh et al. 2022).

Puheohjauksen haasteena on se, että nykyisin suurin osa järjestelmistä tunnistaa ainoastaan yksittäisiä sanoja tai komentoja, jolloin näiden määrän on oltava rajallinen ja niiden on oltava muodoltaan hyvin yksinkertaisia ja selkeitä, jotta niitä olisi nopea prosessoida (Angleraud et al. 2021). Tilanne on kuitenkin paranemassa tulevaisuudessa, kun järjestelmät pystyvät enenevissä määrin käsittelemään luonnollista kieltä (Thierauf et al. 2023), jolloin puheohjauksen ei tarvitse pohjautua pelkästään rajattuun määrään yksittäisiä sanoja tai komentoja vaan voi olla pohjimmiltaan enenevissä määrin tavanomaista puhetta, mikä puolestaan helpottaisi yhteistyötä erityisesti robottisovelluksen käyttäjän

kanssa (Angleraud et al. 2021). Voidaan kuitenkin todeta, että kirjaimelliset komennot ovat usein luotettavampia ja nopeampia, koska niiden tunnistusprosessi on yksinkertaisempi ja komennot ennalta määriteltyjä. Luonnollinen kieli taas on käyttäjälle luontevampaa ja mahdollistaa monipuolisemman viestinnän. (Ojanen 2024)

Käytettyjen komentojen ohella haasteena on teollisuudelle tyypillinen taustamelu, joka voi häiritä puheen luotettavaa tunnistamista ja aiheuttaa väärinkäsityksiä (Villani et al. 2018). On tärkeää, että komennot tunnistetaan oikein ja yhdistetään oikeaan toimintaan tai kohteeseen. Myös se, miten komennot ilmaistaan, vaikuttaa onnistumiseen. (Ojanen 2024) Robotin on myös kyettävä tunnistamaan, oliko komento tarkoitettu sille, vai oliko kyseessä ulkopuolinen häiriö (Li et al. 2023), kuten yleinen robotin lähellä.

Puheohjauksen voi ajatella koostuvan kahden erillisen ongelman ratkaisemisesta: puheen tunnistamisesta sekä puheen ymmärtämisestä (Parikka 2024). Monet puheentunnistukseen liittyvät teknologiat perustuvat Markovin piilomalleihin (engl. Hidden Markov Model, HMM), syviin neuroverkkoihin (engl. Deep Neural Network, DNN), toistoneuroverkkoihin (engl. Recursive Neural Network, RNN) tai muihin tekoälyyn, koneoppimiseen ja syväoppimiseen liittyviin menetelmiin (Malik et al. 2021). Nykyiset puheeseen liittyvät teknologiat voidaan jakaa karkeasti seuraaviin osa-alueisiin: automaattinen puheentunnistus (engl. Automatic, Speech, Recognition, ASR), luonnollisen kielen käsittely (engl. Neural Language Processing, NLP), tekstistä puheeksi -muunnos, puhujan varmistus ja puhujan tunnistus. (Li et al. 2023)

ASR-järjestelmän tarkoitus on muuntaa puhuttu puhe tekstiksi, ja se toimii useassa vaiheessa. Ensin se suodattaa äänisignaalista kohinan pois erilaisilla suodattimilla ja algoritmeilla sekä poimii siitä tärkeitä piirteitä ja poistaa tarpeettomia piirteitä, jotka tätä kautta auttavat luokitteluvaiheessa tunnistamaan sanoja. Näiden piirteiden avulla järjestelmä luokitteluvaiheessa ennustaa syötesignaalia vastaavaa tekstiä aiemmin poimittujen piirteiden avulla. Ennuste voidaan tehdä esimerkiksi yhteisjakaumien tai parametrimallien avulla, jotka on opetettu harjoitusaineistolla, tai sitten hybridimenetelmillä, kuten HMM:n ja neuroverkkojen yhdistelmillä. Vaikka kielimallit eivät ole aina välttämättömiä, niiden avulla voidaan parantaa järjestelmän tarkkuutta. (Ojanen 2024)

Kun puhe on muutettu tekstiksi, seuraava vaihe on sen ymmärtäminen luonnollisen kielen käsittelyn avulla, missä tavoitteena on saada tietokoneet ymmärtämään puhetta. Tekstin käsittelyssä käytetään useita vaiheita, kuten tekstin jakamista pienempiin osiin, sanojen perusmuotojen tunnistamista, lauseiden kieliopillisen rakenteen tarkistamista ja sen varmistamista, että sanat ymmärretään oikein asiayhteydessä. Lisäksi järjestelmä

pyrkii selvittämään, mihin aiempiin lauseisiin viitataan ja ymmärtämään lauseen todellisen merkityksen, jos se poikkeaa kirjaimellisesta tulkinnasta, kuten sarkasmista. (Ojanen 2024) Kun puhe on ymmärretty, pystytään robotille määrittämään tarvittavat liikekäskyt seuraavissa vaiheissa.

5. KONEOPPIMISEN HYÖDYNTÄMISEN RAJOITTEITA

Tekoälyn ja koneoppimisen avulla voidaan automatisoida monia toistuvia ja arkipäiväisiä teollisuuden tehtäviä, kun näitä hyödynnetään päätöksenteossa joko päätöksenteon tukena tai kokonaan ihmisen korvaajana. Tekoälyn ja koneoppimisen avulla järjestelmät voivat analysoida suuria datamääriä ja tehdä tietoon perustuvia päätöksiä, mikä parantaa niiden päätöksentekokykyä. Näiden teknologioiden avulla järjestelmät voivat sopeutua muuttuviin ympäristöihin ja tehtäviin, mikä lisää niiden monipuolisuutta ja suorituskykyä. Tämä johtaa parempiin tuloksiin ja tehokkaampiin toimintatapoihin (Soori et al. 2023). Nämä teknologiat voivat auttaa järjestelmiä sopeutumaan muuttuviin ympäristöihin ja tilanteisiin, mikä tekee niistä monipuolisempia ja kykeneviä käsittelemään laajempaa tehtäväkirjoa (Zohuri et al. 2022).

Tekoäly on mahdollistanut yhteistyörobottien kehittämisen siten, että ne kykenevät tekemään monimutkaisia päätöksiä ja toimimaan autonomisesti. Tekoäly lisää robottien itsenäisyyttä ja parantaa niiden kykyä avustaa monenlaisissa tehtävissä (Dhanda et al. 2025). Tekoälypohjaiset robotit voivat sopeutua muuttuviin ympäristöihin ja tehtäviin, mikä tekee niistä monipuolisia ja hyödyllisiä useissa eri sovelluksissa (Soori et al. 2023). Tämä kehitys perustuu kehittyneisiin koneoppimisalgoritmeihin, joiden avulla yhteistyörobotit voivat optimoida prosesseja ja parantaa toiminnallista tehokkuutta (Arinez et al. 2020). Samalla tämä korostaa tekoälyn keskeistä roolia ihmisen ja robotin välisen yhteistyön edistämisessä. Näiden teknologioiden avulla voidaan parantaa robottijärjestelmien tarkkuutta ja täsmällisyyttä, vähentää virheitä sekä parantaa yleistä suorituskykyä (Soori et al. 2023). Lisäksi tekoäly mahdollistaa inhimillisen asiantuntemuksen ja tekoälypohjaisten ratkaisujen yhdistämisen, mikä parantaa toiminnan tehokkuutta ja laatua (Scherer 2016).

Tekoälyn tuomista mahdollisuuksista huolimatta on olemassa lukuisia haasteita, jotka rajoittavat tekoälyn hyödyntämistä ihmisen ja robotin yhteistyösovelluksissa teollisessa kontekstissa. Haasteet liittyvät erityisesti dynaamisiin tuotantoympäristöihin, tekoälyn kouluttamiseen sekä tietoturvaan (Dhanda et al. 2025). Seuraavassa esitetään joitakin yleisimpiä selvityksen aikana esiin nousseista haasteista. Luettelo ei ole kaiken kattava, ja se muuttuu tekoälyratkaisujen kehittyessä.

Laboratorio- ja tuotantoympäristöjen erot

Tekoälyyn pohjautuvia robottisovelluksia suunnitellaan, koulutetaan ja testataan simulaattoreissa ja laboratorioympäristöissä, jotka ovat tyypillisesti hyvin hallittuja, rajattuja ja staattisia ympäristöjä. Haasteeksi on muodostunut, kuinka laboratorioissa toimiviksi todetut sovellukset saadaan siirrettyä dynaamisiin tuotantoympäristöihin, joissa on enemmän häiriötekijöitä, muuttuvia tekijöitä ja epävarmuutta. (Liu et al. 2022) Tekoälyn hyödyntämät mallit ovat tunnetusti herkkiä ympäristön häiriöille (Mukherjee et al. 2022).

Kliinisessä hallitussa laboratorioympäristössä suunniteltua ja testattua tekoälypohjaista yhteistoiminnallista sovellusta ei voida suoriltaan siirtää dynaamiseen tuotantoympäristöön. Perimmäinen syy tähän on, ettei kliininen laboratorioympäristö tai simulaattori pysty esittämään todellista tuotantoympäristöä lukuisine muuttuvine parametreineen realistisesti. (Liu et al. 2022) Tällöin laboratorioympäristössä toimivat sovellukset eivät toimi todellisessa tuotannossa ilman näiden uudelleen kouluttamista tai säätämistä (Liu et al. 2022, Mukherjee et al. 2022).

Tyypillisesti tekoälyyn pohjautuvat ratkaisut ovat sovelluskohtaisia (robotti-, tehtävä- ja ympäristökohtaisia). Haasteena on, kuinka tekoälyllä tiettyyn sovellukseen suunnitellut ratkaisut ovat siirrettävissä, skaalattavissa ja yleistettävissä muihin sovelluksiin. (Jaquier et al. 2024) Itse tekoälysovelluksen periaatetta voidaan käyttää useissa robottijärjestelmissä, mutta näiden kouluttaminen uudessa ympäristössä sekä tarvittavien antureiden ja robottien integroiminen on edelleen haasteellista. (Liu et al. 2022)

Useimmat tekoälyä, muodossa tai toisessa, hyödyntävät ihmisen ja robotin yhteistyöhön suunnitellut sovellukset on toteutettu laboratorioympäristöissä pienehköillä yhteistyöroboteilla eli coboteilla, jotka ovat tyypillisesti verrattain kevyitä suhteessa muihin teollisuudessa käytössä oleviin yhteistyörobotteihin puhumattakaan perinteisistä teollisuusroboteista. Haasteeksi muodostuukin, kuinka kevyillä yhteistyöroboteilla kehitetty ratkaisut laboratorio-olosuhteissa pystytään siirtämään raskaimmille roboteille teollisiin olosuhteisin. (Mukherjee et al. 2022)

Teollisten tuotantoympäristöjen ominaispiirteet

Teollisten järjestelmien monimutkaisuuden kasvaessa epälineaaristen ja stokastisten toimintojen hallinta muuttuu haastavaksi epävarmuuksien ja keskinäisten riippuvuuksien vuoksi (Borboni et al. 2023). Ihmisen ja robotin yhteistyössä kohdataan enemmän epävarmuutta aiheuttavia tekijöitä kuin perinteisissä aidatuissa robottisovelluksissa. Perimmäisenä syynä on ihminen, koska ihmisen käyttäytyminen on luonnostaan muuttuvaa ja vaikeasti ennustettavaa. (Yalçinkaya et al. 2023) Tällaiset stokastiset olosuhteet, eli sa-

tunnaisuutta ja epävarmuutta aiheuttavat tekijät, ovat väistämättömiä dynaamisissa teollisissa ympäristöissä. Epävarmuuksien arvioiminen ja tuntemattomien tekijöiden tunnistaminen on edelleen haastavaa. Erityisesti tekoälysovellusten kouluttaminen selviytymään näistä satunnaisista olosuhteista, on edelleen avoin ja vaikea ongelma ratkaistavaksi. (Liu et al. 2022) Tämä puolestaan johtaa siihen lopputulemaan, että tekoälypohjaiset yhteistoiminnalliset robottisovellukset ovat haastavia toteuttaa ihmisen perusolemuksen takia.

Kuten edellä jo osin sivuttiin, tekoälysovellukset on tyypillisesti suunniteltu ja tarkoitettu ennalta määritettyyn käyttökohteeseen (Firoozi et al. 2025), jossa on käytössä tarkasti määritellyt ja spesifioidut laitteistot. Haasteeksi muodostuu, kuinka tarkasti spesifioitu laitteisto pystytään integroimaan heterogeeniseen tuotantoon, jossa on hyvin vaihteleva laitekanta aina tuoreimmista laitteista vanhoihin ”legacy” järjestelmiin (Urrea & Kern 2025). Heterogeeninen laitekanta tarkoittaa erilaisia anturointeja, tiedonsiirtoratkaisuja, -väyliä ja -protokollia, jolloin tekoälysovellus tulee pystyä integroimaan näihin. Tekoälyn kehityksen ja soveltamisen edetessä on tärkeää pohtia, mitkä tekoälyn alalla nykyisin saatavilla olevista lukuisista teknologioista, laitteistoista ja menetelmistä ovat todennäköisimmin menestyksekkäästi sovellettavissa robotteihin sekä miten niitä voidaan mukauttaa tiettyihin tehtäviin ja ympäristöihin (Billard et al. 2025).

Tekoälyn ja koneoppimisen rajoitteet

Useat kirjallisuuskatsaukset teollisuuden ihmisen ja robotin yhteistyöstä osoittavat, että nykyinen tutkimus ei tarjoa yhtä ainoaa, yleispätevää tekoälyn ja koneoppimisen menetelmää, jolla ihmisen ja robotin yhteistoimintaa voitaisiin tehostaa. Sen sijaan tarjolla on monenlaisia teknologisia lähestymistapoja ja algoritmeja, joita sovelletaan eri tehtäviin ja vuorovaikutusmalleihin. Yksi tällainen järjestelmällinen katsaus analysoi lähtökohtaisesti koneoppimisen tekniikoita HRC:ssa ja toteaa, että tutkimuksessa käytetään laajasti erilaisia algoritmeja (valvottu oppiminen, valvomaton oppiminen, vahvistusoppiminen jne.) ja eri anturointitekniikoita, ilman yhtä yhteisesti hyväksyttyä ratkaisua tai toimintamallia HRC-järjestelmille (Semeraro et al. 2023). Tämä viittaa nimenomaan siihen, että ei ole yhtä oikeaa “parasta” menetelmää AI:n (engl. Artificial Intelligence) soveltamiseen ihmisen ja robotin yhteistyössä, vaan tutkimuskenttä elää edelleen moninaisten lähestymistapojen tutkimisena ja vertailuna. On selkeä tarve menetelmien standardisoinnille, jolla saadaan jalkautettua tekoälypohjaiset HRC sovellukset teollisuuteen.

Yhtenä suurimmista ongelmista ovat rajalliset määrät valmiita ja soveltuvia datasettejä tekoälyn kouluttamiseen ihmisen ja robotin yhteistyössä (Plahl et al. 2025). Käytännössä jokaiseen sovelluskohteeseen on kerättävä tai muokattava oma koulutusdatasetti ja

yleiskäyttöiset tai täysin sellaisenaan uudelleenhyödynnettävät datasetit ovat harvinaisia. Koulutusaineiston luominen on erityisen haastavaa yhteistoiminnallisille robottisovelluksille turvallisuuden näkökulmasta. Tämä johtuu siitä, että simulointidata ei pysty kuvaamaan ihmisen käyttäytymisen ja sen seurausten epävarmuutta, ja koska turvallisuuspoikkeamadataa on niukasti, jolloin turvallisuusmallien on luotettava innovatiivisiin tapoihin hankkia koulutusdataa. (Mukherjee et al. 2022)

Tekoälypohjaisilla järjestelmillä on vaarana, että ne viritetään ylitse vaaditun tarpeen (engl. overfitting). On hyvin vaikea määrittää, milloin järjestelmä on riittävän optimoitu juuri kyseiseen sovellukseen. (Mukherjee et al. 2022)

Universaalin ratkaisun suunnittelu on haastavaa, koska jokaisen teollisuuden ja jopa yrityksen vaatimukset ovat ainutlaatuisia. Kaikki teolliset sovellukset eivät voi olla tekoälypohjaisia, vaan niiden sijasta voidaan hyvin käyttää myös perinteisiä hyvin toimivia tekoälyttömiä ratkaisuja.

Turvallisuus

Turvallisuus asettaa moninaisia haasteita tekoälyn hyödyntämiselle ihmisen ja robotin yhteistyössä lähtien aina ihmisen ja robotin törmäysten välttämisestä aina tietoturvaan asti. Tällä hetkellä suurin osa tekoälyä hyödyntävistä ihmisen ja robotin yhteistyösovelluksista ovat tutkimuslaboratorioissa toteutettuja. Haasteeksi onkin muodostunut, kuinka nämä tekoälyllä varustetut sovellukset saadaan vastaamaan kansainvälisiä teollisia standardeja, jotta niitä voitaisiin hyödyntää valmistavassa teollisuudessa. (Liu et al. 2022)

Teollisuusrobotiikan turvallisuusstandardien tiukentuneet vaatimukset (SFS-EN ISO 10218-1&2: 2025) on täytettävä tavalla tai toisella, jotta voidaan osoittaa robottisovelluksen täyttävän vaaditut turvallisuusvaatimukset robottisovelluksen käyttämiseksi teollisessa ympäristössä. Tekoälyn näkökulmasta haasteeksi voi nousta toiminnallisen turvallisuuden asettamat vaatimukset riittävän suoritustason (engl. Performance Level) eli *PL* tason saavuttamiseksi tekoälypohjaisessa ihmisen ja robotin yhteistyössä. Tyypillisesti tekoälysovelluksissa käytettävät turvallisuuteen käytettävät komponentit, esimerkiksi erilaiset konenäkösovellukset, eivät ole turvaluokiteltuja, mikä estää robottisovelluksen hyödyntämisen sellaisenaan teollisuudessa.

Mikäli tekoälysovelluksella on tarkoitus estää ihmisen ja robotin välinen törmäys, sen tulisi pystyä tunnistamaan ihmisen ennakoimattomat toiminnot luotettavasti ihmisen ja robotin yhteisessä työskentelytilassa, mikä on haastavaa. Turvajärjestelmän tulisi pystyä reagoimaan mikäli ihminen on väärässä paikassa tai suorittaa väärään aikaan tiettyä

toimintoa, mikä voi johtaa virheelliseen toiminnon suorittamiseen (Koch 2019, Mukherjee et al. 2022).

Tekoälysovellusten suunnittelussa ja käyttöönotossa teollisuusrobotiikassa on välttämätöntä huomioida kyberturvallisuus osana kokonaisvaltaista järjestelmäturvallisuutta. Nykyaikaiset teollisuusrobotit ovat yhä useammin verkottuneita, etähallittavia ja osana laajempia kyberfyysisiä tuotantojärjestelmiä (engl Cyber-physical Production Systems), mikä altistaa ne erilaisille kyberuhille (Abubakar & Abada, 2024; Verma et al., 2025). Kyberhyökkäykset voivat kohdistua esimerkiksi robotin ohjausjärjestelmiin, anturidataan tai tekoälypohjaisiin päätöksentekomalleihin, ja niiden seuraukset voivat ulottua tietoturvaloukkauksista fyysisiin turvallisuuspoikkeamiin tuotantoympäristössä. Tekoälyn hyödyntäminen robotin autonomisessa päätöksenteossa ja adaptiivisessa käyttäytymisessä lisää järjestelmien monimutkaisuutta ja samalla hyökkäyspinta-alaa.

Aiempi tutkimus on osoittanut, että koneoppimismallit ovat alttiita muun muassa syötteen manipuloinnille ja adversariaalisille hyökkäyksille, jotka voivat johtaa virheellisiin tulkintoihin ihmisen toiminnasta tai ympäristön tilasta (Carr et al., 2022). Teollisuusrobotiikassa tällaiset virheet voivat ilmetä esimerkiksi robotin odottamattomina liikeratoina, virheellisinä reagointeina ihmisen läsnäoloon tai tuotantoprosessin häiriöinä, mikä korostaa kyberturvallisuuden ja työturvallisuuden välistä vahvaa kytkentää. Tästä syystä tekoälysovellusten kehittämisessä teollisuusrobotiikkaan on huomioitava turvallinen suunnittelu (engl. secure-by-design), vahva autentikointi, pääsynhallinta sekä tekoälymallien luotettavuuden ja eheyden varmistaminen koko niiden elinkaaren ajan (Abubakar & Abada, 2024, Verma et al. 2025).

Fyysisen ja kyberturvallisuuden lisäksi tekoälyratkaisuilta vaaditaan psykologista turvallisuutta. Tällä tarkoitetaan sitä, että operaattorin on pystyttävä luottamaan tekoälyllä ohjattuun autonomiseen järjestelmään ilman pelonsekaisia tuntemuksia. (Seeber et al. 2019) Käyttäjän tulisi myös hyväksi tekoälypohjainen robotiikka työparinaan (Adebayo et al. 2024).

6. YHTEENVETO

Tässä OPLITE-hankkeelle (*Optimaalista lisäarvoa teknologiasta*) tehdyssä selvityksessä tarkasteltiin tekoälyn ja erityisesti koneoppimisen mahdollisuuksia ihmisen ja teollisuusrobotin yhteistyössä (Human–Robot Collaboration, HRC) muuttuvissa ja dynaamisissa tuotantoympäristöissä. Lähtökohtana on valmistavan teollisuuden kasvava tarve joustavuudelle, mukautuvuudelle ja tehokkuudelle tilanteessa, jossa perinteiset jäykät robottisovellukset eivät kykene vastaamaan nopeasti vaihteleviin tuotantovaatimuksiin. Tekoäly nähdään keskeisenä mahdollistajana tämän haasteen ratkaisemisessa.

Selvityksessä tarkasteltiin ihmisen ja robotin yhteistyön eri tasoja rinnakkaiselosta tiiviiseen yhteistyöhön sekä niihin liittyviä turvallisuusvaatimuksia ja -standardeja, korostaen robotin kasvavaa tarvetta tilannetietoisuuteen, ympäristön havainnointiin ja reaaliaikaiseen reagointikykyyn yhteistyön syventyessä. Tekoäly ja koneoppiminen nähtiin tähän ratkaisuna ja erityisesti koneoppimisen roolia havainnollistetaan sovellusesimerkein, jotka kattavat ihmisen toiminnan ja aikomusten tunnistamisen ja ennustamisen, esineiden luovutuksen ja yhteiskäsittelyn, liikkeentunnistukseen perustuvan turvallisuuden parantamisen sekä jäljittelyoppimisen robottien opetuksessa hyödyntäen monenlaisia menetelmiä kuten vahvistusoppimista, ohjattua oppimista ja ohjaamatonta oppimista.

Työn case-esimerkkinä syvennyttiin robottien puheohjaukseen, jota pidetään erityisen intuitiivisena ja tehokkaana ihmisen ja robotin välisen vuorovaikutuksen muotona. Puheohjauksen tekninen toteutus koostuu puheen tunnistuksesta ja luonnollisen kielen ymmärtämisestä, ja sen etuina ovat operaattorien käsien vapautuminen työtehtävien suorittamiseen, dynaaminen ohjaus sekä yhteistyön sujuvuuden parantuminen. Haasteita aiheuttavat kuitenkin teollisuusympäristöjen melu, rajallinen komentojen ymmärrys sekä järjestelmien luotettavuus- ja turvallisuusvaatimukset.

Tekoälyn hyödyntämistä ihmisen ja robotin yhteistyössä rajoittavat erityisesti laboratorio- ja tuotantoympäristöjen erot, koulutusdatan niukkuus, turvallisuusvaatimukset sekä heterogeeniset laitekannat, minkä vuoksi yleispätevää ratkaisua ei ole, vaan tekoälyllä toimivat yhteistoiminnalliset sovellukset vaativat tapauskohtaista suunnittelua. Tästä huolimatta tekoäly ja koneoppiminen tarjoavat merkittäviä mahdollisuuksia ihmisen ja robotin yhteistyön kehittämiseen, mutta näiden laajempi teollinen käyttöönotto edellyttää yhä teknisten, turvallisuuteen liittyvien ja käytännön haasteiden ratkaisemista sekä menetelmien standardisointia.

LÄHTEET

Abubakar J, Abada W. Addressing cybersecurity challenges in robotics: a comprehensive overview. Comput Secur. 2024;135:103550.

Adebayo RA, Obiuto NC, Olajiga OK, Festus-Ikhuoria IC. AI-enhanced manufacturing robotics: a review of applications and trends. World J Adv Res Rev. 2024;21(3):2060–2072.

Aivaliotis P, Aivaliotis S, Gkournelos C, Kokkalis K, Michalos G, Makris S. Power and force limiting on industrial robots for human-robot collaboration. Robot Comput Integr Manuf. 2019;59:346–360.

Alves J, Lima TM, Gaspar PD. Is Industry 5.0 a human-centred approach? A systematic review. Processes. 2023;11(1):193–.

Angleraud A, Mehman Sefat A, Netzev M, Pieters R. Coordinating shared tasks in human–robot collaboration by commands. Front Robot AI. 2021;8:734548.

Arents J, Abolins V, Judvaitis J, Vismanis O, Oraby A, Ozols K. Human–robot collaboration trends and safety aspects: a systematic review. J Sens Actuator Netw. 2021;10(3):48–.

Arents J, Greitans M. Smart industrial robot control trends, challenges and opportunities within manufacturing. Appl Sci. 2022;12(2):937–.

Arinez JF, Chang Q, Gao RX, Xu C, Zhang J. Artificial intelligence in advanced manufacturing: current status and future outlook. J Manuf Sci Eng. 2020;142(11).

Baduge SK, Thilakarathna S, Perera JS, Arashpour M, Sharafi P, Teodosio B, et al. Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications. Automation in construction. 2022;141.

Bauer A, Wollherr D, Buss M. Human–robot collaboration: a survey. Int J Humanoid Robot. 2008;5(1):47–66.

Bauer W, Bender M, Braun M, Rally P, Scholtz O. Lightweight robots in manual assembly – best to start simply! Examining companies' initial experiences with lightweight robots. 2016.

Bilancia P, Schmidt J, Raffaeli R, Peruzzini M, Pellicciari M. An overview of industrial robots control and programming approaches. Appl Sci. 2023;13(4):2582–.

Billard A, Albu-Schaeffer A, Beetz M, Burgard W, Corke P, Ciocarlie M, et al. A roadmap for AI in robotics. Nat Mach Intell. 2025;7(6):818–824.

Bin Akhtar Z. Artificial intelligence (AI) within manufacturing: an investigative exploration for opportunities, challenges, future directions. Metaverse. 2024;5(2):2731–.

Borboni A, Reddy KVV, Elamvazuthi I, Al-Quraishi MS, Natarajan E, Azhar Ali SS. The expanding role of artificial intelligence in collaborative robots for industrial applications: a systematic review of recent works. Machines. 2023;11:111.

Buisan G, Sarthou G, Alami R. Human-aware task planning using verbal communication feasibility and costs. In: Lect Notes Comput Sci. Cham: Springer; 2020. p. 554–565.

Byner C, Matthias B, Ding H. Dynamic speed and separation monitoring for collaborative robot applications – concepts and performance. Robot Comput Integr Manuf. 2019;58:239–252.

Carr C, Wang S, Wang P, Han L. Attacking digital twins of robotic systems to compromise security and safety. arXiv. 2022:2211.09507.

Chartrand G, Cheng PM, Vorontsov E, Drozdzal M, Turcotte S, Pal CJ, et al. Deep learning: a primer for radiologists. Radiographics. 2017;37(7):2113–2131.

Coupeté E, Moutarde F, Manitsaris S. Gesture recognition using a depth camera for human-robot collaboration on assembly line. Procedia Manuf. 2015;3:518–525.

Devin S, Alami R. An implemented theory of mind to improve human–robot shared plans execution. In: Proc ACM/IEEE Int Conf Human–Robot Interaction (HRI); 2016. p. 319–326.

Dhanda M, Rogers BA, Hall S, Dekoninck E, Dhokia V. Reviewing human–robot collaboration in manufacturing: opportunities and challenges in the context of Industry 5.0. Robot Comput Integr Manuf. 2025;93.

Drawdy CC, Yanik PM. Gaze estimation technique for directing assistive robotics. Procedia Manuf. 2015;3:837–844.

Dröder K, Bobka P, Germann T, Gabriel F, Dietrich F. A machine learning-enhanced digital twin approach for human–robot collaboration. Procedia CIRP. 2018;76:187–192.

Du G, Zhang P. Markerless human-robot interface for dual robot manipulators using Kinect sensor. Robot Comput Integr Manuf. 2014;30(2):150–159.

Duckworth P, Hogg DC, Cohn AG. Unsupervised human activity analysis for intelligent mobile robots. Artif Intell. 2019;270:67–92.

Ekrekli A, Angleraud A, Sharma G, Pieters R. Co-speech gestures for human–robot collaboration. arXiv. 2023:1–5.

Evjemo LD, Gjerstad T, Grøtli EI, Sziebig G. Trends in smart manufacturing: role of humans and industrial robots in smart factories. Curr Robot Rep. 2020;1(2):35–41.

Fahle S, Prinz C, Kuhlenkötter B. Systematic review on machine learning (ML) methods for manufacturing processes – identifying artificial intelligence (AI) methods for field application. Procedia CIRP. 2020;93:413–418.

Firoozi R, Tucker J, Tian S, Majumdar A, Sun J, Liu W, et al. Foundation models in robotics: applications, challenges, and the future. Int J Robot Res. 2025;44(5):701–739.

Fischer M, Klingel L, Lechler A, Verl A, Neubauer M. Dynamic safety distance determination for human-robot coexistence in industrial applications. In: Kiefl E, editor. Proceedings of […]; 2023.

Gross S, Krenn B. A communicative perspective on human–robot collaboration in industry: mapping communicative modes on collaborative scenarios. Int J Soc Robot. 2023:1–18.

Gustavsson P, Holm M, Syberfeldt A, Wang L. Human–robot collaboration – towards new metrics for selection of communication technologies. Procedia CIRP. 2018;72:123–128.

Gustavsson P, Syberfeldt A, Holm M. Virtual reality platform for design and evaluation of human-robot collaboration in assembly manufacturing. Int J Manuf Res. 2023;18(1):28–49.

Helm JM, Swiergosz AM, Haeberle HS, Karnuta JM, Schaffer JL, Krebs VE, et al. Machine learning and artificial intelligence: definitions, applications, and future directions. Curr Rev Musculoskelet Med. 2020;13(1):69–76.

Hernandez K, Bacca B, Posso B. Multi-goal path planning autonomous system for picking up and delivery tasks in mobile robotics. IEEE Lat Am Trans. 2017;15(2):232–238.

Hietanen A, Pieters R, Lanz M, Latokartano J, Kämäräinen JK. AR-based interaction for human-robot collaborative manufacturing. Robot Comput Integr Manuf. 2020;63.

Inkulu AK, Bahubalendruni MVAR, Dara A, Sankaranarayana SK. Challenges and opportunities in human robot collaboration context of Industry 4.0: a state of the art review. Ind Robot. 2022;49(2):226–239.

International Organization for Standardization. ISO 10218-2:2025 Robots and robotic devices — Safety requirements for industrial robots — Part 2: Robot systems and integration. Geneva: ISO; 2025.

Jakhar D, Kaur I. Artificial intelligence, machine learning and deep learning: definitions and differences. Clin Exp Dermatol. 2020;45(1):131–132.

Jaquier N, Welle MC, Gams A, Yao K, Fichera B, Billard A, et al. Transfer learning in robotics: An upcoming breakthrough? A review of promises and challenges. The International journal of robotics research. 2025;44(3):465–85.

Knudsen M, Kaivo-Oja J. Collaborative robots: frontiers of current literature. J Intell Syst Theory Appl. 2020:13–20.

Koch T. Approach for an automated safety configuration for robot applications. Procedia CIRP. 2019;84:896–901.

Latokartano J, Liuha A, Lempiäinen J, Billing M. The industrial robot book. Helsinki: The Robotics Society in Finland; 2023.

Lemmerz K, Glogowski P, Kleineberg P, Hypki A, Kuhlenkötter B. A hybrid collaborative operation for human–robot interaction supported by machine learning. In: Proc IEEE Int Conf Human System Interaction (HSI); 2019.

Li C, Chrysostomou D, Yang H. A speech-enabled virtual assistant for efficient human–robot interaction in industrial environments. J Syst Softw. 2023;205:1–11.

Li X. Human-robot interaction based on gesture and movement recognition. Signal Process Image Commun. 2020;81:115686.

Liu H, Wang L. Human motion prediction for human–robot collaboration. J Manuf Syst. 2017;44:287–294.

Liu L, Schoen AJ, Henrichs C, Li J, Mutlu B, Zhang Y, et al. Human-robot collaboration for enhancing work activities. Hum Factors. 2024;66(1):158–179.

Liu Q, Liu Z, Xiong B, Xu W, Liu Y. Deep reinforcement learning-based safe interaction for industrial human–robot collaboration using intrinsic reward function. Adv Eng Inform. 2021;49:101360.

Liu Z, Liu Q, Wang L, Xu W, Zhou Z. Task-level decision-making for dynamic and stochastic human–robot collaboration based on dual agents deep reinforcement learning. Int J Adv Manuf Technol. 2021;115:3533–3552.

Liu Z, Liu Q, Xu W, Wang L, Zhou Z. Robot learning towards smart robotic manufacturing: a review. Robot Comput Integr Manuf. 2022;77.

Malik M, Malik MK, Mehmood K, Makhdoom I. Automatic speech recognition: a survey. Multimed Tools Appl. 2021;80(6):9411–9457.

Matheson E, Minto R, Zampieri EGG, Faccio M, Rosati G. Human–robot collaboration in manufacturing applications: a review. Robotics (Basel). 2019;8(4):100–.

Maurtua I, Fernandez I, Kildal J, Susperregi L, Tellaeche A, Ibarguren A. Enhancing safe human–robot collaboration through natural multimodal communication. In: Proc IEEE 21st Int Conf Emerging Technologies and Factory Automation (ETFA); 2016. p. 1–8.

Mukherjee D, Gupta K, Chang LH, Najjaran H. A survey of robot learning strategies for human–robot collaboration in industrial settings. Robot Comput Integr Manuf. 2022;73:102231.

Munzer T, Toussaint M, Lopes M. Efficient behavior learning in human–robot collaboration. Auton Robots. 2018;42:1103–1115.

Murashov V, Hearl F, Howard J. Working safely with robot workers: recommendations for the new workplace. J Occup Environ Hyg. 2017;13(3):D61–D71.

Nikolaidis S, Ramakrishnan R, Gu K, Shah J. Efficient model learning from joint-action demonstrations for human–robot collaborative tasks. In: Proc ACM/IEEE Int Conf Human–Robot Interaction (HRI); 2015. p. 189–196.

Nuzzi C, et al. MEGURU: a gesture-based robot program builder for meta-collaborative workstations. Robot Comput Integr Manuf. 2021;68:102085.

Ogenyi UE, Liu J, Yang C, Ju Z, Liu H. Physical human–robot collaboration: robotic systems, learning methods, collaborative strategies, sensors, and actuators. IEEE Trans Cybern. 2021;51(4):1888–1901.

Ojanen R. Human-robot collaboration by speech in an industrial assembly task. 2024.

Palčič I, Prester J. Effect of usage of industrial robots on quality, labor productivity, exports and environment. Sustainability. 2024;16(18):8098–.

Pan Z, Polden J, Larkin N, Van Duin S, Norrish J. Recent progress on programming methods for industrial robots. Robot Comput Integr Manuf. 2012;28(2):87–94.

Parikka O. Voice control of industrial robots with large language models trained on code. 2024

Park C, Kim J, Kang JH. Turn-taking intention recognition using multimodal cues in social human–robot interaction. In: Proc Int Conf Control Autom Syst (ICCAS); 2017. p. 1300–1302.

Peternel L, Fang C, Tsagarakis N, Ajoudani A. A selective muscle fatigue management approach to ergonomic human–robot co-manipulation. Robot Comput Integr Manuf. 2019;58:69–79.

Plahl F, Katranis G, Mamaev I, Morozov A. LiHRA: a LiDAR-based HRI dataset for automated risk monitoring methods. In: Proc IEEE/RSJ Int Conf Intelligent Robots and Systems (IROS); 2025. p. 6351–6357.

Plappert M, Mandery C, Asfour T. Learning a bidirectional mapping between human whole-body motion and natural language using deep recurrent neural networks. Robot Auton Syst. 2018;109:13–26.

Probst L, Frideres L, Pedersen B, Caputi C. Service innovation for smart industry: human–robot collaboration. Luxembourg: European Commission; 2015.

Rahman SM, Sadrfaridpour B, Wang Y. Trust-based optimal subtask allocation and model predictive control for human–robot collaborative assembly in manufacturing. In: Proc ASME Dynamic Systems and Control Conf; 2015.

Robla-Gomez S, Becerra VM, Llata JR, Gonzalez-Sarabia E, Torre-Ferrero C, Perez-Oria J. Working together: a review on safe human-robot collaboration in industrial environments. IEEE Access. 2017;5:26754–26773.

Roveda L, Haghshenas S, Caimmi M, Pedrocchi N, Tosatti LM. Assisting operators in heavy industrial tasks: on the design of an optimized cooperative impedance fuzzy-controller with embedded safety rules. Front Robot AI. 2019;6:75.

Rozo L, Calinon S, Caldwell DG, Jimenez P, Torras C. Learning physical collaborative robot behaviors from human demonstrations. IEEE Trans Robot. 2016;32:513–527.

Salehzadeh R, Gong J, Jalili N. Purposeful communication in human–robot collaboration: a review of modern approaches in manufacturing. IEEE Access. 2022;10:129344–129361.

Sanneman L, Fourie C, Shah JA. The state of industrial robotics: emerging technologies, challenges, and key research directions. Found Trends Robot. 2021;8(3):225–306.

Sasagawa A, Fujimoto K, Sakaino S, Tsuji T. Imitation learning based on bilateral control for human–robot cooperation. IEEE Robot Autom Lett. 2020;5:6169–6176.

Scherer MU. Regulating artificial intelligence systems: risks, challenges, competencies, and strategies. Harv J Law Technol. 2016;29(2).

Seeber I, et al. Machines as teammates: a research agenda on AI in team collaboration. Inf Manag. 2019;103174.

Semeraro F, Griffiths A, Cangelosi A. Human–robot collaboration and machine learning: a systematic review of recent research. Robot Comput Integr Manuf. 2023;79.

Sheikhi S, Odobez JM. Combining dynamic head pose–gaze mapping with the robot conversational state for attention recognition in human–robot interactions. Pattern Recognit Lett. 2015;66:81–90.

Shukla D, Erkent O, Piater J. Learning semantics of gestural instructions for human–robot collaboration. Front Neurorobot. 2018;12:7.

Simão M, Neto P, Gibaru O. Improving novelty detection with generative adversarial networks on hand gesture data. Neurocomputing. 2019;358:437–445.

Soori M, Arezoo B, Dastres R. Artificial intelligence, machine learning and deep learning in advanced robotics, a review. Cognitive robotics. 2023;3:54–70.

Tarantino A. Smart manufacturing: the lean Six Sigma way. Hoboken (NJ): Wiley; 2022.

Thierauf C, Thielstrom R, Oosterveld B, Becker W, Scheutz M. “Do this instead” – robots that adequately respond to corrected instructions. ACM Trans Hum-Robot Interact. 2023.

Tliba K, Diallo TML, Penas O, Ben Khalifa R, Ben Yahia N, Choley JY. Digital twin-driven dynamic scheduling of a hybrid flow shop. J Intell Manuf. 2023;34(5):2281–2306.

Tomé De Andrade e Silva M, Azevedo A. Self-adapting WIP parameter setting using deep reinforcement learning. Comput Oper Res. 2022;144:105854.

Tourlomousis F, Chang RC. Dimensional metrology of cell–matrix interactions in 3D microscale fibrous substrates. Procedia CIRP. 2017;65:32–37.

Urrea C, Kern J. Recent advances and challenges in industrial robotics: a systematic review of technological trends and emerging applications. Processes. 2025;13(3):832–.

Urrea C, Kern J. Recent advances and challenges in industrial robotics: a systematic review of technological trends and emerging applications. Processes. 2025;13(3):832.

Verma N, Kumar N, Verma C, Illés Z. A systematic review on cybersecurity of robotic systems: vulnerabilities, threats, attacks, challenges, and frameworks. Int J Inf Secur. 2025.

Villagrossi E, Delledonne M, Faroni M, Beschi M, Pedrocchi N. Hiding task-oriented programming complexity: an industrial case study. Int J Comput Integr Manuf. 2023;36(11):1629–1648.

Villani V, Pini F, Leali F, Secchi C. Survey on human–robot collaboration in industrial settings: safety, intuitive interfaces and applications. Mechatronics. 2018;55:248–266.

Vinanzi S, Cangelosi A, Goerick C. The role of social cues for goal disambiguation in human–robot cooperation. In: Proc IEEE Int Conf Robot and Human Interactive Communication (RO-MAN); 2020. p. 971–977.

Wang S, Zhang J, Wang P, Law J, Calinescu R, Mihaylova L. A deep learning-enhanced digital twin framework for improving safety and reliability in human–robot collaborative manufacturing. Robot Comput Integr Manuf. 2024;85.

Wang W, Li R, Chen Y, Diekel ZM, Jia Y. Facilitating human–robot collaborative tasks by teaching–learning–collaboration from human demonstrations. IEEE Trans Autom Sci Eng. 2018;16:640–653.

Yalçinkaya B, Couceiro MS, Soares SP, Valente A. Human-aware collaborative robots in the wild: coping with uncertainty in activity recognition. Sensors (Basel). 2023;23(7):3388.

Zhou T, Wachs JP. Early Turn-taking Prediction with Spiking Neural Networks for Human Robot Collaboration. arXiv.org. 2018;

Zhu L, Williams T. Effects of proactive explanations by robots on human–robot trust. In: Lect Notes Comput Sci. Cham: Springer; 2020. p. 85–95.

Ziaeefard M, Bergevin R. Semantic human activity recognition: a literature review. Pattern Recognit. 2015;48(8):2329–2345.

Zohuri B, Moghaddam M, Mossavar-Rahmani F. Business resilience system integrated artificial intelligence system. Int J Theor Comput Phys. 2022;3:1–7.

LIITE 1 – KONEOPPIMISEN SOVELLUKSIA ROBOTIIKASSA SEKÄ IHMISEN JA ROBOTIN YHTEISTYÖSSÄ

TEKIJÄT	SOVELLUS/KÄYTTÖKOHDE	KÄYTETTY MENETELMÄ
Agahian et al. (2020)	Toimintojen luokittelu	SL: Extreme Learning Machine, SVM
Aivaliotis et al. (2018)	Tehon ja voiman rajoitus	SL: viiveellinen neuroverkko
Akash et al. (2019)	Luottamuksen ja läpinäkyvyyden mallintaminen	RL: POMDP
Bobka et al. (2016)	Törmäysten ennustus	Geneettinen algoritmi
Bourdonnaye et al. (2016)	Katseen liikeradan ennustaminen	Piilotettu Markovin malli
Brito et al. (2020)	Laaduntarkastus	AC
Chen et al. (2018)	Kasvon ilmeiden tunnistus	USL: regressio autoenkooderilla
Choi et al. (2018)	Ihminen ottaa robotin pitämän kappaleen, mutta muuttaa tarttumisotetta, jolloin robotti mukautuu uuteen tartuntaan	RL
Chung et al. (2015)	Ihminen katsoo kohdetta; robotti tulkitsee aikomuksen	RL + Bayes
Coupet´e et al. (2015)	Käsieleiden havaitseminen	HMM + K-means
D'Orazio et al. (2014)	Ihminen käyttää useita eleitä; robotti luokittelee eleet	Binäärinen neuroverkkoluokittelu
Dhiman & Vishwakarma (2019)	Epänormaalin ihmistoiminnan havaitseminen ja tunnistaminen	SL: Konvoluutioneuroverkko
Fu et al. (2021)	Tekstiilinkäsittely HRC:ssä	DDPG ja NAF
Ghadirzadeh et al. (2020)	Ihminen kokoaa tuotetta; robotti analysoi ja avustaa	VAE + LSTM + DQN
Huang et al. (2015)	Ihminen luovuttaa esineen; robotti vastaanottaa sen	GMM + PI2
Jaradat et al. (2011)	Mobiilirobotin navigointi	Q-Learning
Ko et al. (2015)	Pick and Place / Kokoonpano	Jälittelyoppiminen (Imitation Learning)
Kokkalis et al. (2018)	Eleiden tunnistus	SL: tukivektorikone (SVM)
Li (2020)	Dynaaminen käsieleiden seuranta ja tunnistus	SL: SSD
Liu et al. (2018)	Törmäysten välttäminen ihmisen asennon estimoinnin avulla	SL: konvoluutioneuroverkko
Liu et al. (2019)	Liikeaikomusten ennustus	SL: CNN, LSTM
Liu et al. (2021)	Dynaaminen ja stokastinen työtehtävien suunnittelu	DQN
Liu et al. (2021)	Turvallinen ihmisen ja robotin vuorovaikutus	DDPG
Luo et al. (2015)	Tapin asettaminen reikään	GPS
Maeda et al. (2017)	Ihminen luovuttaa esineen; robotti tunnistaa esinetyypin	GMM
Maldonado-Ramirez et al. (2021)	Visuaalinen reitinseuranta hitsauksessa	PPO

Mohammed et al. (2020)	Pick and Place / Kappaleen käsittely	DQN
Moosmann et al. (2021)	Takertuneiden osien irrottaminen	DQN
Nagi et al. (2011)	Käsieleiden kartoitus komentojen tai palautteen tuottamiseksi	SL: Syvä neuroverkko ja max-pooling
Nikolaidis et al. (2015)	Ihminen kiillottaa robotin pitämää kappaletta	Käänteinen vahvistusoppiminen
Nikolaidis et al. (2015)	Ihminen ja robotti vaihtavat roolejaan toistuvasti yhteistoiminnallisessa tehtäväympäristössä	RL: Cross-training
Nuzzi et al. (2020)	Käsieleiden tunnistus	SL: R-FCN (CNN)
Papandreou et al. (2016)	Ihmisten asennon estimointi ja instanssisegmentointi	SL
Papandreou et al. (2018)	Ihmisten asentoestimaatio ja instanssisegmentointi useita ihmisiä sisältävissä kuvissa	SL
Park et al. (2017)	Vuoronoton aikomusten tunnistus (puhe, katse, kosketus jne.)	SL: päätöspuu, SVM, monikerroksinen tunnistus
Park et al. (2017)	Ihmisen aikomuksen ennustaminen vuoronvaihdossa usealla eri kommunikoinnin keinolla (puhe, katse, kosketus)	Decision tree, SVM, MLP
Parsa & Saadat (2021)	HRC Purkutehtävien optimointi	Geneettinen algoritmi
Pöhler et al. (2019)	Ihmisen liikkeen koodaus	USL: Gaussinen prosessi
Puls et al. (2012)	Ihmisen läsnäolon tunnistus	USL: Gaussinen sekoitemalli
Rahman et al. (2015)	Osatehtävien jakaminen kokoonpanossa	MPC
Rajnathsing & Li (2018)	Kommunikointi yhteistyörobottisolussa	SL
Rossi et al. (2013)	Käsieleiden ja puhekomentojen yhdistäminen	SL: SVM
Sheikhi & Odobez (2015)	Katseen tulkinta	Piilotettu Markovin malli
Sichkar (2019)	Reitinsuunnittelu mobiilirobotilla	Q-Learning
Simao et al. (2019)	Tuntemattomien eleiden nimeäminen	Puoliksi ohjattu oppiminen: generatiivinen adversaarinen verkko (GAN)
Simao et al. (2019)	Ihminen tuottaa uusia eleitä; robotti oppii ja generoi niitä	GAN
Vinanzi et al. (2020)	Ihminen kohdistaa osia, robotti tunnistaa ihmisen aikomuksen ja laittaa osia paikoilleen ihmisen rinnalla	Klusterointi + Bayes
Wang et al. (2015)	Radanseuranta	Mallipohjainen oppiminen
Wang et al. (2018)	Ihminen ojentaa osan robotille	Extreme learning machine
Wang et al. (2021)	Grasp for assembly / Poiminta kokoonpanoon	Q learning
Wng et al. (2021)	Handover collaboration	Jälittelyoppiminen (Imitation Learning)
Wu et al. (2020)	Kappaleen pitäminen ihmisen ohjatessa kappaletta paikoilleen	Q-learning
Zhang et al. (2020)	Työkalun ojennus kokoonpanossa	RNN
Zhang et al. (2021)	Robotisoitu ultraääniskannaus	Jälittelyoppiminen (Imitation Learning)
Zhou et al. (2019)	Työkalun ojennus kokoonpanossa	DNS