



# Laboratorioajanvarausjärjestelmän koneoppimispohjaiset kehittämismahdollisuudet

Emilia Komi

OPINNÄYTETYÖ  
Toukokuu 2022

Dataosaamisen ja tekoälyn ylempi tutkinto-ohjelma

## TIIVISTELMÄ

Tampereen ammattikorkeakoulu  
Dataosaamisen ja tekoälyn ylempi tutkinto-ohjelma

KOMI, EMILIA:

Laboratorioajanvarausjärjestelmän koneoppimispohjaiset kehittämismahdollisuudet

Opinnäytetyö 48 sivua

Toukokuu 2022

---

Terveydenhuollon ajanvarausjärjestelmissä asiakas tai terveydenhuollon ammattilainen varaa asiakkaalle ajan tarvittavaan terveydenhuollon palveluun. Ajanvarausjärjestelmän käyttö mahdollistaa saapuvien asiakkaiden määrän ennakoimisen, jolloin toimintojen resursoiminen on helpompaa. Näitä järjestelmiä halutaan kehittää, jotta palveluntarjoajat pystyisivät resursoimaan tarjoamia palveluita entistä tehokkaammin ja tarjoamaan samalla laadukkaampaa palvelua.

Tekoäly ja sen osa-alue koneoppiminen mahdollistavat ajanvarauspalvelujen uudenlaisen kehittämisen, koska niiden menetelmät kykenevät käsittelemään paljon dataa nopeasti ja tarkasti. Koneoppimisessa kone oppii ratkaisemaan halutun ongelman itsenäisesti algoritmin avulla. Käytännössä kone hyödyntää aiemmin käsittelemäänsä dataa yleistäessään tulevaa dataa. Ihmiseen verrattuna tekoäly on nopeampi ja tarkempi, ja sen suoritus on aina pohjimmiltaan sama.

Tässä opinnäytetyössä käsiteltiin työn tilanteen yrityksen, Fimlab Laboratoriot Oy:n, käytössä olevaa ajanvarausjärjestelmää sekä sen kehitystarpeita. Opinnäytetyössä esiteltiin selkeällä, ymmärrettävällä tavalla terveydenhuollon ajanvarausjärjestelmien koneoppimispohjaisia kehittämismahdollisuuksia. Tutkimusmenetelmänä käytettiin kvalitatiivista toimintatutkimusta.

Opinnäytetyössä oli kaksi päätoimista tutkimuskysymystä. Ensinnäkin etsittiin vastausta siihen, voidaanko koneoppimista hyödyntää nykyisen ajanvarausprosessin kehityksessä. Toisekseen tutkittiin, millaisten koneoppimisen ratkaisujen avulla voidaan saavuttaa nykyisen ajanvarausprosessin kehittämistavoitteita.

Tuloksena todettiin, että koneoppimista voidaan hyödyntää nykyisen ajanvarausprosessin kehityksessä monin eri tavoin. Opinnäytetyössä esitettiin hyödyntämismahdollisuuksia kaikilta koneoppimisen osa-alueilta. Nykyisen ajanvarausprosessin kehittämistavoitteita tukee parhaiten vahvistusoppimista hyödyntävä menetelmä.

---

Asiasanat: koneoppiminen, ajanvarausjärjestelmä, tekoäly

## **ABSTRACT**

Tampereen ammattikorkeakoulu  
Tampere University of Applied Sciences  
Master's Degree in Data Expertise and Artificial Intelligence

KOMI, EMILIA:  
Machine Learning Based Development Opportunities in Laboratory Appointment Scheduling System

Master's thesis 48 pages  
May 2022

---

Appointment scheduling systems are used in health care and other services to manage the flow of customers. Artificial intelligence and machine learning can be used to improve many scheduling systems, and their applications can process a huge amount of data in a short time, much faster or more precise than human could do.

The commissioner of the study was Fimlab Laboratoriot Oy Ltd. The objective of the study was to gather information about machine learning applications that could be used to improve the current scheduling system of the commissioner. The methodology used in the thesis was action research.

The results of the study suggest that machine learning could be used in the development of the current scheduling system. The study shows multiple usable machine learning applications of health care appointment systems that could be used to develop the current scheduling system. The results suggest that reinforcement learning application presented in the study was closest to match the development goals of the current scheduling system.

---

Key words: machine learning, appointment scheduling, artificial intelligence

## SISÄLLYS

1	JOHDANTO .....	5
2	TOIMINTATUTKIMUS TUTKIMUSMENETELMÄNÄ.....	8
	2.1. Toimintatutkimuksen käyttö menetelmänä .....	8
	2.2. Toimintatutkimus käytännössä opinnäytetyöprosessin aikana .....	11
3	AJANVARAUSJÄRJESTELMÄ JA SEN KEHITTÄMISTARPEET .....	15
	3.1. Kehittämisen kohteena olevan järjestelmän ominaisuudet.....	16
	3.2. Kehittämisen kohteena olevan järjestelmän käyttäminen ajanvaraukseen.....	18
	3.3. Kehittämisen kohteena olevan järjestelmän kehitystarpeet.....	21
4	TEKOÄLY JA KONEOPPIMINEN .....	23
	4.1. Ohjaamaton koneoppiminen .....	25
	4.2. Ohjattu koneoppiminen .....	26
	4.3. Vahvistusoppiminen .....	27
5	AJANVARAUSJÄRJESTELMIEN KEHITTÄMINEN.....	29
	5.1. Potilasdatan klusterointi ajanvarausjärjestelmien kehittämisessä	32
	5.2. Saapumatta jättämisen ennakointi .....	33
	5.3. Vahvistusoppimisen hyödyntäminen ajanvarausjärjestelmissä ....	36
6	POHDINTA .....	38
	LÄHTEET.....	45

## 1 JOHDANTO

Terveydenhuollon laboratorioissa tarjotaan terveydenhuollon asiakkaille erilaisia näytteenottopalveluita sekä analysointipalveluita. Jotta laboratorioiden toiminta olisi tehokasta ja resursointi riittävä, tarvitsevat ne näytteenoton palveluiden koordinoitua varten ajanvarausjärjestelmän. Ajanvarausjärjestelmiä käytetään useilla palvelualoilla. Ne voivat olla täysin palveluntarjoajan hallitsemia, jolloin ajanvaraukset tekevät palveluntarjoajan edustajat ja asiakkailla on vain vähän mahdollisuuksia vaikuttaa oman ajanvaraukseensa. Monissa ajanvarausjärjestelmissä asiakas pystyy kuitenkin itse vaikuttamaan oman ajanvarauksensa ajoitukseen varaamalla ajan haluamaansa ajankohtaan joko itse tai palveluntarjoajan edustajan kautta.

Ajanvarausjärjestelmiä halutaan kehittää, jotta palveluntarjoajat pystyisivät resursoimaan tarjoamiaan palveluita tehokkaammin ja tarjoamaan samalla laadukkaampaa palvelua. Tämä on palveluntarjoajalle edullisempaa, kun työvoiman hyödyntämistä voidaan tehostaa. Samalla laadukkaat palvelut houkuttelevat lisää asiakkaita.

Laadukkaat palvelut ja asiakkaiden houkuttelu on tärkeää myös terveydenhuoltoalalla. Monet julkisen terveydenhuollon kanssa palvelusopimuksen tehneet terveydenhuoltoalan yritykset ovat yksityisiä yrityksiä, joiden omistajina toimivat sairaanhoitopiirit, yksityishenkilöiden omistamia yrityksiä tai pörssiyrityksiä. Sekä julkisen että yksityisen terveydenhuollon on oltava kannattavaa ja mieluiten tuottoisaa. Laadukkaat ja kustannustehokkaat palvelut parantavat kannattavuutta.

Tekoäly ja sen osa-alue koneoppiminen ovat suuria mahdollisuuksia yritysten palveluiden kehittämiseksi. Koneoppimisessa kone hyödyntää aiemmin läpikäymäänsä dataa yleistäessään tulevaa dataa. Tällöin kone pystyy ratkaisemaan halutun ongelman itsenäisesti. Monille yksityishenkilöille ja yrityksille tekoäly näyttää vielä kaukaisena ja hankalasti hyödynnettävänä menetelmien kimpuna, mutta lähitulevaisuudessa erilaisia tekoäly- ja koneoppimismenetelmiä tullaan hyödyntämään yhä kiihtyvissä määrin eri yritysten palveluratkaisuissa. Tekoäly voi suorittaa loputtomasti toistoja ja on työssään tarkka ja nopea. Tekoälyä

ja koneoppimista voidaan hyödyntää palvelujen rakenteessa siten, että ihmis-työntekijöitä vapautuu haastavampiin ja monimutkaisempiin töihin.

Tässä opinnäytetyössä esitellään ajanvarausjärjestelmien koneoppimis pohjaisia kehitysmahdollisuuksia, joita voitaisiin hyödyntää Fimlab Laboratoriot Oy:n laboratorioajanvarausjärjestelmän kehitystyössä. Opinnäytetyössä on käytetty tutkimusmenetelmänä kvalitatiivista toimintatutkimusta. Toimintatutkimukset ovat spiraalimaisesti eteneviä tutkimuksia, joissa osallistuva tutkimus, tiedonhankinta, tiedon analysointi ja näiden pohjalta tapahtuva toiminta vuorottelevat. Toimintatutkimuksessa tutkija on aktiivinen osallistuja tutkimuksen kohteena olevissa tapahtumissa.

Opinnäytetyön tarkoituksena on tutustua opinnäytetyön tilaavan yrityksen käyttämään ajanvarausjärjestelmään ja sen kehittämistarpeisiin ja -tavoitteisiin, ja hyödyntää tätä tietoa selvitettäessä ajanvarausjärjestelmien koneoppimis pohjaisten kehittämiskäytäntöjä. Opinnäytetyön tavoitteena on esitellä erilaisia koneoppimis pohjaisia kehittämiskäytäntöjä ja niiden soveltamismahdollisuuksia selkeällä, ymmärrettävällä tavalla. Opinnäytetyössä esitellään koneoppimisen ratkaisuja ja termejä, joita voidaan tulevaisuudessa hyödyntää ajanvarauspalvelujen kehittämisessä. Opinnäytetyön sisältöä voidaan siten hyödyntää Fimlab Laboratoriot Oy:n käyttämän Vihta-ajanvarausjärjestelmän kehittämisprojektissa sekä mahdollisesti myös muussa palvelunkehityksessä.

Opinnäytetyössä esitetyt kehittämiskäytäntöt on rajattu koneoppimis pohjaisiksi niiden käytännön hyödyntämismahdollisuuksien ja tarjolla olevan tutkimusmateriaalin saatavuuden vuoksi. Rajaukseen on vaikuttanut myös opinnäytetyön sisällön rajaaminen.

Vihta-ajanvarausjärjestelmä on Netorek Oy:n tarjoama selainpohjainen ajanvarauspalvelu, jota käyttävät Fimlab Laboratoriot Oy:n lisäksi muun muassa Huslab, Nordlab, Helsingin yliopisto ja Maahanmuuttovirasto. Fimlab Laboratoriot Oy:n sisäisen kehittämisprojektin tavoitteena on kehittää ajanvarausjärjestelmän ulkopuolinen moduuli, jonka kanssa ajanvarausjärjestelmä keskustelisi ohjelmointirajapintojen kautta. Opinnäytetyöhön ei kuulu ulkopuolisen moduulin käytännön järjestelmä- ja ohjelmistosuunnittelu tai toteutus.

Opinnäytetyössä on kaksi päätoimista tutkimuskysymystä:

1. Voidaanko koneoppimista hyödyntää nykyisen ajanvarausprosessin kehityksessä?
2. Millaisten koneoppimisen ratkaisujen avulla voidaan saavuttaa nykyisen ajanvarausprosessin kehittämistavoitteita?

Vihta-ajanvarausjärjestelmän kehittämisprojektiin osallistuvat mm. Fimlab Laboratoriot Oy:n henkilöstöstä koottu projektiryhmä sekä toimittajan henkilöstöä. Myös opinnäytetyön kirjoittaja on osallistunut opinnäytetyöprosessin aikana projektiryhmän toimintaan.

Fimlab Laboratoriot Oy on sairaanhoitopiirien omistama laboratorioalan yritys, joka toimii 1,3 miljoonan suomalaisen asuttamalla alueella, viidessä sairaanhoitopiirissä: Pirkanmaalla, Kanta-Hämeessä, Päijät-Hämeessä, Keski-Suomessa ja Pohjanmaalla. Fimlab Laboratoriot Oy:lla on noin 120 näytteenottopistettä. (Fimlab Laboratoriot Oy: Medialle n.d.) Vuodessa Fimlab Laboratoriot Oy:n toimipisteissä tehdään yli 3,3 miljoona näytteenottoa, joita seuraa yli 16 miljoonaa tehtyä tutkimusta (Fimlab Laboratoriot Oy: Yritys n.d.). Verkkoajanvarauspalvelun kautta tehdään vuodessa jopa 850 000 ajanvarausta (Saloranta 2020).

## 2 TOIMINTATUTKIMUS TUTKIMUSMENETELMÄNÄ

### 2.1. Toimintatutkimuksen käyttö menetelmänä

Pertti Alasuutari kuvaa teoksessaan *Laadullinen tutkimus 2.0* (2011) kvalitatiivisen tutkimuksen vaiheiksi havaintojen pelkistämisen ja tulosten tulkinnan. Tutkimuksen aineistoa tarkastellaan vain valitun teoreettis-metodologisen näkökulman kannalta. Tarkastelun tarkoituksena on pelkistää aineistosta tutkimuksen kannalta olennaiset havainnot erillisiksi raakahavainnoiksi. Havaintojen pelkistäminen jatkuu havaintojen yhdistämisellä. Havainnoista etsitään yhteinen piirre tai nimittäjä. Havaintojen perusteella voidaan myös muotoilla sääntö, joka pätee koko aineistoon. Tällöin raakahavainnot karsitaan yhdeksi havainnoksi tai havaintojen joukoksi. (Alasuutari 2011, 30–34.)

Havaintojen yhdistämistä seuraa tulosten tulkinta. Sen tuloksena on, että tutkittavasta ilmiöstä tehdään merkitystulkinta. Tutkittavan aineiston tulkinnan lisäksi tulkinnassa hyödynnetään tilastotietoja, teoriakirjallisuutta ja muita tutkimuksia. Havaintojen pelkistämisen haaste on raakahavaintojen tyypittely; mikäli hyvin yksityiskohtaista tyypittelyä on paljon, on vaikea löytää yhteisiä piirteitä tai luoda sellaista sääntöä, joka pätee koko aineistoon (Alasuutari 2011, 34–36.)

Kvalitatiivisen toimintatutkimuksen vaiheet ovat kuitenkin jossain määrin erilaiset. Toimintatutkimusta kuvataan usein spiraalina, jossa suunnittelu, toiminta, havainnointi, tutkijan reflektio ja tutkimuksen kohteena olevan toiminnan muuttaminen vuorottelevat. (Juuti & Puusa 2020, 263.) Toimintatutkimuksen osiksi on kuvattu myös osallistuvaa tutkimusta, tiedonhankintaa, tiedon analysointia ja näiden pohjalta tapahtuvaa toimintaa (Mäntylä 2007, 54).

Toimintatutkimukset ovat yleensä kvalitatiivisia tutkimuksia, joissa samanaikaisesti yhdistyvät käytäntö ja systemaattinen teoreettinen tutkimus (Juuti & Puusa 2020, 256). Toimintatutkimukset ovat ongelmakeskeisiä ja käytäntöön suuntautuvia. Toimintatutkimuksissa tutkija ja tutkittavat tai ns. käytännön edustajat ovat aktiivisia toimijoita tutkimukseen liittyvässä muutosprosessissa, ja heidän suhteensa perustana on yhteistyö. (Kuula 2006.)



Toimintatutkimuksien tavoitteena on muuttaa käytännön toimintatapoja eli senhetkistä todellisuutta ja lisätä kohteena olevan ongelman teoreettista ymmärrystä. Tavoitteena oleva muutos voi toteutua tai jäädä toteutumatta, tai toteutua erilaisena kuin tutkimuksen alkuperäisenä tavoitteena. Tämä tuottaa omanlaisiaan tietoa tutkittavasta kohteesta. Muutoksen lopputuloksen perusteella toimintatutkimus vastaa kysymykseen *miten tutkittavat kohteet voivat muuttua tai miksi tutkittavat eivät muutu*. Muutoksen avulla pyritään kehittämään, edistämään tai parantamaan nykyhetkeä mahdollisimman reaaliaikaisesti. (Kuula 2006.)

Toimintatutkimukset soveltuvat hyvin organisaatioiden kehittämiseen. Organisaatioissa toimintatutkimukset voivat lisätä organisaation itseymmärrystä, kehittää konkreettisia muutostoimia ja toteuttaa niitä käytännössä. (Juuti & Puusa 2020, 256–260.) Toimintatutkimuksen lähtökohdat nousevat usein tutkimuskohteen itsensä tai sitä edustavan henkilöiden ongelmien ratkaisutarpeesta, aiemmissa tutkimuksissa havaituissa ongelmien ratkaisutarpeista tai näiden yhdistelmästä (Kuula 2006). Toimintatutkimusta on käytetty käsitteenä 1940-luvulta lähtien, ja sillä on ollut lähes alusta lähtien yhteys organisaatioiden onnistuneeseen kehittämistoimintaan (Juuti & Pusa 2020, 256). Toimintatutkimukset ovat jakautuneet eri mantereilla eri koulukunniksi. Australiassa toimintatutkimus nähdään yhteiskunnallisesti vaikuttavana tutkimusmenetelmänä, kun taas Iso-Britanniassa ja Yhdysvalloissa toimintatutkimukset ovat perinteisesti olleet ammattikäytäntöjä kehittäviä tutkimuksia. (Sarajärvi & Tuomi 2018, 34–35.)

Toimintatutkimusta on kritisoitu tutkimusmenetelmänä koko sen historian ajan. Toimintatutkimusta on kuvattu enemmänkin tutkimusstrategiseksi lähestymistavaksi kuin tutkimusmetodiksi (Sarajärvi & Tuomi 2018, 34–35). Voidaan kuitenkin todeta, että mikäli toimintatutkimukseen ja siihen liittyvään kehittämistehtävään sisältyy tiedon kerääminen ja analysointi tieteellisen käytännön mukaisesti, toimintatutkimus luetaan tieteelliseksi tutkimukseksi (Juuti & Pusa 2020, 256).

Myös toimintatutkimuksen esitystapaa jatkuvana spiraalina on kritisoitu. Usein toimintatutkimuksissa tapahtumat ja tutkimuksen eteneminen ovat paljon monisyisempiä kuin spiraalissa voidaan esittää. (Mäntylä 2007, 53–54.)

Toimintatutkimus valittiin opinnäytetyön tutkimusmenetelmäksi, koska toimintatutkimuksen tavoitteet, joissa halutaan muuttaa käytännön toimintatapoja ja lisätä tutkimusongelmana olevana kohteen teoreettista ymmärrystä, sopivat tähän työelämän konkreettiseen kehittämissuunnitelmaan. Myös toimintatutkimusten vankka historia erilaisten työorganisaatioiden kehittämisessä sopi tähän tutkimukseen. Toiveena on myös tuoda tämän opinnäytetyön myötä konkreettisia muutoksia työelämään, opinnäytetyön päätoimisena kohteena olevan ajanvarausjärjestelmän tai mahdollisen muun tulevaisuuden ajanvarausjärjestelmän koneoppimispohjaisia kehitysmahdollisuuksia esitellessä. Koska työelämää rasittavat monet velvollisuudet ja vaatimukset, erilaisiin nykyhetken ja tulevaisuuden innovaatioihin ja niihin liittyvään tiedonhakuun voi olla vaikeaa löytää aikaa ja voimavaroja.

Myös muita tutkimusmenetelmiä harkittiin tämän opinnäytetyön tutkimusmenetelmiksi. Näitä olivat mm. tapaustutkimus ja konstruktiiivinen tutkimus. Tapaustutkimuksessa tutkitaan yhtä tai useampaa tapausta tai ilmiötä, jotka halutaan tutkimuksessa määritellä, analysoida ja ratkaista. Koska tapaustutkimukseen liittyy usein tutkijan etäisyys ja kontrollin vähäisyys tutkimuksen kohteena olevasta asiasta, tapaustutkimus jätettiin tutkimusmenetelmänä syrjään. Opinnäytetyöprosessiin on liittynyt myös ajanvarausjärjestelmän projektiryhmässä työskentely sekä mielipiteiden ja tiedon jakaminen, eikä tutkijan etäisyys tutkinnan kohteena olevasta asiasta siten toteutunut. Koska tapaustutkimukseen liittyy myös tapauksen tiheä ja ainutlaatuinen kuvaus, tulkinta ja ymmärtäminen, ei työelämä olisi saanut opinnäytetyöstä vastaavaa hyötyä, mikäli opinnäytetyö olisi painottunut kuvaamaan, miksi ajanvarausjärjestelmää pitää kehittää. (Eriksson & Koistinen 2005, 4–18.) Myös observointitutkimusta harkittiin tutkimusmenetelmäksi, mutta myös sen haasteeksi todettiin työelämän saaman konkreettisen hyödyn vähäisyys.

Konstruktiiivinen tutkimusmenetelmä nähdään usein yhtenä tapaustutkimuksen alamenetelmänä. Se on kehitetty erityisesti liiketaloustieteen käyttöön, mutta myöhemmin sitä on käytetty menestyksekkäästi myös muilla aloilla. Konstruktiiivisen tutkimusmenetelmän tavoitteena on tuottaa innovatiivinen konstruktio, eli jonkinlainen ihmisen luoma artefakti, joka ratkaisee reaali maailman ongelman. Konstruktiiiviseen tutkimusmenetelmään liittyy tutkijan ja käytännön edustajien

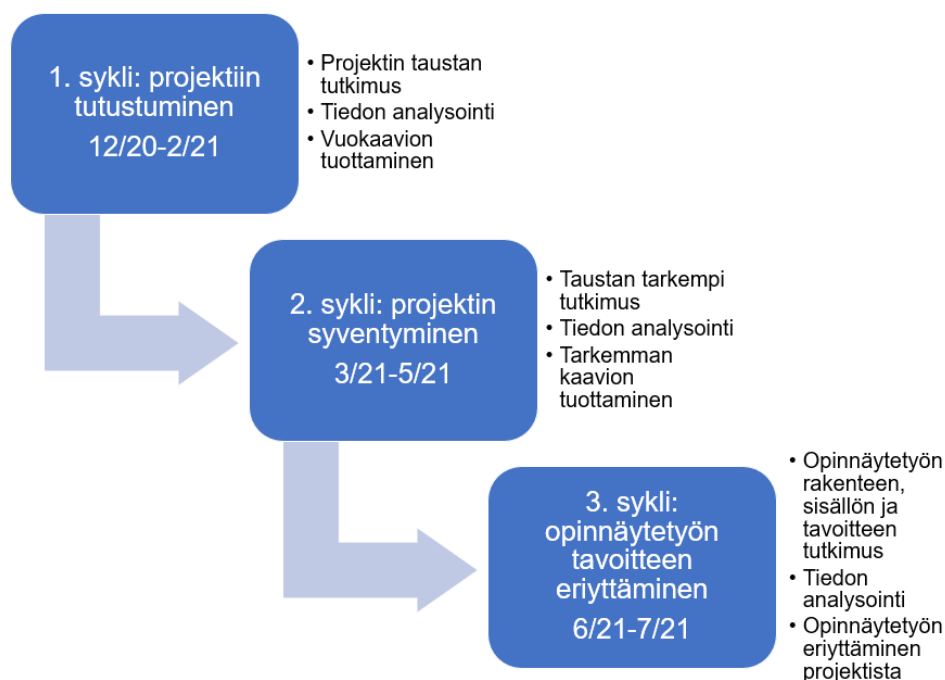
yhteistyö ja oppimisprosessi. Tältä osin se muistuttaa toimintatutkimusta. Konstruktiiiviseen tutkimukseen liittyy myös halu vaikuttaa senhetkiseen todellisuuteen. (Lukka 2001.) Alun perin tämän opinnäytetyön tavoitteena oli tuottaa konkreettinen tulos, projektiryhmän yhteistyön tuloksena kehitetty ajanvarausjärjestelmä. Aikataulupaineiden ja projektiin liittyvien haasteiden takia opinnäytetyötä haluttiin kuitenkin eriyttää projektiryhmän toiminnasta ja suunnata sen sisällöllistä hyötyä enemmän tulevaisuuteen. Tämän takia todettiin, että konstruktiiivinen tutkimusmenetelmä ei sovellu tähän opinnäytetyöhön. Suurena haasteena olisi ollut myös kaikkien työelämän konstruktiiivisten tutkimusten ongelma – pelko liikesalaisuuksien menettämisestä (Lukka 2001).

Täten toimintatutkimuksen valintaa tutkimusmenetelmäksi puolsivat useat seikat, eivätkä muut opinnäytetyön tutkimusmenetelmiksi harkitut menetelmät olleet yhtä osuvia tähän tutkimukseen. Myös jälkeenpäin menneisyyteen projektiryhmän toimintaa katsoessa sekä koko prosessia pohtiessa voidaan todeta, että toimintatutkimus oli tähän työhön sopiva menetelmä.

## **2.2. Toimintatutkimus käytännössä opinnäytetyöprosessin aikana**

Opinnäytetyön kirjoittaja on työskennellyt ajanvarausjärjestelmän kehittämissuorituksissa tammikuusta 2021 alkaen. Tämä työskentely on sisältänyt ajanvarausjärjestelmään liittyviin kokouksiin osallistumista, ajanvarausjärjestelmään tutustumista mm. sen toiminnan sekä erilaisten käyttäjäryhmien kautta, kehittämissuorituksiin liittyvien kaavioiden ja taulukoiden tuottamista sekä tiedonhakuja.

Kehittämissuoritus ja siihen liittyvä opinnäytetyö on edennyt spiraalimaisesti, toimintatutkimuksen tunnettua rakennetta mukaillen. Projektin ja opinnäytetyön eteneminen on kuvattu kuvioissa 1 ja 2. Spiraalin ja toiminnan syklisyyden tunnistaminen projektin aikana oli tärkeä syy tutkimuksen menetelmävalintaan. Spiraaliin liittyvän syklin rakenne on ollut projektin sen hetkisen tilanteen vaatimien toimien tutkimus, näihin liittyvä tiedonhankinta, sitä seuraava tiedon analysointi ja edellä mainittujen tapahtumien pohjalta tapahtuva toiminta, usein esimerkiksi jonkinlaisen kaavion tuottaminen.



KUVIO 1. Tutkimuksen syklit 1, 2 ja 3.

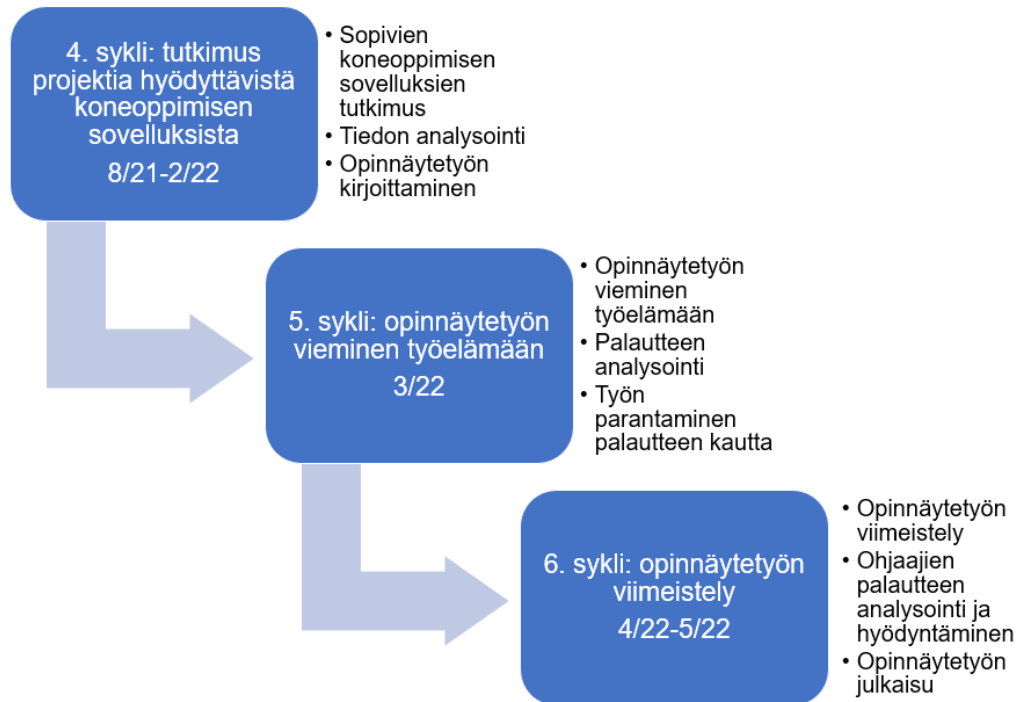
Joulukuussa 2020 tutkimus lähti liikkeelle, kun opinnäytetyön kirjoittaja tutustui kehittämissuoritusprojektiin. Tavoitteena oli tällöin työskennellä projektiryhmässä ja saada aikaan asiakasta ohjaava laboratorioajanvarausjärjestelmä yhteistyössä toimittajan henkilökunnan kanssa. Opinnäytetyön kirjoittaja teki tiedonhankintaa ja tiedon analysointia mm. projektiryhmän aiempien materiaalien perusteella, erilaisten näytteiden näytteenotto- ja käsittelyvaatimuksista sekä Fimlab Laboratoriot Oy:n intran työohjeista ja laboratoriotoiminnasta, ja tämän pohjalta laati yksinkertaistetun vuokaavion, jossa esitettiin malliesimerkki ajanvarausjärjestelmän kehittämismahdollisuuksista. Koska vuokaavio sisältää tarkkaa tietoa mm. palvelun vaatimuksesta ja palvelunkuvauksesta, sitä ei kuitenkaan voida esittää osana opinnäytetyötä.

Kaaviota pidettiin hyvänä pohjatyönä projektiin ja sitä hyödynnettiin materiaalina projektissa. Keväällä 2021 alkoi kuitenkin näyttää siltä, että projektiryhmän aikataulut eivät kohtaa opinnäytetyön aikataulun kanssa. Tästä huolimatta tutkimus ehti edetä vielä toisen toimintatutkimuksen kaltaisen syklin (toimien tutkimus, tiedonhankinta, tiedon analysointi ja toiminta) verran, kun uuden tiedonhankintarupeaman jälkeen opinnäytetyön kirjoittaja esitti tarkemman, taulukkomallisen kaavion, jossa esitettiin ajanvarauspalvelun asiakkaita rajoittavia tekijöitä. Kaavio sisälsi mm. tiedon näytteenottopisteistä, joilla on valmius kylmänäytteenottoon,

ja yhdisti tämän tiedon kylmänäytteenottoa vaativiin, yleisimpiin tutkimuksiin. Tätä kaaviota hyödynnettiin jälleen projektimateriaalina.

Aikatauluhaasteet järjestelmän kehittämissä projektissä kuitenkin konkretisoituivat entisestään kesän aikana, ja tehtiin päätös opinnäytetyön eriyttämisestä projektin etenemisestä. Opinnäytetyön kirjoittajan työskentely projektin parissa kuitenkin jatkui samaan tapaan. Opinnäytetyön tavoitetta sen sijaan muutettiin enemmän tulevaisuuteen sopivaksi. Opinnäytetyön tarkoitus – tutustua ajanvarausjärjestelmään ja sen kehittämistarpeisiin ja -tavoitteisiin – säilyi samana.

Kolmas tutkimuksen sykli lähti käyntiin kesäkuukausien aikana pohtimalla, miten opinnäytetyön sisällöstä saataisiin mahdollisimman hyvä hyöty tulevaisuudessa projektin edetessä. Pohdinnan jälkeen todettiin, että kannattavaa olisi esittää ymmärrettävällä tavalla erilaisia ajanvarauspalveluiden koneoppimispohjaisia kehittämismahdollisuuksia. Näistä löytyisi hyvin tietoa mm. tieteellisten artikkeleiden muodossa. Mikäli vastaavia järjestelmätoteutuksia haluttaisiin kokeilla suomalaisissa digitaalisissa terveydenhuollon palveluissa ja järjestelmissä, on kuitenkin otettava huomioon, että nämä vaatisivat soveltamista ja käytännön toteutustilanteissa toimintamallin muutoksia ja mm. vaativaa koodausosaamista. Tärkeäksi kuitenkin nähtiin näiden sovellusten esittely jo pelkästään tulevaisuuden järjestelmäosaamisen ja -kehittämisen kannalta. Vaikka sovelluksia ei lopulta voitaisiakaan hyödyntää ajanvarausjärjestelmän kehittämisessä lähitulevaisuudessa, voidaan menetelmiä hyödyntää muussa järjestelmäkehityksessä ja vähintään tuoda niitä tutuiksi ja tiettäväksi projektiryhmän jäsenille.



KUVIO 2. Tutkimuksen syklit 4, 5 ja 6.

Neljäs tutkimuksen sykli oli opinnäytetyöhön liittyvä tiedonhaku sekä varsinaisen opinnäytetyön kirjoittaminen. Sykli sisälsi ajanvarausjärjestelmän kehitykseen soveltuvien koneoppimisen sovellusten tutkimusta, tiedon analysointia ja opinnäytetyön kirjoittamista. Viidentenä syklinä voidaan pitää opinnäytetyön ja sen sisältämän tutkimustiedon viemistä työelämään, jossa sitä tullaan hyödyntämään ajanvarausjärjestelmän kehittämisessä. Opinnäytetyön ja projektiryhmän toiminnan aikataulujen vaihtelevuuden vuoksi konkreettista hyödyntämis- ja kehittämisuutta ei voida kuvata tässä opinnäytetyössä. Kuudes ja viimeinen tutkimuksen sykli kuvaa opinnäytetyön viimeistelyä, saadun palautteen analysointia ja hyödyntämistä sekä valmiin opinnäytetyön julkaisua.

### 3 AJANVARAUSJÄRJESTELMÄ JA SEN KEHITTÄMISTARPEET

Erilaisia ajanvarausjärjestelmiä on käytössä lähes kaikissa terveydenhuollon palveluissa. Ajanvarausjärjestelmien tarkoituksena on hallita palvelun kysyntää ja tarjontaa palveluiden priorisoinnin ja resurssien optimoinnin kautta. Tehokkaan ajanvaraustarjonnan mahdollistaa ajanvarausjakson jakaminen lyhyisiin palvelu-aikoihin. Terveydenhuollossa ajanvarausjärjestelmillä on tärkeä rooli. Hyvä ajanvarausjärjestelmä lisää sekä asiakkaiden että työntekijöiden tyytyväisyyttä. Ajanvarausjärjestelmien käyttö vähentää asiakkaiden odotusaikaa sekä odotushuoneiden ruuhkautumista. (Akinode & Oloruntoba 2017, 16.)

Paine erilaisten terveydenhuollon järjestelmien kehittämiseen on voimakas. Tämä johtuu paitsi terveydenhuollon palvelujen kasvaneesta kysynnästä, myös terveydenhuollon kustannusten noususta. Samaan aikaan vanheneva väestö lisää terveydenhuollon tarvetta entisestään. Myös vaatimukset terveydenhuollon palvelujen laatua kohtaan kasvavat jatkuvasti. Tutkimusten mukaan ennakoiva terveydenhuolto parantaa väestön yleistä terveydentilaa ja voi laskea sairaalatasoisesta hoidosta aiheutuvia kuluja. (Ahmadi-Javid, Jalali & Klassen 2017; Chia & Loh 2018.) Ajanvarausjärjestelmät ovat terveydenhuollon järjestelmissä poikkeuksellisia, sillä ne palvelevat toiminnallisuuksillaan suoraan potilasta.

Internet-ajanvarausjärjestelmän käyttämisessä on lukuisia hyötyjä. Käytännössä lähes kaikista ajanvarausjärjestelmistä pystytään keräämään tilastotietoa ajanvarausprosessista. Esimerkiksi ajanvarauskalentereja, ajanvaraustilastoja ja palvelun konkreettista kestoa mittaavien tilastoja hyödyntäen palveluntarjoaja kykenee seuraamaan asiakkaiden virtausta. Myös mahdollisissa ongelmatapauksissa voidaan hyödyntää ajanvarausjärjestelmän keräämiä tietoja yksittäisen tapauksen selvittämisessä tai yleisen asiakaskokemuksen parantamisessa.

Ajanvarauksien käyttämättä jättäminen aiheuttaa terveydenhuollossa tehottomuutta ja resurssien hukkaa. Se pidentää myös muiden asiakkaiden odotusaikaa ajanvarauksen ja ajanvarauksen toteutumisen välillä, mikä laskee yleistä asia-

kastyytyväisyyttä. Tutkimusten mukaan Euroopassa jopa 19,3 % terveydenhuollon ajanvarauksista jää käyttämättä. (Dantas, Fleck, Hamacher & Oliveira 2018, 412–414.)

Internet-ajanvaraus vähentää ajanvarauksien käyttämättä jättämistä. Internet-ajanvarauksen käyttöönoton vaikutuksesta ajanvarauksien käyttöön on hyvin vähän tuoreita tutkimuksia, koska suurimmassa osassa länsimaita internet-ajanvaraus on saattanut olla käytössä kuluvan vuosituhannen alusta lähtien. Sen sijaan monissa vähemmän kehittyneissä valtioissa internet-ajanvarauksien käyttöönotto on ajankohtaista. Näihin käyttöönottoihin liittyviä tutkimuksia voidaan hyödyntää myös länsimaissa, ottaen kuitenkin huomioon kulttuurilliset erot ja mahdollisen paikallisen poliittisen epävakauden. Esimerkiksi vuonna 2017 Iranissa toteutetun tutkimuksen mukaan 25 % varatuista terveydenhuollon ajoista jäi käyttämättä ennen internet-ajanvarausta. Internet-ajanvarauksen käyttöönoton jälkeen vain 11 % ajoista jäi käyttämättä. (Abu-Hanna ym. 2019, 4–6.) On myös huomioitava, että mahdollisuus muistutukseen esimerkiksi tekstiviestillä ennen varattua aikaa vähentää ajan käyttämättä jättämisen todennäköisyyttä entisestään (Binachon ym. 2019, 216–219; Bhanbhro ym. 2016, 488–490).

Internet-ajanvaraus vähentää myös inhimillisiä virheitä ajanvarauspalvelussa, kuten virheellisiä yksittäisten aikojen moninkertaisia varauksia. Lisäksi internet-ajanvaraus mahdollistaa yleensä lisätietojen antamiseen ajanvarauksen yhteydessä, mikä voi parantaa asiakkaan saaman yksittäisen palvelukerran laatua. (Akinode & Oloruntoba 2017.) Esimerkiksi mikäli lisätietoihin lisätään tieto huonosta kuulosta tai näkövammasta, asiakaspalvelija voi ottaa sen huomioon palveluksessaan.

### **3.1. Kehittämisen kohteena olevan järjestelmän ominaisuudet**

Vihta-ajanvarausjärjestelmä on Netorek Oy:n (myöhemmin ”toimittaja”) tarjoama selainpohjainen ajanvarausjärjestelmä. Ajanvarausjärjestelmä liitetään yleensä asiakasyrityksen kotisivuun. Ajanvarausjärjestelmässä asiakkaat voivat varata, muuttaa ja peruuttaa palveluaikoja. Järjestelmä on laiteriippumaton pilvipalvelu



ja vaatii käyttämiseensä vain internet-yhteyden ja -selaimen. Järjestelmä mahdollistaa myös asiakkaan niin halutessa ohjelmistorajapintojen käytön REST-ohjelmistoarkkitehtuurimenetelmää mukaillen. Tarvittaessa toimittaja tarjoaa myös erillisen integraattorin paikallisiin tietojärjestelmiin. (Netorek Oy n.d.)

Ajanvarauksen saatavuuden valitsee asiakasyritys selainpohjaisen käyttöliittymänsä kautta. Asiakasyritys voi valita, mitkä ajanvarauspalvelut ovat julkisia ja mitkä esimerkiksi ammattilaisajanvaraajien saatavilla. Lisäksi eri asiakkaille voidaan avata erillisiä varausoikeuksia eri palveluihin. Järjestelmä tarjoaa myös mahdollisuuden asiakasohjaukseen verkkolomakkeiden kautta, mutta tämä ominaisuus ei ole ollut käytössä Fimlab Laboratoriot Oy:n ajanvarauspalveluissa tämän opinnäytetyön kirjoittamisen aikana.

Ajanvarausjärjestelmän palvelukokonaisuuteen kuuluu myös jononhallinta. Näytteenoton ammattilaiset seuraavat päivän varaustilannetta kunkin näytteenottolaboratorion työjonosta. Näytteenotossa samaa jonoa saattaa palvella useampi laboratorion työntekijä, ja palvelun kautta he merkitsevät ajan varannutta asiakasta palvellessaan varauksen työn alle ja valmiiksi. Toimittajan kanssa solmittuun sopimukseen kuuluvat myös näytteenottolaboratorioissa käytössä olevat itseilmoittautumisautomaatit, joilla asiakkaat ilmoittautuvat saapuneensa laboratorioon tai ottavat vuoronumeron, mikäli laboratoriossa tarjotaan myös palvelua vuoronumeroilla.

Ajanvarausjärjestelmä tarjoaa myös raportointimahdollisuuksia, joilla järjestelmästä voidaan kerätä dataa ja seurata mm. palvelutilanteiden kestoa ja resursien riittävyyttä. Varaus- ja asiakasmääriä voidaan seurata myös reaaliaikaisesti. Tämä tarjoaa mahdollisuuksia toiminnan kehittämiseen.

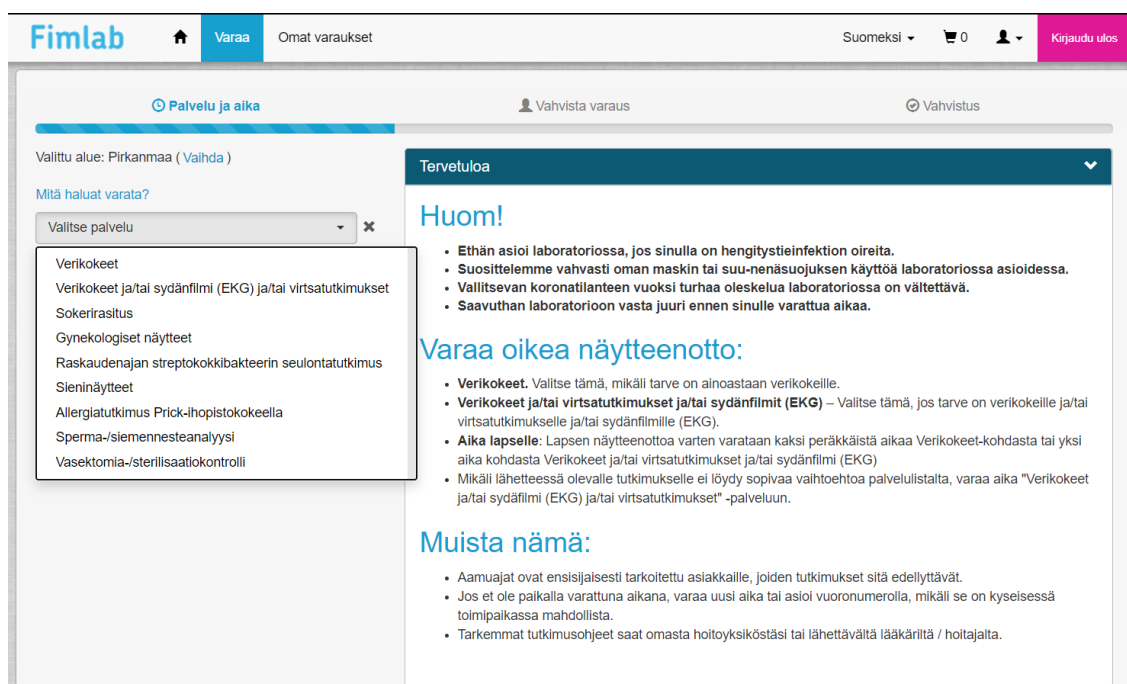
Järjestelmä täyttää Euroopan tietosuoja-asetuksen GDPR:n vaatimukset. Järjestelmän tietoturvallisuus on suojattu palomuurilla sekä käyttöjärjestelmän ja siihen liittyvien laajennuksien jatkuvalla ylläpidolla. Järjestelmän asiakastaso on eriytetty käyttäjä- ja ylläpitotasosta erillisille virtuaalipalvelimille. Järjestelmän kone-sali on valvottu. (Netorek Oy n.d.)

### **3.2. Kehittämisen kohteena olevan järjestelmän käyttäminen ajanvaraukseen**

Ajanvarausjärjestelmää käyttävät asiakasajanvaraajat, puhelinajanvaraajat ja ammattilaisajanvaraajat. Asiakasajanvaraajia ovat kaikki Fimlab Laboratoriot Oy:n toiminta-alueella asuvat yksityishenkilöt. Puhelinajanvarauksessa työskentelee joitakin kymmeniä henkilöitä, jotka varaavat ajanvarausjärjestelmän kautta ajan puhelinajanvaraukseen soittaville asiakkaille. Puhelinajanvarauksen työntekijöillä ei ole terveysalan koulutusta, eivätkä he näe asiakkaiden terveystietoja, kuten laboratoriopyyntöjä.

Ammattilaisajanvaraajia on satoja. He ovat erilaisten hoitoyksiköiden työntekijöitä (esimerkiksi sairaanhoitajia), jotka varaavat aikoja oman hoitoyksikkönsä potilaita varten. Ammattilaisajanvaraajilla voi olla pääsy erillisiä varausoikeuksia vaativien palvelujen varaamiseen, kuten sternaali- eli luuydinpunktion ajanvaraukseen.

Tällä hetkellä ajanvarausjärjestelmän varausprosessissa asiakasajanvaraaja valitsee ensin haluamansa maantieteellisen alueen, jossa asioida. Asiakas valitsee haluamansa palvelun alavetovalikosta (kuvakaappaus valikosta kuvassa 1). Asiakasajanvarauksessa palveluvaihtoehtoina ovat verikokeet, verikokeet ja/tai sydänfilmi (EKG) ja/tai virtsatutkimukset, sokerirasitus, gynekologiset näytteet, raskaudenajan streptokokkibakteerin seulontatutkimus, sieninäytteet, allergiatutkimus Prick-ihopistokokeella, sperma-/siemennesteanalyysi ja vasektomia-/sterilisaatiokontrolli.



KUVA 1. Kuvankaappaus ajanvarauspalvelusta. Asiakas valitsee haluamansa palvelun annetuista vaihtoehdoista. Kuvankaappaus otettu 18.9.2021.

Eri palveluille on varattu laboratorioihin eri määriä varattavia palveluaikoja soveltuviin kellonaikoihin. Esimerkiksi aamulla on tehostettu verikoe- sekä verikokeet ja/tai sydänfilmi (EKG) ja/tai virtsatutkimukset-palveluiden saantia, ja gynekologisten näytteiden palveluajat on keskitetty myöhempään aamupäivään ja iltapäivään.

Palvelun valinnan jälkeen valitaan toimipiste. Aikaa varaavalle esitetään vain ne toimipisteet, joissa asiakkaan valitsemaan palvelua voidaan tarjota. Asiakas voi valita, näyttääkö ajanvarausjärjestelmä vapaat ajat päivä vai viikko kerrallaan. Vapaat ajat esitetään allekkain aloittaen aikaisimmasta vapaasta ajasta.

Asiakkaan valitessa ajan, järjestelmä pyytää tarkistamaan valinnan. Järjestelmä esittää ponnahdusikkunassa valitun palvelun, valitun päivämäärän ja varauksen kellonajan sekä valitun toimipisteen. Asiakas voi myös tehdä valinnan ”lisää varauskoriin”, jolloin hän siirtää valitun aikansa odottamaan varauskoriin ja pystyy varaamaan useita aikoja kerralla. Asiakkaalla on 120 minuuttia aikaa vahvistaa varauskorissa oleva varaus.

Varaus on vahvistettava täyttämällä asiakastiedot. Varausvahvistukseen voidaan täyttää asiakkaan henkilötunnus, etunimi, sukunimi, puhelinnumero ja sähköpostiosoite. Asiakas voi myös kirjoittaa erilliseen viestikenttään, mikäli hänellä on jokin lisähuomioita varauksestaan. Pakollisia kenttiä ovat henkilötunnus, etunimi ja sukunimi.

Mikäli asiakas on luonut itselleen käyttäjätunnuksen ajanvarausjärjestelmään, järjestelmä täyttää kaikki muut kentät paitsi henkilötunnuksen automaattisesti. Mikäli järjestelmän käyttäjä on varaamassa aikaa toiselle henkilölle, hän voi tehdä valinnan ”varaamiseksi toiselle henkilölle”. Silloin ohjelma tyhjentää kentät ja käyttäjän on täytettävä ne varauksen kohteen tiedoilla. Järjestelmä myös kertoo, että mikäli käyttäjä haluaa varauksen kohteelle varauksen vahvistusviestin sähköpostitse tai tekstiviestitse, sähköpostiosoite tai puhelinnumero on täytettävä kenttiin.

Järjestelmä pyytää tarkistamaan ja vahvistamaan varauksen. Asiakkaalle esitetään varattu palvelu, päivämäärä ja aika sekä varattu toimipiste. Lisäksi asiakkaalle esitetään yleisiä ohjeita ennen näytteenottoa. Yleiset ohjeet esitetään kuvassa 2. Verikokeisiin liittyvissä ohjeissa esimerkiksi kehoitetaan varamaan kilpirauhastutkimukset ennen klo 10, ohjeistetaan paastoamaan paastoa vaativiin tutkimuksiin ja pyydetään välttämään fyysistä rasitusta näytteenottoon tullessa.

**i** Ohjeiden noudattamisella varmistatte luotettavien tulosten saannin. Jos et voi noudattaa ohjeita, toivomme sinun ilmoittavan siitä näytteenottajalle.

Verinäytteenottoon valmistautuminen. Noudattakaa seuraavia ohjeita ellei lääkäri ole toisin määrännyt:

- **Kilpirauhastutkimukset:** mikäli teille on määrätty kilpirauhastutkimuksia ( P -T4-V, P -TSH), varatkaa aika ennen klo 10.00
- **Lääkepiteisyyden määrittäminen:** mikäli teille on määrätty lääkepiteisyyden määrittäminen, ottakaa kyseinen lääke vasta näytteenoton jälkeen

Näin valmistaudutte paastoa edellyttäviin laboratoriotutkimuksiin.

- ei saa syödä eikä juoda 10-14 tuntia ennen näytteenottoa
- näytteenottoa edeltävänä vuorokautena ei saa nauttia alkoholia

Näytteenottoaamuna:

- ei saa tupakoida
- voit juoda lasillisen vettä ja ottaa mahdolliset lääkkeet lääkärin näin ohjeistaessa

Näytteenottoon tullessanne välttää fyysistä rasitusta.

**Virtsanäytteet**

- Virtsan on oltava rakossa vähintään 4 tuntia ennen keskisuolavirtsanäytteen (PLV) ottoa.
- Jos joudutte käymään yöllä WC:ssä, ottakaa näyte vasta sitten kun edellisestä virtsaamisesta on kulunut vähintään 4 tuntia, mielellään 6 tuntia.
- Virtsanäytteen voi ottaa myös kotona. Laboratorio tai terveysasema antaa sinulle erilliset ohjeet ja näytteenottotarvikkeet. Huom. virtsanäyte tulee antaa laboratorion tai terveysasemalta annettuun näyteastiaan.

**EKG-tutkimus**

- Ennen tutkimusta suositellaan olemaan kaksi tuntia ilman vahvaa ateriaa ja neljä tuntia ilman piristäviä juomia kuten kahvia, teetä ja kolajuomia.
- Tutkimus ei edellytä paastoa

**KUVA 2. Kuvankaappaus ajanvarauspalvelusta. Ajanvarauspalvelun asiakkaalle esittämät yleiset ohjeet verikokeet ja/tai sydänfilmi (EKG) ja/tai virtsatutkimukset -ajanvarauksen yhteydessä. Kuvankaappaus otettu 18.9.2021.**

Asiakas pystyy myös valitsemaan haluamansa muistutustyylin ja muistutuksen ajankohdan. Mikäli asiakas haluaa tilata muistutuksen varauksestaan, hän voi valita sähköposti- tai tekstiviestimuistutuksen. Muistutuksen ajankohdan vaihtoehdot ovat kaksi päivää, päivä, 12 tuntia, kaksi tuntia tai tunti ennen varattua aikaa.

Puhelinajanvaraajien ja ammattilaisajanvaraajien käyttämä näkymä on samanlainen asiakasajanvaraajien näkymään verrattuna. Puhelin- ja ammattilaisajanvaraajilla on yleensä mahdollisuus varata myös erillisiä varausoikeuksia vaativia palveluita. Lisäksi mikäli ajanvarauspalveluun siirrytään järjestelmäintegraation kautta, ajanvarausjärjestelmään siirtyvät myös toisessa järjestelmässä käsitellyt potilaan tai asiakkaan henkilötiedot varaukseen valmiiksi täytettyinä.

### **3.3. Kehittämisen kohteena olevan järjestelmän kehitystarpeet**

Kehittämisen kohteena olevan järjestelmän kehittämistarpeet oli määritetty sisäisesti ennen opinnäytetyöprosessin alkamista, ja kehittämistä koskevat vaatimukset tarjottiin luottamuksellisesti opinnäytetyön kirjoittajan haltuun. Luottamuksen ja liikesalaisuuden säilymiseksi kehittämistarpeita käsitellään tässä luvussa vain pintapuolisesti.

Monet ajanvarausta tekevät asiakkaat eivät tiedä, millaista ajanvarausta heidän laboratoriolähetteensä vaativat. Lähetteen tehneen terveydenhuollon yksikön tehtävä on ohjata asiakasta tekemään oikeanlainen ajanvaraus laboratorioon. Valitettavan usein tämä ohjaaminen jää tekemättä, ei ole riittävän selvää tai asiakas unohtaa saamansa ohjauksen ennen kuin ajanvaraus on ajankohtaista. Kun asiakkaalle ei ole selvää, pitääkö ennen näytteenottoa esimerkiksi paastota tai ei, hän voi paastota ”varmuuden vuoksi” ja tarvitsee siksi aamuajan näytteenottoonsa. Aamuaikoja on kuitenkin rajallisesti, ja joissakin toimipisteissä ajanvaraus voi siirtyä siksi pitkänkin ajan päähän. Tämä ei välttämättä ole haaste työikäiselle, autoilevalle laboratorioasiakkaalle – hän voi käydä laboratoriokokeissaan helposti myös toisissa toimipisteissä. Haasteita aiheutuu siitä, että asiakkaat, joiden

liikkuminen toimipisteiden välillä on hankalampaa tai joiden näytteenotolla on toimipisterajoituksia, eivät välttämättä pysty valitsemaan toista toimipistettä, jossa esimerkiksi aamuaikoja olisi paremmin saatavilla.

Ajanvarausjärjestelmää halutaan kehittää asiakasta ohjaavaksi järjestelmäksi, joka suosittelee asiakkaalle tämän laboratoriotutkimuksiin nähden oikeaa aikaa sopivimpaan laboratorioon. Tämä palvelee täten paitsi asiakasta itseään, myös toisia asiakkaita, kun laboratorion näkökulmasta virheellisiä ajanvarauksia on vähemmän. Kun varatut ajat jakaantuvat tehokkaammin koko päivän ajalle, laboratorion toiminta on sujuvampaa. Tämä mahdollistaa myös paremman resurssien ja kysynnän kohtaamisen. Ajanvarausjärjestelmän kehityksen parissa työskentelee projektiryhmä, johon kuuluu mm. Fimlab Laboratoriot Oy:n henkilöstöä ja toimittajan henkilöstöä.

Projektiryhmän tavoitteena on kehittää ajanvarausjärjestelmän ulkopuolinen moduuli, joka tunnistaa ohjelmistorajapintojen avulla laboratorioasiakkaan laboratoriolähetteen ja tuntee niiden preanalyttiset vaatimukset, kuten näytteenoton suositellun kellonajan, näytteenottoaikan tai paastovaatimuksen. Moduuli välittää nämä vaatimukset ajanvarauspalvelulle, joka ohjaa sen jälkeen asiakasta varamaan oikean ajan sopivimpaan laboratorioon. Toteutukseltaan moduuli voisi esimerkiksi olla sääntöpohjainen asiantuntijajärjestelmä. Järjestelmän kehityksen tarkoitus on vähentää hukkaa ja lisätä henkilöstön tyytyväisyyttä, kun virheelliset ajanvaraukset ja niihin liittyvä kuormitus vähenevät.

Tämän opinnäytetyön tavoitteena on esitellä ja pohtia koneoppimispohjaisia kehitysmahdollisuuksia, joita ajanvarausjärjestelmän kehittämisessä voitaisiin hyödyntää tulevaisuudessa. Näiden kehitysmahdollisuuksien on oltava sellaisia, jotka voisivat parantaa asiakasohjausta, -hankintaa ja -pitoa sekä lisätä verkkoajanvarausta. Näiden tavoitteiden saavuttaminen lisäisi välillisesti yrityksen toiminnan kustannustehokkuutta.

## 4 TEKOÄLY JA KONEOPPIMINEN

Tekoäly on koneen suorittama toiminto, jossa kone käyttää aiemmin ihmisen älykkyyteen liitettyjä taitoja, kuten oppimista, päättelyä, suunnittelemista tai luomista. Järjestelmät, jotka pohjautuvat tekoälyyn, voivat esimerkiksi havainnoida ympäristöään, käsitellä näitä havaintoja ja ratkaista niihin liittyviä ongelmia. (Euroopan parlamentti: Mitä tekoäly on ja mihin sitä käytetään? 2021.)

Ihmiseen verrattuna tekoäly on nopeampi ja tarkempi. Tekoäly ei väsy koskaan, sen suoritus on aina pohjimmiltaan sama, ja mikäli sovelluksen kehitykseen käytetty data on puolueetonta, myös tekoäly on puolueeton. Tekoäly ei ole tietoinen tai itsenäinen. Tekoälyn hyödyntämismahdollisuudet kohdistuvat tehtäviin, joissa on käsiteltävä paljon dataa nopeasti ja tarkasti. Tällaiset tehtävät vaativat usein nopeutta, paljon toistoja ja asioiden järjestämistä tai luokittelua. (Kananen & Puolitaival 2019, 37–39.)

Tekoäly voidaan jakaa vahvaan ja heikkoon tekoälyyn. Vahvana tekoälynä pidetään ihmisen kaltaista älykkyyttä ja tietoisuutta, jota voitaisiin käyttää yleisesti kaikkiin mahdollisiin tehtäviin. Vahva tekoäly on ajatuksena usein esillä, kun tekoälyä esitetään populaarikulttuurissa. Vahvaa tekoälyä ei kuitenkaan ole pysytty kehittämään. Kaikki saatavilla olevat tekoälysovellukset ovat heikkoa tekoälyä. Heikko tekoäly kykenee ratkaisemaan vain sovelluskohteensa ongelman, kunhan ratkaisumalli on sille ensin opetettu. (Kananen & Puolitaival 2019, 37–39.)

Tekoälyyn liittyy myös käsite supertekoäly. Supertekoälyllä tarkoitetaan tekoälyä, joka olisi älykkäämpi kuin älykkäimmät ja lahjakkaimmat ihmiset. Teorioiden mukaan supertekoäly voisi syntyä niin sanotusta älykkäästä räjähdyksestä tai teknologisesta singulariteetista, jota alustaisivat kvanttietokoneiden käyttöönotto, käsittämätön määrä muistikapasiteettia, valtava määrä kerättyä dataa ja kyky oppia jatkuvasti lisää. Lisäksi supertekoälyn synty vaatisi suuria harppauksia nykyisessä tekoälytutkimuksessa. (Pietikäinen & Silvén 2022, 199–200.)

Tekoäly on yleistynyt voimakkaasti viimeisen vuosikymmenen aikana. Sen on mahdollistanut tietokoneiden laskentatehon kasvaminen ja saatavilla olevan datan määrän lisääntyminen. Lisäksi samaan aikaan uudet algoritmit, avoimet lähdekoodit, erilaiset internet-alustat ja niihin liittyvä ideoiden ja tiedon jakaminen, sekä helposti saatavilla oleva koulutus- ja kurssimateriaali ovat tuoneet tekoälyn hyödyntämismahdollisuuksia uudella tavalla esille eri ihmisryhmille. (Euroopan parlamentti: Mitä tekoäly on ja mihin sitä käytetään? 2021; Kananen & Puolitaival 2019, 35–36.)

Koneoppiminen on tekoälyn osa-alue. Koneoppimisessa kone oppii ratkaisemaan halutun ongelman itsenäisesti algoritmin avulla. Koneella ei kuitenkaan ole tiedossa ennalta määriteltyä toimintaohjetta jokaiseen sille annettuun ongelmaan, vaan se ratkaisee jokaisen ongelman sen hetkisten tietojensa mukaan. Koneen toiminnan onnistumistarkkuus paranee sen oppimisen myötä, eli yleensä suoritettujen toimintojen määrän kasvaessa. Käytännössä kone oppii sille annettun datan perusteella yleistämään tulevaa dataa. (Chandramouli, Das & Dutt 2018.) Koneoppimisen hyödyntämisen tarkoitus on siis automatisoida datan tulkitsemista (Neittaanmäki & Siukonen 2019, 316).

Koneoppimisen hyödyntämistä varten tarvitaan dataa sen kohteesta. Yleensä käytettävä data on lähes mitä tahansa tapahtumia tai ilmiöitä, jotka on kerätty tietyn mittaiselta menneeltä ajanjaksolta. Näitä datapisteitä kutsutaan instansseiksi. Ryhmiä, joihin datapisteet kuuluvat, kutsutaan attribuuteiksi. (Kelleher 2019.) Koneoppimisen hyödyntämiseen tarvitaan myös algoritmeja. Algoritmi on ohje, jonka mukaan jokin toiminto suoritetaan. Yksinkertaistettuna esimerkiksi keittokirjan ohjetta voitaisiin kuvata algoritmiksi, mutta yleensä algoritmilla tarkoitetaan kaavaa tai ohjetta, joka ohjeistaa jonkin matemaattisen tai tietoteknisen menetelmän suorittamiseen. (Kananen & Puolitaival 2019, 112.)

Datan käsittely ja attribuuttien valinta on yksi suurimmista haasteista koneoppimisen hyödyntämisessä ja voi olla kriittinen tekijä koko projektin onnistumisen kannalta. Datan on oltava siinä muodossa, että algoritmi sen ymmärtää. Se saattaa esimerkiksi tarkoittaa sanallisten arvojen muuttamista numeerisiksi. Kaikkea kerättyä dataa ei yleensä kannata tai voi hyödyntää algoritmissa. Hyödynnettävien attribuuttien valinta voi olla hankalaa, ja saattaa vaatia alan asiantuntijoiden



apua. Mikäli attribuutteja valitaan minimimäärä, on todennäköistä, että datasta jää uupumaan tärkeitä piirteitä. Mikäli attribuutteja valitaan puolestaan maksimimäärä, todennäköisesti mukaan tulee valittua myös turhia attribuutteja. Tämä voi aiheuttaa algoritmin heikon toiminnan. Mitä enemmän hyödyttömiä attribuutteja on valittu dataan mukaan, sitä todennäköisempää on, että käytetty algoritmi löytää harhaanjohtavia korrelaatioita attribuuttien välillä. Harhaanjohtavia korrelaatioita syntyy, kun algoritmi löytää turhia datan sisäisiä yhtäläisyyksiä, joita esiintyy vain valitussa esimerkkidatassa. (Kelleher 2019.)

Oikeiden attribuuttien valinta vaatii dataan tutustumista (usein asiantuntijoiden kanssa) sekä datan tilastollista analyysia. Analyysissa on huomioitava sekä instanssien jakauma, että instanssien välisten korrelaatioiden määrä. Kun prosessissa on päästy algoritmien kokeiluun asti, attribuuttien valintaan voi yhä vaikuttaa mallien rakentaminen ja niiden testaaminen. (Kelleher 2019.)

#### **4.1. Ohjaamaton koneoppiminen**

Ohjaamaton koneoppiminen tarkoittaa koneoppimista, jossa kone löytää aiemmin tuntemattomasta datasta kuvioita, yhtäläisyyksiä ja ryhmiä tai vaihtoehtoisesti poikkeavuuksia (Chandramouli, Das & Dutt 2018).

Klusterointi on ohjaamattoman koneoppimisen menetelmä, jonka tavoitteena on löytää luonnollisia ryhmiä datajoukosta. Klusteroinnin avulla datasta voidaan löytää rakenteita ja luokkia tai vaihtoehtoisesti muusta datasta eroavia poikkeuksia. (Maloik & Tuckfield 2019, 3–5.) Yleisiä klusterointia hyödyntäviä ratkaisuja ovat esimerkiksi verkkokauppojen suositukset – jos valitset tietyn tuotteen ostoskoriisi, aiempien asiakkaiden ostosten perusteella sinut voidaan luokitella tiettyyn asiakasryhmään ja sinulle voidaan tarjota muita, tälle ryhmälle sopivia tuotteita.

Yksi tunnetuimmista ja yksinkertaisimmista klusterointialgoritmeista on k-means klusterointi. K-means klusteroinnissa N-dimensioinen datajoukko jaetaan k-määrään joukkoja. Datasta valitaan satunnaisesti klusterin keskipisteet, ja kaikki datapisteet kuuluvat johonkin klusteriin lähimmän keskipisteen mukaisesti. Tämä

algoritmi pyrkii löytämään datasta joko ennalta määrättyjä yhtäläisyyksiä tai mitataamaan datapisteiden etäisyyksiä toisistaan. Tapoja mitata etäisyyksiä on useita, ja niiden valintaan vaikuttaa usein datan rakenne ja sen dimensioiden määrä. K-means algoritmin haasteena on klustereiden määrän valinta. Tuntematonta dataa klusteroidessa, on klusterointeja yleensä suoritettava useita eri  $k$ :n arvoilla. Klustereiden määrän valintaa varten on kehitetty useita eri menetelmiä, joista esimerkkinä silhouette score (yksinkertaistetusti laskennallinen tapa määrittää, onko datapisteillä lyhyt klusterin sisäinen etäisyys klusterin keskukseen mutta pitkä klusterien välinen etäisyys). (Maloik & Tuckfield 2019, 3–34; Žalik 2008, 1385–1387.)

Klustereiden muodostaminen vaatii myös joko datapisteiden välisen etäisyyden tai datapisteiden samankaltaisuuden, korrelaation, laskemisen. Yleisin datapisteiden välisen etäisyyden mittaustapa on euklidinen etäisyys (suoran etäisyys kahden pisteen välillä). Datapisteiden korrelaatiossa kaksi datapistettä kuuluvat samaan klusteriin, kun niiden ominaisuudet korreloivat toisiaan, vaikka datapisteiden arvot ovat erilaisia. Käytännössä datapisteiden korrelaatiossa voidaan esimerkiksi tunnistaa ostoksien tekijän asiakasryhmä tehtyjen ostoksien ominaisuuksien, eikä määrän perusteella. Datapisteiden välisen etäisyyden tai korrelaation laskemisen menetelmä vaikuttaa klusterien muotoon ja kokoon. (Kassambara 2017, 8–11.)

## 4.2. Ohjattu koneoppiminen

Ohjatussa koneoppimisessa kone ennustaa, mihin luokkaan data kuuluu tai ennustaa regression kautta datan eli numeraalisten arvojen muutosta tulevaisuudessa. Ohjatussa koneoppimisessa datan attribuutit ovat tiedossa. Ohjatun koneoppimisprosessin ohjaaja tekee päätöksen, mitä prosessista saadaan tulokseksi. Kone perustaa päätöksensä vertaamalla uutta dataa sille aiemmin opetettuun, valmiiksi luokiteltuun dataan ja kykenee yleistämään sitä. Ohjattu koneoppiminen voidaan jakaa luokitteluun ja regressioon. (Chandramouli, Das & Dutt 2018; Alpaydin 2021, 51–61.)

Luokittelussa kone voi luokitella datan kahteen tai useampaan luokkaan, jotka ovat ennalta määriteltyjä. Luokat voivat olla esimerkiksi kyllä/ei-vastaus haluttuun kysymykseen tai datan luokittelu koneelle aiemmin opetettuihin ryhmiin. (Chandramouli, Das & Dutt 2018.)

Regressiossa kone ennustaa numeraalisia tuloksia, esimerkiksi pörssikursseja tai asuntojen hintoja sille syötetyn datan avulla (Chandramouli, Das & Dutt 2018). Regression onnistumista arvioidaan sen pohjalta, kuinka lähellä opetusdatasta havaittuja arvoja mallin ennustukset ovat. Kun opetusdata on riittävän laaja niin sisällöltään kuin määrältään, kykenee malli tekemään ennustuksia myös arvoista, joita ei ole sisällytetty opetusdataan. Tällöin malli on kyennyt yleistämään opetusdatan ja hyödyntää yleistystään ennustusten teossa.

Haasteena on pohtia, kuinka onnistunut ohjatun koneoppimisen mallin yleistys on. Voi olla hyvin hankalaa tai mahdotonta päätellä, millaisia syy-seuraussuhteita malli on löytänyt opetusdatasta. Mallin onnistumiseen vaikuttavat mallin valinta ja sen toiminnan optimointi sekä käytetyn opetusdatan määrä. Mallin yleistyksen on oltava riittävän tarkka, mutta ei liian tarkka. Mikäli mallin yleistys on liian tarkkaa, löytää se datasta riippuvuuksia, joita ei tosiasiaassa ole olemassa.

K-Nearest neighbour (KNN) on yksi vanhimmista ja tarkimmista ohjatun koneoppimisen algoritmeista, joita voidaan käyttää sekä luokitteluun että regressioon. Algoritmissa pyritään yhdistämään datapisteet ennalta määriteltyihin luokkiin ja valitsemaan kaikista samanlaisin. Etäisyyttä tai samankaltaisuutta eri luokkiin voidaan mitata useilla erilaisilla mittareilla. Mittarien valinta vaikuttaa lopulliseen luokittelun tai regression tulokseen. Optimaalista mittaria ei ole olemassa, vaan so-piva mittari on valittava datasetin mukaan. (Ferreira & Vasconcelos 2019; Abu Alfeilat ym. 2019.)

### **4.3. Vahvistusoppiminen**

Vahvistusoppimisessa kone tekee päätöksiä, joiden seurauksien perusteella se oppii tekemään oikeat päätökset (Enan 2021, 3–4). Vahvistusoppimisessa kone on toimija eli agentti, joka on sijoitettu ympäristöön ja vuorovaikuttaa sen kanssa.

Agentti saa toiminnallaan aikaan ympäristössä muutoksen, joka muuttaa ympäristön tilaa. Toiminnastaan agentti voi saada palkinnon. Palkinto määrittelee toiminnan tavoitteen. Palkintojen kautta agentti oppii suorittamaan tehtävän mahdollisimman nopeasti ja maksimaalisilla palkinnoilla. (Alpaydin 2021, 153–166.)

Käytännössä vahvistusoppimiseen pohjautuvassa ohjelmassa lasketaan sisäinen arvo toimintaan kuuluville osioille. Sisäiseen arvoon vaikuttaa, kuinka ne vaikuttavat tavoitteen toteutumiseen ja palkinnon ansaitsemiseen. Aluksi sisäinen arvo on kaikissa toiminnoissa nolla. Agentin pyrkimyksenä on valita toimintasarjaansa sisäiseltä arvoltaan sellaisia osioita, jotka johtavat tavoitteen saavuttamiseen ja palkintoon. Sisäistä arvoa nostavat tai laskevat havainnot toimintojen koekulun kautta. Yrityksen ja erehdyksen kautta agentti oppii hyödyntämään tietoa sisäisistä arvoista toiminnassaan. (Alpaydin 2021, 153–166.) Agentti luo siis itse dynaamisella toiminnallaan päätöksessään käyttämänsä datan (Enan 2021, 4).

Vahvistusoppimisten algoritmit ovat hitaampia kuin esimerkiksi ohjatun oppimisen algoritmit. On kuitenkin otettava huomioon, että vahvistusoppimisessa algoritmeissa puuttuvat ohjaajan aiheuttamat vinoumat. Sen vuoksi vahvistusoppimisen kautta kehitetyt mallit voivat olla toiminnaltaan tarkempia kuin ohjatun oppimisen mallit. (Alpaydin 2021, 167–171.) Vahvistusoppiminen mahdollistaa toiminnan optimoinnin muuttamalla ongelman ja sen ratkaisun loogiseen muotoon (Eschmann 2021, 25.)

Vahvistusoppimista voidaan parhaiten hyödyntää tehtävissä, joissa on kyse sarjatyönä tapahtuvasta päätöksenteosta ja joissa tehty päätös vaikuttaa myöhempiin päätöksiin. Päätöksen onnistuneisuus riippuu päätöstä edeltävistä ja sitä seuraavista päätöksistä, ja niiden pohjalta voidaan lopulta arvioida kaikista päätöksistä syntynyttä lopputulosta. (Alpaydin 2021, 171–174.)

## 5 AJANVARAUSJÄRJESTELMIEN KEHITTÄMINEN

Terveydenhuollon kehittäminen vaatii tuekseen tekoälyä. Vanhenevat kansat lisäävät painetta terveydenhuoltoon paitsi kustannuksien, myös toiminnan tehokkuuden kannalta. Etenkin Aasian suuret tekoälyvaltiot – Kiina, Japani ja Etelä-Korea – kehittävät kiihtyvällä tahdilla erilaisia tekoälysovelluksia tukemaan terveydenhuollon toimintaa ja suurien potilasmäärien hallintaa. Tekoälyä hyödyntävät sovellukset voivat ratkaista potilaiden luokitteluun, diagnostiikkaan ja terveydenhuollon ammattilaisten pulaan liittyviä haasteita. (Neittaanmäki & Ojalainen 2018.)

Terveydenhuoltoon liittyviin tekoälyratkaisuihin on investoitu maailmanlaajuisesti enemmän rahaa viime vuosien aikana kuin millekään muulle tekoälyn hyödyntämisalueelle. Yllättävää kuitenkin on, että käyttöön otettuja ratkaisuja on ollut melko vähän. Tunnetuimpia laboratorioalan tekoälyratkaisuja ovatkin yleensä erilaiset kuvantunnistusmenetelmät esimerkiksi hematologian ja patologian aloilta. Haasteena terveydenhuollon tekoälyratkaisujen kehittämisessä on ratkaisujen saaminen käytäntöön: useimmiten näiden innovaatioiden tuloksena on yksi seuraavasta kolmesta vaihtoehdosta. Usein innovaatio ei kohtaa yleisön ja kohteidensa vaatimustasoa. Parempi vaihtoehto on, että vaatimustaso kohdataan, mutta tekoälypohjaisen ratkaisun sovellusala on kovin kapea ja sen hyödyntäminen jää hyvin marginaaliseksi. Paras vaihtoehto tekoälypohjaiselle innovaatiolle olisi, että sen hyödyntämisestä saadaan suuri hyöty kliinisessä työssä ja sitä voidaan hyödyntää laajalla skaalalla. (Alvarez & Lin 2021, 479–499.)

Terveydenhuollon ajanvarausjärjestelmien kehittämismahdollisuudet ovat kenties hieman sivussa terveydenhuollossa tällä hetkellä muodikkaista tekoälyratkaisuista, jotka liittyvät usein kuvantamiseen ja diagnostiikkaan. Terveydenhuollon ajanvarausjärjestelmät ovat tarpeiltaan myös hieman erilaisia kuin muiden alojen ajanvarausjärjestelmät. Muiden alojen ajanvarausjärjestelmien tekoälyratkaisuja voi siksi olla hankala hyödyntää terveydenhuollossa. Mikäli kuitenkin kyettäisiin yhdistämään eri alojen ajanvarausmenetelmiin liittyviä tekoälyinnovaatioita ja ter-

veydenhuollon osaamista, voitaisiin saada aikaiseksi todella toimivia ja tehokkaita ratkaisuja, jotka palvelevat paitsi potilaita, myös terveydenhuollon yksiköitä ja laboratorioalaa.

Terveydenhuollon ajanvaraus voidaan jakaa kolmeen luokkaan varausmallin mukaisesti: unit process (potilaskohtainen ajanvaraus), periodic process (jaksoittainen ajanvaraus) ja single batch process (yksittäisen joukon ajanvaraus) (Taveira-Gomes 2017, 5–6; Akinode & Oloruntoba 2017, 16–17). Tässä työssä käytetään selvyuden vuoksi opinnäytetyön kirjoittajan kääntämiä suomenkielisiä termejä.

Ajanvaraukset voidaan tehdä yksittäin potilaskohtaisesti, potilaan halutessa varata ajan (unit process). Tällöin ajanvarauksia ei ole mahdollista järjestää erityisen optimaalisesti. Ajanvarauksien järjestämistä voidaan kuitenkin kehittää arvioimalla tarvittavia resursseja. Tämä vaatii tutustumista ajanvarauksien kysyntään ja tarjontaan. (Taveira-Gomes 2017, 5–6; Akinode & Oloruntoba 2017, 16–17.) Tässä opinnäytetyössä käsiteltävä ajanvarausjärjestelmä toimii potilaskohtaisesti.

Kaksi muuta ajanvarausmallia ovat jaksoittainen ajanvaraus (periodic process) ja yksittäisen joukon ajanvaraus (single batch process). Jaksoittaisessa ajanvarauksessa ajanvarauspyyntöjä kerätään tiettyyn määrään saakka, jonka jälkeen ajanvaraukset järjestetään ja jaetaan. (Taveira-Gomes 2017, 5–6.) Jaksoittainen ajanvaraus mahdollistaa asiakkaiden tarpeiden huomioon ottavan ja työn resurssin kannalta paremman ajanvarausjärjestyksen (Akinode & Oloruntoba 2017, 16–17).

Yksittäisen joukon ajanvarauksessa ajat jaetaan, kun kaikki varauspyynnöt tietylle ajanjaksolle on saatu. Tällöin varaushetkellä tiedossa ovat kaikkien potilaiden varausjärjestykseen vaikuttavat vaatimukset ja ominaisuudet. Yksittäisen joukon ajanvarausta käyttävät terveydenhuollon yksiköt pystyvät järjestämään ajanvarauksensa kaikista optimaalisimmalla ja tehokkaimmalla tavalla. Tällöin ajanvarauksien järjestyksessä tapahtuu vähiten virheitä ja hukkaa. Esimerkkinä tällaisesta ajanvarauksesta voidaan pitää leikkauksien järjestystä leikkaussalissa. Käytännössä jaksoittaista ja yksittäisen joukon ajanvarausta voidaan kui-

tenkin käyttää vain sellaisissa terveydenhuollon yksiköissä, joissa potilailla on vähän vaikutusmahdollisuuksia omaan ajanvaraukseensa. (Taveira-Gomes 2017, 5–6.)

Terveydenhuollon ajanvaraukseen liittyvä odotusaika voidaan puolestaan jakaa kahteen luokkaan. Suora odotusaika tarkoittaa mitattua aikaa, joka alkaa potilaan saapumishetkestä ja päättyy varatun terveydenhuollon palvelutapahtuman alkamiseen. Epäsuora odotusaika tarkoittaa aikaa ajanvarauksen varaustapahtuman ja varatun palvelutapahtuman välissä. Pitkä epäsuora odotusaika lisää saapumatta jättämisen todennäköisyyttä. Pitkä epäsuora odotusaika voi myös aiheuttaa terveyden huonontumista kroonisesti sairailta tai kiireellisiksi luokitelluilla potilailla. (Hasankhani, Kiani & Yousefi 2020.)

Terveydenhuollon ajanvarauksien koneoppimispohjaisia kehittämissuuntauksia on monenlaisia. Tähän opinnäytetyöhön on valittu esiteltäväksi hyödyllisimpiä koneoppimispohjaisia kehittämismahdollisuuksia opinnäytetyön kirjoittajan näkemysten mukaan. Pohdinnassa hyödyllisimpien artikkelien valinnassa on hyödynnetty tutustumista ajanvarausjärjestelmään, ajanvarausmenetelmiin, ajanvarauksista käytäviin asiakkaisiin sekä ajanvaraukseen liittyviin tilastoihin ja dataan. Lisäksi pohdinnassa on hyödynnetty opinnäytetyön kirjoittajan kokemusta ja osaamista näytteenotosta, asiakaspalvelusta ja laboratorioanalytiikasta.

Artikkelien valintaan ja niiden sisältöön kohdistunut tutkimus on ollut osa toimintatutkimuksen spiraalimaista rakennetta. Artikkelien valinta on tehty kehittämistarpeiden tutkimuksien perusteella. Tämän jälkeen artikkelien sisältöä on analysoitu, mikä on johtanut sekä uusien artikkelien löytämiseen että opinnäytetyön tieteellisen taustan rakentumiseen. Tämän pohjalta toimintana on ollut tehdä kirjallinen sisällöntutkimus artikkeleissa esitellyistä menetelmistä. Tätä sisällöntutkimusta voidaan hyödyntää tulevaisuudessa, kun pohditaan, miten laboratorioajanvarausjärjestelmiä voitaisiin kehittää yhä tehokkaammiksi ja paremmin palveleviksi järjestelmiksi.

### 5.1. Potilasdatan klusterointi ajanvarausjärjestelmien kehittämisessä

Koska erilaiset koneoppimispohjaiset algoritmit vaativat paljon dataa päätöksensä tueksi, suurin osa ajanvarausjärjestelmien koneoppimiseratkaisuista painottuvat jaksoittaiseen ajanvaraukseen ja yksittäisen joukon ajanvaraukseen. Tällöin varauksia voidaan verrata toisiinsa ja potilaista on tiedossa mahdollisimman paljon dataa.

Lisäksi monet ratkaisut pohjaavat siihen, että järjestelmällä on pääsy koko potilashistoriaan. Tähän saattaa liittyä terveydenhuollon kokonaiskuva ja rakenne muualla maailmassa. Monet tekoälypohjaiset terveydenhuollon ajanvarausjärjestelmät on kehitetty joko Yhdysvaltojen tai Kaukoidän sairaalamaailmassa, missä julkisen terveydenhuollon taso vaihtelee ja yksityissairaaloissa järjestetään terveydenhuollon palveluita laidasta laitaan. Tällöin luonnollisesti yksityissairaalalle kehitetty ajanvarausjärjestelmä voi hyödyntää datana koko potilastietojärjestelmää. Hyödynnettynä datana voidaan esimerkiksi käyttää ikää, sukupuolta, perussairauksia ja niiden riskiluokituksia (Taivera-Gomes 2017, 10).

Potilaiden ajanvarauksen kiireellisyyden priorisointia on tutkittu melko paljon. Koneoppimisen menetelmät tarjoavat mahdollisuuden jakaa potilaita kiireellisyydeltään erilaisiin ryhmiin. Ne mahdollistavat suuren datajoukon käsittelyn aina yhtä nopeasti ja tarkasti. Tämän tyylisten ratkaisujen toteutus pohjautuu usein potilaiden luokitteluun klusteroinnin avulla.

Monissa tutkimuksissa klusterointia hyödynnetään esimerkiksi ensiavussa potilaiden saapumishetkellä, samaan tapaan kuin nykyhetken terveydenhuollossa potilaan voinnin ja kiireellisyyden arvioi triagehoitaja. Erilaisia klusterointiratkaisuja on tutkittu runsaasti myös poliklinisessä ajanvarauksessa.

Esimerkiksi Hasankhani, Kiani ja Yousefi hyödyntävät artikkelissaan *Appointment scheduling model in healthcare using clustering algorithms* k-means klusterointia jaotellessaan poliklinisia potilaita kahteen ryhmään, potilaiden matalan tai korkean prioriteetin mukaan. Mallin tarkoitus on tarjota korkean prioriteetin potilaille lähintä mahdollista ajanvarausta. Mallissa ajanvarauksia tehdään tietty



määrä seuraavien seitsemän päivän ajan molemmille prioriteeteille. Klusterointidatana käytettiin 29 attribuuttia, joita olivat mm. ikä, paino, pituus, sukupuoli, tupakointi, korkea kolesteroli, verenpainetauti ja kilpirauhassairaus. Huonoa mallissa on se, että se on kehitetty tekemään varauksia vain seitsemälle päivälle kerrallaan ja perumaan ylijääneet varaukset. (Hasankhani, Kiani & Yousefi 2019.) Potilaalle tämä on ikävää, ja saattaa johtaa toistuviin yhteydenotto-pyyntöihin, mikäli potilasta ei luokitella korkean prioriteetin ryhmään ja ajanvarauspyyntöjä on paljon.

Potilaiden klusterointia saapumishetkellä voitaisiin myös hyödyntää laboratoriossa, mikäli laboratorioon saapuvat potilaat ilmoittautuisivat esimerkiksi ilmoittautumisautomaatin kautta kelakortilla. Tällöin järjestelmä voisi käydä läpi potilaasta ja tämän pyynnöistä tiedossa olevan datan ja klusteroida potilaat näytteenoton kiireellisyysprioriteetin mukaan vastaanottojärjestykseen. Klusterointia voitaisiin hyödyntää myös poliklinisessa laboratorioajanvarauksessa, mikäli attribuutteina voitaisiin hyödyntää esimerkiksi pyyntöjen päivystysstatusta ja pyydettyjä laboratoriotutkimuksia. Kysymykseksi kuitenkin nousee, pidettäisiinkö tällaista ohjaavaa tai määräävää järjestelmää hyvänä palveluna. Perusterveydenhuollon palveluissa suomalaiset usein ovat tottuneet tekemään itse päätöksen itselleen sopivasta vastaanotto- tai palveluajasta mahdollisuuksien mukaan. Myös jonottamista ja saapumisjärjestyksen mukaista palvelua pidetään tärkeänä suomalaisessa kulttuurissa.

## **5.2. Saapumatta jättämisen ennakointi**

Toinen suuri ajanvarausjärjestelmien kehitystrendi on käyttämättä jääneiden aikojen ennustaminen ja niihin liittyvä aikojen tuplavaraaminen. Ajanvaraukselleen saapumatta jättäneet kuluttavat terveydenhuollon resursseja turhaan. Saapumatta jättäminen onkin suuri ongelma terveydenhuollossa, ja sitä on tutkittu runsaasti.

Saapumatta jättämisen ennakointiin liittyy usein kolme kiinnostuksen kohdetta. Ensinnä on tärkeää tunnistaa ne henkilöt, jotka todennäköisesti jättävät saapu-

matta. Tämän jälkeen on pohdittava, voitaisiinko resurssien haaskaus estää tekemällä tuplavaraus todennäköisesti saapumatta jättävien potilaiden kohdalla. Kolmantena kiinnostuksen kohteena nousee esiin se seikka, miten tuplavarauksen tekeminen vaikuttaa terveydenhuollon yksikön toimintaan ja potilaiden saamaan asiakaspalveluun, mikäli molemmat potilaat saapuvatkin ajanvaraukselleen.

Ajanvaraukselle saapumatta jättäminen voi olla tahallista tai tahatonta. Useiden tutkimusten mukaan yleisin syy saapumatta jättämiseen on ajanvarauksen unohtaminen. Erilaiset muistutukset ajanvaraukseen liittyen vähentävätkin todennäköisyyttä saapumatta jättämiseen. Myös lyhyempi epäsuora odotusaika ennen ajanvarausta lisää saapumisen todennäköisyyttä. Mikäli epäsuora odotusaika on pitkä, on todennäköisempää, että potilas jättää saapumatta ajanvaraukselleen kuin peruu sen. Myös henkilökohtaiset syyt, kuten perhe- tai työelämän haasteet, tai logistiset syyt voivat vaikuttaa saapumatta jättämiseen. (Almeida, Silva & Vasconcelos 2021; Ferreira & Vasconcelos 2019.)

Yhdysvalloissa tehdyn tutkimuksen mukaan myös sää vaikuttaa saapumatta jättämiseen. Etenkin lumisade aiheuttaa enemmän saapumatta jättämiä. (Chand ym. 2014.) On kuitenkin otettava huomioon, että tutkimus on tehty Indianapoliksessä, Indianan osavaltiossa Yhdysvalloissa, jossa lumisateet ovat melko satunnaisia. Niinpä en näkisi, että lumisade vaikuttaisi Suomessa samalla tavalla saapumatta jättämiseen.

Potilaan ikä vaikuttaa saapumatta jättämiseen siten, että todennäköisimmin vastaanotolle saapumatta jättävät teini-ikäiset ja nuoret aikuiset. 28 vuotta täyttämisen jälkeen saapumatta jättämisen todennäköisyys laskee melko tasaisesti aina 75-vuotiaaksi asti. Muita saapumatta jättämiseen vaikuttavia tekijöitä ovat viikonpäivät, joista korkein saapumatta jättämisen todennäköisyys on maanantaisin, tiistaisin ja perjantaisin. (Chand ym. 2014.) Myös mikäli potilas ei koe ajanvarauksen syynä olevaa terveystapahtumaa riittävän vakavaksi tai mikäli hänen vointinsa paranee epäsuoran odotusajan aikana, saapumatta jättämisen todennäköisyys nousee (Almeida, Silva & Vasconcelos 2021).

Useimmat potilaiden saapumatta jättämistä tutkivat algoritmit vaativat taustatietoja sekä potilaasta, terveydenhuollon yksikön ajanvaraushistoriasta ja ajanvarausjärjestelmästä. Näiden taustatietojen kautta ohjatun koneoppimisen algoritmi osaa laskea todennäköisyyden sille, saapuko potilas vastaanotolle vai ei. Usein tällaisissa algoritmeissa käytetään logistista regressiota. (Ferreira & Vasconcelos 2019.)

Logistisessa regressiossa ennustetaan, onko ilmiö tosi vai epätosi. Muun muassa logistista regressiota hyödynnetään tutkimuksessa *MedClick: Last minute Medical Appointments No-Show Management*. Tutkimuksessa esitetään malli, joka arvioi potilaan saapumatta jättämisen todennäköisyyttä 48 tuntia ennen ajanvarauksista potilaan iän, siviilisäädyn, vakuutuksen, varaushistorian, epäsuoran odotusajan sekä ajanvarauksen päivän, kiireellisyyden ja kyseisen terveydenhuollon yksikön saapumattajättämisprosentin kautta. Lisäksi kaikille potilaille on lähetetty 72 tuntia ennen ajanvarauksista viesti, johon vastaamalla on pystynyt varmistamaan ajanvarauksensa. Näiden ominaisuuksien sekä viestiin vastaamisen perusteella malli arvioi, kuinka todennäköistä on, että potilas jättää saapumatta. Mikäli saapumatta jättäminen näyttää todennäköiseltä, järjestelmä pyrkii tekemään potilaan ajanvaraukselle tuplavarauksen, ja lähettää viestin tarjolla olevasta ajasta jonotuslistalla oleville potilaille. (Ferreira & Vasconcelos 2019.)

Pohdittavaksi jääkin, voisiko vastaavaa hyödyntää laboratorioajanvarausjärjestelmissä ja esimerkiksi avata internet-ajanvaraukseen maksimissaan kaksi päällekkäistä aikaa, mikäli ensimmäinen kyseisen ajan varannut ei todennäköisesti saavu varatulle ajalleen. Tärkeää on kuitenkin varmistaa, ettei malli fokusoidu liiaksi tiettyjä ominaisuuksia omaaviin henkilöihin ja heikennä heidän saamaansa palvelukokemusta tuplavarauksien aiheuttamalla paineella.

Mielenkiintoista voisi myös olla pohtia sitä, vaikuttaisiko saapumatta jättämisen määrään, mikäli asiakasajanvaraukseen liittyvää epäsuoraa odotusaikaa vähennettäisiin. Tällöin asiakkaat pystyisivät tekemään internet-ajanvarauksensa lyhyemmän aikavälin sisään (esimerkiksi seuraavalle kahdelle viikolle) ja vain ammattilaisajanvaraajat pystyisivät tekemään ajanvarauksia pitemmän ajan päähän. Tarvittaessa asiakkaat voisivat tehdä ajanvarauksia yli kahden viikon pää-

hän soittamalla puhelinajanvaraukseen. Tällaisen mallin käyttöönotto vaatisi kuitenkin syvempää tutustumista saapumatta jättämisen tilastoihin ja niiden yhteydestä epäsuoraan odotusaikaan.

### 5.3. Vahvistusoppimisen hyödyntäminen ajanvarausjärjestelmissä

Vahvistusoppimista on tähän mennessä hyödynnetty terveydenhuollon ajanvarauksiin liittyvässä tutkimuksessa ja kehityksessä melko vähän. Esimerkiksi vuoden 2020 kirjallisuuskatsauksessa *Reinforcement learning for intelligent healthcare applications: A survey* mainitaan vain yksi tutkimus, jossa vahvistusoppimista hyödynnetään terveydenhuollon ajanvarauksessa (Coronato ym. 2020). Sama tutkimus esitetään myös vuoden 2021 marraskuussa julkaistussa kirjallisuuskatsauksessa *Reinforcement Learning in Healthcare: A Survey*. Ajanvarauksia yleisempiä vahvistusoppimisen hyödyntämismenetelmiä ovat tällä hetkellä esimerkiksi optimaalisen lääkeannostuksen tai hoidon arviointi. (Liu, Nemat, Yin & Yu 2021, 6–8.) Vuoden 2021 kirjallisuuskatsauksessa esitetään myös toinen, vahvistusoppimisen menetelmää ajanvarauksessa hyödyntävä tutkimus. Tässä opinnäytetyössä esitetään kuitenkin näistä kahdesta opinnäytetyön tavoitteen kannalta relevantimpi tutkimus.

Tutkimus, joka oli nostettu esiin molemmissa kirjallisuuskatsauksissa, kuvaa vahvistusoppimispohjaisen algoritmin kehittämistä. Algoritmin tarkoituksena on hyödyntää sitä portugalilaisella yleislääkärin vastaanotolla, jossa on tarjolla erilaisia ja kestoiltaan erilaisia aikoja eri potilasryhmille, esimerkiksi aikoja lapsille, aikuisille, diabetes- tai verenpainepotilaille, perhesuunnitteluun ja matalan riskin raskauden seurantaan. Varattavien aikojen kestot vaihtelivat kymmenestä kolmeen kymmeneen minuuttiin ja samankaltaiset ajat oli ryhmitelty peräkkäin tietyille aikavälille, esimerkiksi kahden tunnin mittaiselle ajanjaksolle. (Taveira-Gomes 2017, 5–10.)

Ajanvarausjärjestelmälle asetettiin kolme päätavoitetta. Ensimmäisenä tavoitteena oli, että järjestelmä kykenee reagoimaan taustalla tapahtuviin aikojen jakaantumisen muutoksiin ilman ihmisen puuttumista tilanteeseen. Toinen tavoite oli, että järjestelmän on kyettävä tekemään varauksia myös vaillinaisilla tiedoilla

ajanvarauspyyntöjen jakaumasta. Kolmannen tavoitteen mukaan järjestelmän on toimittava reaaliajassa siten, että se ei aiheuta viivettä yleislääkäriin vastaanoton päivittäiseen toimintaan. (Taveira-Gomes 2017, 10.)

Lisäksi ajanvarausjärjestelmälle määriteltiin viisi rajoitetta, joita sen pitäisi seurata. Järjestelmän pitäisi varata oikea aika oikealle aikavälille ja ajanvarauksen keston pitäisi olla oikea. Samankaltaiset ajanvaraukset pitäisi varata lähekkäin, eikä varattujen aikojen väliin saanut jäädä varaamatonta aikaa. Varatut ajat eivät myöskään saaneet olla päällekkäin. Järjestelmän agentti palkittiin, mikäli se valitsi ajanvaraukselle tyhjän aikavälin ja mikäli samankaltaiset ajat oli varattu vierekkäisille ajoille. Agentti sai rangaistuksen, mikäli se teki päällekkäisiä varauksia tai mikäli ajat menivät osittain päällekkäin. (Taveira-Gomes 2017, 10, 42.)

Tutkimuksessa verrattiin vahvistusoppimiseen ja erilaisiin muihin tekoälymenetelmiin pohjautuvan agentin toimintaa satunnaisia aikoja varaavaan agenttiin, algoritmia seuraavan, parhaiden aikojen varaamiseen pyrkivään agenttiin sekä ihmiseen. Vahvistusoppimiseen ja muihin tekoälymenetelmiin pohjautuva agentti toimi lähes yhtä hyvin kuin algoritmia seuraava agentti tai ihminen ja oli myös 400 kertaa nopeampi haastavassa ympäristössä kuin algoritmia seuraava agentti. (Taveira-Gomes 2017, 55–80.) Siten tutkimusta voidaan pitää lupaavana toteutuksena vahvistusoppimisen hyödyntämisestä ajanvarausjärjestelmien kehittämisessä.

Tämä tutkimus on opinnäytetyössä esitetyistä kehitysmenetelmistä kaikista lähimpänä luvussa 3.3. esitettyjen ajanvarausjärjestelmän kehittämistarpeiden toteutumista. Haasteena kuitenkin on, että tutkimuksessa esitetty järjestelmä on suunniteltu yleislääkäriin vastaanotolle, ja varattavia aikoja on hyvin maltillinen määrä. Asiakas itse ei myöskään pysty vaikuttamaan hänelle ehdotettavaan aikaan. Tämä voi aiheuttaa ongelmia asiakastyytyväisyydessä. Lisäksi erilaiset varattavat ajat ovat melko yksiselitteisiä ja helposti tunnistettavia. Järjestelmää testattiin vain testiympäristössä ja vaativimmillaankin varaukset jakaantuivat vain yhdelle päivälle (Taveira-Gomes 2017, 76–77). Käytännössä tutkimuksessa esitettyä järjestelmää ei testattu esimerkiksi pidemmän ajanjakson ajanvarauksista suoriutumisesta.

## 6 POHDINTA

Opinnäytetyön alussa esitettiin kaksi päätoimista tutkimuskysymystä. Tutkimuskysymykset olivat:

1. Voidaanko koneoppimista hyödyntää nykyisen ajanvarausprosessin kehityksessä?
2. Millaisten koneoppimisen ratkaisujen avulla voidaan saavuttaa nykyisen ajanvarausprosessin kehittämistavoitteita?

Näiden kehitysmahdollisuuksien on oltava sellaisia, jotka voisivat parantaa asiakasohjausta, -hankintaa ja -pitoa sekä lisätä verkkoajanvarausta.

Opinnäytetyössä esitettyjen menetelmien ja tutkimusten pohjalta voidaan todeta, että koneoppimista voidaan hyödyntää nykyisen ajanvarausprosessin kehityksessä monin eri tavoin. Kaikista koneoppimisen osa-alueista – ohjaamattomasta, ohjatusta ja vahvistusoppimisesta – esitettiin käytännön hyödyntämismahdollisuuksia. Kaikki esitetyt kehitysmahdollisuudet voivat omalta osaltaan parantaa asiakasohjausta, -hankintaa ja -pitoa tai ja lisätä verkkoajanvarausta ainakin välillisesti. Lisäksi ne vähentävät hukkaa ja parantavat henkilöstön tyytyväisyyttä, kun virheellisiin ajanvarauksiin liittyvä kuormitus vähenee.

Tutkimuksen pohjalta opinnäytetyön kirjoittajan näkemys on, että lähimmäksi nykyisen ajanvarausprosessin kehittämistavoitteita ylettyy parhaiten luvussa 5.3 esitetty vahvistusoppimisen menetelmä. Menetelmässä hyödynnetään vahvistusoppimista ja luodaan sen avulla ajanvarausjärjestelmästä opinnäytetyön luvussa 3.3 esitetyn kaltainen asiakasta ohjaava järjestelmä. Mikäli koneoppimista halutaan hyödyntää asiasta ohjaavan järjestelmän kehittämisessä, opinnäytetyön kirjoittaja suosittelee menetelmävalinnaksi vahvistusoppimista.

Myös saapumatta jättämisen ennakointi ohjatun koneoppimisen kautta voitaisiin nähdä tavoiteltavaksi ominaisuudeksi. Saapumatta jättämisen ennakointi vähen-

täisi eniten hukkaa ja säästäisi resursseja. Ajat, joiden varaajan arvioitaisiin jätävän saapumatta, voitaisiin avata varattaviksi muille asiakkaille ja tehostaa siten ajanvarauksen toimintaa.

Asiakkaiden luokittelua ohjaamattoman koneoppimisen kautta voitaisiin hyödyntää asiakkaiden ohjaamisessa tai erilaisten asiakastyypin tai -tarpeiden tunnistamisessa. Myös asiakkaiden priorisointia voitaisiin hyödyntää erilaisissa ajanvarausratkaisuisissa. Ajanvarauksien määrä ja tarve sekä asiakkaiden toiveet ja vaatimukset on kuitenkin otettava huomioon. Tämä voi aiheuttaa haasteita menetelmän käytännön hyödyntämisessä.

Ajanvarausjärjestelmien koneoppimispohjainen kehittäminen vaatii paljon asiakasdataa, dataan tutustumista ja sen taidokasta hyödyntämistä. Koneoppimispohjaisten ratkaisujen kehittäminen vaatii siten tietoa ja osaamista paitsi kehitettävästä palvelusta, myös datan hyödyntämisestä ja koneoppimispohjaisista menetelmistä.

Terveyspalvelujen ajanvarausjärjestelmien koneoppimispohjaisten kehittämismahdollisuuksien haasteina ovat tiedon ja osaamisen puute, projektien rahoitus ja datan hyödyntämiseen liittyvät eettiset ongelmat. Monet näkevät tekoälyn vaikeana ja jopa pelottavana asiana. Tekoälyn menetelmät, kuten tässä opinnäytetyössä esitetty koneoppiminen, ovat suurelle yleisölle vieraita. Tekoälyä pidetään itsenäisempänä ja inhimillisempänä todellisuuteen nähden ja pelätään populaarikulttuurin esittämää vahvaa tekoälyä. Tosiasiassa tekoälyä voitaisiin hyödyntää väsymättömänä työjuhtana. Tekoäly ei myöskään voi oppia mitään, mitä sille ei opeteta.

Koneoppimispohjaisten ratkaisujen kehittämisessä pitäisi hyödyntää alan ammattilaisia, joilla on tekoälyyn liittyvää tietoa ja taitoa. Valitettavasti tällaisia alan ammattilaisia on vielä hämmästyttävän vähän ja heidän osaamisensa ei välttämättä yhdisty toivottujen ratkaisujen tai rahoitusten kanssa. Erilaisissa kehitysprojekteissa ei välttämättä myöskään hyödynnetä riittävästi palveluihin liittyvää, yrityksen sisäistä substanssiosaamista. Tekoälyprojektit vaativatkin projektiryhmään monen eri alan ammattilaisia, jotta tuloksena saadaan haluttu ja hyödyllinen ratkaisu.

Vielä tällä hetkellä tekoäly- ja koneoppimispohjaisten ratkaisujen kehittäminen ja käyttöönotto suuremmissa mittakaavoissa voi olla kallista ja liian korkealentoista monille yrityksille. Tulevaisuudessa näistä ratkaisuista tulee kuitenkin arkipäivää. Kun palveluntuottajille on selkeämpää, miten ja missä prosesseissa tekoälyä ja esimerkiksi koneoppimista voidaan hyödyntää, kohtaavat paremmin palvelujen kehitysprojektit ja tekoälymenetelmät sekä niiden alan ammattilaiset. Tekoälyn hyödyntämisen arkipäiväistyessä myös todennäköisesti erilaisten ratkaisujen hinnat tulevat saavutettavammiksi. Samaan aikaan kuitenkin menetelmiä tulevat hyödyntämään myös kilpailevat yritykset, jolloin palvelujen laatustandardit nousevat yleistasoisesti. Mikäli erilaisten uusien menetelmien hyödyntämistä arkilaan liaksi, menetetään etulyöntiasema palvelujen kehittämisessä ja asiakashankinnassa.

Koneoppimispohjaiset menetelmät vaativat paljon dataa menetelmien opetus- ja testausvaiheeseen. Mitä enemmän dataa on saatavilla, sitä laadukkaampi ja halutumpi tulos prosessista saadaan. Opinnäytetyön tiedonhakuvaiheessa todettiin, että useat ajanvarauspalvelujen koneoppimispohjaiset kehittämismahdollisuudet olivat peräisin Kaukoidän tai Yhdysvaltojen sairaalamaailmasta. Tähän selkeästi liittyi siellä vallalla oleva yksityissairaaloiden kulttuuri. Etenkin Yhdysvalloissa yksityissairaaloiden kulttuuri ja painoarvo ovat voimakkaita. Yksityissairaalat ovat myös suuria ja niillä on hallussaan paljon potilasdataa. Ulkomailla myös potilasdataan suhtaudutaan eri tavalla kuin Suomessa. Esimerkiksi Yhdysvalloissa vain New Hampshiren osavaltiossa terveystietojen omistajaksi on määritelty potilas, ja suurimmassa osassa osavaltioita omistajaa ei ole määritelty. Liittovaltion lain mukaan dokumentoidut terveystiedot, niin paperisessa kuin sähköisessä muodossa, kuuluvat yritykselle, instituutille tai laitokselle, joka konkreettisen dokumentin omistaa. Mikäli terveystiedot anonymisoidaan, niitä voidaan hyödyntää tutkimuksissa ja ne voidaan myös myydä ulkoisille yrityksille. Potilailta ei tarvitse kysyä tähän lupaa, eivätkä he ole tietoisia oman terveystietojensa myynnistä. (Sharma 2018.) Myös Kaukoidässä saatavilla olevan terveystietojen suureen määrään liittyy paitsi suuri väestömäärä myös osassa valtioita vallalla oleva heikko yksilönsuoja (Neittaanmäki & Ojalainen 2018). Ulkomaisista tutkimuksista voidaan aistia näkemys, että ihmisten terveystietojen omistaa se terveydenhuoltoalan laitos, joka potilasta hoitaa. Sen sijaan Suomessa on selkeästi vallalla enemmän



käsitys, että terveystietojen omistaa ihminen itse, vaikka sitä hallinnoidaan terveydenhuoltoalan potilastietojärjestelmissä ja -arkistoissa.

Suomessa potilasdataan eli käytännössä potilastietojärjestelmiin ja -kirjauksiin suhtaudutaan hyvin ankarasti. Potilasdataan on pääsy vain rajatuilla henkilöillä. Laboratoriotoimijoilla on tiedossaan vain oma, potilaista saamansa laboratoriodata. Laboratoriotoimijoilla ei ole useinkaan oikeutta muun potilastietojärjestelmän sisältämien tietojen käyttöön, eikä toimijoilla siten ole muuta tietoa esimerkiksi potilaiden perussairauksista kuin senhetkiset tai menneet laboratoriovastaukset. Potilaan tietojen katsomisesta jää myös jälki, ja erilaisia lokitietoja seurataan ahkerasti. Lisäksi potilailla itsellään on oikeus tilata lista henkilöistä, jotka ovat katsoneet tai tehneet muutoksia heidän terveystietoihinsa. Suomessa potilastietoja saa katsoa vain terveydenhuoltoalan toimija, jolla on hoitosuhde potilaaseen.

Sen sijaan ulkomaalaisista tutkimuksista saa käsityksen, että tutkijoilla on ollut (lähes) rajaton pääsy potilasdataan. Tällöin järjestelmien kehityksessä on voitu hyödyntää esimerkiksi tietoja perussairauksista ja hoitosuhteista. Toisaalta käytössä on ollut usein vain kunkin yksityissairaalan oman potilastietojärjestelmän potilasdata, jolloin dataa voidaan ajatella olevan vähemmän ja rajatummin kuin esimerkiksi Suomessa, jossa henkilöstä voi olla kerätty potilasdataa koko elämän ajalta. Mikäli Suomessa pystyttäisiin hyödyntämään enemmän potilasdataa erilaisten terveydenhuollon järjestelmien kehittämisessä, hyödynnettävää dataa olisi valtavasti. Toki on otettava huomioon, että mitä enemmän dataa on saatavilla, sitä enemmän sitä on muokattava ja siistittävä tietyn menetelmän hyödyntämistä varten. Mikäli dataa ei siivota, voi lopputuloksena olla, että tekoäly löytää datasta kuvitteellisia tai virheellisiä yhtäläisyyksiä. Koska tekoäly ei osaa tulkita dataa tai ymmärrä sen pohjimmaista sisältöä, tämä on mahdollista.

Algoritmien tuottamia tekoälymalleja kutsutaan usein mustiksi laatikoiksi, koska vaikka malli toimii halutusti, voi olla vaikeaa tai mahdotonta ymmärtää, miksi malli toimii siten kuin toimii. Tähän liittyvät tekoälyn löytämät yhtäläisyydet ja rakenteet sen läpikäymästä datasta. Huolestuttavaa on, että tekoälypohjaisista ajanvarausjärjestelmistä on löydetty rasismia. Tekoälyjärjestelmä ei ole rasistinen siinä mie-

lessä missä ihminen on. Kyse ei ole periaatteista tai mielipiteistä. Sen sijaan tekoäly voi poimia datapisteitä ja tulkita niitä väärällä tavalla. Esimerkiksi monet saapumatta jättämisen koneoppimis pohjaiset ratkaisut ovat paljastuneet rasistisiksi. Näissä ratkaisuissa potilaille, joilla on suuri saapumatta jättämisen riski, on varattu päällekkäinen aika toisen potilaan kanssa. Kun riskipotilas onkin saapunut ajalleen, hän on saanut huonompaa palvelua kuin muut potilaat, koska vastaanottava terveydenhuollon henkilö on ollut kiireisempi ja kuormittuneempi päällekkäisen ajanvarauksen takia. Potilas ei ole välttämättä saanut apua vaivaansa tai kokee entistä suurempaa vastenmielisyyttä saapua varatuille ajoilleen.

On myös pohdittava, kuinka eettistä on käyttää ihmisten terveystietoa tekoälyjärjestelmien datalähteenä. Olisiko eettisempää luoda kuvitteellista dataa opetus- ja testausmateriaaliksi? On kuitenkin otettava huomioon, että kuvitteellisen datan luominen voi jo itsessään olla epäeettistä. Se voi olla myös äärimmäisen yksipuolista ja lisäksi kuvitteellisen datan luominen on jo itsessään suuritöistä. Lisäksi kuvitteellisesta datasta voi puuttua kokonaan jotain merkittäviä todellisen datan piirteitä. Siksi on aina luotettavampaa käyttää todellista dataa.

Länsimaissa Internet-ajanvarausjärjestelmät ovat olleet käytössä jo vuosikymmeniä ja niiden käyttöönotosta ei ole juurikaan saatavilla tutkimuksia. Siksi yhtenä lähteenä tässä opinnäytetyössä hyödynnettiin Iranissa toteutettua tutkimusta Internet-ajanvarauksen käyttöönotosta. Voidaan kuitenkin pohtia, voidaanko Irania verrata lainkaan Länsimaihin. Lähi-idän poliittista tilannetta voidaan kuvata epästabiliiksi, ja tämä voi vaikuttaa valtion palveluiden laatuun ja yhteiskunnan järjestäytymiseen. Iranin eduksi on kuitenkin mainittava, että sen terveydenhuollon kehittämiseksi on laadittu suunnitelmia 1970-luvulta lähtien ja 2000-luvulla tehdyt uudistukset ovat merkittävästi parantaneet terveydenhuollon laatua (Gholamzadeh Nikjoo, Poursaghar & Tabrizi, 2017). Tämän perusteella näen, että tutkimuksen hyödyntäminen on perusteltua, joskin sen luotettavuuteen ja hyödynnettävyyteen on kohdistettava samaa perusteltua kritiikkiä ja arviointia kuin kaikkiin muihinkin lähteenä käytettyihin tutkimuksiin.

Tämän opinnäytetyön haasteena ja puutteena näen konkreettisuuden puutteen. Puute johtuu eritahtisesta etenemisestä opinnäytetyön ja käytössä olevan ajanvarausjärjestelmän kehitystyöryhmän välillä. Koska opinnäytetyön kirjoittajan

opintojen edistyminen on riippuvainen opinnäytetyön valmistumisesta, on opinnäytetyö ollut pakko eriyttää kehitystyöryhmän edistymisestä. Mikäli näin ei olisi tehty, olisi opinnäytetyön valmistuminen voinut venyä tai se olisi voinut jäädä kokonaan keskeneräiseksi.

Konkreettisuuden puute voidaan nähdä isona haasteena alalla, jossa opiskelijoilta usein toivotaan opinnäytetyön yhteydessä jonkinlaista sovelluskehitystä tai selkeää ehdotelmaa siitä, mikä opinnäytetyön tulos on ollut. Tässä opinnäytetyössä on käsitelty erilaisia kehitysehdotuksia tutkimusten ja artikkelien pohjalta. On kuitenkin otettava huomioon, että opinnäytetyöhön on valittu vain parhaat ja hyödyllisimmät artikkelit ja niihin liittyvät menetelmät, ja opinnäytetyön ulkopuolelle on jäänyt runsaasti, useita kymmeniä, läpikäytyjä artikkeleita.

Koska artikkeleita on arvioitu asiaankuuluvalla kritiikillä, on opinnäytetyöhön päätynyt vain artikkelien parhaimmisto. Tarvittaessa opinnäytetyön tieteellistä taustaa ja sisältöä on arvioitu uudestaan artikkelien parhaimmiston kautta. Mikäli artikkeleista olisi hyväksytty mukaan myös painoarvoltaan vähäisempiä tutkimuksia, olisi opinnäytetyön sisältö voinut toki olla laajempi, mutta vastaavasti sisällön laatu olisi ollut hajanaisempi ja heikompi. Siten vaikka opinnäytetyö voi tuntua osin liiankin kevyeltä luettavalta ja painoarvoltaan vähäiseltä, on siihen liittyvä tutkimus voinut olla paikoin vaativampaa kuin tarkemmin strukturoidussa työssä, jossa tiedonhaku on voinut olla huomattavasti yksinkertaisempaa ja rajatumpaa ja jossa esimerkiksi tarvittava tieteellinen tausta on ollut hyvinkin selkeä ja rajattu alusta lähtien.

Tärkeänä osana opinnäytetyössä on nähty menetelmien ja kehitysmahdollisuuksien esittely selkeällä tavalla. Koska tekoälymenetelmät tulevat todennäköisesti yleistymään nopeasti, on tämä opinnäytetyö lukijalleen mahdollisuus saada ensikosketus tekoälymenetelmistä ja tekoälyyn liittyvistä termeistä.

Opinnäytetyössä esiteltyjen artikkelien paremmuutta ja hyödyllisyyttä on pohdittu opinnäytetyön kirjoittajan toimesta. Tähän pohdintaan ovat vaikuttaneet opinnäytetyön kirjoittajan saama koulutus dataosaamisen ja tekoälyn ylemmässä tutkinto-ohjelmassa, kokemus laboratoriotyöstä sekä bioanalyytikon koulutus ter-

veydenhuoltoalalta. Opinnäytetyön kirjoittajalla on usean vuoden kokemus työskentelystä opinnäytetyön tilaavassa yrityksessä ja vahva tietämys sen tarjoamista palveluista sekä yrityksen asiakasryhmistä. Lisää tietoa ja kokemusta on tullut opinnäytetyön kirjoittamisen aikana. Opinnäytetyöhön on pyritty valitsemaan vain opinnäytetyön kirjoittajan arvion mukaan hyödyllisimmät kehitysmenetelmät, joihin liittyviin tutkimuksiin opinnäytetyön kirjoittajalla on ollut pääsy.

Myös opinnäytetyön tutkimusmenetelmän valintaa voidaan kritisoida. Voidaan kuitenkin todeta, että toimintatutkimuksen tavoitteena on kehittää työelämää. Opinnäytetyöhön liittyvän tutkimuksen tuloksena on kerätty tietoa erilaisista ajanvarausjärjestelmien kehitysmahdollisuuksista. Opinnäytetyön kirjoittaja on ollut aktiivinen osa ajanvarausjärjestelmän kehitystyöryhmää ja tehnyt työryhmään liittyvän kehitystyön lisäksi laajaa tiedonhankintaa ja tiedon analysointia, joiden tulos on esitetty tässä opinnäytetyössä. Toimintana on ollut siten tiedon jäsentely kirjallisessa muodossa tässä opinnäytetyössä. Opinnäytetyö tuo selkeitä vastauksia kysymykseen *miten tutkittavat kohteet (ts. ajanvarausjärjestelmä) voisivat muuttua*. Siten tutkimusmenetelmä on ollut onnistunut valinta, toimintatutkimuksiin liittyvästä kritiikistä huolimatta.

Opinnäytetyön jatkotutkimusaiheina voitaisiin pyrkiä kehittämään konkreettinen tekoälyä hyödyntävä ajanvaraussovellus tai tuoda tutkimukseen muuta konkreettisiä. Jatkotutkimuksessa voitaisiin myös pyrkiä keräämään Vihta-ajanvarausjärjestelmästä dataa ja segmentoida tätä dataa esimerkiksi asiakastyyppejä tai ominaisuuksia tutkien. Asiakastyypin tunnistamisen jälkeen voitaisiin ajanvarausjärjestelmää pyrkiä suuntaamaan tiettyyn suuntaan.

## LÄHTEET

- Abu Alfeilat, H., Bashir Alhasanat, M., Eyal Salman, H., Hassanat, A., Lasassmeh, O., Surya Prasath, V. & Tarawneh, A. 2019. Effects of Distance Measure Choice on K-Nearest Neighbor Classifier Performance: A Review. *Big data* 7 (4), 221–248.
- Abu-Hanna, A., Eslami, S., Habibi, M., Mohammadabadi, F., Tabesh, H. & Vassili-Arki, H. 2019. Effect of an Online Appointment Scheduling System on Evaluation Metrics of Outpatient Scheduling System: a before-after Multicenter Study. *Journal of Medical Systems* 43 (8), 1–9.
- Ahmadi-Javid A., Jalali, Z. & Klassen, K. 2017. Outpatient appointment systems in healthcare: A review of optimization studies. *European Journal of Operational Research* 258, 3–34.
- Akinode, J. & Oloruntoba, S. 2017. Design and Implementation of a Patient Appointment and Scheduling System. *International Advanced Research Journal in Science, Engineering and Technology* 4 (12), 16–23.
- Alasuutari, P. 2011. *Laadullinen tutkimus 2.0*. Tampere: Vastapaino.
- Almeida, R., Silva, N. & Vasconcelos, A. 2021. A Machine Learning Approach for Real Time Prediction of Last Minute Medical Appointments No-shows. *Proceedings of the 14th International Joint Conference on Biomedical Engineering Systems and Technologies (BIOSTEC 2021) - Volume 5: HEALTHINF*, 328–336.
- Alpaydin, E. 2021. *Koneoppiminen*. Helsinki: Terra Cognita Oy.
- Alvarez, J. & Lin, R. 2021. Industry perspectives and commercial opportunities of artificial intelligence in medicine. Teoksessa Giger, M., Min, J. & Xing, L. (toim.) *Artificial Intelligence in Medicine: Technical Basis and Clinical Applications*. Academic Press.
- Bhanbhro, S., Booth, A., Cobb, M., Gee, M., Nancarrow, S., McLean, S. & Salway, S. 2016. Appointment reminder systems are effective but not optimal: results of a systematic review and evidence synthesis employing realist principles. *Patient Preference and Adherence* 10 (1), 479–499.
- Binachon, B., Hoen, B., Lamaury, I., Melot, B., Ouissa, R. & Zebina, M. 2019. Impact of an SMS reminder service on outpatient clinic attendance rates by patients with HIV followed-up at Pointe-à-Pitre University Hospital. *Patient preference and adherence* 13, 215–221.
- Chand, S., Kumar, C., Moskowitz, H., Norris, J., Shade, S. & Willis, D. 2014. An empirical investigation into factors affecting patient cancellations and no-shows at outpatient clinics. *Decision Support Systems* 57, 428–443.
- Chandramouli, S., Das, A. & Dutt, S. 2018. *Machine Learning*. Pearson Education India.

Chia, N. & Loh, S. 2018. Using the stochastic health state function to forecast healthcare demand and healthcare financing: Evidence from Singapore. *Review of development economics* 22 (3), 1081–1104.

Coronato, A., De Pietro, G., Naeem, M. & Paragliola, G. 2020. Reinforcement learning for intelligent healthcare applications: A survey. *Artificial Intelligence in Medicine* 109.

Dantas, L., Fleck, J., Hamacher, S. & Oliveira, F. 2018. No-shows in appointment scheduling – a systematic literature review. *Health Policy* 122, 412–421.

Enan, M. 2021. Prediction Error and Actor-Critic Hypotheses in the Brain. Teoksessa Abdulsamad, H., Belousov, B., Klink, P. Parisi, S. & Peters, J. (toim.) Reinforcement Learning Algorithms: Analysis and Applications. *Studies in Computational Intelligence* vol. 883. Cham, Sveitsi: Springer.

Eriksson, P. & Koistinen, K. 2005. Monenlainen tapaustutkimus. Helsinki: Kuluttajatutkimuskeskus, julkaisuja 4/2005.

Eschmann, J. 2021. Reward Function Design in Reinforcement Learning. Teoksessa Abdulsamad, H., Belousov, B., Klink, P. Parisi, S. & Peters, J. (toim.) Reinforcement Learning Algorithms: Analysis and Applications. *Studies in Computational Intelligence* vol. 883. Cham, Sveitsi: Springer.

Euroopan parlamentti: Mitä tekoäly on ja mihin sitä käytetään? 2021. Ajankoh-taista. Julkaistu 4.9.2020. Päivitetty 29.3.2021. Luettu 12.12.2021.

<https://www.europarl.europa.eu/news/fi/headlines/society/20200827STO85804/mita-tekoaly-on-ja-mihin-sita-kaytetaan>

Ferreira, I. & Vasconcelos, A. 2019. MedClick: Last Minute Medical Appointments No-Show. Proceedings of the 12th International Joint Conference on Bio-medical Engineering Systems and Technologies (BIOSTEC 2019), 206–215.

Fimlab Laboratoriot Oy: Medialle. n.d. Fimlab lyhyesti. Luettu 5.3.2021. <https://fimlab.fi/media>

Fimlab Laboratoriot Oy: Yritys. n.d. Luettu 5.3.2021. <https://fimlab.fi/yritys>

Gholamzadeh Nikjoo, R., Poursagher, F. & Tabrizi, J. 2017. Status of Iran's Primary Health Care System in Terms of Health Systems Control Knobs: A Review Article. *Iranian Journal of Public Health* 46 (9), 1156–1166.

Juuti, P. & Puusa, A. 2020. Toimintatutkimus. Sekä toimintaa että tutkimusta. Teoksessa Juuti, P. & Puusa, A. (toim.) Laadullisen tutkimuksen näkökulmat ja menetelmät. Gaudeamus.

Hasankhani, F., Kiani, M. & Yousefi, N. 2019. Appointment scheduling model in healthcare using clustering algorithms. ArXiv preprint.

Kananen, H. & Puolitaival, H. 2019. Tekoäly – Bisneksen uudet työkalut. Helsinki: Alma Talent Oy.

Kassambara, A. 2017. Practical Guide to Cluster Analysis in R: Unsupervised Machine Learning. STHDA.

Kelleher, J. 2019. Deep Learning. Cambridge: MIT Press.

Kuula, A. 2006. Toimintatutkimus. Verkkojulkaisussa Saaranen-Kauppinen, A. & Puusniekka, A. (toim.) KvaliMOTV – Menetelmäopetuksen tietovaranto. Tampere: Yhteiskuntatieteellinen tietoarkisto. [https://www.fsd.tuni.fi/menetelmaopetus/kvali/L5\\_4.html](https://www.fsd.tuni.fi/menetelmaopetus/kvali/L5_4.html)

Liu, J., Nemati, S., Yin, G. & Yu, C. 2021. Reinforcement Learning in Healthcare: A Survey. ACM Computing Surveys 55 (1), 1–36.

Lukka, K. 2001. Konstruktiivinen tutkimusote. Metodix-menetelmäartikkelit. Luettu 15.9.2021. <https://metodix.fi/2014/05/19/lukka-konstruktiivinen-tutkimusote/>

Maloik, A. & Tuckfield, B. 2019. Applied Unsupervised Learning with R: Uncover Hidden Relationships and Patterns with K-means Clustering, Hierarchical Clustering, and PCA. Birmingham, Iso-Britannia: Packt Publishing.

Mäntylä, R. 2007. Kertovan muutosselonteon menetelmä. Opettajatiimien kehitymis- ja oppimisprosessi. Teoksessa Eronen, A., Syrjäläinen, E. & Värri, V-M. (toim.) Avauksia laadullisen tutkimuksen analyysiin. Tampere: Tampereen Yliopistopaino Oy.

Neittaanmäki, P. & Ojalainen, A. 2018. Tekoäly terveydenhuollossa – katsaus Aasiaan. Jyväskylä: Jyväskylän yliopiston informaatioteknologian tiedekunta, julkaisu 53/2018.

Neittaanmäki, P. & Siukonen, T. 2019. Mitä tulisi tietää tekoälystä. Jyväskylä: Docendo Oy.

Netorek Oy. n.d. Vihta: Ominaisuudet. Luettu 1.10.2021. <https://www.vihta.com/ominaisuudet/>

Pietikäinen, M. & Silvén, O. 2022. Challenges of artificial intelligence: from machine learning and computer vision to emotional intelligence. Oulu: Oulun yliopisto, Center for Machine Vision and Signal Analysis (CMVS).

Saloranta, S. 2020. Henkilökohtainen tiedonanto. Sähköposti. Vastaanotettu 7.9.2020.

Sarajärvi, A. & Tuomi, J. 2018. Laadullinen tutkimus ja sisällönanalyysi. Uudistettu laitos. Helsinki: Kustannusosakeyhtiö Tammi.

Sharma, R. 2018. Who Really Owns Your Health Data? Forbes Technology Council. Julkaistu 23.4.2018. Luettu 16.1.2022. <https://www.forbes.com/sites/forbestechcouncil/2018/04/23/who-really-owns-your-health-data/?sh=317393ed6d62>

Taveira-Gomes, T. 2017. Reinforcement Learning for Primary Care Appointment Scheduling. Faculdade de Engenharia da Universidade do Porto. Universidade Do Porto.

Žalik, K. 2008. An efficient k<sup>1</sup>-means clustering algorithm. Pattern Recognition Letters 29, 1385–1391.