



TEKNILLINEN TIEDEKUNTA

TEKOÄLYN SOVELTAMINEN PROTEESEISSA

Eveliina Takkunen

KONETEKNIIKAN TUTKINTO-OHJELMA

Kandidaatintyö

Maaliskuu 2023

TIIVISTELMÄ

Tekoälyn soveltaminen proteeseissa

Eveliina Takkunen

Oulun yliopisto, Konetekniikan tutkinto-ohjelma

Kandidaatintyö 2023, 35 s.

Työn ohjaaja yliopistolla: Yrjö Louhisalmi

Kandidaatintyön tarkoituksena on selvittää, miten tekoälyä sovelletaan proteeseissa. Työssä käsitellään ensin tekoälyn liittyvät asiat, kuten koneoppiminen ja oppimiseen liittyvät menetit, neuroverkot sekä Turingin testi. Perehdytään myös elektromyografisen proteesin perustoimintaan sekä proteeseissa hyödynnettävään koneoppimiseen. Myoelektrisen proteesin käytöstä löytyy ongelmakohtia ja näihin keksittyjä ratkaisuja myös selvitetään.

Proteesit ovat olleet käytössä jo tuhansia vuosia, ja niitä käytetään palauttamaan ihmisen toiminta tai ulkonäkö esimerkiksi amputaation jälkeen. Syitä amputaatiolle on monia, osa ihmisistä on syntynyt ilman tiettyä kehon osaa, kun taas toiset ovat menettäneet raajansa osana syövän, diabeteksen tai vakavan infektion hoitoa. Tutkijat ovat kehittäneet niitä vuosisatoja, jotta amputaatiopotilaalle eläminen olisi helpompaa. Ohjelmoimisen myötä pystytään suunnittelemaan entistä laadukkaampia ja erittäin realistisia proteeseja.

Tutkimusmetodina tässä kandidaatintyössä on käytetty kirjallisuuskatsausta. Tavoitteenani on tunnistaa yhteyksiä tutkimusaiheen ja kerätyn aineiston välillä ottaen huomioon tutkimusaineiston ajankohtaisuus. Työn tuottamaa tietoa voi käyttää kuka vaan aiheesta kiinnostunut.

Työssä nousee esille erityisesti myoelektrisen proteesin käytön haastavuus sekä erilaisia ratkaisuja tälle ongelmalle.

Asiasanat: Tekoäly, koneoppiminen, proteesit, elektromyografia

ABSTRACT

Application of artificial intelligence in prostheses

Eveliina Takkanen

University of Oulu, Degree Programme of Mechanical Engineering

Bachelor's thesis 2023, 35 pp.

Supervisor at the university: Yrjö Louhisalmi

The purpose of the bachelor's thesis is to find out how artificial intelligence is applied in prostheses. The work first deals with issues related to artificial intelligence, such as machine learning and learning-related methods, neural networks, and the Turing test. We will also familiarize ourselves with the basic operation of an electromyographic prosthesis and machine learning used in prostheses. There are problems with the use of myoelectric prosthesis, and solutions invented for these are also reviewed.

Prostheses have been in use for thousands of years, and they are used to restore a person's function or appearance after, for example, amputation. There are many reasons for amputation, some people are born without a certain body part, while others have lost a limb as part of treatment for cancer, diabetes, or a serious infection. Scientists have been developing them for centuries to make life easier for amputees. With programming, it is possible to design even higher-quality and highly realistic prostheses.

A literature review has been used as a research method in this bachelor's thesis. My goal is to identify connections between the research topic and the collected material, considering the topicality of the research material. The information produced by the work can be used by anyone interested in the subject.

In the work, the challenge of using a myoelectric prosthesis and different solutions to this problem come to the fore.

Keywords: Artificial intelligence, machine learning, prostheses, electromyography

SISÄLLYSLUETTELO

TIIVISTELMÄ

ABSTRACT

LYHENTEET

1 JOHDANTO.....	6
2 TEKOÄLY.....	7
2.1 Turingin testi.....	7
2.2 Tekoälyn haitat ja hyödyt.....	8
2.3 Koneoppiminen.....	9
2.3.1 Syväoppiminen ja neuroverkot.....	10
3 PROTEESIT.....	14
3.1 Proteesien historiaa.....	14
3.2 Myoelektriset proteesit.....	14
4 TEKOÄLY PROTEESEISSA.....	17
4.1 Kehitys.....	17
4.2 Koneoppinen ja proteesit.....	18
4.3 Tekoälyn soveltaminen proteeseissa.....	21
4.3.1 Tekoäly yläraajojen proteeseissa.....	22
4.3.2 Tekoäly alaraajojen proteeseissa.....	25
5 PROTEESIEN ONGELMAT JA RATKAISUT.....	28
6 YHTEENVETO.....	31
LÄHTEET.....	34

LYHENTEET

AI	Artificial intelligence eli tekoäly
ANN	Artificial neural network eli keinotekoinen neuroverkko
BCI	Brain Computer Interface eli aivotietokone-liitäntä
CRT	Choice reaction time eli valintareaktioaika
DL	Deep Learning eli syväoppiminen
EEG	Elektroenkefalogrammi
EMG	Electromyogram eli Elektromyografia
FES	Functional electrical stimulation eli toiminnallinen sähköstimulaatio
LfD	Learning from Demonstration eli demonstraatiosta oppiminen
MES	Myoelektrinen signaali
ML	Machine Learning eli koneoppiminen
PE	Processing elements eli käsittelyelementti
SRT	Simple reaction time eli yksinkertainen reaktioaika
TMR	Targeted Muscle Reinnervation eli kohdennettu lihasten uudelleenhermotus

1 JOHDANTO

Proteesit ovat keinotekoisia kehon osia, joilla pystytään palauttamaan kehon toiminta tai ulkonäkö. Syitä amputaatiolle on monia, osa ihmisistä on syntynyt ilman tiettyä kehon osaa, kun taas toiset ovat menettäneet raajansa osana syövän, diabeteksen tai vakavan infektion hoitoa. Proteesien kehittäminen on tärkeää, sillä amputoiduille proteesien käyttö on oleellinen heidän elämänlaatunsa kannalta. Kehittyneemmällä proteesilla he pystyvät tekemään yhä enemmän asioita ilman ulkopuolisen ihmisen apua.

Tekoäly on aina ollut hyvin kiehtovaa mielestäni. Sitä sovelletaan monessa aihealueessa ihmisen arjen helpottamiseksi. Kiinnostuin tekemään kandidaatintyöni näistä kahdesta aiheesta ja halusta tietää enemmän sekä mahdollisesti olla tulevaisuudessa proteesien kehityksessä mukana. Minua alkoi kiinnostamaan proteeseissa niiden suunnittelu sekä toiminta. Proteesien kehitys on hyvin ajankohtaista, sillä käyttäjille pyritään antamaan mahdollisuus hallita proteesien käyttöä haluamallaan tavalla.

Tämän työn tavoitteena on selvittää, mitä tekoäly on ja miten sitä voidaan soveltaa proteeseihin sekä mitä kehityskohteita tällä alalla on vielä jäljellä. Työssä tehdään yleiskatsaus tekoälyyn, jotta voitaisiin ymmärtää, miten se käytännössä toimii. Proteesien aiherajauksena toimii myoelektriset proteesit. Mekaaniset proteesit ovat työn aihealueen ulkopuolella.

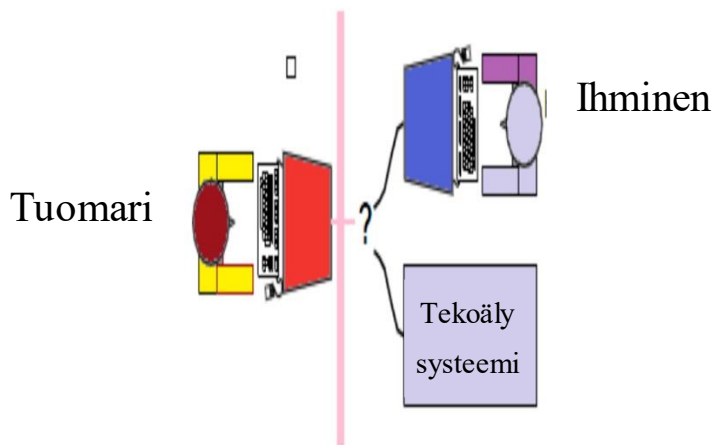
2 TEKOÄLY

Pohjimmiltaan älykkyys on kykyä saavuttaa tavoitteita maailmassa käyttämällä laskennallisia prosesseja. Ajatteleminen, kuvitteleminen, muistaminen, ymmärtäminen, muutokseen sopeutuminen sekä oppiminen ovat kaikki älykkyyteen liittyviä kykyjä. Tekoälyn avulla koneet voivat toimia ikään kuin ne olisivat ihmisiä, mutta tietyn ongelman ratkaisemiseen sillä kuluu selkeästi vähemmän aikaa kuin ihmisillä. (Borana, 2016)

Tekoälyn tarkoitus on jäljitellä tai jopa ylittää ihmismielen toiminnallisuus. Tekoälyä on meidän ympärillämme koko ajan ja varsinkin lääketieteen, robotiikan, lain ja osakekaupan aloilla. Avaruuteen lähetetään robotteja tutkimaan muiden planeettojen elinympäristöä ja ilmakehää. (Borana, 2016)

2.1 Turingin testi

Alan Turing kehitti pelin nimeltä ”The Imitation Game”. Tämä peli ei kuitenkaan sisältänyt itsessään tekoälyä. Pelin ideana on se, että nainen, mies sekä pelin tuomari ovat eri huoneissa. Mies ja nainen kommunikoivat kaukokirjoittimella tuomarin kanssa. Tuomarin on tarkoitus tunnistaa naine ja mies oikein. (French, 2000)



Kuva 1. Turingin testin perusidea (Borana, 2016).

Tämä peli loi pohjan tekoälylle sen jälkeen, kun Alan Turing julkaisi julkaisun "Computing Machinery and Intelligence" vuonna 1950, jossa peruskysymys oli: "Voivatko koneet ajatella?". Koe on tarkoitettu mittaamaan tekoälyn ihmismäisyyttä. Osana koetta tuomarina toimivan ihminen asetetaan keskusteluun koneen ja toisen ihmisen kanssa. Kone läpäisee testin, jos tuomari ei pysty erottamaan konetta ja ihmistä toistaan. Tämä testi kuitenkin rajoitetaan näyttöön ja tietokoneen näppäimistöön eli tehdään teksti muodossa, ettei puheesta paljastuisi kummasta on kyse. (Borana, 2016)

2.2 Tekoälyn haitat ja hyödyt

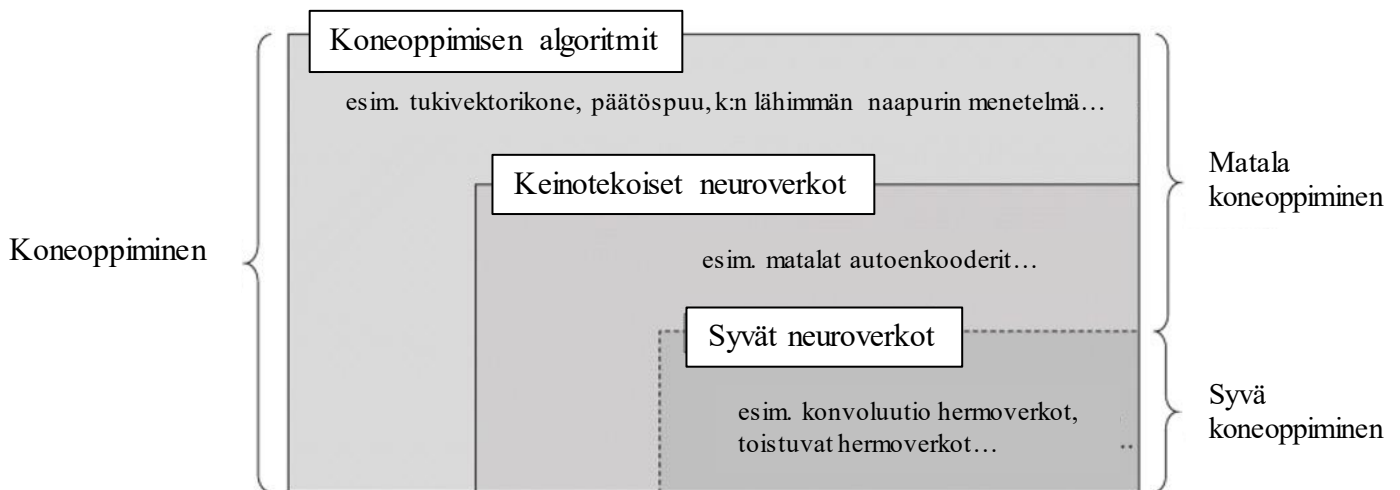
Yksi merkittävä etu tekoälyssä on sen päätöksenteko, joka perustuu vain tosiasioihin eikä tunteeseen. Ihmisen päätöksen teossa vaikuttavat myös tunteet, jotka toisinaan vaikuttavat päätöksiin negatiivisella tavalla. Tämä myös johtaa siihen, että koneen vastaukset eivät ole kovin luovia. Maalaisjärjen puute voi aiheuttaa isoja ongelmia ratkaisuisissa. Tekoälyä käyttävä kone ei vaadi myöskään unta, missä se voi voittaa väsyneen ihmisen. Tekoälyllä ei ole myöskään kykyä selittää logiikkaa tai perusteella annettua päätöstä, eikä tekoäly tiedä milloin sillä ei ole ratkaisua ongelmaan. Mikä tahansa toimintahäiriö voi johtaa siihen, että tekoäly tuottaa vääriä ratkaisuja, ja koska tekoäly ei pysty selittämään vastaustensa syitä, siihen sokeasti luottaminen voi olla ongelmallista. (Borana, 2016)

Tiedonjakaminen on paljon tehokkaampaa tekoälyn myötä. Tekoälyllinen kone on helppo opettaa suorittamaan tehtävä, kun se on koulutettu siihen. Tämän seurauksena muut voivat helposti toistaa koulutuksen, jolloin voimme lyhentää aikaa, joka muuten kuluisi tiedon välittämiseen muille. (Borana, 2016)

Yksi tekoälyn haitoista tulee olemaan työpaikkojen korvaantuminen koneilla. Toisaalta aloilla tullaan tarvitsemaan ihmisen älykkyyttä ja hyvin vahvasti uskotaan kuitenkin, että koneet eivät tulisi koskaan korvaamaan ihmisiä. (Borana, 2016)

2.3 Koneoppiminen

Janiesch esittää että, koneoppimisen (ML) pystyy jakamaan koneoppimisalgoritmeihin, keinotekoisiiin neuroverkoihin sekä syviin neuroverkoihin. Nimensä mukaan kone oppii eli myös samalla kehittyä mitä enemmän tietoa sille syötetään. Koneoppimisen käyttökelpoisuus on hyvä, sillä se voi auttaa tuottamaan luotettavia ja toistettavia päätöksiä. (Janiesch et al., 2021)



Kuva 2. Venn-kaavio koneoppimiskonsepteista ja luokista (Janiesch et al., 2021)

Tutkimusalana tekoäly kattaa monia erilaisia menetelmiä, teknologioita, sovelluksia ja tutkimussuuntia. Yksi hyvin tärkeä tekoälyn alakategoria on koneoppiminen. Koneoppimisessa saavutettiin merkittävä virstanpylväs 2010-luvun alussa digitaalisen datan huomattavan lisääntymisen, tietokonelaitteistojen nopean kehityksen sekä 1980-luvulta peräisin olevien menetelmäkeksintöjen seurauksena. (Vartiainen et al., 2021)

Ero ohjelmoinnissa ja koneoppimisessa on sen tekijä. Perinteisessä ohjelmoinnissa kehittäjät suunnittelevat tarvittavat vaiheet, miten tietyssä vaiheessa toimitaan. Koneoppimisessa nimensä mukaan opetetaan konetta antamalla sille esimerkkejä tai dataa. Data tai esimerkki pitävät sisällään tietoa, jonka avulla ohjataan tekoälymallin toimintaa toivottuun suuntaan. Neuroverkkojen syväoppiminen on viimeisin tekoälyn kehityskohde. Tällä menetelmällä on mahdollista tunnistaa esineitä kuvista, puheesta ja tehdä markkinointiennusteita. Tilanteissa, jossa ilmiöstä on tietoa saatavilla paljon,

koneoppiminen tulee hyödylliseksi. Suuren datamäärän mallintaminen ja analysoiminen tai ilmiön ymmärtäminen saattaa olla liian työlästä ihmiselle. (Vartiainen et al., 2021)

Koneoppimisen voi jakaa kolmeen eri osaan: ohjattuun koneoppimiseen, ohjaamattomaan koneoppimiseen sekä vahvistusoppimiseen. Ohjatussa koneoppimisessa opetusdata syötetään koneelle etukäteen, mikä osoittaa, mitä syöte- ja tulostepareja tulisi hyödyntää. Ohjaamattomassa koneoppimisessa kone tunnistaa datan yhtäläisyyksiä keskenään. Osana vahvistusoppimiseen perustuvia ratkaisuja algoritmi pyrkii optimoimaan toimintatapojaan kompleksisessa ympäristössä, jossa huomioidaan useita kriteerejä, joiden perusteella määritetään, mitkä toiminnot ovat toivottuja ja mitkä ei-toivottuja. (Vartiainen et al., 2021)

2.3.1 Syväoppiminen ja neuroverkot

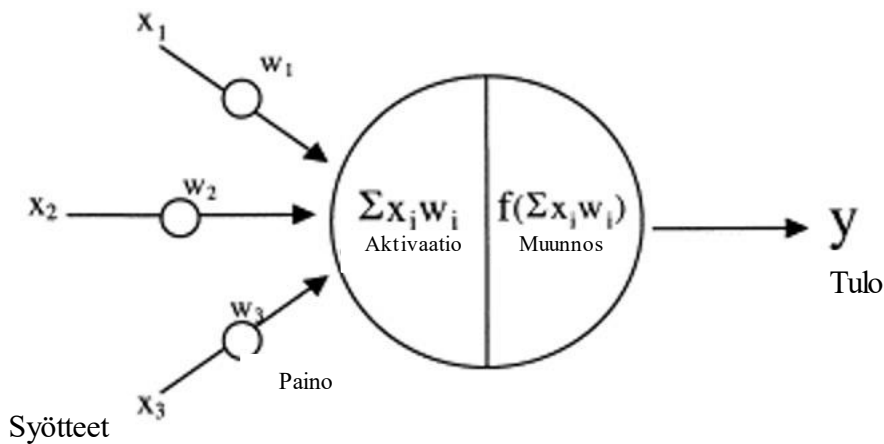
Syväoppiminen (DL) on yksi koneoppimiskäsite, jossa hyödynnetään usean kerroksen neuroverkkoja. Syväoppimisella tarkoitetaan yleensä keinotekoisia neuroverkkoja (ANN), jossa on edistyneet oppimismahdollisuudet. (Janiesch et al., 2021)

ANN on matemaattinen esitys yhdistettyjen prosessointiyksiköiden tai keinotekoisien neuronien verkostosta. Tämä periaate on johdatettu biologisten järjestelmien tiedonkäsittelyn periaatteesta eli ihmisen hermoverkoista. ANN:n joustava rakenne mahdollistaa niiden mukauttamisen monenlaisiin tilanteisiin kaikissa kolmessa koneoppimistyyppissä. Neuronit ovat kuin aivojen synapsit. Niiden välillä kulkee signaaleja ja näiden signaalien voimakkuutta voidaan vahvistaa tai vaimentaa käyttämällä painoja, joita säädetään jatkuvasti oppimisprosessin aikana. Neuronit on yleensä järjestetty verkkokerroksiksi. Aktivointitoiminnot määrittävät ylitetäänkö aktivaatiokynnys ennen kuin seuraavat hermosolut käsittelevät signaaleja. (Janiesch et al., 2021)

Hermorakenteet koostuvat sadoista erillisistä yksiköistä, joita kutsutaan keinotekoisiksi neuroneiksi, jotka ovat yhteydessä rakenteen muodostaviin painoihin. Niitä kutsutaan myös käsittelyelementeiksi (PE), sillä nimensä mukaan ne käsittelevät tietoa. PE on

yhtälö, jonka tarkoitus on tasapainottaa tulot ja lähdöt. (Agatonovic-Kustrin & Beresford, 2000)

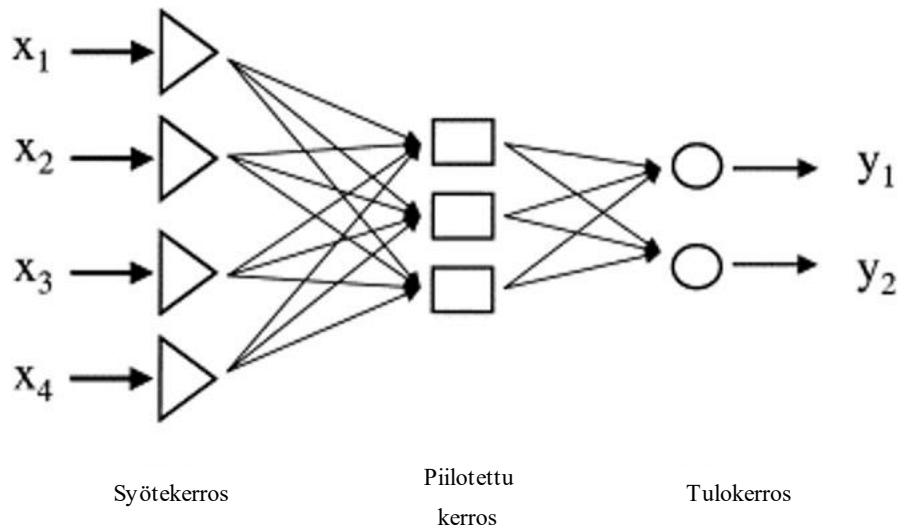
Neuroni kerää syötteitä eri lähteistä, joille on määritelty jokin kerroin. Summaajan tehtävä on laskea kaikkien syötteiden summa ja neuroni tuottaa tämän summan perusteella aktivaatiofunktion kuvan 3 esittämällä tavalla. (Agatonovic-Kustrin & Beresford, 2000)




Kuva 3. Keinotekoisin neuronin malli (Agatonovic-Kustrin & Beresford, 2000)

Hermoverkon toimintaan vaikuttaa tyyli, miten neuronit ovat liitetty toisiinsa. Neuronit pystyvät vastaanottamaan kiihdyttäviä tai estäviä syötteitä. Kiihdyttävien syötteet saavat aikaan summausmekanismin lisäämisen, kun taas estävät syötteet vähentävät sitä. (Agatonovic-Kustrin & Beresford, 2000)

Kuva 4 esittää Feedforward-rakennetta, joka havainnollistaa, miten tulon ja syötteen välillä ei ole yhteyttä. Näin ollen se ei pidä kirjaa aiemmista lähtöarvoistaan. Toisin kuin Feedforward-rakenne, feedback-rakenteessa (kuva 5) syöte ja tulo ovat yhteydessä. Tämä verkkorakenne säilyttää siis tiedon aiemmasta tilasta, jolloin seuraavaan tilaan vaikuttaa verkon aikaisemmat tilat. (Agatonovic-Kustrin & Beresford, 2000)



Kuva 4. Feedforward-rakenne (Agatonovic-Kustrin & Beresford, 2000)



Kuva 5. Feedback-rakenne (Agatonovic-Kustrin & Beresford, 2000)

Data-analyysiä tehdessä on huomioitava ANN-mallit sekä ANN-algoritmit. Koulutuksessa käytetään joko ohjattua tai ohjaamatonta oppimista. ANN, jossa on ohjattu backpropagation oppimissääntö, on yleisimmin käytetty sekä erinomainen ennuste- ja luokittelutehtävissä. Toinen vaihtoehto on Kohonen eli Self-Organizing Map. Tässä käytetään ohjaamatonta oppimisalgoritmia ja se on erinomainen luonteeltaan monimutkaisten tietokokonaisuuksien välisten yhtäläisyyksien löytämisessä. (Agatonovic-Kustrin & Beresford, 2000)

Ohjatut oppimisverkot ovat neuronien kerroksia, jotka ovat täysin yhteydessä toisiinsa. Näissä verkoissa on syöte- ja tulokerros sekä niiden välissä sijaitsevat piilotetut kerrokset. Piilotettujen kerroksien neuronien määrä vaikuttaa yhteyksien määrään. Piilotetut

neuronit ovat vuorovaikutuksessa ainoastaan muiden neuronien kanssa ja niiden määrä vaikuttaa yhteyksien määrään. Harjoitusvaiheen aikana syötteitä muunnetaan liitospainoilla, jolloin kontaktien määrä on olennainen verkon suorituskyvyn kanssa. Oppimisprosessia vaikeuttaa piilotettujen neuronien puute, kun taas liiallinen määrä johtaa yliharjoitteluun, mikä heikentää ennustamiskykyä. Tulosten emustamiseksi uudelle syöttödatajoukolle painotetut linkit yksiköiden välillä tallennetaan sen jälkeen, kun ANN tuottaa halutun lähdön. (Agatonovic-Kustrin & Beresford, 2000)

Ohjaamattomassa koulutuksessa verkko vastaanottaa vain syötteitä. Täten järjestelmän tulee itse päättää, mitä toimintoja se haluaa käyttää syöttötietojen lajitteluun. Tätä prosessia kutsutaan itseorganisoitumiseksi. Prosessin aikana neuronit kilpailevat keskenään sekä tekevät yhteistyötä toistensa kanssa. Kilpailu edellyttää neuronien luokittelua siten, että yksi hermosolu reagoi voimakkaammin tiettyyn syötteeseen vaimentaen tai estämällä muiden neuronien ulostulon. Kun taas yhteistyössä nimensä mukaan neuronit tekevät yhteistyötä vahvistaakseen tulostaan. (Agatonovic-Kustrin & Beresford, 2000)

3 PROTEESIT

3.1 Proteesien historiaa

Muinaisen Egyptin ja Rooman valtakunnista lähtien proteesien suunnittelu on kehittynyt ympäri maailmaa. 1800-luvulla John Hanger kehitteli proteesin nimeltä 'The Hanger limb' Yhdysvaltojen sisällissodassa haavoittuneiden sotilaiden hoitamiseksi. Tällä proteesilla nostettiin proteesien kehitys aivan uudelle tasolle. (Manero et al., 2019)

Nykyaikaisia proteeseja voidaan hallita kolmella tavalla: kehon kautta eli mekaanisesti, painikkeilla sekä elektromyografialla, (EMG). Osana tätä lisätoimintoa henkilö pystyy hoitamaan tiettyjä tehtäviä, joita hän tulee kohtaamaan jokapäiväisessä elämässään. Proteesit valitaan usein potilaan kokemusten, erityistarpeiden ja toiminnallisten vaatimusten perusteella. (Manero et al., 2019)

EMG-signaalia on käytetty käsiproteesin toiminnassa vuodesta 1948. Moskovan keskusproteesitutkimuslaitos aloitti kaupallisten käsiproteesien valmistuksen myoelektronisella signaalilla vuonna 1957. Myöhemmin lisättiin kestmagneettiset tasavirtamoottorit ja sähkömagneettiset releet. Tässä tutkimuksessa myoelektristä ohjausstrategiaa analysoitiin perusteellisesti ja myöhemmin kehitettiin yksinkertainen on-off-ohjausjärjestelmä. (Geethanjali, 2016)

3.2 Myoelektriset proteesit

Elektromyografia, eli EMG, on tärkein menetelmä yläraajan proteesien hallinnassa. Proteesien käyttökokemuksen tuomia ongelmia on tutkittu useilla eri tavoilla viimeisen 15 vuoden ajan. Tämä on myös johtanut monipuoliseen kirjallisuuteen. Erilaiset proteesien hallintamenetelmät toimivat eri tavalla riippuen ympäristöolosuhteista ja kokeellisesta asetelmasta. Tämä osoittaa, että ongelmaan ei ole olemassa yhtä ainoaa ratkaisua, vaan se on tapauskohtainen. (Iguar et al., 2019)

Myoelektriset signaalit (MES), ovat auttaneet useiden erilaisien sovelluksien kehityksessä, esimerkiksi käyttäjien aikomusten tunnistaminen ja ortoosien eli

tukisidoksien ja eksoskeletonin ohjaamiseen käyttäjien liikuntavalmiuksien lisäämiseksi. (Geethanjali, 2016)

On tärkeää tiedostaa, että käsiproteesia kiinnittäessä vartaloon, sen liikkeet eivät vastaa ihmisen luonnollisia liikkeitä, vaan pikemminkin käyttäjän ohjaamia liikkeitä. Antureiden kautta kulkeneet fysiologiset ohjaussignaalit kertovat, miten käyttäjä aikoo hallita kättä. (Geethanjali, 2016)

Myoelektrisiä signaaleja käytetään nykyaikaisissa proteeseissa keinokäden ohjaamiseen pintaelektrodin kautta. Keinotekoisessa käsiohjauksessa EMG-signaalit havaitaan ihon pinnalta, ja ne ovat edullisia helppokäyttöisyytensä ja ei-invasiivisuutensa vuoksi. Signaalin hankintakohtien tunnistamisessa on kuitenkin rajoituksia ja pintaelektroidien asentaminen ei ole ongelmaton. (Geethanjali, 2016)

Pinnan EMG:ssä kyky hankkia signaaleja on vaikeampaa. Signaalien saamiseksi peräkkäistä ohjausta varten pintaelektrodeja voidaan käyttää tunnistamaan kolme tai neljä potentiaalista sijaintia jäännösraajassa. Kirurgista toimenpidettä vaaditaan signaaleihin kolmesta neljään, jotta signaaleja voidaan kerätä mahdollisimman laajasti. (Geethanjali, 2016)

Suurin osa käyttäjien proteeseissa käytetyistä ohjausjärjestelmistä on peräkkäisohjattuja. EMG-signaalien muuntamiseen käytetään usean tyyppisiä peräkkäisiä ohjausmenetelmiä, mukaan lukien on-off-ohjaus, suhteellinen ohjaus, suora ohjaus, äärellisen tilan koneohjaus, kuviontunnistusperustainen ohjaus, asemon ohjausjärjestelmät sekä regression ohjausjärjestelmät. (Geethanjali, 2016)

On/off-ohjaus perustuu EMG-kynnykseen, joka määrittää, mihin suuntaan kättä ohjataan. Ohjausjärjestelmässä käsi liikkuu vakionopeudella supistuksesta riippumatta. Liikkeitä voidaan ohjata samanaikaisesti ja tasaisella nopeudella moottoreiden ollessa päällä tai sammutettuna. (Geethanjali, 2016)

Suhteellisessa ohjausjärjestelmässä syötetty jännite on verrannollinen EMG-signaalien supistustasoon tai intensiteettiin. Karkeiden liikkeiden kohdalla tämä mahdollistaa nopeat

liikkeet, mutta säätimen soveltuvuus yläraajojen proteeseihin on vielä selvittämättä. (Geethanjali, 2016)

Suoraohjaus on identtinen suhteellisen ohjauksen kanssa muuten paitsi, että se sisältää itsenäiset EMG-kohdat, jotta saavutetaan sormen liikkeiden yksilöllinen hallinta. EMG-signaalien ristivaikutuksen vuoksi on vaikea saada aikaan itsenäisesti hallittuja proteeseja. (Geethanjali, 2016)

Äärellisen tilan koneohjausta käytettäessä käsien asennot pystytään määrittämään ennalta tiloiksi. Siirtyminen tilojen välillä on määritelty aiemmin tai dekodattu syötteistä. Tämä ohjaus ei ole monikäyttöinen, sillä asentoja on rajoitettu määrä. Rajoitukset on mahdollista kumota kuviontunnistuksella. Sen avulla tutkijat ovat kehittäneet erilaisia algoritmeja signaalien tunnistamiseen. (Geethanjali, 2016)

Signaalinkäsittelyssä kuviontunnistuspohjainen myoelektrinen ohjaus sisältää tyypillisesti piirteiden erottamisen ja luokittelun segmentoiduista signaaleista sen määrittämiseksi, mitkä komennot tulee lähettää moottoriohjaimelle. MES:n tietosisältö tunnistetaan yleensä poimimalla aika-, taajuus- ja aika-taajuuspiirteet. (Geethanjali, 2016)

Myoelektrisessä asennonohjauksessa kartoitetaan EMG-signaalit ohjaamaan parametreja pääkomponenttialueella. Alueen kohdeasennot esitetään lineaarisesti muuntamalla koordinaatit nivelkulmiksi. Tämä ohjausmenetelmä mahdollistaa useampien nivelien samanaikaisen ohjauksen. (Geethanjali, 2016)

4 TEKOÄLY PROTEESEISSA

Raajalla voi olla heikko toiminallisuus tai ei toiminnallisuutta ollenkaan ehjän raajan tavoin. Tämä voi johtua amputaatiosta, selkäydinvauriosta tai traumaattisesta aivovauriosta, jolloin raajojen ja aivon välillä ei ole yhteyttä. Proteeseilla, ortoosilaitteilla sekä kuntoutusapuvälineillä korvataan joko puuttuva raaja tai palautetaan raajan toiminta. (Nayak & Kumar Das, 2020)

Biologinen mekaniikka on mekatroniikan alatiede, joka käsittelee mekatronisten laitteiden kehittämistä ihmiskehon auttamiseksi tai palauttamiseksi antamalla proteesin ja ortoosin käsitteelle uuden merkityksen. Tässä järjestelmässä on neljä yksikköä: biosensorit, mekaaniset anturit, ohjain ja toimilaitte. Biosensorien avulla ihmisen aikomukset havaitaan hyödyntämällä hermo- tai lihasjärjestelmästä peräisin olevia biologisia reaktioita. Biologiset rakenteet ja elektroniset rakenteet yhdistetään ohjaimen kautta, joka valvoo biomekatronisen laitteen toimintaa sekä toimii muuntajana. Mekaaniset anturit välittävät tietoa biosensorille tai ohjaimelle biomekatronisesta laitteesta mitatusta datasta. Toimilaitteet ovat mekaanisia laitteita, jotka toimivat keinolihasina eli robotteina, jotka avustavat tai korvaavat ihmiskehon toimintoja. (Nayak & Kumar Das, 2020)

4.1 Kehitys

Chas A Blatchford & Sons, Ltd. kehitti ensimmäisen älykkään proteesin vuonna 1993, jota seurasi paranneltu versio nimeltä Intelligent Prosthesis Plus vuonna 1995. Vuonna 1998 Blatchford kehitti mukautuvan proteesin, joka yhdistää hydraulikan, pneumatiikan ja mikroprosessorit. (Nayak & Kumar Das, 2020)

Vuonna 1997 Ottobock kehitti mikroprosessoriohjatun polven, joka tunnetaan nimellä C-leg. Vuosina 2005 ja 2006 OSSUR kehitti sekä Rheo-polven että voimapolven käyttämällä tekoälyä. OSSUR esitteli bionisen jalan robotiikkamekanismilla vuoden 2011 lopussa, ja sitä kutsutaan "symbioiseksi jalaksi". Samaan aikaan Ottobock toi markkinoille Genium X3:n, joka mahdollistaa kävelemisen taaksepäin sekä tarjoaa intuitiivisen ja luonnollisen liikkeen kävelyn aikana. Ottobock on myös kehittänyt

sähköisesti toimivan proteesin nimeltä ”Michelangelo Hand”, jossa on liikkuva peukalo. Tämä proteesi otettiin käyttöön ensimmäisen kerran vuonna 2010. (Nayak & Kumar Das, 2020)

Blatchford Group ilmoitti vuonna 2015 julkaisevansa maailman ensimmäisen kokonaan integroidun jalkaproteesin nimeltä Linx. Linx-proteesissa on seitsemän anturia sekä neljä prosessoria. Polvi- ja nilkkaniveltä voidaan koordinoita ja synkronoida aistimalla ja analysoimalla käyttäjän liikkeisiin, toimintaan, ympäristöön ja maastoon liittyviä tietoja, mikä mahdollistaa luonnollisemman seisomisen tai kävelyn rampilla. Tohtori Hugh Herr kehitti maailman ensimmäisen pohjajärjestelmällisen bionisen jalan nimeltä Iwalk BiOM. Käyttämällä patentoituja algoritmeja se toistaa lihasten ja jänteiden toiminnan. Kehittääkseen monimutkaisempia laitteita, jotka jäljittelevät luonnollisia aivoja, tutkijat ottavat tekoälyn käyttöön ajotietokoneessa. Se lukee ja vastaa hermosignaaleja, jotka välitetään robottiproteeseihin ja -ortooseihin auttamaan amputoituja ja halvaantuneita ruumiinosia toimimaan paremmin. (Nayak & Kumar Das, 2020)

4.2 Koneoppinen ja proteesit


Käyttämällä vaiheriippuvaista hahmontunnistusmenetelmää ohjattu oppiminen ennustaa polvikulman vaihtelumallin mikroprosessoripolvinivelille perustuen lukuisiin syötteisiin tai merkittyihin tietoihin kävelysyklin eri osavaiheissa. Mallia on sovellettu uusiin amputointeihin ja samalla kerätään uutta tietoa liikkeiden ennustamiseksi. Toinen vaihtoehto on intuitiivinen myoelektrinen proteesi tai kuvion tunnistuksen ohjausproteesi, joka tunnetaan myös nimellä FES (toiminnallinen sähköstimulaatio). Menestyneen algoritmin harjoittelun tapauksessa mallia voidaan käyttää uuden datan ennustamiseen. Algoritmi viimeistellään kolmen perusvaiheen kautta: koulutus, validointi ja sen soveltaminen uuteen tietoon. (Nayak & Kumar Das, 2020)

Ohjaamattomassa oppimisessä pystytään tekemään paljon monimutkaisempia ratkaisuja, sillä toisin kuin ohjatussa oppimisessä, se kerää itse tietoa. Uuden datan kuvion tunnistuksen muodostus tehdään klusteri eli ryhmittelyanalyysillä sekä k-keskiarvolla. Klusterit ovat datapisteiden kokoelmia, jotka perustuvat tietynlaisiin yhtäläisyyksiin. K-keskiarvoanalyysissä lasketaan keskiarvo annetusta datasta eli

määritetään tietojoukon painopiste. Mikroprosessoripolussa käytetään tätä oppimismenetelmää hyödyksi. (Nayak & Kumar Das, 2020; Garbade, 2018)

Vahvistusoppimisen (RL) komponentit tunnetaan nimellä agentti ja ympäristö. Yrityksen ja erehdyksen kautta agentti oppii tekojensa seuraukset ja tekee valinnan menneiden kokemusten perusteella. Agentit eli oppijat oppivat strategioita tai lähestymistapoja, joita ne käyttävät havaintojensa ja vuorovaikutustensa perusteella määrittääkseen seuraavan toimintatapansa. Oppiminen tapahtuu toiminnan ja tilan kautta, jotka molemmat edustavat agentin nykyistä tilaa oppimisprosessin aikana. Termillä "käytäntö" tarkoitetaan agentin lähestymistapaa seuraavan toimenpiteen määrittämiseen nykyisen tilan perusteella. Palkinto on välitön arvio ympäristön viimeisestä toiminnasta. Löytääkseen optimaalisen palkkion tai toiminta-arvon agentti noudattaa etsintä- ja hyödyntämiskonseptia. Tutkimuksessa tutkitaan ja kerätään lisää tietoa ympäristöstä ja hyödynnetään jo tiedossa olevan informaatiota palkinnon saamiseksi. (Nayak & Kumar Das, 2020)

Erinomaisena esimerkkinä vahvistusoppimiseen voidaan käyttää demonstraatiosta oppimista (LfD). Opettaja antaa esimerkkejä tai esityksiä eli demonstraatioita auttaakseen opiskelijoita oppimaan yhdistämään tilat toimintaan LfD:ssä ja toiminta määrittellään eräänlaisiksi tilatoimintapareiksi. Tätä oppimista voidaan esimerkiksi hyödyntää, kun on käsi, kyynärvarsi sekä kyynärpää on amputoitu. Tätä kutsutaan transhumeraaliseksi amputaatioksi. Tällä asetuksella käyttäjä haluaa kouluttaa biologisen raajan ja robottiraajan reagoimaan asianmukaisesti jäännösraajan ohjattuun lihaskudokseen. Ohjausvarreksi kutsutaan sitä kättä, joka tuottaa ohjaussignaaleja käyttäjälle. Robotisoitua kyynärpäätä voidaan ohjata suoraan EMG-signaaleilla, jotka tulevat henkilön jäännöshauksesta ja kolmipäisestä olkalihaksesta, jotka on kiinnitetty robottiproteesiin. Harjoituskäsivarsi on ehjä biologinen raaja, joka suorittaa harjoitusliikkeitä. (Vasan & Pilarski, 2017)



a. Bento Arm



b. Kokeellinen asennus

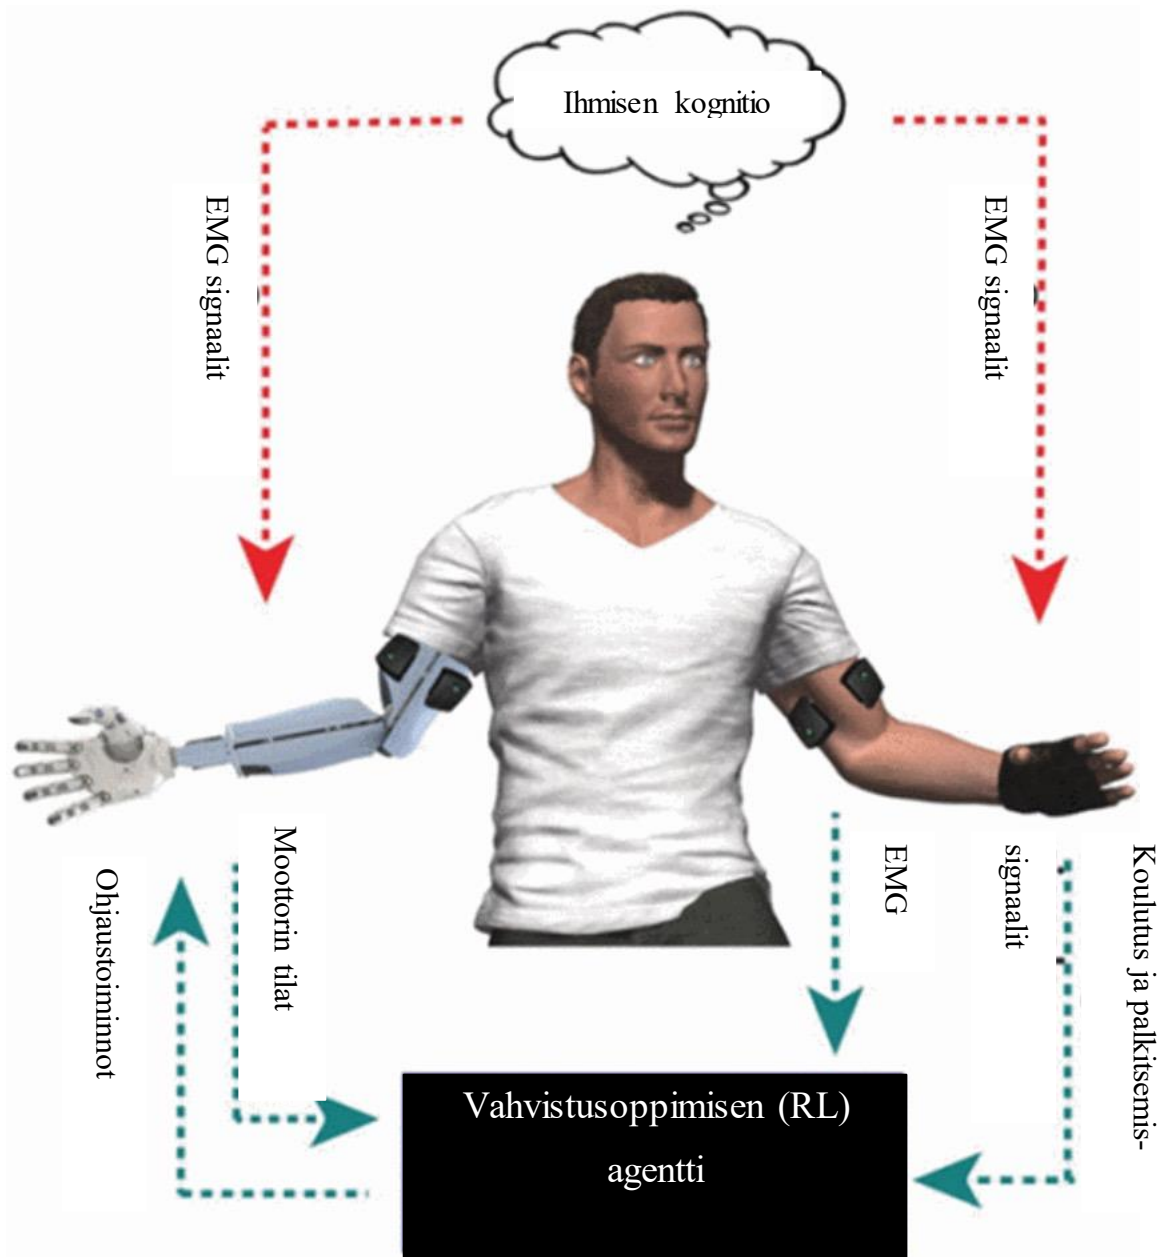
Kuva 6. Kokeellinen asennus, jossa on Bento Arm, langaton Delsys Trigno-laboratorio ja cybertouch II (Vasan & Pilarski, 2017).

Delsys Trigno -yksiköt asennetaan kuvan 6b mukaisesti, ja ne lähettävät sEMG-signaaleja ja inertiamittauksia kiihtyvyyssantureista, magnetometreistä ja gyroskoopeista. Yksi ylimääräinen hitausmittausyksikkö asennetaan harjoituskäsivarren ranteeseen ja kaksi yksikköä on kiinnitetty kolmipäiseen olkalihakseen ja hauislihaksiin. (Vasan & Pilarski, 2017)

Kokeissa käytetään Bento Arm robottialustaa kuvassa 6 esitetyllä tavalla. Robottialusta on myoelektrinen harjoitustyökalu, jota yläraajoista amputoidut voivat käyttää oppiakseen käyttämään lihassignaalejaan ennen kuin heille asennetaan myoelektriset proteesit. Bento Arm kiinnitetään jäykästi pöytään suoraan kohteen eteen siten, että käsiproteesin varsi on linjassa ohjausta antavan käsivarren kanssa kuvan 6b mukaisella tavalla. Myoelektrinen ohjausjärjestelmä vastaanottaa nivelten kulma-asennon ja nopeuden Bento Arm:lta. (Vasan & Pilarski, 2017)

Kuvasta 7 voidaan nähdä tiedon kulku. Käyttäjän tehdessä liikkeitä molemmilla käsillään, voidaan kerätä harjoitustietoa proteesin kinematiikan luomiseksi. Tämä tarkoittaa, että käyttäjän ohjausraajan hallinta on yhdistetty proteettisten käsien jäljellä olevia niveliä vastaaviin motorisiin komentoihin, eivätkä ne voi hallita itse itseään autonomisesti. Tilaehtoista käytäntöä hyödyntäen robottiproteesi voi ikään kuin "täyttää aukot"

käyttäjälle niin kauan kuin hän jatkaa sen käyttöä koulutuksen jälkeen. (Vasan & Pilarski, 2017)



Kuva 7. Kaavio tiedon kulusta kokeellisessa asennuksessa harjoituksen aikana (Vasan & Pilarski, 2017).

4.3 Tekoälyn soveltaminen proteeseissa

Tekoäly on lisääntynyt huomattavasti proteesien hoidossa, jolloin amputoidut voivat käyttää proteesejaan itselleen sopivimmalla tavalla. Säättämällä tuloa

takaisinkytkentämekanismiin kautta mukautuva ohjaus mahdollistaa järjestelmän paremman suorituskyvyn lähempänä alkuperäisiä raajoja. Mielen ohjaama raaja esiteltiin äskettäin yleisölle yhtenä viimeisimmistä edistysaskeleista tekoölyavusteisissa ohjausjärjestelmissä. (Nayak & Kumar Das, 2020)

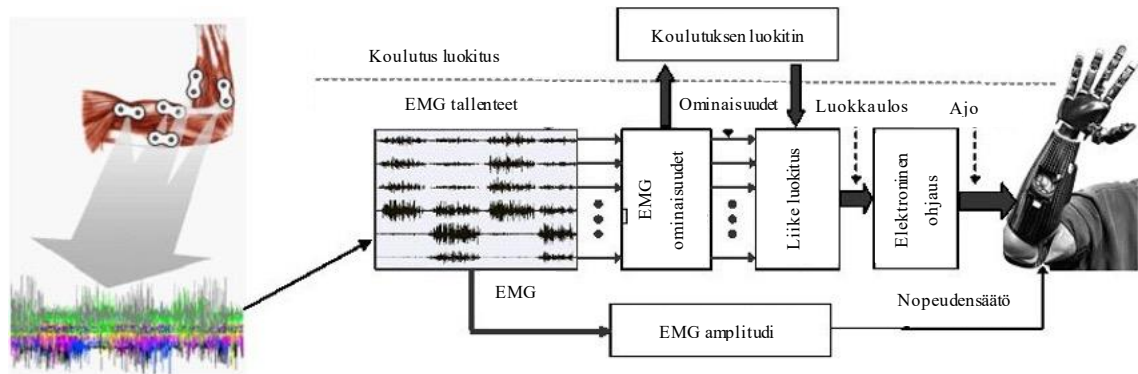
Pentagon ja Johns Hopkins Applied Physics Laboratory (APL) ovat tehneet yhteistyötä modulaarisen proteesin kehittämiseksi. Proteesia ohjataan täysin aivoihin istutetuilla antureilla, ja se jopa palauttaa tuntoaistin reitittämällä sähköiset impulssit raajasta takaisin sensoriseen aivokuoreen, mikä palauttaa aistihavainnon. (Nayak & Kumar Das, 2020)

Proteesissa ja ortotikassa tekoölyä sovelletaan useilla erilaisilla tavoilla riippuen siitä, mikä kehon osa on vaurioitunut. Esimerkkejä ovat esimerkiksi alaraajaproteesit ja -ortoosit, yläraajaproteesit ja -ortoosit sekä kuntoutuksen apuvälineet, kuten moottoroidut liikkumisvälineet. (Nayak & Kumar Das, 2020)

4.3.1 Tekoöly yläraajojen proteeseissa

Erilaisten signaalien, antureiden, ohjaimien, algoritmien sekä tekoölyn avulla yläraajojen proteeseja pystytään ohjaamaan joko suorana tai epäsuorana hermoverkosta. Ohjaussignaaleja on kahdenlaisia elektromyografinen (EMG) ja elektroenkefalogramminen (EEG). EMG-kuvion tunnistuksen käyttö myoelektristen proteesien ohjausstrategioissa oli avain EMG-hallinnan edistymiseen. Tämän myötä käyttäjällä on paljon vapaamuotoisempi hallinta proteesista. TMR eli kohdennettu lihasten uudelleenhermotus on edistynein ja kehittynein hermokonerajapintatekniikka. (Nayak & Kumar Das, 2020)

Liikkeenluokissa ja jäljellä olevissa käsivarren lihaksissa on paljon vaihtelua myoelektriseen hallintaan amputoiduilla, joilla on eri tasoisia yläraajan amputaatioita. Kuvioiden luokittelutekniikkaa hyödyntäen pystytään tunnistamaan suunniteltuja liikkeitä EMG-kuvioiden avulla. Luokittelun seurauksena lihasten supistukset voidaan saada aikaan lähettämällä liikekäskyjä proteesin ohjaajalle. (Li, 2011)



Kuva 8. Kaavio EMG-kuvion tunnistuksesta (Li, 2011)

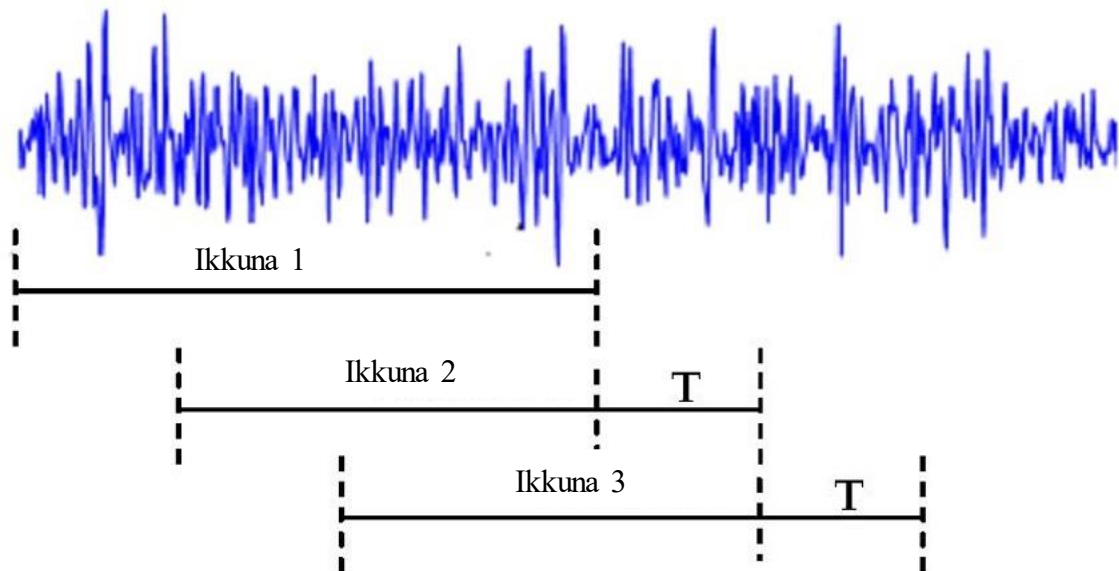
Jäljellä olevan kyynärvarren ympäröivän alueen ympärille asetetaan joukko bipolaarisia elektrodeja (8-16) EMG-signaalien mittaamiseksi jäännöslihakista, joita käytetään myoelektrissä transradiaalisissa proteeseissa. Kahdeksan elektrodiä jaetaan tasaisesti proksimaalisen osan ympärille ja neljä elektrodiä jaetaan kyynärvarren distaaliseen päähän. Maadoitusta varten, iso pyöreä elektrodi asetetaan kyynärpäähän amputoidussa kädessä. (Li, 2011)

Myoelektrisen proteesin ohjaussuorituskyvyn parantamiseksi pintaelektrodi yleensä suodattaa sieppaamat EMG-signaalit kaistanpäästösuodattimella. Ylipäästöraajataajuutta 5 Hz - 20 Hz on käytetty lähes kaikissa aikaisemmissa tutkimuksissa EMG-kuvion tunnistuspohjaisista proteesikontrolleista. (Li, 2011)

EMG-tallenteista poimittuja ominaisuuksia käytetään kuvaamaan raajan liikkeeseen liittyvää EMG-kuviota. Suorituskykyyn vaikuttaa huomattavasti ominaisuusjoukon valinta. Monimuuttuja-ominaisuusjoukkoa ehdotetaan ja käytetään monitoimisten proteesien EMG-kuvion tunnistuspohjaiseen ohjaukseen keinona tarjota enemmän tietoa kunkin kanavan EMG-kuvioista. (Li, 2011)

EMG-kuvion tunnistus tehdään ikkunoidulle EMG-datalle. Nämä EMG-tallenteet erotellaan sarjaan 100-250 ms pituisiin analyysi-ikkunoihin joko päällekkäin tai ilman kuvan 9 mukaisesti. Jatkuvan tietovirran tehokkuuden maksimoimiseksi ja mahdollisimman tiheän päätösvirran tuottamiseksi käytetään päällekkäisiä analyysi-ikkunoita. EMG-ominaisuudet poimitaan kustakin analyysi-ikkunasta EMG-signaalikuvion esityksenä. Jokaiselle analyysi-ikkunalle poimitaan ominaisuusjoukko

jokaiselle tallennuskanavalle, mikä tuottaa L-ulotteisen piirvektorin. Kun kaikkien kanavien ominaisuusjoukot on ketjutettu, koko EMG-ominaisuusmatriisi harjoitusjoukosta toimitetaan luokittelijalle harjoittelua varten. (Li, 2011)



Kuva 9. EMG-tallenteiden analyysiikkunoiden segmentointi (Li, 2011)

EMG-kuvion tunnistuspohjainen proteesin ohjausstrategia ei kuitenkaan toimi ihmisillä, joilla on amputaatio tehty olkapäästä asti. Tämä johtuu heidän jäännöslihaksien vajeudesta, joista ei pystytä saamaan myoelektrisiä ohjaussignaaleja. Kohdennettu lihasten uudelleenhermotus (TMR) tulee tässä tilanteessa hyödyksi. (Nayak & Kumar Das, 2020).

Yläraajan amputaation seurauksena TMR:ää voidaan käyttää parantamaan myoelektristen proteesien toimivuutta. Tämä johtuu siitä, että jäännöslihasten reinnervaatio luo lisää myoelektrisiä ohjauskohtia, joita voidaan käyttää usean DoF-proteesin ohjaamiseen ilman, että sinun on vaihdettava eri tilojen välillä. Vuonna 2004 suoritettiin ensimmäinen TMR-leikkaus, jossa potilaalla oli molemminpuolinen olkapään amputaatio. (Mereu et al., 2021)

TMR-leikkaus pystytään tekemään kolmella eri amputaatiotasolla: olkapään disartikulaatio eli käsivarren kirurginen erottaminen olkanivelestä, transhumeraalinen eli kyynärpään yläpuolelta amputoiminen, sekä transradiaalinen eli kyynärpään alapuolelta

amputoiminen. Hermotusstrategiat riippuvat täysin amputaation tyypistä. (Mereu et al., 2021)

Potilaat, joilla ei ole olkaniveltä, denervoidaan tavallisesti jäljelle jääneiden käsivarren ääreishermosten vuoksi ja hermotetaan myöhemmin uudelleen rintalihaksilla. On myös mahdollista, että selkälihaksen hermotetaan myöhemmin, jotta saataisiin aktiivisempia kohtia. (Mereu et al., 2021)

Transhumeraalinen amputoitu voi saada käden sulkemis- tai pronaatiotoiminnan takaisin siirtämällä keskihermon hauislihaksen motorisen haaran lyhyeen päähän. Saadakse enemmän ohjauksipisteitä käden sulkemista varten, kyynärluuhermo siirretään jäljellä olevaan olkalihaksen motoriseen haaraan. Käden avautumisen tai supinaation hallitsemiseksi säteittäinen hermo hermotetaan uudelleen kolmipäisen olkalihaksen haaran motoriseen haaraan. (Mereu et al., 2021)

Transradiaalisilla amputoiduilla käytetään TMR-signaaleja, jotka mahdollistavat sormi- ja peukalolihasen toimintaa. Tässä distaalinen mediaanihermo siirretään sormien pinnalliseen koukistajalihakseen (*flexor digitorum superficialis*) ja kyynärluuhermon uudelleenhermotetaan ranteen pikkusormenpuoleisen koukistaja lihakseen (*ulnaris carpi ulnaris*). (Mereu et al., 2021)

Kun lihaksen uudelleenhermottaminen ei ole mahdollista, käytetään kolmea anteriorisen tiukan lihaksen nippua. Tällöin saadaan kolme aktiivista kohtaa proteesin hallintaa varten. Iso etu TMR:ssä on sen mahdollisuus hoitaa ja vähentää haamuraajakipua sekä neuroomakipua, minkä seurauksena mahdollisten opioidien käyttö vähenee amputaatiopotilailla. (Mereu et al., 2021)

4.3.2 Tekoäly alaraajojen proteeseissa

Tekoälyä hyödynnettiin ensimmäisen kerran polvinivelessä, eräänlaisena älykkäänä proteesina. Tässä proteesissa on käytetty yhdistelmää mikroprosessoriohjauksesta sekä hydraulisista tai pneumaattisista toimilaitteista. Mikroprosessori käsittelee polvikulmananturin vastaanottaman signaalin, jolla saadaan tietoa polven taivutus- ja venytyskulmasta


sekä sivu- ja kulmaliikkeen nopeudesta. Tämän lisäksi magneettisen implantin avulla anturi määrittää liikkeen suunnan ja toinen anturi määrittää painopisteen ja voiman sijainnin. Jotta kävelyliikkeestä saataisiin mahdollisimman aidon tuntuinen, amputoidun raajan liike analysoidaan ja tulkitaan mikroprosessorin avulla. Mikroprosessorit käyttävät näitä tietoja laitteen sijainnin ja liikkeen määrittämiseen. (Nayak & Kumar Das, 2020)

Mikroprosessorissa on kytkettynä kaksi anturia, jotka ovat yhdistettynä sarjaan johtoverkkoja miimikoiden hermoverkkoja. Näillä johtoverkoilla voidaan kuljettaa erilaisia liikekäskejiä, jolloin saadaan haluttu liike. Nämä johtoverkot palvelevat viestintäpiirejä anturien, mikroprosessorien, servomoottorien ja hydraulijärjestelmien välillä. Pienen venttiilin avulla, mikä kontrolloi mitä kulkee hydraulisylinterissä sisään ja sieltä ulos, kerätään liiketietoa. Näitä tietoja käytetään hydraulisylinterien tuottaman vastuksen ohjaamiseen polvinivelen venymisen ja taipumisen ohjaamiseksi. Polvinivel pystyy liikkumaan tällöin 0 asteesta maksimikulmaan 60-70 astetta. Tämän toiminnan myötä liikkeet, jossa tarvitaan enemmän liikkuvuutta kuten portaiden kiipeäminen, lenkkeily, juokseminen sekä kävely epätasaisessa maastossa ovat mahdollisia. (Nayak & Kumar Das, 2020)

Polvinivelproteesia ohjaa koneoppimista käyttävä mikroprosessori, kun taas jalkaproteesi jäljittelee jalkojen ja nilkkojen luonnollista liikkumista tekoälyn avulla. Transtibiaalisessa eli sääri- ja pohjeluun amputaatiossa, proteesi on osa EMG-ohjausrobotiikkaa, jonka Baojun Che on kehittänyt vuonna 2014. Tämän proteesin avulla amputoidut voivat kävellä ylä- sekä alamäkeen useissa eri kulmissa. Tässä proteesissa yhdistyy myoelektroniikka sekä sisäinen ohjaushallinta, joka vähentää lihasten väsymistä. Alaraajaproteesia voidaan ohjata EMG-ohjauksen lisäksi myös elektroenkefalografia (EEG) -signaalilla käyttämällä aivotietokoneiliitäntää (BCI). (Nayak & Kumar Das, 2020)

Tekoäly, kuten FES, BCI ja myoelektriset ohjaimet, muuttavat ortoosin toimintatapaa potilailla, joilla on toispuolihalvaus (hemiplegia), alaraajahalvaus (paraplegia) tai traumaattinen aivovamma. FES:ää hyödynnetään aivo- ja selkäydinvammoissa, halvauksissa, multipeliskleroosissa eli MS-taudissa sekä CP-vammoissa. FES-menetelmää käytetään halvaantuneen hermon tai lihaksen toiminnan palauttamiseksi. (Nayak & Kumar Das, 2020)

Monessa alaraajahalvaustapauksessa lihaksilla on edelleen kyky supistua ja tuottaa liikettä. Tämä johtuu siitä, kun alempi motorinen neuron, joka yhdistää keskushermoston selkäytimestä etusarvisoluun muodostaakseen toiminnallisen yhteyden lihakseen, on edelleen ehjä. Tässä tilanteessa FES tulee hyödyksi, sillä toimenpiteessä sähköisiä ärsykeitä kohdistetaan halvaantuneeseen hermoon, jolloin supistuksen luodaan raajaan keinotekoisesti, kuvan 10 mukaisesti. Aktivointinopeus ja motorisen yksiköiden määrä määrittävät FES:n tuottaman lihasvoiman. (Schauer, 2017)



Kuva 10. Periaate FES toiminnasta (Schauer, 2017)

FES:n etuja voivat olla esimerkiksi parantunut lihasjänteys, parantunut raajan verenkierto tai vähentynyt osteoporoosi. Tämä johtaa myös kardiopulmonaalisen kunnon parantumiseen, mikä estää sydän- ja keuhkosairauksien riskiä, mikä on hyvin yleistä liikuntarajoitteisten keskuudessa. (Schauer, 2017)

5 PROTEESIEN ONGELMAT JA RATKAISUT

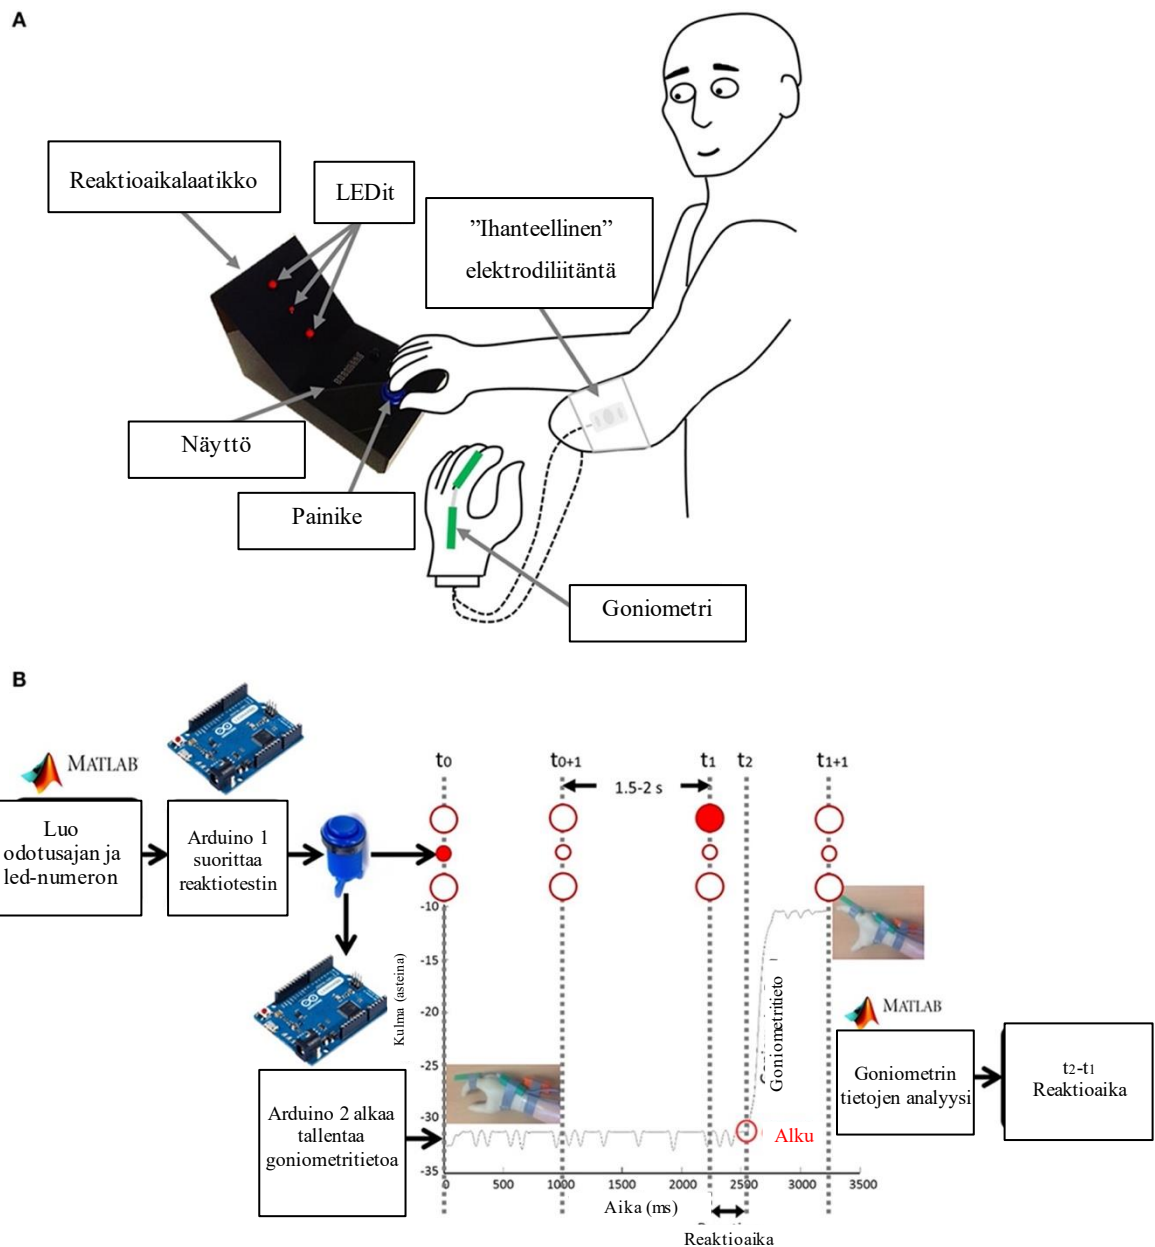
Myoelektrisen proteesin ohjaaminen on hyvin haastavaa ja mahdollisesti voi johtaa heikkoon käyttöön tai jopa proteesin käytön lopettamiseen. Tällöin ehjää raajaa käytetään liikaa, jolloin tulee liikakäyttövamma. Vaikka myoelektrisen proteesin parantamisen alalla on tehty paljon tutkimusta, ei kuitenkaan tiedetä, mitkä saatavilla olevien klinisten järjestelmien näkökohdat vaikuttavat eniten yleiseen toimintaan sekä päivittäiseen käyttöön. (Chadwell et al., 2016)

Tämän takia Chadwell et al. (2016) kehitti protokollan, jossa arvioidaan, kuinka hyvin proteesin käyttäjä hallitsee elektromyografisen proteesin. Arviointi suhteuttaa nämä tiedot toimivuuteen ja jokapäiväiseen käyttöön. Yksinkertaisella yläraajan toiminnallisella tehtäväproteesilla arvioidaan liikkeiden ja katsekäyttäytymisen laatua sekä annettujen tehtävien onnistumista sekä suoriutumisen kestoa. Erilaisilla menetelmillä tutkitaan elementtejä, jotka vaikuttavat proteesin ohjaukseen. Tätä kutsutaan terminä EMG-taito. (Chadwell et al., 2016)

EMG-taidossa tutkitaan vasteaika. Donders kehitti 1860-luvulla vähennysmenetelmän, jossa hyödynnetään reaktioaikatestien käyttöä. Testien tarkoitus on määrittää kognitiivisten ja motoristen prosessien suorittamiseen kulutettu aika. Testejä on kahdenlaisia, yksinkertainen reaktioaikatesti (SRT) sekä valintareaktioaikatesti (CRT). SRT:ssä tiedostavat vaaditun vasteajan ennen ärsykkeen esittämistä, kun taas CRT:ssä määritellään itse vasteaika. Vasteajat segmentoidaan eri aikoihin, kuten ärsykkeen havaitsemiseen, reagointipäätökseen eli päätösaikaan sekä neuronien aktivoimiseen eli motoriseen vasteeseen. SRT-testissä ei kuitenkaan ole päätösaikaa, sillä vaadittu liike on jo tiedossa. (Chadwell et al., 2016)

EMG-taitoja tutkiessa ideaali elektrodi tulee sijoittaa jäljellä olevan raajaan parantaakseen osallistujan mahdollisuutta suoriutua kokeesta. Tämä elektrodi asetetaan ihanteellisempaan kohtaan, jossa on optimaalinen lihas ja hyvä kontakti ihon kanssa. Tässä kokeessa käytetään vakioelektrodeja, jotka ovat lähellä osallistujan omia elektrodeja, jolloin vältetään proteesin hylsyn purkamista. (Chadwell et al., 2016)

Osallistujia pyydetään supistamaan lihaksiaan toistuvasti. Aluksi elektrodi sijoitetaan lihasmassan keskelle, joka merkitään muistiin. Tämän jälkeen elektrodi aloitetaan liikuttamaan puolen elektrodin mittaisella etäisyydellä, mitaten sijaintien amplitudeja. Tässä ideana on paikantaa sijainti, jossa on suurin signaalin amplitudi. (Chadwell et al., 2016)



Kuva 11. Reaktioaikakoe (Chadwell et al., 2016)

Tässä kokeessa on käytetty MyoHand VariPlus Speed -käsiproteesia. Koe aloitetaan aina proteesikäsi neutraalissa asennossa sekä anatominen käsi reaktioaikalaatikon takana

olevalla sinisellä painikkeella. Osallistujalla edessä olevassa reaktioaikalaatikossa on kaksi punaista halkaisijaltaan 10 mm:n LED-valoa, jotka toimivat ärsykkeinä käsien avaamiseen ja sulkemiseen (kuva 13). Ylempi valo tarkoittaa merkkiä käden avaamiselle ja alempi valo käden sulkemiselle. Näiden kahden valon keskellä on halkaisijaltaan 5 mm punainen LED-valo, jonka tarkoitus on keskittää osallistujan huomio jokaisen kokeen alussa. Koe aloitetaan, kun osallistuja kertoo olevansa valmis ja painaa sinistä painiketta. Ensin keskimäinen valo palaa sekunnin ajan, jonka jälkeen jompikumpi ylemmästä tai alemmasta valosta syttyy, jolloin osallistujan tulee avata tai sulkea kätensä. SRT-testissä osallistujalla on valmiiksi jo tiedossa pitääkö käsi avata vai sulkea. (Chadwell et al., 2016)

Arvioinnissa on kahdenlaisia seurantatehtäviä, staattisia sekä dynaamisia. Staattisen seurantatehtävän arvioinnissa käytetään Ottobock GmbH:n arviointityökaluja, joita käytetään kliinisessä hoidossa rutiininomaisesti. Tietokone vastaanottaa signaalin kliinisiltä elektrodeilta Myoboy®-laitteiston avulla. Tehtävän kulkua seurataan myotestaussignaalin visualisointinäyttöllä, jossa rajat ovat asetettu tarpeeksi haastavaksi osaavammille osallistujille, mutta kuitenkin saavutettavissa osittain vähemmän kykeneville. Osallistujalla on kolme yritystä, jolloin heidän tulee pitää signaalin amplitudi kunkin lihaksen rajoissa. Pisteet perustuvat prosentiosuuteen ajasta, jonka signaali pysyy rajojen sisällä. (Chadwell et al., 2016)

Dynaamisessa seurantatehtävän arvioinnissa käytetään PAULA (Prosthetist's Assistant for Upper Limb Architecture) -ohjelmistoa. Koe on eräänlainen autopeli, mikä kestää minuutin ajan, jossa tarkoituksena on ohjata autoa lähestyvien, korkeutta vaihtelevien seinien aukkojen läpi. EMG-signaalin avulla auton korkeutta ohjataan lihasten supistumisen ja rentoutumisen avulla. Supistamalla auto liikkuu ylöspäin ja rentouttamalla auto liikkuu alaspäin. Osallistujalla on kaksi yritystä saada mahdollisimman korkeat pisteet. Koe suoritetaan kahdessa eri osassa erikseen käden avaus- sekä sulkulihaksilla. Tämän jälkeen koe suoritetaan vielä samanaikaisesti käyttäen käden avausta sekä sulkemista. Tarkoituksena on tutkia kuinka hyvin osallistuja osaa erottaa signaalit. (Chadwell et al., 2016)

6 YHTEENVETO

Kandidaatintyön tarkoituksena oli laatia kirjallisuuskatsaus tekoälyn sovelluksista proteeseissa ja luoda kirjallisuuden pohjalta mahdollisimman kattava kokonaisuus. Työn aihe nousi kiinnostuksesta proteeseihin ja niiden toimintaan sekä tekoölyyn. Tekoölyä sovelletaan erittäin moneen asiaan nyky-yhteiskunnassa. Pää tarkoituksena on ymmärtää, mitä tekoöly on ja syventyä kysymykseen: ”Miten tekoölyä käytetään proteeseissa?”.

Työssä otettiin esille tekoälyn perusasiat kuten koneoppiminen, neuroverkot sekä syväoppiminen. Esitettiin Turingin testi ja sen toteutus, josta tekoälyn huikkea kehitys on saanut alkunsa. Tekoölyssä on paljon hyviä, mutta myös huonoja puolia. Isoja hyviä puolia on sen nopeus verrattuna ihmiseen. Huonoja puolia on esimerkiksi työpaikkojen korvautuminen sekä sen yksinkertaisuus omalla tasolla. Tekoölyllä ei ole tunneälyä, mikä vaikuttaa päätöksiin negatiivisella tavalla. Koneoppimisessa syvennyttiin erilaisiin opetusmetodeihin, joita ovat ohjattu oppiminen, ohjaamaton oppiminen sekä vahvistusoppiminen. Käytiin läpi myös neuroverkkojen toimintaperiaate ja miten neuroverkot pyrkivät luomaan oikeanlaista algoritmia syväoppimisen kehittämistä varten.

Proteesit eivät ole mikään uusi keksintö, sillä proteeseja on käytetty muinaisen Egyptin ja Rooman valtakunnista lähtien. Proteeseja voidaan ohjata kolmella eri tavalla mekaanisesti, painikkeilla ja elektromyografialla. Tässä työssä keskityimme elektromyografialla toimiviin myoelektrisiin proteeseihin. EMG-signaaleilla luodaan käden liikkeistä aidomman näköisiä, sillä ohjaussignaalit kertovat, miten proteesin käyttäjä aikoo hallita kättänsä. Näitä signaaleja kerätään pintaelektrodien kautta, jotka ovat proteesin hylsyn sisällä tai ihon alla kirurgisesti asetettuna. Proteesien ohjausmenetelmiä on olemassa muutamia, jotka esiteltiin työssä. Proteesin kehitystä käytiin läpi ja lueteltiin erilaisia proteeseja, mitä kehityksen virstanpylväitä on saavutettu vuosien varrella, sekä miten nämä proteesit pitää sisällään toiminnallisesti.

Työssä kerrottiin kattavasti, miten koneoppimista käytetään proteeseissa. Suurimmaksi osaksi käytetään ohjaamatonta oppimista sekä vahvistusoppimista. Vahvistusoppimisesta kerrottiin hyvänä esimerkkinä demonstraatiosta oppimista. Käytännön esimerkkinä

näytettiin Bento Arm -robotialustaa, jotta amputoidut pääsevät itse harjoittelemaan käyttämään lihassignaalejaan.

Työssä käytiin läpi erikseen ylä- sekä alaraajojen proteesit ja mitä eri toimintoja niissä käytetään. EMG-kuvion tunnistus yläraajaproteeseissa on yleisimmin käytetty ohjausstrategia, jolloin pystytään tunnistamaan suunniteltuja liikkeitä. Tarpeen vaatiessa voidaan tehdä kohdennettu lihasten uudelleenhermotus (TMR), parantamaan signaalien saatavuutta proteesien toiminnan mahdollistamiseksi. Alaraajaproteeseissa on käytetty mikroprosessoriohjauksesta, jossa hyödynnetään antureita, mikroprosessoreja, servomootoreita ja hydraulijärjestelmiä.

Työssä ei kuitenkaan keskitytty pelkästään myoelektrisen proteesin toimintaan vaan, miten eri amputaatiotapauksissa mahdollistetaan myoelektrisen proteesin käyttö. Vaikka työ on kirjoitettu tekniikan näkökulmasta, joitakin lääketieteellisiä aiheita käsiteltiin proteesien toiminnan ymmärtämiseksi. Otettiin selvää, miten erilaiset amputaatiot vaikuttavat myoelektristen proteesien käyttöön. Siinä on iso ero, onko amputaatio tehty kyynärpäähän ylä- vai alapuolelta vai onko koko käsi irrotettu olkanivelestä.

Työssä puhutaan paljon hermosignaaleista mitä tarvitaan tekoälyn toimintaan proteeseissa. Näitä ei kuitenkaan välttämättä saa ihmisen jäännösraajasta riippuen tämän amputaatiosta ja sen mahdollisesta vakavuudesta. Tämän takia on menetelmiä, jolla pystytään parantamaan hermojen toimintaa, jotta voitaisiin saada signaaleja proteesin toimimiseen.

Työssä tulee hyvin selkeästi ilmi proteesin vaikea käytettävyys, johon yritetään kokoajan keksiä uusia ratkaisuja. Liian vaikea käyttö voi johtaa proteesin käytön laiminlyömiseen ja lopulta sen hylkäämiseen. Tämän takia tutkijat ovat kehittäneet protokollan, jossa pystytään mittaamaan, onko amputoidulla tarpeeksi kykyä käyttää myoelektronista proteesia.

Proteeseista ei ole löydy järkyttävästi kirjallisuutta suomen kielellä, ainoastaan erillisiä proteeseihin liittyviä opinnäytetöitä. Työssä on käytetty suurimmaksi osaksi englanninkielistä kirjallisuutta liittyen koneoppimiseen, neuroverkoihin, myoelektrisiin

proteeseihin, EMG-signaaleihin, lihasten uudelleenhermoitukseen ja moneen muuhun. Ainoastaan koneoppimiseen löytyi kirjallisuutta, minkä myötä proteeseihin liittyviä aiheita olisi hyvä tutkia lisää.

Työn aikana huomataan, että tekoälyllä toimivan proteesin kehittäjän täytyy myös ymmärtää jonkin verran itse koneoppimisesta, robotikasta, antureista, signaaleista sekä mekaanisista toiminnoista kuten pneumatiikasta tai hydraulikasta. Ilman tätä ymmärrystä tekstin perässä pysyminen saattaa olla haastavaa, vaikka selittäisikin mahdollisimman laajasti jonkin menetelmän toiminnan.

On selvää, että proteesien kehitys on hyvällä mallilla, vaikka kehityskohtia löytyyk in. Näihin ongelmakohtiin yritetään kuitenkin keksiä ratkaisuja, sillä tekoälyn käyttöä lisätään jatkuvasti, tämän myötä jo tiedossa oleviin ongelmiin tulisi keksiä ratkaisu kehityksen takaamiseksi.

LÄHTEET

- Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. In *Journal of Pharmaceutical and Biomedical Analysis* (Vol. 22, Issue 5). [https://doi.org/10.1016/S0731-7085\(99\)00272-1](https://doi.org/10.1016/S0731-7085(99)00272-1) [Luettu 3.2.2023]
- Borana, J. (2016). Applications of Artificial Intelligence & Associated Technologies. *Proceeding of International Conference on Emerging Technologies in Engineering, Biomedical, Management and Science*. [Luettu 3.2.2023]
- Chadwell, A., Kenney, L., Thies, S., Galpin, A., & Head, J. (2016). The reality of myoelectric prostheses: Understanding what makes these devices difficult for some users to control. *Frontiers in Neurorobotics*, 10(AUG). <https://doi.org/10.3389/fnbot.2016.00007> [Luettu 8.11.2022]
- French, R. M. (2000). The turing test: The first 50 years. In *Trends in Cognitive Sciences* (Vol. 4, Issue 3). [https://doi.org/10.1016/S1364-6613\(00\)01453-4](https://doi.org/10.1016/S1364-6613(00)01453-4) [Luettu 7.2.2023]
- Garbade, M. (2018). *Understanding K-means Clustering in Machine Learning*. Towards Data Science. [Luettu 15.3.2023]
- Geethanjali, P. (2016). Myoelectric control of prosthetic hands: State-of-the-art review. In *Medical Devices: Evidence and Research* (Vol. 9). <https://doi.org/10.2147/MDER.S91102> [Luettu 19.12.2022]
- Igual, C., Pardo, L. A., Hahne, J. M., & Igual, J. (2019). Myoelectric control for upper limb prostheses. *Electronics (Switzerland)*, 8(11). <https://doi.org/10.3390/electronics8111244> [Luettu 1.12.2022]
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3). <https://doi.org/10.1007/s12525-021-00475-2> [Luettu 6.2.2023]

- Li, G. (2011). Electromyography Pattern-Recognition-Based Control of Powered Multifunctional Upper-Limb Prostheses. In *Advances in Applied Electromyography*. <https://doi.org/10.5772/22876> [Luettu 27.2.2023]
- Manero, A., Smith, P., Sparkman, J., Dombrowski, M., Courbin, D., Kester, A., Womack, I., & Chi, A. (2019). Implementation of 3D printing technology in the field of prosthetics: Past, present, and future. *International Journal of Environmental Research and Public Health*, 16(9). <https://doi.org/10.3390/ijerph16091641> [Luettu 15.11.2022]
- Mereu, F., Leone, F., Gentile, C., Cordella, F., Gruppioni, E., & Zollo, L. (2021). Control strategies and performance assessment of upper-limb tmr prostheses: A review. In *Sensors* (Vol. 21, Issue 6). <https://doi.org/10.3390/s21061953> [Luettu 23.2.2023]
- Nayak, S., & Kumar Das, R. (2020). Application of Artificial Intelligence (AI) in Prosthetic and Orthotic Rehabilitation. In *Service Robotics*. <https://doi.org/10.5772/intechopen.93903> [Luettu 16.11.2020]
- Schauer, T. (2017). Sensing motion and muscle activity for feedback control of functional electrical stimulation: Ten years of experience in Berlin. In *Annual Reviews in Control* (Vol. 44). <https://doi.org/10.1016/j.arcontrol.2017.09.014> [Luettu 25.2.2023]
- Vartiainen, H., Tedre, M., Jormanainen, I., Kahila, J., Valtonen, T., & Toivonen, T. (2021). Tekoäly, koneoppiminen ja teknologinen murros: *Ainedidaktiikka*, 5(2). <https://doi.org/10.23988/ad.90776> [Luettu 17.1.2023]
- Vasan, G., & Pilarski, P. M. (2017). Learning from demonstration: Teaching a myoelectric prosthesis with an intact limb via reinforcement learning. *IEEE International Conference on Rehabilitation Robotics*. <https://doi.org/10.1109/ICORR.2017.8009453> [Luettu 17.2.2023]