

Aleksis Virtanen

KONEOPPIMINEN TERVEYDENHUOLLON TUKENA



JYVÄSKYLÄN YLIOPISTO
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA
2020

TIIVISTELMÄ

Virtanen, Aleksis

Koneoppiminen terveydenhuollon tukena

Jyväskylä: Jyväskylän yliopisto, 2020, 30 s.

Tietojärjestelmätiede, Kandidaatintutkielma

Ohjaaja: Kyppö, Jorma

Lähitulevaisuudessa potentiaalisesti lähes kaikkea mullistava koneoppiminen on ollut vuosikymmeniä IT-alan toimijoiden mielessä, mutta vasta viimeisenä vuosikymmenenä se on kyetty kunnolla ottamaan käyttöön, kun tietokonelaitteistot ovat kehittyneet jatkuvasti tehokkaammiksi. Koneoppimisen kontekstissa voidaan nähdä pätevän, että mitä enemmän dataa, sitä paremmin koneoppimisjärjestelmä menestyy. Terveydenhuollossa riittää dataa niin potilas-, lääke- kuin diagnoositietojen lisäksi lääketieteellisen kuvantamisen tuloksena muodostuvissa kuvissa. Koneoppimisen perinpohjainen ja tehokas valjastaminen terveydenhuollon tueksi saa aikaan taloudellisia säästöjä tehokkaampien hoitoratkaisujen kautta, ihmishenkien säästymistä tarkempien diagnoosien kautta ja jokaiselle keventynyttä mielentilaa, kun sairauksia voidaan ennustaa paremmin, jolla mahdollistetaan aikaisempi diagnoosi ja hoito. Tutkielma kävi läpi koneoppimisen määritelmän ja muutaman tavallisen koneoppimismenetelmän toiminnan pintapuolisesti. Myös terveydenhuollon dataa ja digitalisaa-tiota käsiteltiin, sillä niiden voidaan nähdä olevan selkeitä edellytyksiä koneoppimisen omaksunnalle. Pääosassa on tutkielman nykyhetken selvitys koneoppimisen käyttökohteista terveydenhuollon piirissä ja koneoppimISRatkaisujen diagnostisesta tarkkuudesta. Käsitellyillä aloilla, joita ovat farmasia, farmakologia, neurologia, onkologia ja kardiologia, koneoppineet järjestelmät saavuttivat vaihtelevaa tarkkuutta. Parhaimmillaan koneoppimisen hyödyntäminen johti ammattilaisia parempaan tarkkuuteen rytmihäiriön havaitsemisessa ja luokittelussa. Systemaattisen kirjallisuuskatsauksen kautta tutkielman tavoitteena on olla laaja, jäsennetty kokonaisuus, joka on helposti luettavissa ja jonka lukeminen mahdollistaa alan ulkopuolisillekin lukijoille pintapuolisesti kattavan käsityksen aihealueesta.

Asiasanat: tekoäly, koneoppiminen, neuroverkot, syväoppiminen, terveydenhuolto

ABSTRACT

Virtanen, Aleksis

The support of machine learning for healthcare

Jyväskylä: University of Jyväskylä, 2020, 30 pp.

Information Systems Science, Bachelor's Thesis

Supervisor: Kyppö, Jorma

Machine learning is in the process of transforming almost everything. It has been in the minds of information technology actors for decades, but only in the most recent decade has it properly been engaged with developments in computer hardware resulting in perpetually higher performance. In the context of machine learning it stands that with more data comes ever improving ability for machine learning to succeed. There is an abundance of data relating to patients, medicine and diagnostics in addition to data in the form of images taken as part of medical imaging. Exhaustive and effective harnessing of machine learning brings about financial savings through more effective healthcare solutions, saved lives through more accurate diagnoses and, for everyone, a lightened state of mind as diseases can better predicted, allowing for earlier diagnosis and treatment. This thesis went over the definition of machine learning and the operation of a few common machine learning methods superficially. Healthcare data and digitalization were also addressed as they can be considered clear prerequisites for the adoption of machine learning. The focus of the thesis was a present-day review of the applications of machine learning in healthcare and the diagnostic performance of machine learning solutions. In the fields covered, which include pharmacy, pharmacology, neurology, oncology and cardiology, machine learning solutions performed varyingly. At its best, a machine learning solution outperformed radiologists in the detection and classification of arrhythmia. As a result of systematic literature review, the objective of the thesis is to present a broad, structured body, which can be read at ease, and which allows readers outside the field to have a superficial yet comprehensive understanding of the topic.

Keywords: artificial intelligence, machine learning, neural networks, deep learning, healthcare

KUVIOT

KUVIO 1 Eteenpäin kytketty neuroverkko	9
KUVIO 2 Loogiset tietovarannot.....	12
KUVIO 3 Potilaskertomusjärjestelmät maissa tuloluokittain	14
KUVIO 4 PubMed-hakukoneen tulokset hakutermillä "machine learning"	15

SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT

1	JOHDANTO.....	6
2	KONEOPPIMINEN	8
2.1	Koneoppimismenetelmät	8
2.1.1	Päätöspuut.....	8
2.1.2	Neuroverkot.....	9
2.1.3	Syväoppiminen.....	10
3	TERVEYDENHUOLLON DATA JA DIGITALISAATIO.....	11
3.1	Terveydenhuollon data Suomessa	11
3.2	Terveydenhuollon data ulkomailla.....	13
3.3	Terveydenhuollon digitalisaatio Suomessa	14
4	KONEOPPIMINEN TERVEYDENHUOLLOSSA	15
4.1	Farmasia ja farmakologia.....	16
4.2	Neurologia	17
4.3	Onkologia.....	18
4.4	Kardiologia	20
4.5	Haasteita.....	21
5	YHTEENVETO	22
	LÄHTEET	24

1 JOHDANTO

Koneoppiminen on yksi IT-alan trendikkäistä teemoista ja ei suotta, sillä käyttökohteita löytyy monilta aloilta (Banco Bilbao Vizcaya Argentaria, 2019). Puheentunnistus, luottokorttipetosten havainnointi, osakemarkkinoiden analysointi, hakukoneet ja monet muut voivat hyötyä koneoppimisen tuomista mahdollisuuksista. Koneoppimisen menetelmille löytyy käyttökohteita yllättävissäkin paikoissa, kuten peliteollisuuden huijauksenestossa ja valtiojohton toteuttaman sensuurin kierrossa (Alayed, Frangoudes & Neuman, 2013; Bock, Hughey, Qiang & Levin, 2019). Koneoppimisen voidaan silti nähdä olevan vielä lapsenkengissä, koska voidaan nähdä tulevaisuus, jossa koneoppiminen voi viedä merkittävän osan ihmisten töistä tehokkuudellaan ja tarkkuudellaan (Borana, 2016, s. 4).

Terveydenhuollon kehittäminen on yhteiskunnallisesti tärkeää, sillä alan edistykset kirjaimellisesti säästävät henkiä. Ihmismielen epätäydellisyyden ongelmat voidaan nähdä ohitettavan antamalla koneoppineen järjestelmän luoda oma puolueeton havainto, joka ottaa kaiken aiemmin opitun ja nyt havaittavan informaation huomioon. Lisäksi yhteiskunta saavuttaa kustannussäästöjä vauhdikkaampien päätösten, toimivampien hoitoratkaisujen valintojen ja puolueettomien analyysien kautta (Eubanks, 2017; Kannan, 2009).

Tässä tutkielmassa käsitellään terveydenhuollon näkökulmasta koneoppimista, jonka yläkäsite IT-alalla on tekoäly. Selvitetään koneoppimisen menetelmiä korkealla tasolla ja keskitytään koneoppimista hyödyntävien järjestelmien mahdollisuuksiin ja tehokkuuksiin terveydenhuollon alalla. Selvitetään myös terveydenhuollon alan digitalisaation tilannetta, joka luo pohjan koneoppineiden järjestelmien käytölle. Tutkielma rajoittuu koko tekoälyn sijaan koneoppimiseen, jotta tutkielma pysyy sopivassa laajuudessa. Rajaudun koko tekoälyn sijaan koneoppimiseen pitääkseni tutkielman sopivassa laajuudessa. Tutkielma pyrkii vastaamaan seuraaviin tutkimuskysymyksiin:

- Miten koneoppimista hyödynnetään terveydenhuollossa?
- Millaisia tuloksia koneoppimisen hyödyntämisellä saavutetaan terveydenhuollossa?

Tutkielma toteutettiin systemaattisella kirjallisuuskatsauksella, jonka tiedonhankintaprosessin aikana käytetyt hakupalvelut olivat IEEE Explorer, Google Scholar, PubMed, JYKDOK ja Scopus. Lähteiden haku palveluista tapahtui aluksi hakusanoilla: ”machine learning” ja ”healthcare”, mutta sitten myös haku suoritettiin spesifisemmin käsittelemieni sairauksien nimillä.

Tutkielman rakenne etenee niin, että toisessa luvussa käsitellään pintapuolisesti koneoppiminen ja muutama sen tavallisista lähestymistavoista. Kolmas luku kokoaa tiedon terveydenhuollon digitalisaation tilanteesta ja siihen liittyvän datan käsittelystä. Laajimmaksi kappaleeksi muodostuu neljäs kappale, jossa käsitellään koneoppimiskäytön toteutuksia niin lääkkeiden kehityksen kuin sisätautien tunnistuksen aloilla. Neljännen kappaleen lopuksi käsitellään niitä haasteita, joita voidaan kohdata hyödyntäessä koneoppimista terveydenhuollossa. Viimeiseksi kappaleeksi jää yhteenveto.

Terveydenhuollon datatilanteen voidaan nähdä olevan paikallisesti hyvällä tasolla ja valtio antaakin ylhäältä alaspäin olevan toimintamallin tiedon liikumiselle ja säilönnälle. Suomen valtio nykytilanteessa mahdollistaa terveydenhuollon datan toissijaiseen käytön, joka tarkoittaa muuta käyttöä kuin yksilön hoitoon vaadittava käyttö. Muissa länsimaissa ja Aasian varakkaimissa maissa terveydenhuollon datan tilanne on sopiva, vaikka kansallinen järjestelmä ei olekaan käytössä melkein puolista korkean tulotason maista (WHO, 2016).

Tutkielmassa havaittiin, että koneoppimisen hyödyntämistä terveydenhuollossa tutkitaan kiivaasti ja erityisesti kuvantamisen jälkeisessä päätöksenteossa koneoppimiskäytöt ovat kykeneviä monissa tapauksissa antamaan tarkkoja arvioita. Kuvantamisen lisäksi myös lääkealalla koneoppimista järjestelmiä käytetään tehokkaasti uusien lääke-ehdokkaiden löytöön, löytämään uusia käyttötarkoituksia vanhoille lääkkeille, ennakoimaan uusien lääkkeiden farmakologisia vaikutuksia ja louhimaan lääkkeiden yhteisvaikutuksia. Koneoppimisen hyödyntämisen hyötyjen lisäksi havaitaan myös haasteita. Ennakoasenteisen opetusdatan käyttö tekee koneoppimista järjestelmistä ennakoasenteisia.

2 KONEOPPIMINEN

Koneoppiminen on tekoälyn alaluokka. Kirjoittamishetkellä Oxfordin sanakirjassa (2017) koneoppiminen on määritelty mukaillen seuraavasti: "tietokoneen kyky oppia menneestä eli kyky muokata omaa prosessointiaan uuden tiedon pohjalta." Lähes sama määritelmä löydetään Alpaydinin (2014, s. 3) kirjasta, jossa koneoppiminen määritellään tietokoneiden ohjelmointi niin, että ne optimoituvat tehokkuudessa käyttäen aiempaa kokemusta tai esimerkkidataa.

2.1 Koneoppimismenetelmät

Koneoppiminen sisältää useita menetelmiä ja algoritmeja, jotka erikoistuvat erilaisten tehtävien ratkontaan. Tämän kappaleen alaluvuissa käydään läpi koneoppimisen yleisiä menetelmiä. Koneoppimisen menetelmät monesti jaetaan kategorioihin sillä perusteella millaista dataa niille syötetään. Ohjatussa oppimisessa opetusdata koostuu syötteistä ja halutuista tuloksista. Ohjaamattomassa oppimisessä opetusdatasta ei ole luokiteltua. Tällaista järjestelmää voidaan käyttää esimerkiksi tunnistamaan poikkeavia datayksiköitä massan seasta. Vahvistusoppimisessa järjestelmälle annetaan joko positiivinen tai negatiivinen palaute sen toiminnan perusteella.

Koneoppimista hyödyntävissä menetelmissä nähdään vaivaa monessa vaiheessa. Tällaisia vaiheita ovat opetusdatan muuttaminen tai rajaaminen mahdollisimman soveltuvaksi ja tilastollisten menetelmien käyttö tunnistamaan soveltuvimmat piirteet koneoppineen järjestelmän fokukseksi (Alpaydin, 2014, s. 115–116).


2.1.1 Päätöspuut

Päätöspuut ovat binääripuita, joilla mallinnetaan puumaista päätöksentekoa (Neittaanmäki & Vähäkainu, 2018, s. 14). Staattisena tällainen puu eivät ole oppiva järjestelmiä, mutta puita yhdistelemällä ja uusilla puilla voidaan luoda

oppiva järjestelmä (Neittaanmäki & Vähäkainu, 2018, s. 14). Yksinkertaisissa järjestelmissä päätöspuilla voidaan saada tuloksia, mutta ne jäävät jälkeen muissa tapauksissa. (Neittaanmäki & Vähäkainu, 2018, s. 14).

2.1.2 Neuroverkot

Inspiraatio keinotekoisiiin neuroverkkoihin tuli hermojärjestelmien, kuten aivojen, toiminnasta (Haykin, 2009, s. 1-3; Stergiou & Siganos, n.d.). Stergiou ja Siganos (n.d.) kertovat raportissaan neuroverkon koostuvan lukuisista neuroneista, jotka ovat yhteydessä keskenään (kuvio 1).



Syötekerros Piilokerros Tulostekerros

KUVIO 1 Esimerkki eteenpäin kytketystä neuroverkosta (Haykin, 2009, s. 22)

Haykin (2009, s. 2) määrittelee neuroverkon eräänlaisena mukautuvana koneena seuraavalla tavalla:

Neuroverkko on massiivisesti rinnakkainen hajautettu prosessori, joka koostuu yksinkertaisista prosessointiyksiköistä, joilla on luontainen taipumus säilyttää kokemuksellista tietoa ja tehdä se käytettäväksi. Se muistuttaa aivoja kahdella tapaa:

1. Verkosto hankkii tietonsa ympäristöstään oppimisprosessin kautta.
2. Interneuronien yhteyksien voimakkuuksia, joita kutsutaan synaptisiksi painoiksi, käytetään saadun tiedon säilytykseen. (Haykin, 2009, s. 2)

Neuroverkkojen tapauksessa oppiminen tehdään oppimisalgoritmien avulla. Oppimisalgoritmin tehtävä on uuden opittavan datan myötä säätää verkon synaptisia painoja niin, että neuroverkko toimii jatkossa tarkemmin. Synaptisten painojen säätö on tavanomainen menetelmä neuroverkon muokkaamiseen, ja

neuroverkko on kykenevä itsenäisesti muokkaamaan neuronien välisiä yhteyksiä. (Haykin, 2009, s. 2).

2.1.3 Syväoppiminen

Deng ja Yu (2014, s. 199–200) antavat syväoppimiselle monia määritelmiä, joista ensimmäinen tuo spesifisyyttä säästämällä helppolukuisuudessa: ”Koneoppimistekniikoiden luokka, joka hyödyntää monia epälineaarisen informaation prosessoinnin tasoja ohjattuun ja ohjaamattomaan piirreirrotukseen ja muutokseen sekä kaavojen analysointiin ja luokitteluun.” Piirreirrotuksella tarkoitetaan sellaista algoritmin suorittamaa piirteiden erottelua, jossa tunnistetaan mitkä piirteet ovat merkityksellisiä luokittelun kannalta ja mitkä piirteet ovat epäoleellisia (Alpaydin, 2014, s. 115–116). Akagi (2014) täydentää aiempaa määritelmää tuomalla mukaan hierarkkisuuden, jolla syväoppimisen kontekstissa tarkoitetaan sitä, että neuroverkon eri osilla voidaan aliohjelmamaisessa mielessä käsitellä omia kokonaisuuksia. Kansankielisemmin syväoppimisessä on tavoitteena käyttää usean kerroksen neuroverkkoja ratkaisemaan ongelmia (Neittaanmäki & Vähäkainu, 2018, s. 16). Neuroverkko voidaan oppimisprosessin kautta konfiguroida tunnistamaan malleja tai luokittelemaan dataa (Neittaanmäki & Vähäkainu, 2018, s. 16).

3 TERVEYDENHUOLLON DATA JA DIGITALISAA- TIO

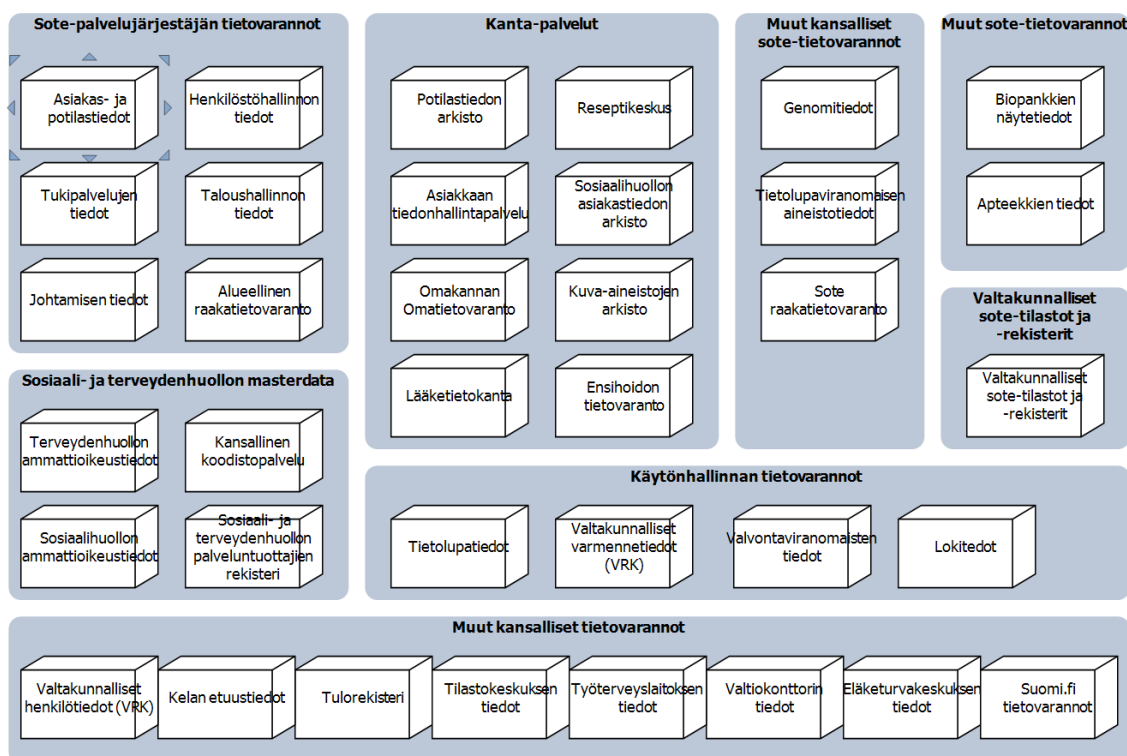
Terveydenhuollon dataksi määritellään tässä monenlainen elektronisesti säilötty tieto, jota käytetään tai tuotetaan terveydenhuollossa yksilön vaivojen ratkaisussa. Tutkielman aiheen vuoksi määritelmää on mielekästä jatkaa sillä, että tiedon tulee olla mahdollista käyttää esimerkkitietona koneoppimisessa. Tällaista tietoa voivat olla potilastiedot, potilasasiakirjat, hyvinvointitiedot, asiakastiedot ja henkilötiedot. Määritelmän pohjana on kansainvälisen ISO-standardointijärjestön (2005) sähköisen potilaskertomuksen määritelmä, joka on mukaillen seuraava: ”informaatioarkisto hoidettavan henkilön terveydentilasta tietokoneen ymmärtämässä muodossa.”

Nykyisellään Suomessa tällaisen datan käyttötarkoitus on puhtaasti yksilön akuuttien terveydellisten ongelmien korjaaminen ja vaivojen ratkaisu (Neittaanmäki, Lehto, Ruohonen, Kaasalainen & Karla, 2019, s. 17), mutta samaan aikaan on käynnissä hankkeita, kuten Kansa-hanke, joiden myötä tällaisen datan toissijaista käyttöä tehdään helpommaksi tekemällä datasta määrämuotoista, vähentämällä datan hajanaisuutta ja tuomalla järjestelmiä yhteen (Rötsä ym. 2016, s. 12).

3.1 Terveydenhuollon data Suomessa

Suomen terveydenhuollon dataa kerääntyy yksilön terveydestä, elämäntilanteesta ja palvelujen käytöstä, joilla ensisijaisesti pyritään huolehtimaan yksilön terveydestä tai kehittämään palvelujärjestelmää (Neittaanmäki ym., 2019, s. 16). Tieto kerääntyy useisiin kansallisiin järjestelmiin. Valviran (2020) tietojärjestelmärekisteriin on kirjoitushetkellä merkitty 30 eri potilastiedon arkistopalvelua. Sosiaali- ja terveystieteiden ministeriön asetus (1257/2015 2 §) velvoittaa organisaatiot viemään dataa valtakunnallisiin arkistointipalveluihin. Tällaisia palveluja ovat esimerkiksi Kanta-palveluihin kuuluvat Omakannan Omatietovaranto, potilastiedon arkisto, sosiaalihuollon asiakastiedon arkisto ja reseptikeskus. Kokonai-

suudessaan käytössä olevien tietovarantojen määrä on melko suuri ja sosiaali- ja terveysministeriön (2019a, s. 51) mukaan yksi tietovaranto voi kattaa useita tietokantoja tai rekistereitä sekä sisältää monen tahon hallinnassa olevia tietoja (kuvio 2).



KUVIO 2 Loogiset tietovarannot (Sosiaali- ja terveysministeriö, 2019a, s. 52)

Yksilöstä kerätty tieto on erityisesti potilasasiakirjojen osalta tarkoin määritelty vuoden 2009 sosiaali- ja terveysministeriön potilasasiakirja-asetuksessa (298/2009 7 §). Asetus antaa varsin kattavan potilasasiakirjojen laatimisvelvollisuuden, josta voidaan nostaa esiin aikajärjestyksessä esitetty potilaskertomus, osastohoidossa tapahtuneet potilaan tilan muutokset sekä potilaalle tehdyt tutkimukset, lääkärin tekemät havainnot, arviot, johtopäätökset ja toimenpiteet sekä niiden perusteet. Merkinnöissä oleellista on se, että niiden perusteella voidaan päästä uudestaan käsiksi siihen harkintaan, johon lääkäri perusti päätöksensä.

Ensisijaisen käytön lisäksi terveydenhuollon dataa voidaan hyödyntää muissakin tarkoituksissa. Eduskunnan päätöksellä 2019 hyväksyttiin laki toissijaisesta käytöstä, jonka myötä toissijaisesta käytöstä tuli entistä vaivattomampaa ja sujuvampaa (Sosiaali- ja terveysministeriö, 2019). Laissa sosiaali- ja terveystietojen toissijaisesta käytöstä (552/2019 2 §) kohdistetaan toissijaisiksi käyttökohteiksi tieteellisen tutkimuksen, innovaatiot, opetuksen, tilastoinnin ja tietojohdamisen sekä viranomaisen ohjaus-, valvonta-, suunnittelu- ja selvitys- tehtävät.

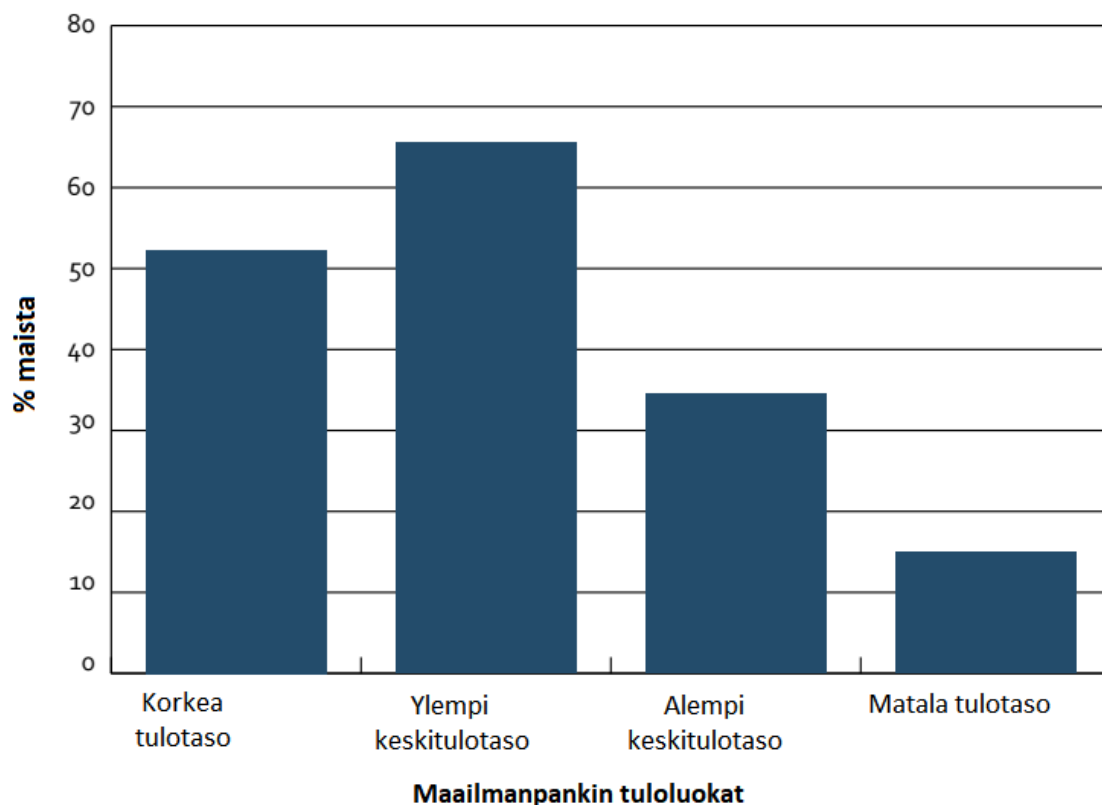
3.2 Terveydenhuollon data ulkomailla

Terveydenhuollon datan tilannetta käsitellään tässä joidenkin länsimaiden, Aasian maiden ja kehitysmaiden näkökulmista. Erityisen mielekästä on selvittää millä tasolla sähköisten potilaskertomusten omaksuminen on ympäri maailmaa.

Länsimaista Isossa-Britanniassa hallitus (2014) pyrki tekemään paikallista julkisesta terveydenhuoltojärjestelmästä paperittoman vuoteen 2020 mennessä, ja terveydenhuoltojärjestelmä odottikin omassa raportissaan, että ainakin perusterveydenhuollon potilasasiakirjat saataisiin valtakunnallisesti potilaiden luettaviksi sähköisesti vuoden 2019 aikana (NHS Digital, 2019, s. 33). Yhdysvalloissa hyväksyttiin 2009 laki, jonka yhtenä tarkoituksena oli edistää sähköisten potilaskertomusten käyttöönottoa ja joka sai aikaan kahdeksan prosenttiyksikön vuosittaisen nousun sähköisen potilaskertomuksen omaksuvissa sairaaloissa vuosina 2008-2015 (Adler-Milstein & Jha, 2017, s. 7).

Aasian maista Etelä-Koreasta saadaan tietoa Kimin ym. (2017, s. 103) kyselytutkimuksesta, josta käy ilmi vuoden 2015 tilanne: kattava tai yksinkertainen sähköinen potilaskertomusjärjestelmä on käytössä 83,5 %:ssa yliopistollisista sairaaloista ja 54,4 %:ssa tavallisista sairaaloista. Japanin tilanteesta saadaan kuvaa Kanakubon ja Kharrazin (2019) artikkelista, jossa kerrotaan sähköisen potilaskertomuksen olleen käytössä 65,6 %:ssa isoista sairaaloista, 29,3 % keskikokoisista sairaaloista ja 14,2 % pienistä sairaaloista vuonna 2014.

Quintana ja Safran (2017, s. 4) esittävät kirjallisuuskatsauksessaan melko vanhaan tietoon pohjautuen sähköisten potilaskertomusten käyttöönoton virallisten arvioiden mukaan jossain määrin onnistuneen kehitysmaissa, kuten Intia (Sequist ym., 2007) ja Kenia (Rotich ym., 2003). Toisaalta, Kumarin ja Mostafan (2020) kirjallisuuskatsauksesta käy ilmi, että vaikka potilaskertomusjärjestelmiä on käytössä alemman keskitulotason maissa, niiden käyttö monesti rajoittuu tiettyihin tauteihin, kuten HIV:hen tai tuberkuloosiin. Myös WHO:n (2016) kansainvälisestä katsauksesta käy ilmi, että alemman keskitulotason ja matalan tulotason maat ovat merkittävästi muita jäljessä (kuvio 3).



KUVIO 3 Prosenttiosuus maista, joissa on kansallinen sähköinen potilaskertomusjärjestelmä, Maailmanpankin tuloluokittain (WHO, 2016, s. 95)

3.3 Terveydenhuollon digitalisaatio Suomessa

Sosiaali- ja terveysministeriö (2020) kertoo, että se on vastuussa sosiaali- ja terveyspalvelujen kehittämisen määrittelystä, lainsäädännön valmistelusta ja uudistusten ohjauksen toteuttamisesta, mutta kuntien vastuulle jää palveluiden järjestäminen.


Sosiaali- ja terveydenhuollon alalla on käynnissä monia hankkeita, kuten Kanta-palvelujen laajentaminen sekä sairaanhoitopiirittäin ja kunnittain asiakas- ja potilastietojärjestelmähankkeita, kuten Apotti, Keski-Suomen sairaanhoitopiirin APTJ-konsortio, Kaari-APTJ (Neittaanmäki ym., 2019, s. 21–22). Neittaanmäen ym. (2019) raportissa kerrotaan kehitystä tapahtuvan myös kansalaisille suunnatuissa sähköisissä palveluissa, kuten ODA, PSOP, Virtuaalisairaala 2.0, Omakanta, omatietovaranto ja KaPA-palvelunäkymät.

Jatkossa uuden hallitusohjelman (2019, s. 107–108) mukaisesti panostetaan siihen, että kehittämällä digitalisaation tuomia mahdollisuuksia ja ottamalla niitä käyttöön Suomi pysyy maana, joka tunnetaan digitaalisen kehityksen edelläkävijänä. Valtiovarainministeriön (2020, s. 7–13) digitalisaation edistämisen ohjelmassa annetaan vuoteen 2023 mennessä toteutettavat tavoitteet, joista ensimmäisen voi nähdä liittyvän myös terveydenhuoltoon, sillä se koskee laadukaiden digitaalisten palvelujen tuomista kansalaisten ja yritysten käyttöön.

4 KONEOPPIMINEN TERVEYDENHUOLLOSSA

Koneoppimisen hyödyntäminen vaatii isoa datamäärää, jonka pohjalta järjestelmä voi oppia. Terveysthuollon kontekstissa tällainen data, jonka pohjalta oppiminen tapahtuu, voi olla kuvia diagnosointiin, biokemiallinen data biokemialliseen analyysiin, kemian tietämys lääkesuunnitteluun ja potilastiedot sekä sairaustiedot diagnosointiin. Vallianin, Rantin ja Oermannin (2019, s. 351) katsauksessa kerrotaan biolääketieteellisen tiedon runsauden olevan tyypillistä 2000-luvun terveydenhuollolle, joka luo hyvän pohjan koneoppimiskäytöille. Näin ei kuitenkaan ole kaikilla osa-alueilla, sillä Kohli, Summers ja Geis (2017, s. 392) tuovat esiin, että opetusdatasta on erityinen puute lääketieteellisen kuvantamisen pohjalta tehtävään diagnosointiin.

Tutkimus koneoppimisen hyödyntämisestä terveydenhuollossa on kiihtynyt viime vuosina kovasti. PubMed-hakukoneen käyttö paljastaa eksponentiaalisen nousun alan koneoppimisaiheisten julkaisujen määrässä (kuvio 4).



KUVIO 4 PubMed-hakukoneen tulokset hakuterminä "machine learning" julkaisuvuosittain (PubMed, 2020)

Selvitys artikkeleissa esiteltävien menetelmien toteuttamiskelpoisuudesta terveydenhuollon arjessa jää tutkielman laajuuden ulkopuolelle. Diagnostisen tehokkuuden arvioinnissa käytettävistä mittareista tutkielma keskittyy tarkkuuteen, kun taas herkkyyden, spesifisyyden ja AUC-arvon syvemmästä tarkastelusta toivotaan myöhempää tutkimusta. On hyvä huomata, että ulkopuolelle jää myös koneoppimistarkoituksiin käytettävän materiaalin esivalmistelun ja optimoinnin lähempi tarkastelu. Tällainen datan esivalmistelu ja optimointi on odotettavaa sekä tehokasta ja se voi olla kohinan poistoa, kuvien rajausta, segmentointia, tutkittavien piirteiden valintaa ja piirteiden korostusta (Alpaydin, 2014, s. 115-135).

Valmiissa menetelmässä järjestelmä on jo tarpeeksi oppinut ja käyttö voi tapahtua niinkin yksinkertaisesti kuin syöttämällä dataa tarkasteluun ja järjestelmä voi kertoa diagnoosin sekä arvion tuloksen luotettavuudesta.

Seuraavissa alaluvuissa käsitellään koneoppimisen hyödyntämistä lääkkeiden kehittämisen, neurologian ja joidenkin sisätautialojen sekä haasteiden näkökulmista.

4.1 Farmasia ja farmakologia

Farmasia tutkii lääkkeiden ominaisuuksia, valmistamista ja käyttöä, kun taas farmakologiassa keskitytään lääkeaineiden vaikutuksiin kehossa sekä biokemian ja fysiologiaan siinä määrin, kuin se on lääkeaineiden vaikutusten ymmärtämisen kannalta soveltuvaa. Lähdekirjallisuudessa esiin nousee erityisesti syväoppiminen.

Kirjoitushetkellä alan tutkimus on niin kypsää, että lääkesektorilla panostetaan koneoppimismenetelmien käyttöön (Pfizer, 2020). Panostuksen ymmärtää, sillä täysin uusien lääkeaineiden kehitys ja markkinoille tuonti on perinteisesti hyvin kallista (Paul ym., 2010). Paulin ym. (2010) artikkelissa todetaan, että Yhdysvalloissa täysin uuden lääkeaineen tuonnin hinta markkinoille oli vuonna 2010 1,8 miljardia dollaria. Hintaan sisältyy myös markkinoille pääsemättömien lääkkeiden tutkimus ja tuotekehitys (Paul ym., 2010, s. 204). Jos koneoppineilla järjestelmillä saadaan tehokkuutta lääke-ehdokkaiden etsintään tai löydetään nykyisille lääkkeille uusia käyttötarkoituksia, voivat lääkkeet halventua myös yksilön kannalta, kun lääkeyritysten lääkekohtaiset kustannukset laskevat.

Syväoppimista voidaan farmasian kontekstissa käyttää **uusien lääke-ehdokkaiden löytämiseen**. Tästä esimerkkinä voidaan ottaa esiin Altae-Tranin, Ramsundarin, Pappun ja Panden (2017) artikkeli, jonka tarkoituksena oli esitellä uusi arkkitehtuuri lääke-ehdokkaiden löytöön. Perinteisesti koneoppimismenetelmät tarvitsevat opetustietona isoja datamääriä saavuttaakseen merkityksellisen tarkkuuden, mutta Altae-Tranin ym. (2017) artikkelissa esitellyllä arkkitehtuurilla saavutettiin aiempia tarkempia ennustuksia erityisen vähäisellä opetusdatan määrällä. Tarkemmin artikkelin menetelmä perustuu oppimiseen, joka tapahtuu vain yhden näytteen perusteella (engl. one-shot learning) (Altae-Tran ym., 2017). Syväoppimista hyödynnettiin myös Aliperin ym. (2016) artikkelissa,

jossa **ennustettiin lääkkeiden farmakologisia vaikutuksia** ja tuntemattomia käyttökohteita lähetti-RNA-molekyylien perusteella. Artikkelissa tutkittiin myös mahdollisuutta **löytää vanhoille lääkkeille uusia käyttötarkoituksia** (Aliper ym., 2016, s. 2526–2527).

Kang (2018) tutki artikkelissaan koneoppimismenetelmän käyttöä eri **diabeteslääkitysten potilaskohtaisen tehokkuuden ennustukseen**. Artikkelissa käytettiin takaisinkytkettyä neuroverkkoa, jonka Kang selitti niin, että siinä neuroverkon kerros säilyttää syötteiden välillä tietoa muistin kaltaisesti, jolloin neuroverkko alkaa soveltua tehokkaammin dataan, jossa ilmenee peräkkäisyyttä, kuten vaikka ajan kuluessa voi käydä. Opetusdatana artikkelissa oli käytetty diabetesta sairastavien sähköisiä potilaskertomuksia, joista käy ilmi lääkitykset ja potilaskohtaiset tulokset (Kang, 2018, s. 3).

Koneoppimismenetelmiä on käytetty myös **lääkkeiden yhteisvaikutusten** louhintaan alan kirjallisuudesta (Lim, Lee & Kang, 2018). Limin ym. (2018, s. 15) tutkimusartikkelissa esitetty luonnollisen kielen käsittelyn menetelmä perustui rekursiiviseen neuroverkkoon, joka saavutti aiempia malleja suuremman tehokkuuden. Menetelmän tehoa nostettiin hyödyntämällä pitkän lyhytkestoisen muistin arkkitehtuuria. Pitkän lyhytkestoisen muistin (engl. long short-term memory) ajatus voidaan korkealla tasolla selittää niin, että siinä opitaan mikä tieto on hyödyllistä tulevaisuudessa ja mikä tieto voidaan unohtaa, jolloin ajan kuluessa vain oleellinen tieto säilyy (Hochreiter & Schmidhuber, 1997).

4.2 Neurologia

Neurologia tutkii hermoston ja lihasten sairauksia. Vallianin ym. (2019, s. 352) katsauksessa kerrotaan kliinisten neurotieteiden olevan ainutlaatuisessa asemassa hyötymään koneoppimisen mahdollisuuksista, sillä neurologiassa diagnosointi tehdään hienoisten oireiden tai ilmentymien kautta, joista koneoppinut järjestelmä voi tehokkaasti tunnistaa kaavoja. Kirjallisuudesta käy ilmi, että neurologian tutkimuksessa koneoppimisen potentiaalin realisointi on hyvällä tasolla.

Tässä luvussa käsitellään tarkimpia yleisten neurologisten sairauksien tunnistamiseen käytettäviä koneoppimismenetelmiä, minkälaista opetusdataa menetelmissä käytetään ja minkä tyyppisiä koneoppimisen ratkaisuja hyödynnetään.

Alzheimerin taudin ennustaminen on lievän kognitiivisen heikentymän aikana onnistuttu tekemään tarkasti Spasovin ym. (2019) artikkelin menetelmällä. Spasov ym. (2019, s. 277) käyttivät artikkelissaan konvoluutioneuroverkkoa, joka oli koulutettu niin 3D-kuvien kuin neuropsykologisen testitulosten, geenitestaustietojen ja potilaiden perustietojen pohjalta ja jolla saavutettiin 86 % tarkkuus. **Parkinsonin taudin** tapauksessa Choi, Ha, Im, Paek ja Lee (2017) esittävät artikkelissaan syväoppimiseen pohjautuvan järjestelmän, joka diagnosoi Parkinsonin taudin kuvista yhtä tarkasti kuin ammattilainen. Choin ym. (2017, s. 591) kouluttamaa konvoluutioneuroverkkoa voisi päätöksenteon tuen lisäksi

käyttää artikkelin mukaan myös luokittelemaan tarkemmin tiettyjä potilasryhmiä. Kong ym. (2019) ehdottavat **autismin kirjon** luokittelussa tukevaa menetelmää, jossa luokittelu tehdään syväoppimiseen järjestelmän avulla. Kongin ym. (2019, s. 63–66) menetelmässä opetusdatana käytettiin magneettikuvia ja menetelmän käytöllä saavutettiin 90 %:n tarkkuus. **Migreenin luokittelun** saralla Yang, Zhang ja Wang (2018, s. 9) esittävät tutkimuksessaan konvoluutioneuroverkon, jonka saavuttama tarkkuus oli 99,25 %. Opetusdatana Yang ym. (2018, s. 3) käyttivät magneettikuvia. Vaikkakin saavutettu tarkkuus oli korkea, artikkelin kirjoittajat kertoivat tutkimuksen olleen osin rajoittunut vähäisen opetusdatan vuoksi (Yang ym., 2018, s. 12). Magneettikuvia käyttivät myös Karaca, Cattani ja Moonis (2017, s. 144) syväoppimisratkaisussaan **MS-taudin** luokitteluun. Karaca ym. (2017, s. 152) pyrkivät haastamaan perinteisempää tuki-vektorikoneratkaisua syväoppimisratkaisullaan ja siinä onnistuttiin, mutta vähäisen otoskoon vuoksi artikkelin mallin suoriutumista on huono verrata tai yleistää. **Epileptisen kohtauksen** tunnistaminen onnistui poikkeuksetta Husseinin, Palangin, Wardin ja Wangin (2019, s. 33) tutkimuksessa, jossa kohtauksen tunnistus tapahtui aivosähkökäyrää seuraamalla ja jonka koneoppimisratkaisu oli takaisinkytketty neuroverkko.

Käsitellyissä artikkeleissa käytetyt koneoppimismenetelmät olivat puolessa tapauksista konvoluutioneuroverkkoja, kahdessa artikkelissa menetelmästä puhuttiin vain syväoppimisena ja yhdessä käytettiin takaisinkytkettyä neuroverkkoa. Opetusdatana artikkeleissa käytettiin magneettikuvia, SPECT-kuvia tai aivosähkökäyrää. Kuvien tapauksessa koneoppimisessa kyse oli kuvantunnistuksesta, kun taas aivosähkökäyrän tapauksessa käyrästä pyritään havaitsemaan kaavoja.

4.3 Onkologia

Onkologia tutkii syöpäsairauksia. Syöpäsairauksien havaitseminen ja luokittelu tapahtuu terveydenhuollossa perinteisesti ammattilaisten silmämääräisellä arviolla erilaisista kuvista, jonka voidaan tehdä päätös näytteenotosta. Koneoppimismenetelmät soveltuvat erityisen hyvin juuri tällaiseen toimintaan, jossa tarkoituksena on tunnistaa kuvista tiettyjä piirteitä, joiden perusteella voidaan luokitella syöpäsairauden vaihetta tai laatua. Tässä luvussa käsitellään tarkimpia lähdekirjallisuudesta löytyneitä menetelmiä.

Rintasyövän tapauksessa Agarap (2018) vertaili artikkelissaan useita koneoppimismenetelmiä, joista monikerroksinen perseptroniverkko sai parhaan tuloksen tarkkuudella 99,04 %. Monikerroksinen perseptroniverkko on terminä kuitenkin moniselitteinen ja siksi tarkempi tulkinta jää haasteelliseksi. Opetusdatana artikkelissa käytettiin aineistoa, joka koostui kuvista koneellisesti louhituista piirteistä (Agarap, 2018). **Keuhkosityövän** tunnistuksessa Jakimovski ja Davcev (2019, s. 9) onnistuivat artikkelissaan saavuttamaan 99,6 %:n tarkkuuden. Opetusdatana artikkelissa käytettiin tietokonetomografiakuvia ja menetelmänä käytettiin kaksinkertaistettua konvoluutioneuroverkkoa (Jakimovski &

Davcev, 2019, s. 3). Jakimovski ja Davcev myös vertasivat (2019, s. 9) esittelemäänsä menetelmää tavalliseen konvoluutioneuroverkkoon, joka artikkelin mukaan hävisi kaikissa mittareissa. Keuhkosityövän tunnistusta ennen on kuitenkin havaittava keuhkokyhmä, jonka laatua voidaan sitten alkaa tutkia. Koneoppimismenetelmiä on kehitetty myös pelkästään kyhmyn havaitsemiseen. Setion ym. (2016) artikkelissa esiteltyllä menetelmällä pyrittiin vähentämään virheellisten positiivisten tulosten määrää kyhmysten tunnistuksessa. Esitellyn menetelmän diagnostisesta tehokkuudesta kerrottiin vain sensitiivisyydellä, joka oli yli 85 % (Setio ym., 2016, s. 1165). Sharif, Tanvir, Munir, Khan ja Yasmin (2018) esittivät artikkelissaan tehokkaan menetelmän **aivokasvaimen luokitteluun**. Sharifin ym. (2016, s. 16) artikkelin menetelmällä saavutettiin yli 90 %:n tarkkuus kahdella eri data-aineistolla ja siinä käytettiin tukivektorikoketta luokitteluun. Opetusdatana artikkelissa käytettiin aivojen magneettikuvia erikseen kahdesta eri aineistosta (Sharif, 2016, s. 4). **Ihosityövän** automaattisessa luokittelussa Li ja Shen (2018, s. 14) esittivät artikkelissaan konvoluutioneuroverkon, jonka saavuttama tarkkuus oli 85,7 %. Ihosityövän tapauksessa opetusdatana käytetään kuvia luomista. Wildeboer, Sloun, Wijkstra ja Mischi (2020, s. 1) toteavat katsauksessaan, että **eturauhassyövän** tehokas diagnosointi vaatii monenlaista magneettikuvantamista. Useiden magneettikuvien arviointi lisää haasteita niin ammattilaiselle kuin järjestelmälle, jonka pitäisi tulkita kuvia (Wildeboer ym., 2019, s. 1). Xu, Baxter, Akin ja Cantor-Rivera (2019, s. 2–3) esittävät artikkelissaan koneoppimismenetelmän, joka ottaa eri tyyppin magneettikuvat huomioon havaitakseen häiriötä eturauhasessa. Artikkelin menetelmä perustuu residuaaliseen neuroverkkoon, jonka voi korkealla tasolla selittää niin, että siinä kerrosten syötteet voivat hypätä kerroksen yli ja siirtyä seuraavalle kerrokselle. Menetelmällä saavutettiin 93 %:n tarkkuus (Xu ym., 2019, s. 3).

Urban ym. (2018) esittivät koneoppimismenetelmän **paksu- ja peräsuolisyöpää** epäiltäessä tehtävän tähytyksen tueksi. Artikkelin menetelmän tarkoitus on tunnistaa reaaliajassa videokuvasta polyyppeja eli limakalvon pieniä pullistumia, joita voidaan sen jälkeen tutkia tarkemmin (Urban ym., 2018, s. 3). Artikkelissa käytettiin konvoluutioneuroverkkoa, joka oli koulutettu tähytysvideoista otetuista kuvista ja joka saavutti 96 %:n tarkkuuden (Urban ym., 2018, s. 18). Tällaisen menetelmän tuloksia nostattavaksi tekijäksi voisi päätellä sen, että reaaliaikaista videota tutkittaessa koneoppineella järjestelmällä on tavallista enemmän dataa, josta tehdä johtopäätöksiä. Tähytyksen aikana käy kuitenkin ymmärrettävästi niin, että pullistumat näkyvät videon eri kohdissa eri kulmissa, eri etäisyyksillä ja eri valotuksilla. Toisaalta, videokuvan analysointi reaaliajassa vaatii merkittävästi enemmän tehoa järjestelmältä, sillä kuvien käsittelyllä on kiire ja niitä tulee jatkuvalla syötöllä. Kainz, Pfeiffer ja Urschler (2017, s. 19) saavuttivat 98,3 %:n ja 95 %:n tarkkuudet suorittamissaan testeissä paksu- ja peräsuolisyövän luokittelussa. Kainz ym. (2017, s. 5) käyttivät konvoluutioneuroverkkoa, joka tutki kuvia suolesta otetuista kudoksenäytteistä.

4.4 Kardiologia

Kardiologia tutkii sydäntä ja verenkiertoelimistöä. Terveiden ja hyvinvoinnin laitoksen (2020) mukaan sydän- ja verisuonitaudit ovat yhdessä Suomen suurin kuolinsyiden ryhmä. Tässä alaluvussa keskitytään kolmeen yleiseen sydän- ja verisuonitautiin, jotka ovat sepelvaltimotauti, rytmihäiriöt ja sydämen vajaatoiminta, sekä sydän- ja verisuonitautipotilaiden hoitoajan ennustukseen.

Sepelvaltimotaudin tapauksessa Tan ym. (2018, s. 21) onnistuivat artikkelissaan esitellyllä menetelmällä tunnistamaan sepelvaltimotaudin 99,85 % tapauksista. Artikkelissa käytettiin pitkää lyhytkestoisen muistin arkkitehtuuria ja konvoluutioneuroverkkoa, jonka opetusdatana oli sydänsähkökäyrädata (Tan ym., 2018, s. 20). **Sydämen vajaatoiminta** voidaan tarkasti havaita koneoppimismenetelmin niin aivosähkökäyrästä kuin sykevälivaihtelusta (Bhurane, Sharma, San-Tan & Acharya, 2019, s. 91; Wang & Zhou, 2019, s. 10–11). Bhurane ym. (2019, s. 91) esittivät artikkelissaan menetelmän, joka kykeni sydänsähkökäyrää seuraamalla toteamaan sydämen vajaatoiminnan testausdatan mukaan alhaisimmillaan 99,66 %:n tarkkuudella. Artikkelin menetelmässä käytettiin tukivektorikonetta ja opetusdatana oli luonnollisesti sydänsähkökäyrädata, jota käsiteltiin kahden sekuntin jaksoissa (Bhurane ym., 2019, s. 82). Wang ja Zhou (2019, s. 2) puolestaan käyttivät omassa koneoppimisratkaisussaan sykevälivaihtelua perusteena sydämen vajaatoiminnan arvioinnille. Artikkelissa esitetty menetelmä hyödynsi pitkän lyhytkestoisen muistin menetelmää ja konvoluutioneuroverkkoa. Käytetyn data-aineiston mukaan artikkeli listaa tarkkuuksiksi vähintään 98,85 % tai 82,51 % (Wang & Zhou, 2019, s. 11). Hannun ym. (2019, s. 8) toivat esiin artikkelissaan **rytmihäiriön havaitsemiseen ja luokitteluun** tehdyn menetelmän, jossa käytetään konvoluutioneuroverkkoa, joka lainaa residuaalisilta neuroverkoilta mahdollisuuden syötteiden hyppäämiselle kerrosten yli. Artikkelin menetelmällä saavutettiin ammattilaista korkeampi diagnostinen tarkkuus (Hannun ym., 2019, s. 3–5).

Koneoppimista on hyödynnetty myös **sydän- ja verisuonitautipotilaiden hoitoajan ennustukseen** Daghistanin ym. (2019) artikkelissa. Artikkelissa huomattiin merkittävimiksi hoitoajan keston vaikuttavista tekijöistä sykkeen, systolisen verenpaineen, diastolisen verenpaineen, iän ja potilaan oman vakuutuksen riittävyden (Daghistani ym., 2019, s. 142). Opetusdatana artikkelissa käytettiin lukuisia sähköisistä potilaskertomuksista saatavia tietoja, jotka vaikuttavat sairaalassaolon keston. Daghistanin ym. (2019, s. 142) esittelemä menetelmä perustuu satunnaismetsä-malliin, jolla saavutettiin 80 %:n tarkkuus. Satunnaismetsää voidaan korkealla tasolla hahmotta päätöspuiden joukoksi, jossa kunkin puun vaihtelevuus on rajattua (Breiman, 2001).

4.5 Haasteet

Koneoppimisen potentiaaliseen vaikutukseen kirjoon kuuluu myös negatiivisia puolia. On pääteltävissä, että koneoppimisen opetusdatan mukana tulevat ongelmat näkyvät koneoppimiskäytösten tuloksissa. Obermeyerin, Powersin, Vogelien ja Mullainathanin (2019) tutkimus kertoo laajalti käytössä olevasta **algoritmista, jonka käyttö on johtanut rasistisiin hoitopäätöksiin**. Obermeyerin ym. (2019, s. 1) artikkelissa tarkasteltu algoritmi vaikuttaa päätöksiin miljoonien potilaiden kohdalla. Algoritmin oikaisu nostaisi lisääpua saavien tummaihoisten potilaiden määrän 17,7 %:sta 46,5 %:iin (Obermeyer ym., 2019, s. 3). Jos ennakoasenteisen henkilön tuottama opetusdata on ennakoasenteista, ymmärrettäväsi myös järjestelmä, joka oppii kyseisen datan pohjalta, toistaa samaa ennakoasennetta. Ilmiötä vastaan on ainakin rintasyövän tapauksessa luotu **ennakoasenteista tietoinen koneoppimiskäyttö**, jonka Ahsen, Ayvaci ja Raghunathan (2019) esittelevät artikkelissaan. Artikkelissa todetaan, että ennakoasenteet tiedostava järjestelmä voi huomattavasti parantaa potilaan elinajanodotetta ja tarkentaa mammografioiden perusteella tehtyjä päätöksiä (Ahsen ym., 2019, s. 111).

Davis, Lasko, Chen, Siew ja Matheny (2017) selvittivät miten **koneoppimismallit muuttuvat ajan kuluessa** ja tekivät havainnon, että koneoppimismallit lipuivat hitaasti pois alun tarkkuudesta. Davisin ym. (2017, s. 1060) artikkeli painottaa ja ehdottaa, että koneoppimiskäytöksiä käyttäessä olisi hyvä pystyä kalibroimaan järjestelmä uudelleen tai lataamaan jonkinlaisia päivityksiä, jolla ylläpidettäisiin tai parannettaisiin järjestelmän tarkkuutta.

Päätöksentekoa tukevat järjestelmät voivat Rodriguezin, O'Donovanin, Schafferin ja Höllnerin (2019) mukaan altistaa käyttäjät luottamaan järjestelmään liikaa niin, että käyttäjien omat tiedot eivät enää virity ja luottamus siirtyy järjestelmälle. Rodriguez ym. (2019) havaitsivat, että ominaisuudet, jotka saavat päätöksenteon tueksi tarkoitetun järjestelmän näyttämään pätevämmältä, vakuuttavammalta tai muokattavammalta, voivat saada käyttäjän muodostamaan väärä uskomuksia jostain alatietämyksestä.

5 Yhteenveto

Tutkielman tavoitteena oli muodostaa kattava kuva koneoppimisen hyödyntämisestä terveydenhuollossa ja vielä avartaa tätä käsitystä sivuamalla terveydenhuollon digitalisaation tilannetta, jota koneoppimisen hyödyntäminen viime kädessä edellyttää. Tutkielman kulkua ohjasi tarve vastata seuraaviin tutkimuskysymyksiin: ”miten koneoppimista hyödynnetään terveydenhuollossa?” ja ”millaisia tuloksia koneoppimisen hyödyntämisellä saavutetaan terveydenhuollossa?”. Systemaattisen kirjallisuuskatsauksen kautta löydetty tietämys on tutkielmassa jäsennetty ja näin luotu kokonaisuus, jonka lukemalla lukija voi saavuttaa kattavan ymmärryksen aihealueesta.

Tutkielma käsitteli farmasian, farmakologian, neurologian, onkologian ja kardiologian aloja sekä koneoppimisen käytön haasteita terveydenhuollon alalla. Kirjallisuudesta huomataan, että koneoppimisratkaisujen lähestymistavoissa oli samanlaisuutta. Tavallista oli käyttää koneoppineita järjestelmiä tunnistamaan kuvista, kuten magneettikuvista, pahalaatuisia tekijöitä. Tutkielmassa käsitellyissä artikkeleissa luetellut opetusdataa sisältävät tietokannat vaikuttivat kookkailta, mutta Kohli ym. (2017, s. 392) kertovat päinvastaisesti asian niin, että kuvantamisessa opetusdatasta on erityinen puute. Kuvien luokittelun tukena saatettiin käyttää potilaan muita tietoja, kuten neuropsykologisia testituloksia, geenitestausdataa ja potilaan perustietoja. Kuvien luokittelussa koneoppimisen hyödyntäminen havaittiin olevan tarkkuudeltaan hyvin korkeaa kaikilla käsitellyillä aloilla. Teoriassa tämä tarkoittaa sitä, että erityisesti diagnoosia tehtäessä koneoppinut järjestelmä voi toimia tehokkaasti päätöksenteon tukena. Parhaimmillaan koneoppimisratkaisu havaittiin tarkemmaksi kuin ammattilaiset radiologit (Hannun ym., 2019, s. 3–5). Käytännön mahdollisuuksia löytyy terveydenhuollon laitevalmistajien integroidessa koneoppinut järjestelmä osaksi laitteita tai muiden palveluntarjoajien mahdollistaessa koneoppineen järjestelmän helppo käyttö muuten. Luonnollisen kielen prosessoinnin suurta hyödyntämistä kohdattiin vain farmasian alalla, jossa massiivisista tekstimääristä etsittiin mahdollisia lääkkeiden yhteisvaikutuksia. Sähköisten potilaskertomuksen hyödyntäminen oli luetussa kirjallisuudessa merkittävintä farmasian alalla, jossa voitiin ennustaa eri lääkitysten potilaskohtaisia tehokkuuksia. Lähdekirjal-

lisuudessa kohdatut haasteet vaihtelivat merkittävydeltään. Erityisesti Obermeyerin ym. (2019) artikkelissa paljastettu miljoonia ihmisiä koskettava rasistinen algoritmi on merkittävä ongelma. Samalla on tietenkin hyvä, että ongelmat nostetaan esiin.

Tutkielman rajoitukset liittyvät koneoppimismenetelmien arviointiin matalammalla tasolla ja kirjoittajan valistuksen puutteeseen terveydenhuollon diagnostisen tehokkuuden arvioinnista sekä käytännön tasolla tapahtuvasta terveydenhuollosta. Käsiteltyjen koneoppimISRatkaisujen matalamman tason käsittely niin mahdollisten esivalmistelujen kuin optimointien kannalta jää tutkielman laajuuden ulkopuolelle. Diagnostisen tehokkuuden arviointiin liittyen olisi hyötyä alan asiantuntijuudesta, jotta saavutettaisiin varmuus tietämyksen välittymisestä tutkielmaan eheänä ja yleistettävänä. Käytännön tason terveydenhuollon tunteminen mahdollistaisi tehokkaan tiedonhaun koneoppimismenetelmien käytännön sovellutuksiin liittyen.

Merkittävä jatkotutkimusaihe löytyy käytännön terveydenhuollon näkökulmasta. Koneoppimismenetelmien tarkkuuden ollessa jo korkealla tasolla herää kysymys ratkaisujen kypsyydestä siirtyä osaksi terveydenhuoltoa. Ennen päätöstä kypsyydestä olisi myös hyvä luoda jonkinlainen standardi menetelmien testiin, jolloin vertailusta tehtäisiin arkista. Menetelmien paljouden keskeillä standardit ja standardisoitu menetelmien arviointi voisivat luoda pohjaa kaupalliselle omaksunnalle. Tulevaisuuden tutkimuksissa voitaisiin ottaa paremmin huomioon artikkeleissa vastaan tulleet muut terveydenhuollossa käytetyt diagnostisen tehokkuuden mittarit, kuten spesifisyys, herkkyys ja AUC-arvo. Lopuksi jatkotutkimusta voisi tehdä myös haasteista, erityisesti pitkällä aikavälillä koneoppimISRatkaisujen käyttöä sivusta seuraavasti.

LÄHTEET

- Adler-Milstein, J. & Jha, A. K. (2017). HITECH act drove large gains in hospital electronic health record adoption. *Health Affairs*, 36(8), 1416-1422.
- Agarap, A. F. M. (2018). On breast cancer detection: an application of machine learning algorithms on the wisconsin diagnostic dataset. Teoksessa *Proceedings of the 2nd International Conference on Machine Learning and Soft Computing (ICMLSC '18)*. (5-9). Association for Computing Machinery, New York, New York.
- Ahsen, M.E., Ayvaci, M. & Raghunathan, S. (2019). When Algorithmic Predictions Use Human-Generated Data: A Bias-Aware Classification Algorithm for Breast Cancer Diagnosis. *Information Systems Research*, 30, 97-116.
- Akagi, D. (2014, 14. maaliskuuta). A Primer on Deep Learning. Haettu 6.12.2020 osoitteesta <https://www.datarobot.com/blog/a-primer-on-deep-learning>
- Alayed, H., Frangoudes, F. & Neuman, C. (2013). Behavioral-based cheating detection in online first person shooters using machine learning techniques. Teoksessa *2013 IEEE Conference on Computational Intelligence in Games (CIG)*, Niagara Falls, Ontario, 2013.
- Aliper, A., Plis, S., Artemov, A., Ulloa, A., Mamoshina, P. & Zhavoronkov, A. (2016). Deep learning applications for predicting pharmacological properties of drugs and drug repurposing using transcriptomic data. *Molecular pharmaceutics*, 13(7), 2524-2530.
- Alpaydin, E. (2014). *Introduction to Machine Learning*. The MIT Press.
- Altae-Tran, H., Ramsundar, B., Pappu, A. S. & Pande, V. (2017). Low data drug discovery with one-shot learning. *ACS Central Science*, 3(4), 283-293.
- Banco Bilbao Vizcaya Argentaria. (2019, 2. tammikuuta). Nine technology trends in 2019. Haettu 3.12.2019 osoitteesta <https://www.bbva.com/en/nine-technology-trends-in-2019>
- Bhurane, A. A., Sharma, M., San-Tan, R. & Acharya, U. R. (2019). An efficient detection of congestive heart failure using frequency localized filter banks for the diagnosis with ECG signals. *Cognitive Systems Research*, 55, 82-94.
- Bock, K., Hughey, G., Qiang, X. & Levin, D. (2019). Geneva: Evolving Censorship Evasion Strategies. Teoksessa *Proceedings of the 2019 ACM*

SIGSAC Conference on Computer and Communications Security (CCS '19). (2199–2214). ACM, New York, New York.

Borana, J. (2016). Applications of Artificial Intelligence & Associated Technologies. Teoksessa *Proceedings of International Conference on Emerging Technologies in Engineering, Biomedical, Management and Science (ETEBMS-2016)*. Jodhpur, Rajasthan.

Breiman, L. (2001). Random Forests. *Machine Learning* 45, 5–32.

Choi, H., Ha, S., Im, H. J., Paek, S. H. & Lee, D. S. (2017). Refining diagnosis of Parkinson's disease with deep learning-based interpretation of dopamine transporter imaging. *NeuroImage: Clinical*, 16, 586-594.

Daghistani, T. A., Elshawi, R., Sakr, S., Ahmed, A. M., Al-Thwayee, A. & Al-Mallah, M. H. (2019). Predictors of in-hospital length of stay among cardiac patients: A machine learning approach. *International Journal of Cardiology*, 288, 140–147.

Davis, S. E., Lasko, T. A., Chen, G., Siew, E. D. & Matheny, M. E. (2017). Calibration drift in regression and machine learning models for acute kidney injury. *Journal of the American Medical Informatics Association*, 24(6), 1052-1061.

Deng, L. & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends in signal processing*, 7(3–4), 197-387.

Department of Health and Social Care. (2014). *Personalised Health and Care 2020*. Haettu osoitteesta https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/384650/NIB_Report.pdf

Eubanks, R. (2017, 6. lokakuuta). AI and the Healthcare Ecosystem – Why Use Artificial Intelligence. Haettu 22.6.2020 osoitteesta <https://www.capgemini.com/2017/11/ai-and-the-healthcare-ecosystem-why-use-artificial-intelligence>

Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P. & Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature medicine*, 25(1), 65-69.

Haykin, S. (2009). *Neural networks and learning machines*. Upper Saddle River, New Jersey: Pearson Education.

Hochreiter, S. & Schmidhuber, J. (1996). LSTM can solve hard long time lag problems. *Advances in neural information processing systems*, 9, 473-479.

- Hussein, R., Palangi, H., Ward, R. K. & Wang, Z. J. (2019). Optimized deep neural network architecture for robust detection of epileptic seizures using EEG signals. *Clinical Neurophysiology*, 130(1), 25-37.
- International Organization for Standardization. (2005). *Health informatics – Electronic health record – Definition, scope and context* (ISO/TR Standard No. 20514). Haettu osoitteesta <https://www.iso.org/obp/ui/#iso:std:iso:tr:20514:ed-1:v1:en>
- Jakimovski, G. & Davcev, D. (2019). Using double convolution neural network for lung cancer stage detection. *Applied Sciences*, 9(3), 427.
- Kainz, P., Pfeiffer, M. & Urschler, M. (2017). Segmentation and classification of colon glands with deep convolutional neural networks and total variation regularization. *PeerJ*, 5, e3874.
- Kannan, P. V. (2017). Artificial Intelligence – Applications in Healthcare. Asian Hospital & Healthcare Management. Haettu 22.6.2020 osoitteesta <https://www.asianhbm.com/technologyequipment/artificial-intelligence>
- Kang, S. (2018). Personalized prediction of drug efficacy for diabetes treatment via patient-level sequential modeling with neural networks. *Artificial intelligence in medicine*, 85, 1-6.
- Karaca, Y., Cattani, C. & Moonis, M. (2017). Comparison of deep learning and support vector machine learning for subgroups of multiple sclerosis. Teoksessa *International Conference on Computational Science and Its Applications – ICCSA 2017*. (142-153). Springer, Cham.
- Kim, Y. G., Jung, K., Park, Y. T., Shin, D., Cho, S. Y., Yoon, D. & Park, R. W. (2017). Rate of electronic health record adoption in south korea: A nationwide survey. *International Journal of Medical Informatics*, 101, 100-107.
- Kohli, M. D., Summers, R. M. & Geis, J. R. (2017). Medical image data and datasets in the era of machine learning – whitepaper from the 2016 C-MIMI meeting dataset session. *Journal of digital imaging*, 30(4), 392-399.
- Kong, Y., Gao, J., Xu, Y., Pan, Y., Wang, J. & Liu, J. (2019). Classification of autism spectrum disorder by combining brain connectivity and deep neural network classifier. *Neurocomputing*, 324, 63-68.
- Laki sosiaali- ja terveystietojen toissijaisesta käytöstä 552/2019. (2019). Haettu osoitteesta <https://www.finlex.fi/fi/laki/alkup/2019/20190552>
- Li, Y. & Shen, L. (2018). Skin Lesion Analysis towards Melanoma Detection Using Deep Learning Network. *Sensors*, 18(2), 556.

- Lim, S., Lee, K. & Kang, J. (2018). Drug drug interaction extraction from the literature using a recursive neural network. *PLoS ONE*, 13(1), e0190926.
- Machine. (n.d.). Oxford English Dictionary. Haettu osoitteesta <https://www.oed.com/view/Entry/111850>
- Neittaanmäki, P., Lehto, M., Ruohonen, T., Kaasalainen, K. & Karla, T. (2019). *Suomen terveystietojärjestelmien hyödyntäminen: Loppuraportti vol. 4*. Jyväskylä: Jyväskylän yliopisto.
- NHS Digital. (2019). *Annual Report and Accounts*. Haettu osoitteesta https://assets.publishing.service.gov.uk/government/uploads/system/uploads/attachment_data/file/815360/NHS_Digital_annual_accounts_and_report_2018-19.pdf
- Obermeyer, Z., Powers, B., Vogeli, C. & Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447-453.
- Paul, S. M., Mytelka, D. S., Dunwiddie, C. T., Persinger, C. C., Munos, B. H., Lindborg, S. R. & Schacht, A. L. (2010). How to improve R&D productivity: the pharmaceutical industry's grand challenge. *Nature reviews. Drug discovery*, 9(3), 203-214.
- PubMed. (2020). Haettu 26.6.2020 osoitteesta <https://pubmed.ncbi.nlm.nih.gov/?term=machine+learning>
- Quintana, Y. & Safran, C. (2017). Chapter 1 - global health Informatics – An overview. *Global health informatics* (1-13). Academic Press.
- Rodriguez, S. S., O'Donovan, J., Schaffer, J. A. & Höllerer, T. (2019). Knowledge complacency and decision support systems. Teoksessa *2019 IEEE Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA)*, 43-51.
- Rotich, J. K., Hannan, T. J., Smith, F. E., Bii, J., Odero, W. W., Vu, N., Mamlin, B. W., Mamlin, J. J., Einterz, R. M. & Tierney, W. M. (2003). Installing and implementing a computer-based patient record system in sub-Saharan Africa: the Mosoriot Medical Record System. *Journal of the American Medical Informatics Association*, 10(4), 295-303.
- Rötsä, M., Berglind, H., Huovila, M., Hyppönen, K., Peksiö, T. & Mykkänen, J. (2016). *Sosiaalihuollon valtakunnallisten tietojärjestelmäpalvelujen ja määrämuotoisen kirjaamisen toimeenpanohanke (kansa-hanke) : Hankesuunnitelma vuosille 2016-2020*. Helsinki: THL. Haettu osoitteesta <http://urn.fi/URN:ISBN:978-952-302-660-5>

- Sequist, T. D., Cullen, T., Hays, H., Taulii, M. M., Simon, S. R. & Bates, D. W. (2007). Implementation and use of an electronic health record within the Indian Health Service. *Journal of the American Medical Informatics Association : JAMIA*, 14(2), 191–197.
- Setio, A. A., Ciompi, F., Litjens, G., Gerke, P., Jacobs, C., van Riel, S. J., Wille, M. M., Naqibullah, M., Sanchez, C. I. & van Ginneken, B. (2016). Pulmonary Nodule Detection in CT Images: False Positive Reduction Using Multi-View Convolutional Networks. *IEEE transactions on medical imaging*, 35(5), 1160–1169.
- Sharif, M., Tanvir, U., Munir, E. U., Khan, M. A. & Yasmin, M. (2018). Brain tumor segmentation and classification by improved binomial thresholding and multi-features selection. *Journal of Ambient Intelligence and Humanized Computing*, 1-20.
- Sosiaali- ja terveysministeriö. (2019a). *Sosiaali- ja terveystietojen toisiokäytön kokonaisarkkitehtuuri*. Haettu osoitteesta <https://yhteistyotilat.fi/wiki08/display/thlsotekatjulk>
- Sosiaali ja terveysministeriö. (2019b). Toisiolaki mahdollistaa sosiaali- ja terveystietojen tietoturvallisen käytön. Haettu 22.6.2020 osoitteesta <https://stm.fi/sote-tiedon-hyodyntaminen>
- Sosiaali- ja terveysministeriö. (2020). Sosiaali- ja terveydenhuollon järjestelmä ja vastuut. Haettu 27.6.2020 osoitteesta <https://stm.fi/sotepalvelut/jarjestelma-vastuut>
- Sosiaali- ja terveysministeriön asetus potilasasiakirjoista 298/2009. (2009). Haettu osoitteesta <https://www.finlex.fi/fi/laki/alkup/2009/20090298>
- Sosiaali- ja terveysministeriön asetus terveydenhuollon valtakunnallisista tietojärjestelmäpalveluista 1257/2015. (2015). Haettu osoitteesta <https://www.finlex.fi/fi/laki/alkup/2012/20151257>
- Spasov, S., Passamonti, L., Duggento, A., Liò, P., Toschi, N. & Alzheimer's Disease Neuroimaging Initiative. (2019). A parameter-efficient deep learning approach to predict conversion from mild cognitive impairment to Alzheimer's disease. *NeuroImage*, 189, 276–287.
- Stergiou, C. & Siganos, D. (n.d.). *Neural Networks*. Imperial College London. Haettu osoitteesta <http://srii.sou.edu.ge/neural-networks.pdf>
- Tan, J. H., Hagiwara, Y., Pang, W., Lim, I., Oh, S. L., Adam, M., Tan, R. S., Chen, M. & Acharya, U. R. (2018). Application of stacked convolutional and long short-term memory network for accurate identification of CAD ECG signals. *Computers in biology and medicine*, 94, 19-26.

- Terveyden ja hyvinvoinnin laitos. (2020, 3. kesäkuuta). Sydän- ja verisuonitautien yleisyys. Haettu 26.6.2020 osoitteesta <https://thl.fi/fi/web/kansantaudit/sydan-ja-verisuonitaudit/sydan-ja-verisuonitautien-yleisyys>
- Urban, G., Tripathi, P., Alkayali, T., Mittal, M., Jalali, F., Karnes, W. & Baldi, P. (2018). Deep Learning Localizes and Identifies Polyps in Real Time With 96% Accuracy in Screening Colonoscopy. *Gastroenterology*, 155(4), 1069–1078.
- Valliani, A. A., Ranti, D. & Oermann, E. K. (2019). Deep Learning and Neurology: A Systematic Review. *Neurology and therapy*, 8(2), 351–365.
- Valtioneuvosto. (2019). *Pääministeri Sanna Marinin hallituksen ohjelma 10.12.2019: Osallistava ja osaava Suomi – sosiaalisesti, taloudellisesti ja ekologisesti kestävä yhteiskunta* (2019). Valtioneuvoston julkaisuja 2019:31. Haettu osoitteesta <http://urn.fi/URN:ISBN:978-952-287-808-3>
- Valtiovarainministeriö. (2020). *Digitalisaation edistämisen ohjelma 2020–2023 Toimintasuunnitelma 2020*. Haettu osoitteesta <https://vm.fi/documents/10623/1464506/Digitalisaation+edist%C3%A4misen+ohjelman+toimintasuunnitelma/5cd124e3-ec59-2fcb-79e0-a501f7ec404c>
- Valvira. (2020, 11. lokakuuta). Sosiaali- ja terveydenhuollon tietojärjestelmät. Haettu 6.12.2020 osoitteesta <https://www.valvira.fi/terveydenhuolto/sosiaali-ja-terveydenhuollon-tietojarjestelmat>
- Vähäkainu, P. & Neittaanmäki, P. (2018). Tekoäly terveydenhuollossa. Jyväskylä: Jyväskylän yliopisto.
- Wang, L. & Zhou, X. (2019). Detection of Congestive Heart Failure Based on LSTM-Based Deep Network via Short-Term RR Intervals. *Sensors*, 19(7), 1502.
- Wildeboer, R. R., van Sloun, R. J., Wijkstra, H. & Mischi, M. (2020). Artificial intelligence in multiparametric prostate cancer imaging with focus on deep-learning methods. *Computer Methods and Programs in Biomedicine*, 189, 105316.
- Xu, H., Baxter, J. S., Akin, O. & Cantor-Rivera, D. (2019). Prostate cancer detection using residual networks. *International Journal of Computer Assisted Radiology and Surgery*, 14(10), 1647-1650.

Yang, H., Zhang, J., Liu, Q. & Wang, Y. (2018). Multimodal MRI-based classification of migraine: using deep learning convolutional neural network. *Biomedical engineering online*, 17(1), 138.