

Petra Savolainen

**KONEOPPIMINEN KARIOLOGIASSA JA HAMPAIN-  
TON MÄÄRITTÄMISESSÄ: MAHDOLLISUUDET,  
HAASTEET JA IHMISEN ROOLI MALLIEN OPETTA-  
MISESSA**



JYVÄSKYLÄN YLIOPISTO  
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA  
2024

# TIIVISTELMÄ

Savolainen, Petra

Koneoppiminen kariologiassa ja hampaiston määrittämisessä: mahdollisuudet, haasteet ja ihmisen rooli mallien opettamisessa

Jyväskylä: Jyväskylän yliopisto, 2024, 46 s.

Tietojärjestelmätiede, kandidaatin tutkielma

Ohjaaja(t): Vuorinen, Jukka

Karies eli hampaiden reikiintyminen on maailmanlaajuisesti yksi yleisimmistä sairauksista, minkä hoitamatta jättäminen voi johtaa pahimmassa tapauksessa hampaan menettämiseen tai verenmyrkytykseen. Tämän vuoksi kariesen havaitsemisen ja ehkäisemisen tueksi on viime vuosina tutkittu tekoälyn, erityisesti koneoppimisen, hyödyntämistä. Koneoppimisella tarkoitetaan konetta, joka oppii ja ennustaa datasta hyödyntäen aiemmin oppimaansa. Aiemmissä alan tutkimuksissa on keskitytty koneoppimisen mallien teknisiin ominaisuuksiin ja mahdollisiin hyötyihin, mutta ihmisen osallisuutta mallin opettamisessa ei ole juurikaan tutkittu. Täten tämän tutkielman tavoitteena oli vastata kahteen tutkimuskysymykseen: ” Millä tavoin hammaslääkäri voisi hyödyntää koneoppimista työssään kariologiassa ja hampaiston määrittämisessä?” ja ” Mikä on ihmisen rooli koneoppimisen opettamisprosessissa, ja mitkä ovat koneoppimisen kehittämisen haasteita tällä hetkellä suun terveydenhuollossa?”. Tutkielma toteutettiin kuvailevana kirjallisuuskatsauksena ja lähteiksi valittiin erilaisia, pääasiassa vertaisarvioituja tieteellisiä julkaisuja. Koneoppimisen mahdollisuuksiksi löydettiin kariesriskin ennustaminen potilaan esitiedoista sekä automaattinen plakkin, kariesen ja hampaiston tunnistaminen ja määrittäminen erilaisista kuvista. Ihmisen rooli edellisten mallien opettamisessa vaihteli ohjatusta opettamisesta täysin ohjaamattomaan, riippuen mallissa hyödynnetyistä teknologioista. Lisäksi tutkielmassa havaittiin, että suurimmat mallien kehittämiseen liittyvät haasteet suun terveydenhuollon kontekstissa ovat henkilötietojen käsittelyyn liittyvät lainsäädännön vaatimukset, mustan laatikon eettiset ongelmat sekä potilaiden ja hammaslääkärien asenteista ja puutteellisista tiedoista johtuvat haasteet. Tutkielman johtopäätöksenä on, että mallien laajempaa käyttöönottoa varten tarvitaan lisätutkimuksia sekä tietoisuuden lisäämistä ammattilaisten ja potilaiden keskuudessa. Tutkielmassa ehdotetaan jatkotoimenpiteinä toisteisten tutkimusten tekemistä, laajempia tutkimusotantoja sekä alan yhteisten raportointistandardien luomista. Näin tutkimusten tuloksia voitaisiin tarkastella ja verrata luotetavammin keskenään, sekä mahdollistaa mallien käyttöönotto vastaanotoilla.

Asiasanat: koneoppiminen, syväoppiminen, neuroverkot, karies, suun terveydenhuolto

## ABSTRACT

Savolainen, Petra

Machine learning in cariology and determining of dentition: possibilities, challenges and human's role in model's teaching process.

Jyväskylä: University of Jyväskylä, 2024, 46 pp.

Information Systems, bachelor's Thesis

Supervisor(s): Vuorinen, Jukka

Caries is one of the most common diseases worldwide and if left untreated, it might lead to tooth loss or sepsis in the worst-case scenario. Therefore, recent studies have examined the possibilities of machine learning as a solution to prevent and detect caries. Machine learning describes a machine that can learn and predict from data utilizing existing information. However, there is little research about a humans' role human in teaching process of a model and thus this thesis sought for answers to two questions: "How can a dentist use machine learning in cariology and to determine dentition?" and "What is human's role in the teaching process of a machine learning model, and what are the challenges of developing these models in dentistry?". This thesis used mainly peer reviewed scientific publications to create a descriptive literature review. Predicting patient's caries risk and automatic plaque, caries and teeth identification from pictures were the main found possibilities of machine learning. Human's role in the process of teaching a model varied from supervised to unsupervised methods, depending on the technique used. In addition, the biggest challenges in model developing considered the use of personal data, black box's ethical issues and attitude problems among patients and dentists. The study concludes that to deploy the models broader, it is needed to create broader repeated research, create common standards, and spread the knowledge about machine learning in dentistry. With these follow-up measures, the results of studies could be assessed more reliably and thus possibly to deploy these models in practice.

Keywords: machine learning, deep learning, neural networks, caries, dental health care

## KUVIOT

KUVIO 1 Yksinkertaisen neuroverkon rakenne.....	15
KUVIO 2 Yhdistetty oppimisprosessi suun terveyden tutkimuksessa.....	33

# SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT

1	JOHDANTO.....	6
2	TEKOÄLY JA KONEOPPIMINEN.....	9
2.1	Koneoppiminen.....	10
2.1.1	Ohjattu oppiminen.....	11
2.1.2	Ohjaamaton oppiminen.....	12
2.1.3	PuoliOhjattu oppiminen.....	12
2.1.4	Vahvistusoppiminen.....	13
2.2	Syväoppiminen.....	13
2.2.1	Neuroverkot.....	14
2.2.2	Konvoluutioverkot.....	16
3	KONEOPPIMISEN MAHDOLLISUUDET SUUN TERVEYDENHUOLLOSSA.....	18
3.1	Karieksen ennakointi ja ennaltaehkäisy.....	19
3.1.1	Kariesriskin ennustaminen ja keskeisten riskitekijöiden tunnistaminen.....	19
3.1.2	Plakin tunnistaminen.....	21
3.2	Karieksen havaitseminen ja diagnosointi.....	24
3.3	Hampaiston määrittäminen.....	28
4	KONEOPPIMISEN HAASTEET SUUN TERVEYDENHUOLLOSSA.....	31
4.1	Lainsäädäntö ja datan yksityisyys.....	31
4.2	Mustan laatikon lääketiede.....	34
4.3	Asenteet ja suhtautuminen.....	36
5	YHTEENVETO JA JOHTOPÄÄTÖKSET.....	39
	LÄHTEET.....	43

# 1 JOHDANTO

Käypä hoito -suosituksen (2023) mukaan karies on tänä päivänä yksi yleisimmistä sairauksista maailmanlaajuisesti. Karieksella tarkoitetaan hampaiden reikiintymistä, jota aiheuttaa yleisimmin *Streptococcus mutans*-bakteeri. Vaikka kyseessä on bakteerin aiheuttama sairaus, voidaan kariesta ehkäistä hyvillä omahoitotottumuksilla sekä terveellisillä elämäntavoilla. Jos syntynyt kariesta ei kuitenkaan havaita ja hoideta, voidaan hammas menettää ja bakteeri voi päästä leviämään hampaan ytimen kautta verenkiertoon, ollen siten jopa hengenvaarallinen (Karies: Käypä hoito -suositus, 2023). Koska kyseessä on yksi laajimmin levinneistä taudeista, jonka etenemistä voidaan ehkäistä tehokkaasti, on sen varhainen toteaminen terveydenhuollossa erityisen tärkeää.

Sekä kariksen havaitsemiseen että muihinkin suun terveydenhuollon osa-alueisiin on viime vuosina tutkittu tekoälyn hyödyntämistä yhä enenemissä määrin (Khanagar ym., 2021). Tekoälyllä voidaan tarkoittaa konetta, joka algoritmeja hyödyntämällä osaa tehdä tavallisesti ihmisen älykkyyttä vaativia tehtäviä (Schwendicke, Samek & Krois, 2020). Tuzoff ym. (2019) esittävät, että eräät algoritmiset ratkaisut voisivat tarjota monipuolista tukea suun terveydenhuollon diagnoosin ja hoitosuunnitelman tekemisessä, minkä vuoksi koneoppimisen kenttä on tällä hetkellä kiinnostava tutkimuskohde. Koneoppiminen tarkoittaa koneen kykyä oppia datasta ja tehdä siitä ennusteita yhdistäen aina uuden tiedon edellisiin suorituksiin (Mohammed, Khan & Bashier, 2016). Lisäksi koneoppimisen alle voidaan luokitella syväoppiminen, joka hyödyntää toiminnassaan neuroverkkoja, jotka mahdollistavat monimutkaisempien rakenteiden käsittelyn (Goodfellow, Bengio & Courville, 2016). Hammaslääketieteessä neuroverkkojen ja erityisesti konvoluutioverkkojen käyttämistä on tutkittu hampaiden ja niiden rakenteiden luokitteluun (Tuzoff ym., 2019) sekä kariksen havaitsemiseen röntgenkuvista (Lee ym., 2021). Tutkimustulokset ovat olleet lupaavia, mutta tutkimusta ei ole vielä tehty riittävästi, jotta neuroverkkoihin perustuvia malleja olisi otettu laajemmin käyttöön klinikoilla (Tuzoff ym., 2019).

Koska suun terveydenhuollossa karies ja hampaisto määritellään usein hammaslääkärin tekemän kliinisen tutkimuksen ja röntgenkuvien yhdistelmästä (Karies: Käypä hoito -suositus, 2023), voidaan mahdollisesti kuvien ja

riskitekijöiden analysoimiseen löytää tukea koneoppimisen malleista. Myös suhteellisen vähäisen tutkimuksen vuoksi koneoppimisen mahdollisuuksien ja haasteiden tutkiminen on tärkeää. Tutkimuksien myötä uusia malleja voidaan ottaa käyttöön vastaanotoilla sekä löytää ratkaisuja haasteisiin. Tämän vuoksi tutkielman tavoitteena on tutkia kirjallisuuteen pohjautuen, miten koneoppimisen malleja voidaan hyödyntää kariuksen ehkäisyssä, havaitsemisessa ja hampaiston määrittelyssä sekä millaisia haasteita koneoppimisen mallien kehittämiseen suun terveydenhuollossa liittyy. Lisäksi sekä suun terveydenhuoltoon että koneoppimisen kehittämiseen liittyy vahvasti ihmisen osallisuus, ja siten on mielenkiintoista tarkastella myös vähemmän tutkimuksissa esille tulevaa näkökulmaa, eli ihmisen osallisuutta ja roolia mallien kehittämisessä. Suun terveydenhuollossa ihminen näkyy vahvasti vastaanotolla kliinisessä työssä ja päätöksenteossa, kun taas koneoppimisessa ihmisen toiminta näkyy vahvimmin koneoppimisen mallin opettamisprosessissa. Täten tämän tutkimuksen tavoitteena on myös pohdita, mikä on ihmisen rooli koneoppimisen mallien kehittämisessä. Tutkimuskysymykset, joihin kirjallisuuskatsauksessa haetaan vastausta ovat:

- Millä tavoin hammaslääkäri voisi hyödyntää koneoppimista työssään kariologiassa ja hampaiston määrittämisessä?
- Mikä on ihmisen rooli koneoppimisen opettamisprosessissa, ja mitkä ovat koneoppimisen kehittämisen haasteita tällä hetkellä suun terveydenhuollossa?

Valittu kirjallisuuskatsauksen tyyppi on kuvaileva kirjallisuuskatsaus ja tämän savuttamiseksi on pyritty käyttämään laadukkaita tieteellisiä artikkeleita, tutkimuksia, alan e-kirjoja sekä Suomen valtion ja Euroopan antamia asetuksia ja linjauksia. Laadukkaiden artikkeleiden valinta on toteutettu käyttämällä vähintään Julkaisufoorumin 1-luokan saaneita julkaisukanavia, valitsemalla vertaisarvioituja artikkeleita sekä tutkimalla lähteiden viittausten määriä ja kirjoittajien tietoja. Lisäksi tutkimuksien valinnassa on painotettu erityisesti viimeisen viiden vuoden aikana julkaistuja artikkeleita, jotta tutkimustulokset olisivat mahdollisimman ajankohtaisia. Aineisto on kerätty tekemällä hakuja useisiin tieteellisiin tietokantoihin, kuten ProQuest, ScienceDirect, Google Scholar, Scopus ja JYKDOK. Lisäksi sopivia lähteitä on etsitty artikkeleiden lähdeluetteloista. Tietokannoista aineistoja on kerätty käyttämällä hakusanoina erikseen ja yhdessä seuraavia sanoja: "artificial intelligence", "dentistry", "deep learning", "convolutional networks", "machine learning", "caries", "data security" ja "data protection". Tutkielmassa on hyödynnetty haastavien artikkeleiden ymmärtämisen tukemiseen tekoälypohjaista DeepL -kääntäjää sekä Copilot -tekoälybottia ajatusten ja käsitteiden jäsentelyyn, kokonaiskuvan luomiseen ja hakusanojen jatkokehittämiseen.

Tämä kirjallisuuskatsaus koostuu johdannosta, kolmesta sisällysluvusta sekä yhteenvedosta. Seuraavassa luvussa käsitellään ensin yleisesti tekoälyä ja koneoppimista, sekä erilaisia oppimistyylejä. Koneoppimisen määrittelyn jälkeen luvussa siirrytään tarkastelemaan syväoppimista, neuroverkkoja sekä erästä suun terveydenhuollon tutkimuksissa korostuvaa neuroverkkomallia,

konvoluutioverkkoja. Kolmannessa luvussa puolestaan tutkitaan, kuinka koneoppimista voidaan hyödyntää kariuksen ehkäisemisessä, tunnistamisessa ja diagnosoimisessa sekä suussa olevan hampaiston määrittämisessä. Näiden mahdollisuuksien ohella tarkastellaan, millaisia erilaisia koneoppimisen malleja tehtäviin on kehitetty. Lisäksi pohditaan, mikä on ollut ihmisen rooli kyseisten koneoppimisen mallien kehittämisessä ja opettamisessa. Mahdollisuuksien tarkastelun jälkeen siirrytään neljänteen lukuun, jossa käsitellään koneoppimisen kehittämiseen ja kliiniseen käyttöön liittyviä haasteita, kuten lainsäädäntöä, mustan laatikon lääketieteelliseen käyttöön liittyviä ongelmia sekä potilaiden ja ammattilaisten asenteita koneoppimista kohtaan. Sisältölukujen jälkeen on yhteenveto, jossa kootaan tutkielman keskeisimmät löydökset, pohditaan löydösten merkittävyyttä sekä esitetään mahdollisia jatkotutkimusehdotuksia.



## 2 TEKOÄLY JA KONEOPPIMINEN

Tässä luvussa määritellään ensin yleisellä tasolla tekoälyn käsite ja yksi sen alakategorioista, koneoppiminen. Tämän jälkeen tarkastellaan koneoppimisen neljää erilaista oppimistyyliä ja sitä, miten ne eroavat toisistaan. Seuraavaksi luvussa siirrytään käsittelemään tarkemmin mitä on syväoppiminen, neuroverkot ja konvoluutioverkot, sekä avataan niiden rakennetta ja toimintaa hieman tarkemmin.

Tekoälyn historian ei nähdä olevan vielä kovin pitkä ja siten kyseessä on suhteellisen uusi suuntaus. Khanagarin ym. (2021) mukaan tekoälyn historian voidaan katsoa alkavan 1950-luvulta, sillä vuonna 1955 tekoälyn isäksi kutsuttu John McCarthy keksi tekoälyn käsitteen kuvaamaan koneiden älykkäitä toimintoja. Vuotta myöhemmin tekoälyn tutkimushanketta käsiteltiin hänen organisoinnissaan Dartmouthin konferenssissa, josta tekoälyn tieteenalan katsotaan saaneen alkunsa (Khanagar ym., 2021).

Tekoäly käsitteenä on erittäin laaja ja siten sen yksiselitteinen määrittäminen on haastavaa. Tekoälyn voidaan nähdä toimivan sateenvarjoterminä useille eri alakategorioille, kuten koneoppimiselle ja luonnollisen kielen käsittelylle. Nämä alakategoriat hyödyntävät erilaisia tekniikoita, mikä voi hankaloittaa tekoälyn käsitteen yksiselitteistä määrittelyä. Tästä huolimatta useat tutkijat ovat yrittäneet luoda tekoälylle kaiken kattavaa määritelmää. Esimerkiksi Schwendicke ym., (2020) määrittelevät, että tekoälyllä tarkoitetaan tietokonealgoritmeja, jotka kykenevät suorittamaan normaalisti ihmisten älykkyyttä vaativia tehtäviä. Toisaalta Haenleinin ja Kaplanin (2019) määritelmän mukaan tekoäly voidaan nähdä myös järjestelmän kykynä tulkita ja analysoida saamaansa tietoa oikein sekä kykynä oppia saamastaan tiedosta. Lisäksi heidän määritelmänsä mukaan tekoäly voi käyttää saamaansa tietoa ja oppimaansa tavoitteidensa saavuttamiseksi ja sillä on kyky sopeutua joustavasti uusiin tilanteisiin (Haenlein & Kaplan, 2019). Myös Russell ym. (2021, s.20–22) ovat pohtineet tekoälyn määritelmää ja heidän määrittelyssään voidaan nähdä olevan kaksi keskeistä ulottuvuutta, jotka ovat olleet historiallisesti keskeisiä tekoälyn käsitteen määrittelemisessä. Nämä keskeiset ulottuvuudet ovat inhimillinen ja rationaalinen näkökulma. Inhimillinen näkökulma keskittyy pohtimaan, toimiiko kone samalla tavalla, kuin ihminen käyttäytyisi vastaavassa tilanteessa (Russell ym., 2021, s.20–21). Tästä

esimerkkinä voidaan nähdä olevan Turingin testi, joka tarkastelee, kykeneekö kone keskustelemaan niin vakuuttavasti ihmisen kanssa, että ihminen ei voi tunnistaa onko vastaus ihmisen vai koneen luoma. Russellin ym. (2021, s.21–22) mukaan rationaalinen näkökulma puolestaan korostaa optimaalisen ratkaisun löytämistä ja sen löytämiseksi kone käyttää apunaan loogista päättelyä. Siten tämä näkökulma ei siis ole sidoksissa inhimilliseen päätöksentekoon, vaan ratkaisu perustuu puhtaasti järkevään ja optimaaliseen harkintaan. Lisäksi Russellin ym. (2021, s.20–21) näkevät, että on olemassa vielä kaksi muuta huomioitavaa yhdistelmää tekoälyn määrittelyssä, mitkä ovat rationaalinen ja inhimillinen ajattelu-tapa. Heidän mukaansa rationaalisen ajattelun näkökulma keskittyy oikeanlaiseen ajatteluun ja logiikkaan, kun taas inhimillinen ajattelutapa korostaa koneen kykyä ajatella kuten ihminen (Russell ym., 2021, s.20–21). Jos esimerkiksi kuvitellaan tilanne, jossa ihmisen tulee päättää, syökö hän suklaapatukan vai puuroa välipalaksi. Rationaalisesti ajateltuna oikea vastaus on puuro, sillä se on ravitsevampi ja terveellisempi vaihtoehto, kuin suklaapatukka. Koska ihminen ei kuitenkaan aina toimi rationaalisesti ja siten valintaan vaikuttaa myös esimerkiksi tunteet ja mieliteot, saattaa ihminen valita suklaapatukan. Syynä voi olla, että hänen tekee mieli suklaata, hänellä on kiire tai hänen ei tee mieli syödä puuroa. Täten voidaan todeta, että ihminen ei toimi aina rationaalisesti ja siten inhimillinen ajattelu on myös olennainen osa ihmismäistä käyttäytymistä ja ajattelua,

## 2.1 Koneoppiminen

Koneoppiminen on tekoälyn osa-alue, jossa kone oppii tekemään ennusteita entuudestaan tuntemattomalle datalle käyttämällä hyväkseen ja muokkaamalla sen algoritmeja, kaavoja ja malleja, joita se on oppinut aiemmista suorituksista. Mitä enemmän soveliasta dataa kone saa käyttöönsä, sitä tarkempia ennusteita se voi tehdä säätämällä sisäisiä mallejaan ja algoritmejaan erilaisten oppimistyylien avulla. Mohammed ym. (2016) määrittelevät koneoppimisen olevan tekoälyn alakategoria, missä hyödynnetään edistyneitä oppimisalgoritmeja datan rakenteen ja kaavojen oppimiseen. Heidän määritelmänsä mukaan koneoppimista voidaan hyödyntää erityisesti datasta ennustamiseen, minkä vuoksi koneen tulee saada käyttöönsä riittävä määrä sille hyödyllistä dataa, jotta se kykenee analysoimaan sitä ja siten kehittämään toimintaansa (Mohammed ym., 2016). Määritelmästä voidaan huomata, että se keskittyy koneen teknisiin piirteisiin, mutta ei huomioi koneen ympäristön vaikutusta oppimiseen. Russell ym. (2021) puolestaan määrittelevät koneoppimisen koneen kyvyksi havaita ja päätellä kaavoja sekä taidoksi sopeutua muuttuvaan ympäristöön ja tilanteeseen. Lisäksi he jaottelevat kirjassaan koneoppimisen kolmeen eri osa-alueeseen oppimistyylin mukaan, joita ovat ohjattu oppiminen, ohjaamaton oppiminen sekä vahvistusoppiminen (Russell ym., 2021). Sen sijaan Mohammed ym. (2016) puolestaan näkevät, että on olemassa edellisten lisäksi myös neljäs osa-alue, puoliohjattu oppiminen. Seuraavaksi tarkastellaan näitä neljää aluetta hieman tarkemmin sekä pohditaan ihmisen osallisuutta koneen opettamisessa.

### 2.1.1 Ohjattu oppiminen

Ensimmäinen esiteltävä oppimistyyli on ohjattu oppiminen. Mohammedin ym. (2016) määritelmän mukaan ohjatussa oppimisessa (engl. supervised learning) koneelle annetaan harjoitusdataa sekä oikea tulos. Tämän tavoitteena on, että kone oppii luokittelemaan dataa oikein ja tunnistamaan oikean vastauksen harjoitusdatasta. Kun oppimisprosessi on käyty läpi, luo kone mallin, jonka avulla se voi luokitella tulevaisuudessa uutta dataa perustuen harjoitusdatan tuloksiin (Mohammed ym., 2016). LeCunin, Bengion ja Hintonin (2015) mukaan tässä oppimisprosessissa käytetään hyödyksi tavoite- tai virhefunktiota. Heidän mukaansa tavoitefunktiolla voidaan mitata toivotun pistemäärän ja toteutuneen tulostepisteen välistä virhettä. Tässä toivotulla pistemäärällä tarkoitetaan valvojan asettama tavoitepistettä, jota kone tavoittelee. Kone laskee pisteiden välisen erotuksen, eli virheen, minkä jälkeen se muuttaa sisäisiä parametrejaan, eli painotuksiaan (engl. weights), virheen pienentämiseksi seuraavalla suorituskerralla (LeCun ym., 2015). Näin seuraavalla kerralla, kun kone havaitsee samankaltaisen syötteen, arvioitujen tulosteiden pitäisi olla aina vain lähempänä niiden tavoitearvoja, ja siten kone oppii toimimaan koko ajan yhä optimaalisemmin. Lisäksi luotettavan mallin saavuttamiseksi opetusprosessissa on yleensä mukana valvoja, joka kertoo koneelle sen vastausten oikeellisuuden. Mohammedin ym. (2016) mukaan prosessissa valvojana voi toimia ihminen tai kone, mutta useimmiten valvomistehtävässä toimii ihminen. Heidän mukaansa tämä on siksi, että koneiden tekemiä virhearviointeja on huomattavasti enemmän kuin ihmisillä ja siten käyttämällä ihmistä taataan luotettavampi harjoitusdata (Mohammed ym., 2016).

Näistä määritelmistä voidaan todeta yhteenvetona, että ohjatulla oppimisella tarkoitetaan oppimistyyliä, jossa kone opetetaan kategorisoimaan ja tunnistamaan luokiteltua dataa valvojan avulla. Valvojan tehtävänä on kertoa koneelle, onko sen mallin luoma vastaus oikein vai väärin, ja palautteeseen pohjautuen kone pyrkii optimoimaan sen sisäisiä painotuksiaan niin, että seuraavalla kerralla vastaus olisi oikein. Koska ohjatussa oppimisessa datan luokittelijana sekä prosessin valvojana käytetään usein ihmistä, eli ihminen luo manuaalisesti tai koneellisesti raakadatasta oikean tuloksen, voidaan määritelmästä päätellä, että ihmisen rooli ohjatussa oppimisessa on usein suuri. Ihmisellä on siten paljon työtä ja vastuuta ohjattua oppimista hyödyntävien mallien opettamisessa ja ilman tätä ihmisen luomaa luokiteltua dataa ja oikeaa vastausta, ei kone osaisi säätää mallin oppimisvaiheessa algoritmejaan oikein ja siten opetusprosessi voisi epäonnistua ilman ihmistä. Toisaalta, koska ihminen on tärkeässä roolissa tässä oppimistyyliässä, voi ihmisen inhimillinen virhe luoda väärin toimivan mallin. Esimerkiksi jos ihminen luokittelee datan väärin, toimii myös luotu koneoppimisen malli väärin. Tämän vuoksi ohjatussa oppimisessa on tärkeää tarkastaa datan oikea luokittelu, jotta mallilla on edellytykset toimia oikein.

### 2.1.2 Ohjaamaton oppiminen

Toinen oppimistyyli on ohjaamaton oppiminen (engl. unsupervised learning), joka eroaa Goodfellown ym. (2016) mukaan ohjatusta oppimisesta siten, että ohjaamattoman oppimisen algoritmit eivät saa ohjeistusta valvojalta tulosten oikeellisuudesta. Heidän määritelmänsä mukaan ohjaamattomassa oppimisessa kone tekee huomioita annetusta datasta ja etsii siitä erilaisia ominaisuuksia, joiden pohjalta se voi löytää hyödyllisiä rakenteita datasta. Lisäksi heidän mukaansa tätä tekniikkaa hyödynnetään usein syväoppimisessa ja sitä voidaan käyttää tilanteissa, joissa halutaan oppia koko tietokokonaisuuden muodostaneen datan todennäköisyyksien jakauma. Heidän mukaansa tällaisia käyttökohteita voi olla esimerkiksi mallin ymmärtäminen, poikkeavuuksien etsiminen sekä tietojen esikäsittely (Goodfellown ym., 2016). Myös Muhammedin ym. (2016) määritelmän mukaan ohjaamaton oppiminen eroaa ohjatusta oppimisesta siten, että siinä käsitellään luokittelematonta dataa ja tavoitteena on löytää datasta piilotettuja rakenteita. Heidän määritelmänsä mukaan tässä oppimistyyliässä algoritmit osaavat jakaa dataa ryhmiin ja analysoida rakennetta ilman ihmisen tai koneen merkintöjä (Mohammed ym., 2016).

Toisin sanoen ohjaamattomassa oppimisessa koneelle ei anneta luokiteltua opetusdataa, vaan kone oppii itsenäisesti luokittelemaan datan sen itse tekemiinsä luokkiin. Luokittelu perustuu mallin havaitsemiin yhdistäviin ominaisuuksiin. Näin kone luo itse mallin, jolla se luokittelee datan. Tästä voidaan päätellä, että ihmisen rooli opettamisprosessissa on pieni, sillä kone oppii itse datasta ilman ihmisen avustusta. Ihminen voi mahdollisesti antaa koneelle luokittelemattoman datan, mutta ihminen ei auta konetta tekemään päätelmiä siitä, vaan koneen voidaan nähdä toimivan täysin itsenäisesti.

### 2.1.3 Puoli ohjattu oppiminen

Koneoppimisen kolmannessa oppimistyyliässä, puoli ohjatussa oppimisessa (engl. semi-supervised learning) Muhammedin ym. (2016) mukaan kone käyttää luokiteltua dataa hyödykseen muodostaakseen tehokkaita malleja, joilla se voi analysoida ja jakaa luokittelematonta dataa paremmin, kuin ohjatulla oppimisella luoduilla malleilla. Myös Bonaccorson, Fandangon ja Shanmugamanin (2018) mukaan tässä mallissa koneelle annetaan niukasti valvojalta saatua luokiteltua dataa ja runsaasti luokittelematonta dataa ympäristöstä. He määrittelevätkin kirjassaan puoli ohjatun oppimisen hyödyntävän molempia datatyyppejä erityisesti ongelmanratkaisutehtävissä (Bonaccorso ym., 2018).

Näistä määritelmistä voidaan päätellä, että puoli ohjatun oppimistyylin voidaan nähdä olevan yhdistelmä ohjattua ja ohjaamatonta oppimista, jossa koneelle annetaan vain vähän luokiteltua dataa, jonka pohjalta kone oppii luokittelemaan sille annetun suuren määrän luokittelematonta dataa. Näin kone siis luo mallin, jonka avulla se oppii luokittelemaan dataa. Määritelmästä voidaan päätellä, että ihmisen rooli puoli ohjatussa opettamisessa on suurempi, kuin ohjaamattomassa oppimistyyliässä, mutta toisaalta se on pienempi kuin täysin ohjatussa oppimisessa. Tällä tyylillä voidaan siten mahdollisesti säästää tuntuvasti

kustannuksissa, verrattuna ohjattuun oppimiseen, kun ihmistä ei tarvita yhtä suuressa roolissa. Toisaalta puoli-ohjattu oppimistyyli ei toimi täysin ilman ihmistä, koska ihmisen tulee kuitenkin luokitella dataa koneelle, jotta se voi oppia.

#### 2.1.4 Vahvistusoppiminen

Neljännessä oppimistyyliässä, eli vahvistusoppimisessä (reinforcement learning), Russellin ym. (2021) mukaan kone oppii kehittämään toimintaansa ympäristöstä saaduista vahvistuksista ja rangaistuksista. Heidän mukaansa agentin, eli koneoppimisen mallin, tehtävänä on oppia, mikä valinta johti palkkioon tai rangaistukseen, ja päätelmän perusteella muuttaa toimintaansa tulevaisuudessa (Russell ym., 2021). Puolestaan Mohammedin ym. (2016) vahvistusoppimisen määritelmän mukaan koneella ei ole syöte-tuloste-pareja, kuten ohjatussa ja ohjaamattomassa oppimisessä. Lisäksi heidän määritelmässään tuodaan ilmi, että koneen luoman mallin pääasiallisena tavoitteena on maksimaalisen palkinnon ja minimaalisen rangaistuksen tavoittelu saadun palautteen perusteella. Heidän mukaansa tavoitteen saavuttamiseksi agentin on havainnoitava ympäristöä ja tehtävä päätös käyttäen päätöksentekofunktiota. Kun agentti on tehnyt päätöksen ja suorittanut valitsemansa toiminnon, agentti saa vahvistuksen ympäristöltään. Agentti tallentaa tämän palautteen muistiinsa ja hienosäätää siihen perustuen toimintaansa tulevaisuudessa (Mohammed ym., 2016). Näin agentti oppii tekemään tulevaisuudessa vielä optimaalisempia päätöksiä ja toimintoja.

Voidaan siis sanoa, että vahvistusoppimisessä kone tavoittelee parasta mahdollista lopputulosta tai palkintoa yrityksen ja erehdyksen kautta, sekä muuttamalla toimintaansa ympäristöstä saadun palautteen perusteella. Tätä voidaan verrata esimerkiksi tammien pelaamiseen: oppilaalle kerrotaan säännöt ja päätavoite, mutta ei kaikkia mahdollisia siirtoyhdistelmiä, vaan oppilaan on itse pääteltävä kokeilemalla, mikä toimii parhaiten missäkin tilanteessa. Ihmisen rooli vahvistusoppimisen opetusprosessissa on siis suhteellisen pieni, kuten ohjaamattomassa oppimisessä. Tämä voidaan päätellä siitä, että ihminen voi määrittää agentille optimaalisen tilan ja rangaistuksen, mutta agentti joutuu itse päättämään parhaan toimintatavan kuloisessakin tilanteessa ympäristön palautteen perusteella. Eli ihminen voi vain asettaa palkinnot ja rangaistukset, mutta ympäristö antaa palautteen agentille.

## 2.2 Syväoppiminen

Syväoppimisen avulla voidaan esimerkiksi kääntää puhetta tekstiksi, tunnistaa kuvasta tunnettuja kohteita tai havaita kuvassa näkyviä poikkeavia rakenteita. Syväoppiminen on osa koneoppimista ja Lecunin ym. (2015) mukaan sen nähdään saaneen aikaan suuria kehitysaskelaita ongelmassa, joiden ratkomisessa tekoäly-yhteisöllä on ollut pitkään ongelmia. Avaintekijänä syväoppimisen menestykselle voidaan nähdä olevan sen kyky havaita monimutkaisia rakenteita

korkeaulotteisessa datassa, minkä vuoksi sitä voidaan soveltaa useilla eri aloilla. Syväoppimisen voidaankin havaita tehneen läpimurtoja erityisesti visuaalisten kohteiden, kuten videoiden ja kuvien sekä äänen käsittelyssä (Lecun ym., 2015).

Syväoppimisen voidaan nähdä kattavan laajan kirjon erilaisia koneoppimisen tekniikoita, minkä myötä käsitteen määrittäminen ei ole yksiselitteistä. Russellin ym. (2021) määritelmän mukaan nämä tekniikat hyödyntävät päällekkäisiä ja monimutkaisia laskennallisia kerroksia, joiden välisten suhteiden painotuksia voidaan säädellä. Heidän määritelmässään korostuu ajatus siitä, että jokaisella syväoppimisen kerroksella on oma tehtävänsä (Russell ym., 2021). Toisaalta Goodfellown ym. (2016) määritelmän mukaan syväoppimisella tarkoitetaan koneoppimisen osa-alueita, jossa voidaan käsitellä suurempia määriä opittuja funktioita tai käsitteitä, kuin perinteisessä koneoppimisessa. Heidän mukaansa tämä voidaan toteuttaa hyödyntämällä erilaisia keinotekoisia neuroverkkoja (Goodfellow ym., 2016). Syväoppimisen menetelmiä kutsutaankin usein neuroverkoiksi, minkä historian voidaan nähdä juontavan juurensa vuoteen 1943, jolloin McCulloch ja Pitts jäljittelivät ihmisen aivojen neuronien luomien verkostojen välisiä yhteyksiä (Russell ym., 2021). Myös LeCun ym. (2015) ovat pohtineet syväoppimisen määritelmää ja he määrittelevät syväoppimisen joukoksi representaatiooppimismenetelmiä. Heidän mukaansa representaatiooppiminen tarkoittaa menetelmiä, joiden avulla koneelle voidaan antaa syötteenä raakadataa ja kone löytää automaattisesti datasta havaitsemiseen tai luokitteluun tarvittavat representaatiot (LeCun ym., 2015). Toisin sanoen heidän määritelmänsä mukaan syväoppimismenetelmissä on useita eri esitystasoa, jotka muuttavat yhden tason representaation aina abstraktimman tason esitykseksi, eli korkeammalle tasolle.

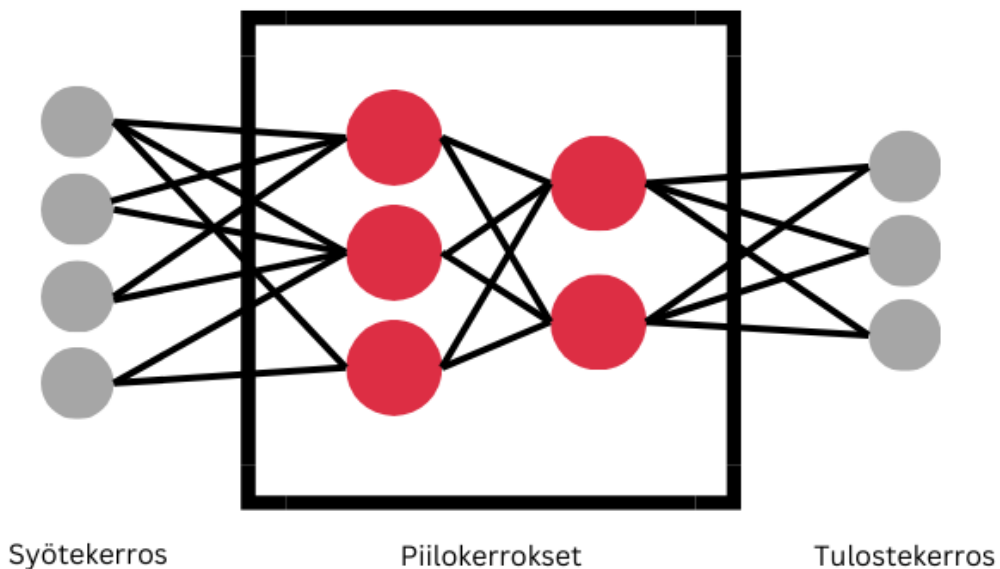
Edellä olevien määritelmien pohjalta voidaan päätellä, että syväoppimisella tarkoitetaan koneoppimisen osa-alueita, jossa hyödynnetään monikerroksisia neuroverkkoja datan käsittelyssä. Mitä korkeammalle tasolle syväoppimisessa mennään, sitä syvempi neuroverkko on, ja sitä monimutkaisempia funktioita voidaan oppia ja käsitellä. Nämä keinotekoiset neuroverkot jäljittelevät ihmisten aivojen hermoverkkojen yksinkertaistettua rakennetta. Lisäksi määritelmistä voidaan päätellä, että perinteisessä syväoppimisessä opitaan yleensä datasta ilman ihmistä, sillä ihminen ei voi vaikuttaa piilokerroksissa tapahtuvaan toimintaan. Kuitenkin joissain syväoppimisen tapauksissa voidaan yhdistellä ohjattua ja ohjaamatonta oppimista tai käyttää niitä erillään, milloin ihmistä tarvitaan erilaisiin opetustehtäviin.

Seuraavassa kappaleessa määritellään tarkemmin neuroverkkoja käsitteenä ja tutustutaan yleisesti niiden toimintaan. Tämän jälkeisessä kappaleessa puolestaan perehdytään hieman tarkemmin erääseen neuroverkkoon nimeltä konvoluutioverkko.

### 2.2.1 Neuroverkot

Alpaydinin (2016) mukaan voidaan ajatella, että aivot tekevät ihmisistä älykkäitä ja tämän vuoksi koneiden älykkyyttä kehitettäessä on perehdytty aivojen tutkimiseen. Siksi aivojen rakenteen ja toiminnan tutkimuksen pohjalta on kehitelty keinotekoisia neuroverkkoja, jotka pyrkivät jäljittelemään aivojen ominaisuuksia.

Neuroverkon yksi kerros koostuu rinnakkain toimivista prosessoivista yksiköistä eli neuroneista sekä synapseista, joiden kautta neuronit ovat yhteydessä toisiin neuroneihin ja siirtävät tietoa eteenpäin (Alpaydin, 2016). Laittamalla päällekkäin useita eri kerroksia, muodostuu siten neuroverkko, joka jäljittelee aivojen toimintatapaa ja rakennetta. Goodfellow ym. (2016) näkevät, että neuroverkon perustyyppi koostuu kolmesta eri kerrostyypistä, joita ovat syötekerros (engl. input layer), tulostekerros (engl. output layer) sekä niiden välissä olevasta yhdestä ja useammasta piilokerroksesta (engl. hidden layer). Heidän mukaansa näistä kerroksista syöte- ja tulostekerroksia kutsutaan näkyviksi kerroksiksi (engl. visible layer), koska niiden sisältämiä muuttujia on mahdollista seurata, kun taas piilokerrosten muuttujia ei voida seurata. Koneen on siten itse pääteltävä piilokerrosten tiedon avulla, mikä tieto on tarpeellista lopputuloksen kannalta, sillä ihminen ei voi kontrolloida piilokerrosten toimintaa. Lisäksi jokaisella piilokerroksella on oma tehtävänsä datan käsittelyssä ja mitä useampi niitä on, sitä monimutkaisempia ja tarkempia funktioita voidaan käsitellä (Goodfellow ym., 2016). Yksinkertaisen neuroverkon rakennetta on hahmoteltu kuviossa yksi (kuvio 1). Syötekerroksen neuronit lähettävät synapsin kautta tiedon eteenpäin piilokerroksen ensimmäiselle kerrokselle, jonka neuronit lähettävät tiedon taas eteenpäin piilokerroksen toisen kerroksen neuroneille. Tämän uloimman piilokerroksen neuronit puolestaan siirtävät tiedon eteenpäin tulostekerrokselle, jonka neuronit luovat mallin vastauksen eli tulosteen tai ennusteen.



KUVIO 1 Yksinkertaisen neuroverkon rakenne (Mohammed ym., 2016, s. 98 mukaan).

Tätä neuroverkkojen toimintaa on alun perin kuvattu Rosenblattin esittämällä Perceptroni-mallilla 1960-luvulla (Alpaydin, 2016). Perceptroni-mallin voidaan nähdä vastaavan rakenteeltaan neuroverkon rakennetta, mutta mallissa

jokaiselle neuronille on määritelty aktivointiarvo sekä yhteydessä olevien neuronien välillä on painotus (engl. weight). Alpaydinin (2016) määrittelyn mukaan painotuksella kuvataan neuronin A vaikutusta neuroniin B ja vaikutus voi olla eksitatorinen (engl. excitatory) tai inhibitorinen (engl. inhibitory). Eli jos neuronin X aktivoi myös neuronin Y ollessaan myös itse aktiivinen, on kyseessä eksitatorinen synapsi. Mutta jos X:n ollessa aktiivinen se pyrkii estämään neuronin Y toiminnan, voidaan sanoa, että synapsi inhibitorinen. Tämän lisäksi painotuksiin liittyy myös Hebbin oppimissääntö, jonka mukaan kahden neuronin välinen painotus vahvistuu, jos molemmat neuronit ovat aktiivisina samaan aikaan (Alpaydin, 2016). Saman voidaan nähdä siten toimivan myös toiseen suuntaan, eli jos kaksi neuronin aktivoituu eri aikoihin, heikentyy niiden välinen yhteys.

Toinen neuroverkkoihin liittyvä keskeinen käsite on aktivointiarvo, joka Alpaydinin (2016) määrittelyn mukaan ilmaisee sitä, aktivoituuiko neuronin vai ei. Hän näkee, että aktivointiarvo muodostuu yhteissummana viereisten neuronien aktivointiarvoista ja painotuksista. Jos yksittäisen neuronin aktivointiarvo ylittää kynnyksen, neuronin syttyä (engl. fires) ja välittää aktivaatioarvon eteenpäin. Jos taas kynnyksen ei ylitä, neuronin ei aktivoitu ja siten se ei välitä tietoa seuraavalle neuronille. Tällä tavalla toimivia verkkoja voidaan järjestää kerroksiksi, jolloin muodostuu monikerroksinen Perceptroni (Alpaydin, 2016). Täten voidaan nähdä, että myös aktivointiarvo vaikuttaa keskeisesti neuroverkon viestien välittämiseen, ja siten myös tämä ominaisuus tulee huomioida neuroverkkojen tutkittaessa.

Yhteenvedon voidaan siis todeta, että syväoppiminen hyödyntää neuroverkkoja, jotka koostuvat vähintään yhdestä piilokerroksesta sekä näkyvistä tuloste- ja syötekerroksista. Yksi kerros neuroverkossa syntyy useista neuroneista, jotka ovat liittyneet toisiinsa synapsien avulla. Lisäksi neuronien välillä on erilaisia painotuksia sekä aktivointiarvot, jotka yhdessä määrittelevät, lähettääkö neuronin viestin eteenpäin seuraavalle kerrokselle vai ei ja siten niiden huomioiminen neuroverkon mallin suunnittelussa on tärkeää. Huomioitavaa on myös se, että neuroverkoissa on aina vähintään yksi piilokerros, jonka toimintaan ihminen ei voi vaikuttaa. Mitä enemmän näitä kerroksia on, sitä monimutkaisempi rakenne neuroverkolle on ja sitä haastavampia tehtäviä se kykenee käsittelemään.

### 2.2.2 Konvoluutioverkot

Konvoluutioverkoiksi voidaan kutsua neuroverkkoja, joissa on erityinen konvoluutiokerros, joka käsittelee suoraan kuvasta saatavia syötteitä, eli pikseleitä. Gu ym., (2018) määrittelyn mukaan tämä konvoluutiokerros sisällytetään neuroverkon rakenteeseen ja näitä kerroksia voi olla yksi tai useampi. Heidän mukaansa konvoluutiokerroksia sovelletaan esimerkiksi kuvien piirteiden erottamiseen (Gu ym., 2018). Näitä piirteitä voi olla esimerkiksi hevosen kaviot tai hiiren muoto. Ilman konvoluutioverkkoja, neuroverkolle tulisi syöttää opetusdataa kaikista mahdollisista kuvakulmista ja -kohdista, jotta verkko osaisi tunnistaa kohteen (Gu ym., 2018). Esimerkiksi jos halutaan, että perinteinen neuroverkko oppii tunnistamaan hevosen, tulisi sille syöttää opetusdatassa kaikki eri kuvakulmat, sijainnit ja koot hevosesta, jotta se voisi nimetä kohteen oikein. Tämä johtaisi



tilanteeseen, että opetusdataa tarvittaisiin valtavan iso määrä tunnistamisen tueksi, mikä puolestaan kuluttaa paljon aikaa ja resursseja, eikä se ole siten kannattavaa. Gun ym. (2018) mukaan tähän ongelmaan ratkaisuna on konvoluutioverkot, jotka kykenevät tunnistamaan kohteen sen sijainnista riippumatta, jolloin tarvitaan huomattavasti pienempi määrä dataa. Myös LeCunin ym., (2015) mukaan konvoluutioverkkoja käyttämällä voidaan vähentää neuroverkon painotusten lukumäärää, ja siten myös tarvittavan opetusdatan määrää. Tämän voidaan katsoa säästävän resursseja, tarvittavaa muistia sekä nopeuttavan prosessia.

### 3 KONEOPPIMISEN MAHDOLLISUUDET SUUN TERVEYDENHUOLLOSSA

Tässä luvussa vastataan ensimmäiseen tutkimuskysymykseen, joka tutkii, millaisia mahdollisuuksia koneoppimisella on hammaslääkärin työn tukemisessa. Löydettyjen mahdollisuuksien tarkastelu on jaoteltu kolmeen osioon: kariksen ehkäisemiseen, kariksen havaitsemiseen sekä hampaiston määrittämiseen. Mahdollisuuksien lisäksi tarkastellaan pintapuolisesti, millaisia koneoppimisen tekniikoita tutkimuksissa on hyödynnetty ja mitä tuloksia niillä on saatu. Tutkimuksien ja tekniikoiden kautta etsitään myös vastauksia toisen tutkimuskysymyksen osioon, joka pohtii, mikä on ihmisen rooli koneoppimisen mallin opettamisessa aiemmin esiteltyjen oppimistyylien kautta. Jotta koneoppimisen mahdollisuuksien tarkastelu olisi helpommin ymmärrettävää, määritellään ensin käsitteistä plakki ja karies, sekä miten ne syntyvät.

Karies eli hampaiden reikiintyminen on suun sairaus ja sen syntymiseen vaikuttaa useat eri tekijät, kuten ravinto, suun terveys sekä suun bakteerikanta. Käypä hoito -suosituksen (2023) mukaan reikiintymistä voidaan ehkäistä ja pysäyttää tarkalla suun puhdistamisella, fluorituotteilla, säännöllisellä ruokarytmillä sekä terveellisellä ruokavaliolla. Kun suun bakteerit kiinnittyvät hampaan pinnalle, muodostuu bakteeriyhdyskunta, jota kutsutaan myös plakiksi. Plakki aiheuttaa useita suun sairauksia, kuten kariesta ja ientulehduksia ja niiden ehkäisemiseksi plakki tulee puhdistaa pois hampaiden pinnoilta (Karies: Käypä hoito -suositus, 2023). Esimerkiksi, jos plakkia ei puhdisteta huolellisesti ja lisäksi ruokavalio sisältää paljon sokerisia ruokia, voi hammas alkaa reikiintyä. Käypä hoito -suosituksen (2023) mukaan hampaan reikiintyessä bakteerien tuottamat hapot liuottavat mineraaleja hampaan pinnalta, minkä seurauksena hampaan pinta pehmenee. Näin syntyy alkava reikä, eli initiaaliekaries, joka voidaan vielä pysäyttää tehostamalla omahoitoa. Jos reikiintymistä ei saada pysäytettyä omahoidon tehostamisella, eli hampaan kiillepintaa ei saada kovetettua uudelleen, syntyy hampaaseen kiilteen läpi hammasluuhun, eli dentiiniin, edennyt reikä, eli karies. Jos dentiiniin edennyttä kariesta ei hoideta, voi reikä edetä hampaan ytimeen asti, minkä seurauksena hammas voi tulehtua (Karies: Käypä hoito -suositus, 2023).

### 3.1 Karioksen ennakointi ja ennaltaehkäisy

Tässä kappaleessa tutkitaan, miten koneoppimista voidaan hyödyntää karioksen ennakoimisessa ja ehkäisyssä. Ensin tarkastellaan, kuinka koneoppimista voidaan hyödyntää karioksen muodostumisriskin arvioimisessa ja keskeisten riskitekijöiden tunnistamisessa, sekä pohditaan, mikä on ihmisen rooli kyseisten mallien opettamisessa. Tämän jälkeen käsitellään koneoppimista plakin tunnistamisen apuna sekä tarkastellaan ihmisen roolia myös näiden mallien opetusprosesseissa.

#### 3.1.1 Kariesriskin ennustaminen ja keskeisten riskitekijöiden tunnistaminen

Eräs suun terveydenhuollon tutkimuskohde on koneoppimisen mallit, jotka ennustavat potilaan karioksen muodostumisriskiä sekä siihen vaikuttavia riskitekijöitä. Tutkimuksissa valitulle mallille annetaan syötteenä mahdollisia karioksen riskitekijöitä sekä potilaan kariesstatus, jotka kone siten analysoi. Analysoituaan tiedot, malli antaa tulosteena listan, jossa on potilaan suurimmat riskitekijät kariekselle, sekä jokaisen riskitekijän painoarvo karioksen muodostumiselle. Esimerkiksi Qun ym. (2022) tutkimuksessa luodaan tällainen lapsille suunnattu kariesriskinarviointimalli (CRPM). Lisäksi heidän tutkimuksessaan verrataan, mikä seuraavista koneoppimisen malleista suoriutuu parhaiten ennustamaan karioksen muodostumisriskin, ja siihen vaikuttavat käyttäytymistekijät: satunnaismetsä (engl. random forest), logistinen regressio (engl. logistic regression) vai adaptiivinen boostaus (engl. adaptive boosting). Tutkimuksessa hammaslääkäri teki lapsille kliinisen alkutarkastuksen sekä heidän tuli täyttää suun terveyskäyttäytymiseen liittyvä kysely yhdessä vanhemman kanssa. Kolmen kuukauden päästä tehtiin uusi tarkastus, jossa katsottiin, oliko lapselle kehittynyt kariesta. Tämän jälkeen alku- ja lopputarkastuksen tulokset sekä käyttäytymiseen liittyvät riskitekijät lisättiin edellä mainittuihin kolmeen erilliseen malliin, jotka antoivat tulosteena kullekin tekijälle oman painoarvon. Painoarvolla tarkoitetaan riskitekijän merkitystä ennusteessa (Qu ym., 2022). Eli mitä suuremman painon malli riskitekijälle antaa, sitä suurempi merkitys kyseisellä tekijällä on karioksen muodostumisessa. Qun ym. (2022) tutkimuksesta selviää, että suurimmat käyttöön liittyvät riskitekijät lapsen karioksen kehittymiselle ovat yöllisen syömisen tiheys sekä puutteelliset harjaustottumukset. Lisäksi tulokset näyttävät, että parhaiten malleista karioksen muodostumisen ennustamisessa onnistui satunnaismetsä (Qu ym., 2022). Satunnaismetsä on koneoppimisen tekniikka, joka on lineaarinen yhdistelmä useita päätöksentekopuita (engl. decision trees), joihin perustuen kone tekee ennustuksia (Alpaydin, 2016). Koska päätöksentekopuut ovat osa ohjattua oppimistyyliä (Mohammed ym., 2016, s. 37) ja koska Alpaydinin (2016) määritelmän mukaan satunnaismetsä yhdistelee useita päätöksentekopuita yhteen tulosteen luomiseksi, voidaan satunnaismetsän nähdä myös olevan ohjatun koneoppimisen oppimistyyli.

Myös Sadegh-Zadehin ym. (2022) tutkimuksessa verrataan erilaisten koneoppimismallien suorituskykyä alle 6-vuotiaan kariuksen muodostumisen ennustamisessa ja riskitekijöiden tunnistamisessa. Tutkimuksessa parhaat tulokset saatiin Perceptroni-mallilla, satunnaismetsällä ja tukivektorikoneella (engl. support vector machine). Tulosten mukaan suurimpia riskitekijöitä maitohampaiston kariuksen kehittymiselle ovat jo olemassa oleva karies, runsassokeristen ruokien ja juomien toistuva nauttiminen, suun tarkastusten väliin jättäminen, huoltajien alhainen sosioekonominen asema sekä alhainen fluorin saaminen (Sadegh-Zadeh ym., 2022). Eräs ero Qun ym. (2022) tutkimukseen on se, Sadegh-Zadehin ym. (2022) tutkimuksessa käytettiin jo entuudestaan vastaanotoilla kerättyä dataa, eli tutkimusjoukolla ei tehty erillistä kliinistä tutkimusta tai kyselyjä, kuten Qun ym. (2022) tutkimuksessa. Toinen merkittävä ero tutkimusten välillä on myös tutkittavat riskitekijät. Saged-Zahedin ym. (2022) tutkimuksessa keskitytään tarkastelemaan karieshistoriaa, biologisia sekä sosio-ekonomisia tekijöitä, kun taas Qun ym. (2022) riskitekijöissä otettiin huomioon vain suun terveyteen liittyvät käyttäytymistekijät. Koska tutkitut riskitekijät ovat siten erilaisia, ei tutkimusten tuloksia voida vertailla täysin luotettavasti keskenään. Lisäksi myös eri tavoin suoritettu riskitekijöiden ja havaintojen keräystapa vaikeuttaa tutkimustulosten vertailun luotettavuutta. Nämä kaksi eroavaisuutta voivat siten myös selittää eroja eri mallien suoriutumisessa, mutta eroista huolimatta satunnaismetsä suoriutui molemmissa tutkimuksissa vakuuttavasti.

Puolestaan Toledo Reyesin ym. (2023) tutkimuksessa kariuksen muodostumista ennustaville koneoppimisen malleille syötettiin kaikkia edellä mainittuja riskitekijöitä: sosioekonomisia, demograafisia, kliinisiä sekä käyttäytymiseen liittyviä tekijöitä. Tutkimuksen alkaessa tutkittavat olivat 1–5-vuotiaita ja he kävivät jatkotutkimuksissa kahden ja kymmenen vuoden päästä tutkimuksen aloittamisesta. Tutkimustuloksissa todetaan, että jo varhaislapsuudessa kerätyistä tekijöistä voidaan koneoppimisen mallien avulla ennustaa kariuksen muodostumisriski niin maitohampaissa, kuin pysyvissäkin hampaissa. Tärkeimpiä pysyvien hampaiden kariuksen riskitekijöitä tutkimuksen mukaan ovat muun muassa lapsuusajan karies, fluorittoman hammastahnan käyttäminen, vanhempien alhainen koulutustaso, suuri sokeripitoisten ruokien ja juomien käyttäminen sekä vanhempien puutteellinen käsitys lapsen suun terveydestä (Toledo Reyes ym., 2023). Tutkimustuloksista voidaan huomata, että löydetyt riskitekijät ovat linjassa myös aiemmin tehtyjen tulosten kanssa, vaikka käytetty koneoppimisen malli onkin eri. Toledo Reyesin ym. (2023) tutkimuksessa koneoppimisen mallina käytettiin loogista regressiota sekä XGBoost-mallia. Tutkimustuloksista selviää, että XGBoost saavutti näistä kahdesta paremman suoriutumisen kariuksen muodostumisen ennustamisessa. XGBoost on koneoppimisen malli, joka perustuu kokoelmaan heikkoja päätöspuita, jotka huomioivat aina edellisessä mallin sovittamisessa ilmenneet vaikeudet ja kehittää siten toimintaansa (Toledo Reyes ym., 2023). Koska myös tämä malli perustuu päätöspuihin, jotka hyödyntävät ohjattua oppimista (Mohammed ym., 2016, s. 37), voidaan päätellä, että myös tämä koneoppimisen malli hyödyntää ohjattua oppimistyyliä opetusvaiheessa.

Edellä esitettyjä tutkimustuloksia yhdistämällä voidaan huomata, että erityisesti ohjattua oppimistyyliä hyödyntävät päätöspuupohjaiset mallit toimivat hyvin lasten kariksen muodostumisriskin ennustamisessa ja keskeisten riskitekijöiden tunnistamisessa. Täten ihmisen rooli koneen opettamisprosessissa on suuri, sillä jo ennen opetuksen aloittamista ihmisen tulee kerätä potilailta tiedot riskitekijöistä ja lopputuloksesta. Edellä esitetyistä tutkimuksista löydettäviä keräystapoja ovat etä- ja lähihaastattelut, kliiniset tutkimukset sekä vanhojen suun terveydenhuollon kirjauksien lukeminen. Tietoihin perehtymisen jälkeen jokaisessa tutkimuksessa tutkijat ovat muuttaneet riskitekijät ja oikeat tulokset malleille syötettävään muotoon opetusdataksi. Esimerkiksi Toledo Reyesin ym. (2023) kliinisessä tutkimuksessa havaittu karies syötettiin malleille Boolean-arvona. Näin ollen yhdenkin kariksen löytyminen johti kyllä-vastaukseen ja vain täysin kariesvapaalla suulla oli mahdollista antaa koneelle negatiivinen totuusarvo, eli ei-vastaus. Yhdistämällä alkuperäisiä arvoja, eli riskitekijöitä, sekä perustotuuden, eli kariksen esiintymisen, mallit päättelivät, mitkä tekijät johtivat useimmiten kariksen muodostumiseen. Näin malli oppi tuottamaan painoarvot eri riskitekijöille ja siten ennustamaan kariksen muodostumisriskin. Toisaalta tutkimuksissa ei tuotu ilmi, onko opetusprosessissa valvojana toiminut ihminen vai kone, minkä vuoksi ihmisen mahdollista roolia valvojana ei voida käsitellä kyseisten tutkimusten tarkastelussa.

Koneoppimista käyttämällä voidaan siis ennustaa olennaisia kariksen muodostumiseen vaikuttavia riskitekijöitä sekä arvioida niiden avulla kariksen muodostumisriskiä. Näistä arvoista voi olla hyötyä hammaslääkärille kariksen ennaltaehkäisyssä, koska huomaamalla riskitekijät aikaisessa vaiheessa, voidaan lapsen terveystyötytymiseen puuttua ja tarjota tukea jo ennen kariksen muodostumista. Tukea voidaan antaa esimerkiksi tarjoamalla harjausopetusta, tietoa ravinnosta tai tekemällä riskihampaisiin pinnoituksia hampaiden puhdistamisen helpottamiseksi. Toimimalla ennakoivasti voidaan mahdollisesti välttää korjattavan karieshoidon tarve tulevaisuudessa ja parantaa siten lapsen terveyttä.

### 3.1.2 Plakin tunnistaminen

Toinen kariksen ennaltaehkäisyyn liittyvä koneoppimisen mahdollisuus on plakin tunnistaminen. Esimerkiksi Youn, Haon, Lin, Wangin ja Xian (2020) tutkimuksessa kehitettiin uusi konvoluutioverkkoja hyödyntävä malli maitohampaiden plakin tunnistamiseen. Mallin opettamista varten potilaalta otettiin ensin alkuperäinen kuva suukameralla huulen puoleisilta pinnoilta ilman plakkiväriä. Tämän jälkeen otettiin vielä toinen identtinen kuva plakkivärjäyksen kanssa (You ym., 2020). Plakkivärillä tarkoitetaan ainetta, joka värjää hampaan plakkikohdat näkyviksi. Seuraavaksi Youn ym. (2020) tutkimuksen mallin opettamisprosessissa molemmat kuvat rajattiin niin, että jokaisessa kuvassa oli vain yksi hammas. Tutkijat merkitsivät hampaiden plakkikohdat plakkivärjätystä kuvasta käyttäen LabelMe -ohjelmistoa, minkä jälkeen tietokoneohjelman avulla väritetyt plakkialueet siirrettiin alkuperäisten kuvien päälle (You ym., 2020). Näin siis luotiin perustotuuskuva, eli kuva, joka on oikea vastaus. Aineistoin keräämisen jälkeen Youn ym. (2020) tutkimuksessa itse plakin havaitsemismalli luotiin

kahdessa osassa. Ensin esiopetettiin perusverkko, jotta saatiin määritettyä verkolle peruspainotukset. Seuraavaksi opetettiin DeepLabV3-malli alkuperäisillä ja värjätyillä kuvilla. Mallille annettiin syötteenä alkuperäinen ja plakkivärjätty kuva, joita vertailemalla malli loi välivaiheen kuvan, johon se merkitsi havaitsemansa plakkikohdat. Tämän jälkeen mallille annettiin perustotuuskuva, jossa oli näkyvillä oikeat plakkialueet. Seuraavaksi malli vertasi omia havaintoja sille annettuun perustotuuskuvaan ja tekemiensä havaintojen perusteella malli muutti sisäisiä painotuksiaan sopivammiksi (You ym., 2020). Näin malli siis opetettiin tunnistamaan plakkia vertailemalla kuvia sekä kehittämään toimintaansa virhehavainnoista. Opetusprosessin kuvauksesta voidaankin päätellä, että malli opetettiin käyttämällä ohjattua oppimistyyliä, koska mallille annettiin syötteenä luokiteltua dataa, eli plakkivärjätty kuva, sekä alkuperäinen kuva havaintojen tekemistä varten. Lisäksi lopulta valvoja antoi mallille perustotuuskuvan, eli oikeat plakkikohdat. Tutkimuksessa ei kerrota esiopetusvaiheen opetusprosessista, minkä vuoksi ihmisen osallisuutta tässä prosessissa ei voida arvioida. Tämän vuoksi päättely ohjatusta oppimistyylistä perustuu täysin DeepLabV3-mallin kuvaukseen.

Myös Lin ym. (2022) tutkimuksessa kehitettiin uusi yhdistetty koneoppimisen malli hampaiden plakin tunnistamiseksi jo olemassa olevia syväoppimisen malleja hyödyntämällä. Tutkimuksessa luotu yhdistetty malli hyödyntää useampaa eri syväoppimisen mallia ja siten sen toiminta koostuu kahdesta päävaiheesta, joita ovat ominaisuuksien poimiminen sekä ominaisuuksien fuusio- ja luokittelu. Toimivalle yhdistetylle mallille annetaan ensin syötteenä raakakuva hampaista, minkä jälkeen se tekee ensin operaatioita superpikselitasolla. Seuraavaksi yhdistetty malli liittää superpikselien paikalliset ja globaalit ominaisuudet yhteen analysointia ja käsittelyä varten. Prosessin tuloksena yhdistetty malli tuottaa kuvan, jossa alkuperäiseen kuvaan on väritetty sen havaitsemat plakkialueet (Li ym., 2022). Kyseessä on siten monimutkaisempi ja useista eri malleista koostuva koneoppimisen yhdistetty malli plakin tunnistamiseen.

Lin ym. (2022) tutkimuksessa käytettiin opetusvaiheessa kuvien merkitsemiseen automaattista kuvien kohdistusmallia, jota varten tutkijoiden tuli merkitä jokaiseen opetuskuvaan neljä valittua avainpistettä. Valitut pisteet olivat hampaan mesiaali- ja distaalilinja, hampaan kuspia tai kärki sekä ienrajan matalin kohta. Nämä kohdat merkittiin sekä plakkivärjättyyn että alkuperäiseen kuvaan (Li ym., 2022). Pisteiden tarkoituksena oli siis helpottaa ja nopeuttaa tutkijoiden työtä, sillä kun pisteet yhdistettiin toisiinsa viivoilla, oli sen jälkeen helpompaa ja tarkempaa yhdistää plakkivärjätyn ja alkuperäisen kuvan alueet toisiinsa. Seuraavaksi Lin ym. (2022) tutkimuksessa tutkijat loivat manuaalisesti perustotuuksuvat, joihin he merkitsivät plakkikohdat. Tämän jälkeen pistemerkityt plakkivärjätty ja alkuperäiset kuvat annettiin yhdistetylle mallille analysoitavaksi oppimista varten. Mallille ei annettu perustotuuksuvia (Li ym., 2022). Tähän kuvaukseen perustuen Lin ym. (2022) tutkimuksessa voidaan nähdä käytettävän puoli-ohjattua oppimista, sillä tutkijoiden tuli merkitä manuaalisesti harjoitusdatan kuviin avainpisteet. Pisteiden avulla yhdistetty malli kykeni yhdistämään plakkivärjätty ja alkuperäiset kuvat toisiinsa, sekä etsimään kuvista oleellisia

havaintoja plakkikohtien tunnistamista varten. Malleille ei kuitenkaan tutkimuksen mukaan annettu perustotuuskuvaa prosessin lopussa, eli yhdistetylle mallille ei kerrottu oliko sen tuottamat tulosteet oikein vai väärin. Näiden seikkojen vuoksi opetustapa ei sovi täysin ohjaamattomaan tai ohjattuun opetustapaan, vaan on niiden välimaastossa. Tämä päätelmä puoliohjattusta opetustyylistä on kuitenkin vain suuntaa antava, sillä tutkimuksesta ei selviä kaikkia oppimistyylin arvioimiseen vaadittavia piirteitä. Esimerkiksi tutkimuksesta ei selviä oliko koko yhdistetty malli, tai sen osiot, esivalmennettu jo ennen tutkimusta. Tämän vuoksi ohjautuuteen arvioiminen jää tämän tutkimuksen osalta melko pintapuoliseksi ja se perustuu tutkimuksesta selviäviin seikkoihin.

Edellä esiteltyjen tutkimusten tuloksista voidaan nähdä, että tutkimuksissa luotujen mallien plakin tunnistaminen on tarkempaa ja tasalaatuisempaa, kuin hammaslääkäreillä (You ym., 2020; Li ym., 2022). Tätä tulosta voi toisaalta selittää se, että tutkimuksien arviointiryhmissä olevien hammaslääkäreiden on täytynyt tunnistaa plakki pelkistä valokuvista. Tämä voi olla haasteellista, sillä plakki on usein lähes hampaan pinnan väristä, ja siten sitä on vaikea havaita pelkästä kuvasta ilman kliinistä arviota. Tästä huolimatta sekä Youn ym. (2020), että Lin ym. (2022) tutkimuksista voidaan tehdä päätelmä, että syväoppimismalleilla, erityisesti konvoluutioverkkoihin pohjautuvilla malleilla, voidaan tunnistaa kuvista plakkialueita. Youn ym. (2020) tutkimuksessa hyödynnettiin ohjattua oppimistyyliä, kun taas Lin ym. (2022) tutkimuksen voidaan tulkita hyödyntäneen puoli-ohjattua oppimistyyliä. Täten ihmisen rooli ja tehtävät opetusprosessissa vaihtelivat kuvien manuaalisesta leikkaamisesta, plakin pikselitason merkitsemisestä ja oikeiden tuloskuvien luomisesta pelkkään neljän pisteen piirtämiseen. Molemmissa tutkimuksissa tutkijat kuitenkin loivat perustotuuskuvat, mutta Lin ym. (2022) tutkimuksessa näitä kuvia ei annettu yhdistetylle mallille. Sen sijaan luotuihin perustotuuskuviin verrattiin mallin tuottamia kuvia, jotta sen suoriutumista voitiin arvioida. Puolestaan Youn ym. (2020) tutkimalle mallille perustotuuskuvat annettiin opetusvaiheessa oppimisen parantamiseksi. Oppimistyyliä tarkastelemalla voidaan päätellä, että Youn ym. (2020) tutkimuksessa ihmisen rooli on huomattavasti suurempi ja oleellisempi suuremman työmäärän ja valvojana toimimisen vuoksi, kuin Lin ym. (2022) tutkimuksessa.

Lupaavista tuloksista huolimatta on huomioitava, että harjoitusdatan määrä molemmissa tutkimuksissa oli suhteellisen pieni ja kuvat oli otettu samoista kuvakulmista (You ym., 2020; Li ym., 2022). Nämä seikat voivat vaikuttaa tutkimusten tuloksiin väärentämällä tulosjakauma ja siten ne on huomioitava tuloksia tarkastellessa. Rajoitteista huolimatta plakin tunnistusmallista voisi kuitenkin olla You ym., (2020) mukaan apua erityisesti yhteistyöhaluttomien lapsipotilaiden kanssa. Lisäksi mallista voisi olla apua myös pelko- ja kipupotilaiden hoidossa. Hammaslääkäri voisi ottaa vastaanotolla kuvan potilaan hampaista ja arvioida hampaiston kariesriskiä automaattisesti analysoidun kuvan ja ulkoisen kliinisen tutkimuksen perusteella ja määrittellä siten tarvittavia jatkotoimenpiteitä sekä totuttaa potilasta vastaanottokäynteihin. Lisäksi Youn ym. (2020) mukaan tällaisesta mallista voisi olla hyötyä myös kotikäytössä, jolloin vanhemmat voisivat arvioida lapsen suun plakkitilannetta älypuhelimien sovelluksen avulla.

Näin jatkokehittämällä malleja, kariksen etenemistä voitaisiin ehkäistä ajoissa niin hammaslääkärissä kuin kotonakin, ja siten parantaa potilaiden terveyttä ja ennaltaehkäistä kariksen syntymistä.

### 3.2 Kariksen havaitseminen ja diagnosointi

Tässä kappaleessa tutkitaan, miten kariksen ehkäisyn lisäksi koneoppimista voidaan hyödyntää kariksen havaitsemiseen röntgenkuvista, ja siten myös hammaslääkärin diagnoosin tekemisen tukena. Tämän lisäksi tarkastellaan pintapuolisesti tutkimuksissa käytettyjä koneoppimisen tekniikoita ja pohditaan, mikä on ihmisen rooli opetusprosessissa. Jotta koneoppimisen mahdollisuuksien tutkiminen kariksen havaitsemisessa olisi helpommin ymmärrettävää, pitää sitä ennen vielä määritellä käsitteistä yleisimmät röntgenkuvatyyppit, joita ovat bite-wing-kuva ja OPG-kuva, sekä tuoda ilmi niiden merkitys suun terveydenhuollossa ja kariksen havaitsemisessa.

Hammasvälien kariksen tunnistamisessa yleisenä käytäntönä on yhdistää hammaslääkärin kliininen tutkimus bitewing-kuvaukseen (Karies: Käypä hoito -suositus, 2023). Wenzelin (2004) mukaan bitewing-kuva tarkoittaa röntgenkuvauksen muotoa, jossa potilaan suuhun asetetaan kuvanpidikkeessä filmi, jota potilaan tulee purra kuvauksen ajan. Kuva otetaan kohdistamalla röntgenputki filmin kohtaan suun ulkopuolelta ja onnistuneesta kuvasta tulisi näkyä suun sivualueiden hampaiden kruunut. Kuvia käytetään erityisesti hammasvälien kariksen tutkimisessa, sillä näiden alueiden mahdollisia muutoksia ei voi havaita pelkällä silmällä (Wenzel, 2004). Lee ym. (2021) toteavat kuitenkin, että erityisesti initiaaliekariesten havaitseminen bitewing-kuvista on vaikeaa, koska kuvan tulkitseminen on täysin riippuvainen sen katsojasta ja tulkinnat samasta kuvasta voivatkin vaihdella ammattilaisten välillä. Lisäksi kuvan lukemiseen vaikuttaa kuvan laatu, käytössä olevat laitteet sekä hammaslääkärin omat odotukset ja kokemukset (Lee ym., 2021). Määritelmistä voidaan siten todeta, että bitewing-kuvat ovat isossa roolissa erityisesti hammasvälien initiaaliekariesten havaitsemisessa, mutta niiden tulkitseminen on täysin riippuvaista kuvan lukijasta. Tämän vuoksi onkin mielenkiintoista tutkia koneoppimisen mahdollisuuksia kuvien tarkastelun tukena, jotta kuvien tulkitseminen voisi olla tasalaatuisempaa ja tarkempaa hammaslääkäristä riippumatta.

Toinen yleinen suun terveydenhuollossa hyödynnettävä röntgenkuva on ortopantomografia eli OPG-kuva. Estainin ym. (2022) mukaan OPG-kuvalla tarkoitetaan koko leuan ja hampaiston röntgenkuvausta, josta hammaslääkäri voi esimerkiksi arvioida hampaiston ja purennan kehityksen vaiheita. Lisäksi kuvaa voidaan käyttää apuna diagnoosien ja hoitosuunnitelmien laatimisessa. Myös näiden OPG-kuvien tulkitsemisessa haasteina ovat kohina, kuvan kaksiulotteisuus, kontrastierot sekä viereisten hampaiden heijasteet ja varjot, aivan kuten pienemmässä bitewing-kuvauksessa (Estain ym., 2022). Toisin sanoen OPG-kuva kattaa koko leuan ja hampaiston kuvantamisen yhdessä kuvassa ja siten se antaa laajemman kuvan koko hampaiston tilanteesta. Puolestaan bitewing-kuva on



hampaiston alueellinen pieni röntgenkuva, josta näkee kuvatun alueen hampaiden rakenteen lähempää ja tarkemmin, kuin OPG-kuvassa.

Eräs koneoppimisen mahdollisuuksista on kariksen havaitseminen röntgenkuvista. Tätä väitettä tukee Leen ym. (2021) tutkimus, jonka mukaan syväoppimista voidaan hyödyntää erityisesti initiaaliekariksen havaitsemisessa bitewing-kuvista. Heidän tutkimuksessaan kehitettiin U-Net konvoluutioverkkoihin perustuva yhdistetty malli, jonka tarkoituksena on tunnistaa hampaiden eri osia sekä kariksen eri asteita bitewing-kuvista. Yhdistetty malli toteutettiin yhdistämällä kaksi eri mallia U-Netistä: U-CS-mallia hyödynnettiin kariksen asteen määrittelyyn ja U-SS-mallia puolestaan hampaiden rakenteiden osittamiseen. Yhdistetyn mallin luoman segmentoinnin perusteella verkko tekee todennäköisyyskartan kariekselle, jonka avulla yhdistetty malli laskee karieksille pikseliarvon. Jos pikseliarvo on yli 0,55, kohta luokitellaan kariekseksi. Tulosteena yhdistetty malli luo kuvan, jossa on väritetty eri väreillä hampaiden eri rakenneosat, sekä merkitty havaitut kariekset. Lisäksi tutkimuksessa tutkittiin, tukeeko yhdistetyn mallin käyttäminen hammaslääkärinä kariesdiagnoosin tekemisessä. Tutkimustulosten mukaan hammaslääkärit havaitsivat initiaaliekariokset herkemmin, kun apuna oli tutkimuksen yhdistetyn mallin tuottama kuva, johon on merkitty karieskohdat ja hampaiden rakenteet (Lee ym., 2021). Yhdistetyn mallin luomasta kuvasta voidaan siis nähdä paljaalla silmällä, kuinka pitkälle karies on hampaassa edennyt. Mallin luomaan kuvaan tukeutuen hammaslääkäri voisi yhdessä kliinisen tutkimuksen ja oman tulkinnan kanssa tehdä hoitosuunnitelman potilaalle kariksen hoitoa varten

Leen ym. (2021) tutkimuksen opetusprosessissa hammaslääkärit kävivät ensin kaikki kuvat läpi piirtämällä manuaalisesti kuviin hampaiden eri rakenteiden rajat sekä merkitsemällä kariekset. Näin siis syntyi perustotuuskuvat. Seuraavaksi Leen ym. (2021) opetusprosessissa kariesta tunnistavalle mallille annettiin syötteenä alkuperäiset bitewing-kuvat sekä tutkijoiden luomat binäärimaskit, jotka kertoivat missä kohdissa kuvaa on kariesta. Lisäksi kyseiselle mallille luotiin rangaistus, jos se havaitsi kariksen kariesvapaasta kuvasta. Puolestaan hampaan osia segmentoivalle mallille annettiin oppimista varten pelkät alkuperäiset bitewing-kuvat. (Lee ym., 2021). Tämän asetetun rangaistuselementin läsnäolo sopisi Mohammedin ym. (2016) määritelmään vahvistusoppimisesta, missä luonnehditaan, että vahvistusoppimisessa agentti muuttaa toimintaansa ympäristöstään saadun palautteen perusteella. Samaan aikaan Mohammed ym. (2016) mainitsevat myös, että vahvistusoppimisessa malli ei käytä syöte-tuloste-pareja, minkä vuoksi Leen ym. (2021) yhdistetyn mallin oppimistyyli ei kuitenkaan sovi vahvistusoppimisen alle. Mutta koska Leen ym. (2021) tutkimuksessa kerrotaan, että kariksen tunnistamismallille annettiin alkuperäinen kuva sekä binäärimaski, jonka voidaan ajatella olevan tässä tapauksessa perustotuuskuva, voidaan kyseessä nähdä olevan ohjattu oppimistyyli. Toisaalta Leen ym. (2021) tutkimuksen segmentointimallille annettiin tutkimuksen mukaan vain alkuperäiset bitewing-kuvat, minkä perusteella tämän mallin opettamiseen voidaan puolestaan nähdä käytetyn ohjaamatonta oppimista. Täten yhdistetyn mallin opettamisessa

voidaan nähdä olevan hyödynnetty ohjaamattoman ja ohjatun oppimisen yhdistelevää oppimistyyliä.

Myös Cantu ym. (2020) ovat tutkineet kariksen havaitsemismallia ja myös heidän tutkimuksessaan on havaittu, että konvoluutioverkkoja hyödyntävä malli kykenee havaitsemaan erityisesti initiaalirikaroksen paremmin bitewing-kuvasta, kuin hammaslääkäri. Täten heidän tutkimustulosten voidaan nähdä tukevan Leen ym. (2021) tutkimuksen tuloksia. Lisäksi myös Cantun ym. (2020) tutkimuksessa on käytetty U-Nettiin perustuvaa konvoluutioverkkomallia. Ibtehan ja Rahmanin (2020) mukaan U-Net saa nimensä sen symmetrisestä u:n muotoisesta arkkitehtuurista: siinä eri kerrokset ovat järjestetty u:n muotoiseen linjaan kerrosten välisten yhteyksien avulla (engl. skip connections). Koodaajapuoli (engl. encoder), eli vasen puoli konvoluutioverkosta ottaa vastaan syötteen, joka on tässä tapauksessa bitewing-kuva, ja tiivistää sen. Tämän seurauksena kontekstietä lisääntyy, kun taas tieto kohteiden tarkasta sijainnista vähenee. Seuraavaksi verkon oikea puoli, dekodeaja (engl. decoder), laajentaa tätä kontekstietä ja se yhdistetään sijaintitietoihin kerrosten välisten yhteyksien avulla (Ibtehan & Rahman, 2020). Näin U-Nettiin perustuva konvoluutioverkko oppii muodostamaan binäärimaskin, jonka avulla se ilmaisee, missä kohdissa bitewing-kuvassa on kariesta ja missä ei.

Vaikka Cantun ym. (2020) sekä Leen ym. (2021) tutkimuksissa hyödynnettiin U-Netistä muokattuja malleja, on konvoluutioverkon oppimistyyllissä nähtävissä eroja. Cantun ym. (2020) tutkimuksessa mallille annettiin luokiteltuja perustotuuskuvia oppimista varten, kun taas Leen ym. (2021) tutkimuksessa annettiin alkuperäisiä bitewing-kuvia sekä karioksen sisältäviä binäärimaskeja. Cantun ym. (2020) tutkimuksen opetusprosessissa hammaslääkärit kävivät kaikki bitewing-kuvat läpi manuaalisesti mallin opettamista varten. Ensin yksi hammaslääkäri segmentoi bitewing-kuvasta jokaisen hampaan erikseen, minkä jälkeen toinen hammaslääkäri vahvisti hampaiden luokittelut oikeiksi. Seuraavaksi hammaslääkärit merkitsivät itsenäisesti kaikkiin kuviin pikseli kerrallaan merkintätyökalulla, sisältääkö kyseinen pikseli kariesta vai ei. Tämän jälkeen yksi hammaslääkäri tarkasti merkinnät ja teki tarvittaessa niihin muutoksia (Cantu ym., 2020). Näin tutkimuksessa siis luotiin perustotuuskuvat. Kuvaukseen perustuen voidaan todeta, että koska opettamisessa on käytetty ihmisen luokittelemia kuvia, jotka ovat olleet perustotuuskuvia, on kyseessä ohjattu oppimistyyli. Suuren luokiteltavan kuvamäärän vuoksi ihmisen osuus neuroverkon opettamisessa on ollut melko suuri, mutta tuloksista päätellen se on ollut kannattavaa, koska Cantun ym. (2020) tulosten mukaan malli ennusti karioksen sijainnin jopa paremmin kuin hammaslääkärit.

Myös Lianin, Zhun, Zhun ja Zhun (2021) tutkimus tukee Cantun ym. (2020) sekä Leen ym. (2021) tutkimusten tuloksia, sillä myös heidän tutkimuksessansa kehitetty yhdistetty konvoluutioverkkomalli tunnisti initiaalirikarokset paremmin, kuin vertailun kohteena olevat hammaslääkärit. Toisaalta isoin ero aiemmin esitettyihin tutkimuksiin on se, että Lianin ym. (2021) tutkimuksessa käytettiin OPG-kuvia bitewing-kuvien sijaan sekä käytetyt mallit olivat hieman erilaisia. Tutkimuksen yhdistetty malli koostui kahdesta eri mallista. Tutkimuksessa

käytettiin kariuksen tunnistamiseen ja segmentoimiseen nnU-Net-mallia, kun taas kariuksen syvyyden määrittämiseen käytettiin DenseNet121 -mallia (Lian ym., 2021). NnU-Net on U-Netin kehittyneempi versio, joka tarjoaa paremman suorituskyvyn ja automatisoidun segmentointimenetelmän (Isensee, Jaeger, Kohl, Petersen & Maier-Hein, 2021). Myös Lianin ym. (2021) kehittämän mallin toinen osa, DenseNet121, hyödyntää konvoluutioverkkoja. Kahdesta erillisestä mallista yhdistetty malli antaa tulosteena OPG-kuvan, jossa karies on väritetty sen syvyysasteen mukaan ja jokaiselle kariuksen asteelle on määritelty omat värit. (Lian ym., 2021).

Jo ennen varsinaisen opetusprosessin aloittamista Lian ym. (2021) käyttivät OPG-kuviin automaattista hampaiden segmentointimallia, eli nnU-Net-mallia. Segmentoinnin jälkeen hammaslääkärit kävivät kaikki OPG-kuvat ja segmentoidut kuvat läpi itsenäisesti ja merkitsivät kuviin merkintätyökalulla kariuksen neljään eri luokkaan sen syvyyden mukaan. Näistä kuviin merkityistä alueista muodostettiin lopulta perustotuuuskuvat, joihin tutkitun yhdistetyn mallin tuloksia verrattiin. Itse varsinaista oppimista varten yhdistetylle mallille annettiin OPG-kuvat sekä perustotuuuskuvat, joihin asiantuntijat olivat merkinneet kariensalveita (Lian ym., 2021). Tästä voidaan päätellä, että kuten aiemmissakin esiteltyissä kariuksen havaitsemiseen liittyvissä tutkimuksissa, myös tässä on käytetty ohjattua oppimistyyliä. Tämä voidaan perustella sillä, että yhdistetylle mallille annettiin oppimista varten alkuperäiset kuvat sekä perustotuuuskuvat, joissa näkyi toivotut tulokset. Näiden kahden annetun syötteen avulla tutkitun yhdistetyn konvoluutiomallin tuli päätellä opetusprosessissa OPG-kuvista piirteet, jotka ilmaisevat kariesta. Toisaalta tässäkin tutkimuksessa ei kerrota kuka on toiminut valvojana ja onko sellaista ollut, minkä vuoksi ohjattu oppimistyyli on tässäkin tapauksessa päätelty tutkimuksessa kerrotuista tiedoista.

Kun tarkastellaan yleisesti ihmisen roolia kariuksen havaitsemismallien opettamisessa edellä esiteltyjen tutkimuksien pohjalta, voidaan huomata, että useimmiten konvoluutioverkkoja opetetaan ohjatulla oppimistyyllillä. Samasta oppimistyylistä huolimatta ihmisen tehtävät vaihtelivat opetuksessa tutkimuksittain. Osassa tutkimuksia ihminen segmentoi hampaat röntgenkuvista käsin piirtämällä tai ohjelmistoa hyödyntäen, kun taas esimerkiksi Lianin ym. (2021) tutkimuksessa segmentoimiseen käytettiin konvoluutiomallia, jonka voidaan nähdä hyödyntäneen ohjaamatonta oppimista. Tämän automatisoidun segmentoinnin voidaan päätellä vähentävän ihmisen työmäärää huomattavasti. Lisäksi ihmisen toinen iso työtehtävä kariuksen tunnistamisen opettamisessa oli kariensalveiden merkitseminen kuviin pikselitasolla tai luomalla binäärimaski, jotta mallit pystyivät tekemään oleellisia havaintoja kuvista oikean tulosteen tuottamiseksi. Myös huomioitavaa on, että kaikissa tarkastelluissa tutkimuksissa tutkijat saivat röntgenkuvat yliopistollisilta sairaaloilta (Cantu ym., 2020; Lee ym., 2021; Lian ym., 2021), eli tutkijoiden ei siten tarvinnut ottaa itse kuvia, mutta heidän tuli valikoida ja käydä tutkimukseen soveltuvat kuvat läpi mallin opettamisprosessia varten.

Yhteenvetona edellisistä tutkimuksista voidaan todeta, että erityisesti konvoluutioverkkoihin perustuvat mallit voivat ohjata ja helpottaa hammaslääkäriin

kariuksen havaitsemista röntgenkuvista ja siten tukea hammaslääkärin diagnoosin tekemistä. Koska konvoluutiomallit onnistuivat erityisesti vielä pysäytettävissä olevan initiaalikariesten havaitsemisessa, voisi tästä mallista olla apua hammaslääkärin vastaanotolla. Tämä siksi, koska mallin avulla hammaslääkäri osaisi kiinnittää huomiota olennaisiin alueisiin, jotka muuten saattaisivat jäädä huomaamatta. Tarkemman ja aikaisemman havaitsemisen myötä potilas voitaisiin ohjata kiinnittämään huomiota ongelmakohtien hoitamiseen ja luoda yksilöllisempi ja sopivampi hoitosuunnitelma jo aiemmassa vaiheessa. Näin voitaisiin estää hampaan kariuksen eteneminen ja mahdollisen tulevaisuuden paikkaushoidon tarve. Toisaalta on huomioitavaa, että vaikka tutkimustulokset ovat lupaavia, voivat mallien antamat tulokset olla myös virheellisiä, eikä hammaslääkäri siten voi luottaa niihin sokeasti. Tämän vuoksi mallien tuottamia karieshavaintoja ei tule pitää totuutena ja ainoana diagnostiikan välineenä, vaan havaintoja tulee käyttää vain suuntaa antavina ja huomiota ohjaavina opastuksina kariuksen havaitsemisessa.

### 3.3 Hampaiston määrittäminen

Kolmantena koneoppimisen mahdollisuutena on hampaiston määrittäminen. Tässä kappaleessa tarkastellaan, kuinka koneoppimista voidaan hyödyntää hampaiston kokonaisuuden määrittämisessä sekä havainnoidaan pintapuolisesti, millaisia koneoppimisen malleja tähän tehtävään on tutkittu. Tämän lisäksi pohditaan, millaisia oppimistyyplejä mallien opettamisessa on käytetty ja mikä on ihmisen rooli opetusprosessissa.

Esimerkiksi Tuzoff ym. (2019) käyttävät tutkimuksessaan kahdesta eri konvoluutioverkkoihin perustuvasta mallista koostuvaa yhdistettyä mallia hampaiden tunnistamiseen ja numeroimiseen OPG-kuvasta. Ensimmäisen mallin, Faster R-CNN:n tarkoituksena on tunnistaa jokaisen hampaan rajat ja sen jälkeen rajata kuvasta kaikki yksittäiset hampaat näiden rajojen perusteella (Tuzoff ym., 2019). Eli toisin sanoen ensimmäisen mallin tehtävä on segmentoida hampaat OPG-kuvasta. Seuraavaksi Tuzoffin ym. (2019) tutkimuksessa toisen mallin, VGG-16, tehtävänä on numeroida jokainen rajattu alue, eli hammas oikein. Tutkimuksen tulokset osoittavat, että yhdistetty malli suoriutui kohtuullisen hyvin hampaiden tunnistamisessa ja numeroimisessa, mutta se teki kuitenkin hieman enemmän virheitä hampaiden numeroimisessa, kuin asiantuntijat. Lisäksi tutkimuksesta selviää, että sekä yhdistetty malli, että asiantuntijat tekivät virhearvioita samantilaisissa tilanteissa, kuten jäännösjuurien, päällekkäisten hampaiden ja isosti karioituneiden hampaiden kohdalla (Tuzoff ym., 2019). Tutkimuksessa siis luotiin kahta eri konvoluutioverkkomallia yhdistelevä malli, jonka tarkoitus on segmentoida ja luokitella jokainen hammas antaen sille sen oikea hammasnumero.

Tuzoffin ym. (2019) tutkimuksen opetusprosessissa hammaslääkärit piirsivät manuaalisesti OPG-kuvien hampaiden ympärille laatikot ja numeroivat hampaat luoden siten perustotuuskuvat. Lisäksi opetusvaiheessa molemmille konvoluutiomalleille käytettiin hyödyksi esiopetettuja painotuksia.

Segmentointimallille annettiin vain alkuperäiset OPG-kuvat, kun taas hampaiden numerointimallille annettiin hammaslääkärien rajaamien hampaiden kuvat sekä kuvia, jotka sisälsivät myös naapurihampaiden rakenteita (Tuzoff ym., 2019). Näiden edellä mainittujen kuvien ei kuitenkaan katsota olevan perustotuuskuvia, sillä ne eivät sisältäneet tietoa hampaan oikeasta numerosta. Tutkimuksen lopussa yhdistetyn mallin tuottamia tulosteita verrattiin hammaslääkärien luomiin perustotuuskuviin yhdistetyn mallin suoriutumisen arvioimiseksi (Tuzoff ym., 2019). Tähän opetusprosessin kuvaukseen perustuen voidaan päätellä, että kyseessä on ohjaamaton oppimistyyli. Malleille annettiin vain alkuperäisiä ja eri tavoin rajattuja kuvia, joissa ei ollut luokitteluja. Siten yhdistetyn mallin piti itse esiopetettujen painotusten ja tekemiensä havaintojen avulla päätellä, mihin luokkaan mikäkin osa kuvasta kuului.

Myös Estainin ym. (2022) tutkimuksessa kehitettiin konvoluutioverkkoihin perustuva automatisoitu havaitsemismalli, joka osaa havaita OPG-kuvasta pysyvät hampaat ja luokitella ne. Tutkimuksessa käytettiin kolmeosaista menettelyä, joka yhdisti kolmea erilaista jo olemassa olevaa konvoluutiomallia peräkkäin (Estain ym., 2022). Kuten Tuzoffin ym. (2019) tutkimuksessa, myös Estainin ym. (2022) tutkimuksessa käytettiin hampaiden segmentoimiseen Faster R-CNN-mallia ja hampaan numeroimiseen VGG-16-mallia, mutta lisäksi Estainin ym. (2022) tutkimuksessa oli U-Net-malli, jota käytettiin aivan ensimmäisenä mallina hampaiston alueen havaitsemiseen. Estainin ym. (2022) mukaan U-Net-mallin tehtävänä oli tunnistaa OPG-kuvasta hampaiston alueen sijainti ja rajata se, jotta kuvasta tulisi pienempi. Tämä mallin rajaama alue siirrettiin seuraavaksi eteenpäin kahdelle seuraavalle mallille käsiteltäväksi (Estain ym., 2022), aivan kuten Tuzoffin ym. (2019) tutkimuksessa. Estainin ym. (2022) tutkimustuloksista voidaan huomata, että käyttämällä kolmea syvääoppimisen mallia hampaiden tunnistamisessa ja numeroimisessa, on yhdistetyn mallin suoriutuminen samalla tasolla, kuin hammaslääkäriin.

Estainin ym. (2022) tutkimuksen opetusprosessin alussa hammaslääkärit ensin segmentoivat hampaat sekä luokittelivat ne hyödyntäen merkintäalustaa. Tämän jälkeen ulkopuolinen hammaslääkäri tarkisti kuvat, joiden merkinnöissä oli eroavaisuuksia ja antoi siten lopullisen luokituksen hampaille. Hampaiston alueen havaitsemismallille syötettiin opetusta varten alkuperäinen OPG-kuva sekä binäärimaski hampaiston alueen tunnistamiseksi. Lisäksi opetusta varten hampaan tunnistamis- ja numerointimalleilla hyödynnettiin esiopetettuja painotuksia. Hampaan tunnistusmallille annettiin yksittäisiä hampaita esittäviä kuvia, kun taas hampaan numerointimallille annettiin hammaslääkäreiden rajaamat ja numeroidut kuvat, eli perustotuuskuvat (Estain ym., 2022). Täten voidaan päätellä, että tässä opetusprosessissa hyödynnettiin ohjattua oppimista, vaikka tutkimuksessa käytettiinkin osittain samoja malleja, kuin Tuzoffin ym. (2019) tutkimuksessa. Oppimistyyli voidaan nähdä ohjatuksi, koska jokaisen eri mallin kohdalla opetusvaiheessa malleille annettiin alkuperäinen kuva ja kyseisen mallin oikea tuloste, eli perustotuuskuva. Myös tässä tapauksessa mallille annettu binäärimaski on päätelty ja luokiteltu perustotuuskuvaksi.

Tuzoffin ym. (2019) ja Estainin ym. (2022) tuloksia vertailemalla voidaan havaita, että hampaiden tunnistamisen tarkkuus käyttämällä lisänä U-Net-mallia oli parempaa, kuin ilman. Tästä voidaankin päätellä, että käyttämällä useampaa mallia OPG-kuvan automatisoidussa analysoimisessa, saadaan korkeampi tarkkuus hampaan tunnistamiseen, kuin käyttämällä vain yhtä mallia. Tämä voi selittyä sillä, että U-Net pienensi alkuperäisen OPG-kuvan noin kolmannesosaan alkuperäisestä (Estai ym., 2022), jolloin Faster R-CNN-malli sai tutkittavakseen tarkemman kuvan, kuin Tuzoffin ym. (2019) tutkimuksessa, ja sitä kautta kolmosaisen mallin tulkinta voi olla tarkempi. Toisalta Estainin ym. (2022) tutkimuksessa otanta oli alle 600, kun Tuzoffin ym. (2019) tutkimuksessa otanta oli yli 1500 OPG-kuvaa, mikä voi vaikuttaa tulosten eroavaisuuksiin. Lisäksi voidaan pohtia, vaikuttiko valittu opetustyyli myös tuloksiin, sillä Estain ym. (2022) käyttivät ohjattua oppimistyyliä, ja tutkimuksen tulokset olivat paremmat, kuin Tuzoffilla ym. (2019), jotka hyödynsivät ohjaamatonta oppimistyyliä mallin opettamisessa.

Tutkimuksia tarkastelemalla voidaankin todeta, että konvoluutioverkkoihin pohjautuvilla malleilla voidaan segmentoida ja luokitella hampaita OPG-kuvista. Lisäksi voidaan tehdä huomio, että vaikka kaksi eri tutkimusta käyttävät osittain samoihin tekniikoihin perustuvia malleja, voidaan niitä kuitenkin opettaa eri tavoin. Tuzoffin ym. (2019) tutkimuksen opetusvaiheessa yhdistetylle mallille syötetään OPG-kuva ilman luokittelua tai muita merkintöjä, ja siten kyseessä voidaan nähdä olevan ohjaamaton oppimistyyli. Estainin ym. (2022) tutkimuksessa voidaan puolestaan nähdä käytetyn ohjattua oppimistyyliä, sillä jokaiselle mallille annettiin opetuksessa alkuperäinen kuva sekä perustotuuskuva, joka kyseisen mallin osion tulisi tuottaa. Toisena erona Tuzoffin ym. (2019) ja Estainin ym. (2022) tutkimusten välillä voidaan nähdä olevan perustotuuskuvien segmentointityyli. Estainin ym. (2022) tutkimuksessa hampaiden rajaukseen hyödynnettiin merkintäalustaa, jota käyttäen hammaslääkärit rajasivat hampaat ja numeroivat ne, kun taas Tuzoffin ym. (2019) tutkimuksessa rajausta tehtiin manuaalisesti ja hampaiden numerot laitettiin erilliseen Excel-taulukkoon. Näistä eroista oppimistyyleissä voidaan päätellä, että Estainin ym. (2022) tutkimuksessa ihmisen rooli on huomattavasti suurempi, koska tutkimuksen yhdistetty malli on opetettu hyödyntäen ohjattua oppimista, kuin Tuzoffin ym. (2019) tutkimuksessa, jossa on hyödynnetty ohjaamatonta oppimista.

Yhteenvedona tutkimusten tarkasteluista, voidaan todeta, että konvoluutioverkkoja hyödyntämällä voidaan parhaimmillaan saavuttaa jopa hammaslääkärin hampaiden havainnointi- ja numerointitaso. Tällaisilla havaitsemisjärjestelmillä voisi mahdollisesti tulevaisuudessa nopeuttaa hammaslääkärin työn kulkua, sillä sen avulla hammaslääkärin ei tarvitsisi käyttää yhtä paljoa aikaa OPG-kuvien tulkitsemiseen sekä hampaiden tunnistamiseen ja numeroimiseen. Näin aikaa vapautuisi enemmän kliiniseen potilastyöhön. Toisaalta on huomioitavaa, että molemmissa tutkimuksissa on käytetty aikuisten OPG-kuvia, joissa on vain luonnollisia juuria omaavia hampaita, mikä voi rajoittaa tulosten yleistettävyyttä.

## 4 KONEOPPIMISEN HAASTEET SUUN TERVEYDENHUOLLOSSA

Tässä luvussa vastataan toiseen tutkimuskysymykseen, joka tutkii millaisia koneoppimisen kehittämiseen ja käyttöönottoon liittyviä haasteita suun terveydenhuollon kontekstissa on. Ensin tarkastellaan, mikä on GDPR-asetus ja millaisia vaatimuksia se asettaa henkilötietojen käsittelylle ja siten myös koneoppimisen mallien kehittämiseksi. Lisäksi käsitellään hieman erästä ratkaisua, yhdistettyä oppimista, jota on kehitelty ratkaisemaan näitä ongelmia. Seuraavaksi siirrytään tarkastelemaan mikä on mustan laatikon ongelma hammaslääketieteessä, miten sitä on yritetty ratkaista ja pohditaan, miksi tämä on iso ongelma koneoppimisen mallien kehittämisessä. Tämän jälkeen tarkastellaan millaisia tulevien hammaslääkäreiden ja potilaiden asenteet ovat tekoälyn sovelluksia kohtaan suun terveydenhuollossa. Lisäksi pohditaan, millaisia haasteita löydökset asettavat koneoppimisen mallien kehittämiseksi ja tarkastellaan keinoja, miten niitä voidaan ratkoa.

### 4.1 Lainsäädäntö ja datan yksityisyys

Koska suun terveydenhuollossa käsitellään arkaluontoisia potilastietoja, ohjaa sen toimintaa useat eri lait, asetukset ja ohjeistukset ja siten ne on otettava huomioon myös terveydenhuollon koneoppimisen mallien kehittämisessä. Valviran (ei pvm.) mukaan henkilötiedoiksi nähdään kaikki tiedot, joista henkilö on tunnistettavissa suoraan tai välillisesti ja siten myös potilastiedot luokitellaan henkilötiedoiksi (Valvira, ei pvm.). Tällaisia henkilötietoja on siten esimerkiksi henkilötunnus, puhelinnumero ja potilastiedot. Henkilötietojen käsittelyksi lasetaan kaikki toimet, joissa käsitellään henkilötietoja (Valvira, ei pvm.), kuten asiakkaan potilaan osoitteen tarkistaminen tai virheellisen potilaskirjauksen poistaminen järjestelmästä. Tämän vuoksi tietoja on käsiteltävä luottamuksellisesti, asianmukaisesti ja lainmukaisesti (Valvira, ei pvm.) Suomessa sosiaali- ja terveysministeriön (2024) mukaan, potilaan tietojen käsittelyä ohjaavia lakeja ovat

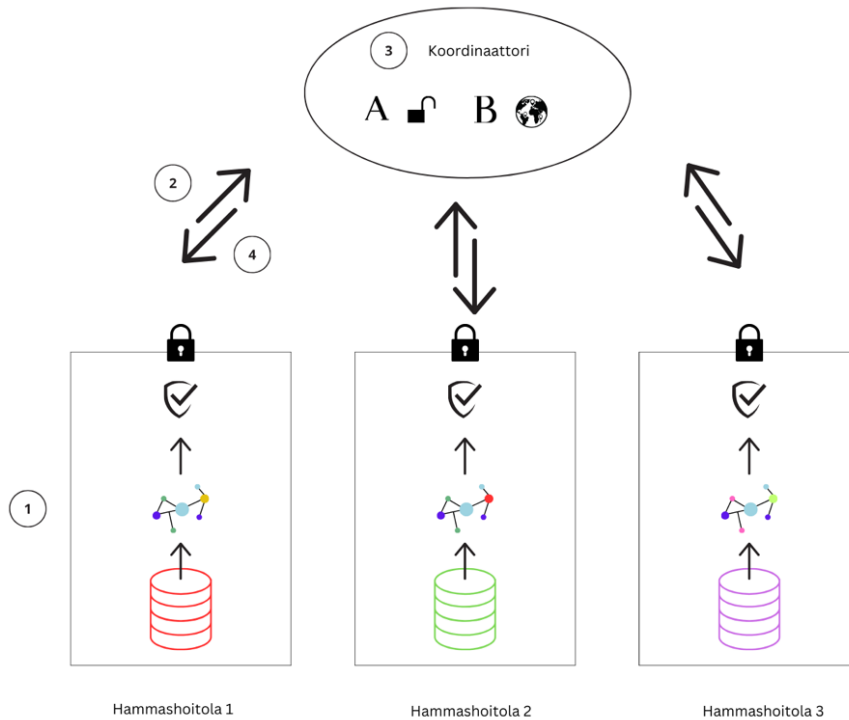
esimerkiksi EU:n yleinen tietosuoja-asetus, tietosuojalaki sekä laki sosiaali- ja terveydenhuollon asiakastietojen käsittelystä. Näistä kaksi jälkimmäistä lakia ovat kansallisia lakeja, joiden käsittely on rajattu ulos tästä kandidaatintutkielmasta, jotta tutkielman laajuus ei paisuisi liian suureksi. Tässä tutkielmassa keskitytäänkin siten pohtimaan erityisesti EU:n yleisen tietosuoja-asetuksen tuomia haasteita.

Euroopan parlamentin ja neuvoston asetuksen (EU) 2016/679 (2016) mukaan EU:n yleisellä tietosuoja-asetuksella, eli GDPR-asetuksella, tarkoitetaan jokaista EU:n maata ja sen alueella toimivia yrityksiä koskevaa lakia, joka sääntelee henkilötietojen käsittelyä. Tämän toukokuussa 2018 voimaan astuneen lain tarkoituksena on parantaa yksilöiden henkilötietojen hallittavuutta sekä yhdenmukaistaa säädäntöä EU-maissa. Asetuksen yksilöihin kohdistuvia parannuksia ovat esimerkiksi yksilön oikeudet päästä omiin tietoihin, siirtää tietoja toiseen järjestelmään sekä saada tietoa henkilön tietoihin kohdistuneista tietoturvaloukkauksista. Yksityishenkilöiden lisäksi asetus sisältää sääntöjä yrityksille, jotka käsittelevät henkilötietoja. Nämä säännöt liittyvät esimerkiksi henkilötietojen pseudonysoimiseen ja salaukseen sekä EU:n ulkopuolisiin yrityksiin, joilla on liiketoimintaa EU:ssa (Euroopan parlamentin ja neuvoston asetus (EU) 2016/679, 2016). GDPR-asetuksen tehtävänä on siis turvata yksilön henkilötietojen käyttöä EU:n alueella sekä korostaa yritysten vastuuta asiakkaiden henkilötietojen käytössä. Täten myös terveydenhuollon laitosten ja tutkijoiden tulee ottaa asetus huomioon, kun toimitaan EU:n alueella. Koska asetus voi olla tiukentanut henkilötietojen käyttöä, voivat tiukennukset aiheuttaa haasteita esimerkiksi terveydenhuollon koneoppimista hyödyntävien mallien kehittämiseksi. Tämä voi ilmetä esimerkiksi mallin harjoitusdatan, eli henkilötietojen, keräämisen ja käyttämisen vaikeuksina. Mallille tarjottavan tiedon tulee olla anonymisoitua sekä tietojen hyödyntämiseen tarvitaan lupa potilaalta. Lisäksi asetukseen vedoten, potilaalle tulee kertoa mihin tarkoitukseen ja miten luovutettua tietoa käytetään. Tämä prosessi voi siten hidastaa ja rajoittaa koneoppimismallien kehittämistä.

Yangin, Liun, Chen ja Tongin (2019) mukaan toinen GDPR-asetuksen haittapuoli koneoppimisen kehittämisen kannalta on se, että yritysten ja laitosten keräämä data jää vain paikalliseen käyttöön, eikä sitä voida kerätä yhteen analysointia varten. Tähän ongelmaan Yangin ym. (2019) artikkelin mukaan Google on ehdottanut yhtenä mahdollisena ratkaisuna menetelmää nimeltä yhdistetty oppiminen (engl. federated learning), joka tarkoittaa kouluttamista etäaineistoilla. Eli sen sijaan, että lähteet tuotaisiin keskitetysti yhteen paikkaan koneoppimismallin opettamista varten, opetetaankin konetta etänä (Yang ym., 2019). Tämän yhdistetyn oppimisen toimintaprosessia on havainnollistettu kuviossa kaksi (ks. kuvio 2). Eli esimerkiksi luotaessa karieksen havaitsemismallia, voitaisiin ensin hammashoitolassa yksi opettaa koneoppimisen malli kyseisen hammashoitolan paikallisen tietokannan tiedoilla. Opetuksen jälkeen opetettu paikallinen malli salataan ja se lähetetään koordinaattorille. Kaikki tutkimukseen osallistuvat hammashoitolat 1-3 toistavat myös nämä kaksi vaihetta samanaikaisesti. Kolmannessa vaiheessa koordinaattori avaa kaikkien hammashoitoloiden lähetettävien mallien salaukset ja lisää niiden tiedot globaaliin malliin. Tämän jälkeen



koordinaattori lähettää päivitetyn globaalin mallin salattuna takaisin jokaiselle hammashoitolalle. Tätä neljän vaiheen mallia toistetaan iteratiivisesti, kunnes mallin opettaminen on valmis.



KUVIO 2 Yhdistetty oppimisprosessi suun terveyden tutkimuksessa (Muokattu Brauneck ym., 2023, s. 3 mukaan)

Myös Brauneckin ym., (2023) mukaan yksityisyyttä parantavat teknologiat, kuten yhdistetty oppiminen, pyrkivät mahdollistamaan henkilötietojen lainmuokaisen käsittelyn ja analysoinnin. Heidän artikkelissaan tuodaan kuitenkin ilmi, että yhdistetty oppiminen yksinään ei riitä takaamaan GDPR-asetuksen turvallisuusvaatimuksia terveydenhuollossa. Tämän vuoksi tukena tulisi käyttää myös muita teknologioita, kuten eriytettyä yksityisyyttä (engl. differential privacy) sekä turvallista moniarvoista laskemista (engl. secure multiparty computation). Näitä teknologioita voitaisiin hyödyntää paikallisen mallin kouluttamisen jälkeen, ennen tiedon salausta (Brauneck ym., 2023). Siten tämän vaiheen voidaan nähdä sijoittuvan yhdistetyn oppimisprosessin vaiheeseen yksi (ks. kuvio 1). Tätä teknologiayhdistelmää hyödyntäen koneoppimisen malli voisi pitää paremmin käyttäjien henkilötiedot yksityisinä, ja siten mahdollisesti noudattaa GDPR-asetuksen vaatimuksia. Eriytetyllä yksityisyydellä tarkoitetaan tekniikkaa, jolla lisätään kohinaa opetusjoukkoon, mikä vaikeuttaa yksittäisten potilaiden tunnistamista (Brauneck ym., 2023). Eli toisin sanoen potilaan dataan lisätään satunnaistekijöitä tunnistamisen vaikeuttamiseksi, jotta voidaan minimoida tietovuodon riskiä. Turvallisella moniarvoisella laskemisella puolestaan tarkoitetaan teknologiaa, jonka avulla useat osapuolet pyrkivät edistämään samaa toiminnallisuutta tietäen vain oman syötteen ja tulosten potilaan yksityisyyden takaimiseksi (Yang ym., 2019).

Yksityisyyttä parantavat teknologiat siis anonymisoivat potilaiden henkilötietoja parantaen siten mallien tietoturvaa jo opetusvaiheissa, mutta myös niiden käytössä nähdään olevan haasteita. Esimerkiksi eriytetyn yksityisyyden käyttäminen voi alentaa opetettavan mallin ennusteiden luotettavuutta. Brauneckin ym. (2023) mukaan tämän voidaan nähdä johtuvan siitä, että mitä enemmän kohinaa malliin lisätään, sitä alempi mallin luotettavuus on. Toisaalta jos kohinaa lisätään vähemmän on pohdittava, onko potilastiedot enää anonyymeja ja henkilöt tunnistettavissa, jolloin malli ei täytä GDPR-asetuksen vaatimuksia (Brauneck ym., 2023). Tämän vuoksi koneoppimisen mallin kehittämisessä suun terveydenhuollossa on löydettävä tasapaino mallin luotettavuuden ja henkilötietojen turvaamisen välille. Mallin on oltava tarpeeksi luotettava, jotta sen ennusteisiin voidaan tukeutua hoitopäätösten tekemisessä. Toisaalta taas potilaiden henkilötietojen turvallisuus ja salaaminen on varmistettava, jotta malli täyttää lainsäädännön vaatimukset eikä potilastiedot ole alttiita tietomurroille.

Voidaan siis todeta, että GDPR-asetuksen vaatimukset on otettava huomioon EU-maissa suun terveydenhuollon koneoppimisen malleja kehitettäessä. Tämän voidaan nähdä koskevan kaikkia koneoppimisen malleja oppimistyylistä riippumatta, koska kaikki luotavat mallit käsittelevät henkilötiedoiksi luokiteltavaa tietoa. Tämän vuoksi koneoppimisen mallia suunniteltaessa sekä opetusvaiheessa on siten pohdittava erilaisia yksityisyyttä parantavia teknologioita sekä niiden soveltuvuutta kehiteltävään malliin. Lisäksi kaikilta tutkimuspotilailta on pyydettävä lupa henkilötietojen käyttämiseen sekä kertoa käyttötapa ja -kohde, eikä tietoa saa kerätä enempää, kuin on tutkimuksen kannalta tarpeellista.

## 4.2 Mustan laatikon lääketiede

Poonin ja Sungin (2021) mukaan yksi isoimmista haasteista tekoälyn implementoimisessa lääketieteeseen on mustan laatikon (engl. black box) ongelma. Heidän mukaansa tällä tarkoitetaan sitä, että hyödynnettäessä ohjaamatonta oppimistyyliä ja neuroverkkoja, ei voida tietää tarkasti mitä piilokerroksissa tapahtuu ja miksi malli tuottaa tietyn lopputuloksen (Poon & Sung, 2021). Täten ei siis voida olla varmoja, millä logiikalla malli esimerkiksi huomaa kariuksen tiettyssä hampaassa tai miksi se luokittelee jonkun hampaan tiettyyn kategoriaan. Poon ja Sung (2021) toteavatkin, että koska terveydenhuollon kultaisena standardina on ollut pitkään tutkimukseen ja tarkkaan tietoon pohjautuva päätöksenteko, voi tällaisen mustan laatikon tuottaman tiedon hyödyntäminen diagnoosin tekemisessä olla kyseenalaista. Tämän vuoksi suun terveydenhuollossa onkin pohdittava, voidaanko koneoppimisen mallien tuottamaan tietoon luottaa, koska niiden päätöksentekoprosessia ei voida todistaa kaikissa tapauksissa. Siten kyseessä voidaan nähdä olevan myös osittain eettinen ongelma.

Ratkaisuna ongelmaan Poon ja Sung (2021) ehdottavat, että koneoppimisen mallien opettaminen aloitetaan yksinkertaisista algoritmeista, kuten satunnaismetsistä, joita kehitetään hiljalleen eteenpäin. Näin malli oppisi ohjatun oppimisen avulla hyödyntämään hammaslääkärin antamaa tietoa ja tunnistamaan

olennaisia ominaisuuksia ja samalla mallin toimintalogiikkaa voitaisiin valvoa helpommin. Tämän vaiheen jälkeen Poonin ja Sungin (2021) ehdotuksen mukaan voitaisiin siirtyä käyttämään neuroverkkoja, eli mustaa laatikkoa. Kun ensin on hyödynnetty ohjattua oppimista ja siten malli on jo oppinut sen tunnistamia tärkeitä ominaisuuksia datasta, tiedetään mallin toiminnasta jo paljon ennen mustaa laatikkoa. Poonin ja Sungin (2021) mukaan mustan laatikon toiminnan selvittämiseksi voidaan hyödyntää useita eri tulkittavuustekniikoita (engl. interpretability techniques), jotka antavat erilaisia selityksiä koneoppimisen mallin käyttäytymiselle. Vaikka näin ei saadakaan tietoon täysin mustan laatikon toimintaa, voidaan kuitenkin tekniikoiden antamista tuloksista ja opetetun mallin toimintalogiikan tuntemisesta päätellä tietovajetta umpeen (Poon & Sung, 2021).

Eräs toinen haasteen muodostava näkökulma liittyen mustaan laatikkoon on Bjerringin ja Buschin (2021) mukaan se, että mallin käyttäminen riitelee potilaskeskeisen lähestymistavan kanssa. Heidän mukaansa eräs syy tälle on se, että musta laatikko ei näe potilasta uniikkina yksilönä, toisin kuin lääketieteessä opetetaan (Bjerring & Busch, 2021). Täten käyttämällä mustan laatikon omaavaa mallia päätöksenteon tukena, voidaan ajautua tilanteeseen, jossa potilaan yksilöivien piirteiden merkitys hoitopäätöksen tekemisessä unohdetaan. Esimerkiksi karieksen muodostumisriskin arvioimisessa voidaan unohtaa diagnosoimattomien sairauksien mahdollisuus ja niiden vaikutus suun terveyteen. Tällöin mahdollisesti ajaututaan tilanteeseen, jossa koneoppimisen mallin antama tulos ei olekaan pätevä. Jos tähän tulokseen luotetaan ilman arviointia, voidaan potilaalle mahdollisesti antaa vääränlaista hoitoa, millä voi olla ikävät seuraukset.

Toisena potilaskeskeisen näkökulman kanssa riitelevänä seikkana Bjerring ja Busch (2021) nostavat esille, kuinka mustan laatikon tekniikassa ei voida saavuttaa täyttä ymmärrystä ja syytä hoidon tarpeelle potilaan ja lääkärin kanssa, koska mustan laatikon toimintaa ei voida täysin selittää. Esimerkiksi kuvitellaan tilanne, jossa konvoluutioverkkoihin perustuva malli on luonut kuvan, josta se on merkinnyt karieksen hammasväliin, jota hammaslääkäri ei ole huomannut. Uudelleen tutkimalla alkuperäisen kuvan ja kliinisen suun tilanteen, hammaslääkäri ei edelleenkään huomaa kariesta. Täten hammaslääkärille muodostuu ongelma, jolloin täytyy pohtia, pitääkö hammaslääkäri mallin tulosta vai omaa tutkimusta luotettavampana. Lisäksi hammaslääkärille voi muodostua ongelma siinä, miten hän selittää tilanteen potilaalle, kun ei itsekään ymmärrä mihin perustuen malli on tuottanut ennusteen.

Edellä esiteltyihin artikkeleihin perustuen voidaan siten päätellä, että erityisesti ohjaamatonta oppimista hyödyntävien koneoppimisen mallien käytössä suun terveydenhuollossa voidaan nähdä olevan eettisiä haasteita. Poon ja Sung (2021) ovat pyrkineet ratkaisemaan ongelman käyttämällä tekniikoita, jotka hyödyntävät sekä ohjattua että ohjaamatonta oppimista, sekä erilaisia tekniikoita, joilla voidaan testata algoritmien toimintaa ja tuoda siten mustan laatikon tapahtumia näkyvämmäksi. Tämä hiljalleen opetuksen lisääminen, testaaminen ja tulosten validoiminen voidaan toteuttaa jo opetusvaiheessa ja siten mahdollisesti lisätä mallin ymmärrettävyyttä. Sen sijaan Bjerringin ja Buschin (2021) mukaan ohjaamatonta oppimista hyödyntävät tekniikat riitelevät potilaskeskeisen

lähestymistavan kanssa, mikä vähentää hoidon yksilöllisyyttä ja ymmärryksen saavuttamista. Heidän mukaansa, koska mustan laatikon toimintaa ei voida ymmärtää täysin, ei sellaista mallia voi myöskään käyttää lääketieteessä hoitopäätöksen tukena (Bjerring & Busch, 2021). Tämä mustan laatikon käyttöä koskeva eettinen kysymys onkin yksi isoimmista haasteista, joita suun terveydenhuollon tulee selvittää, jotta koneoppimisen malleja voidaan kehittää lisää ja ottaa laajemmin käyttöön vastaanotoilla.

### 4.3 Asenteet ja suhtautuminen

Tässä luvussa tarkastellaan, millaisia tulevien hammaslääkäreiden ja potilaiden asenteet ovat koneoppimisen ja tekoälyn hyödyntämistä kohtaan suun terveydenhuollossa. Lisäksi pohditaan myös, miten hammaslääkärien asenteet ja suhtautuminen vaikuttavat tekoälyn käyttöönottamiseen ja kehittämiseen. Tämän jälkeen tutkitaan vielä yleisesti potilaiden suhtautumista tekoälyn käyttämiseen vastaanotolla sekä pohditaan, mikä on potilaiden suurin huolenaihe liittyen tekoälyn käyttämiseen suun terveydenhuollossa.

Ensin tarkastellaan hammaslääketieteen opiskelijoiden asenteita ja ajatuksia tekoälyn hyödyntämisestä suun terveydenhuollossa. Bisdasin ym. (2021) kyselyssä on kerätty jokaisesta maanosasta hammas- ja yleislääketieteen opiskelijoiden ajatuksia asenteista tekoälyn käyttämisestä lääketieteessä. Kyselyn mukaan vastaajista lähes 84 prosenttia uskoo tekoälyn mullistavan lääketieteen alan ja suurin osa opiskelijoista oli myös sitä mieltä, että lääketieteen opetussuunnitelmaan tulisi sisällyttää tekoälyn opettamista. Lisäksi tutkimustuloksista voidaan huomata, että kehittyneiden maiden opiskelijat kokevat omaavansa paremman ymmärryksen ja tietämyksen tekoälyn sovellusten hyödyntämisestä, kuin kehitysmaiden opiskelijat (Bisdas ym., 2021). Tämä ero tietämyksessä kehittyneiden ja kehitysmaiden lääketieteen opiskelijoiden välillä voi johtaa tulevaisuudessa entistä suurempiin terveyseroihin. Mahdollisesti lisääntyvää tietämyseroa tukee myös se, että Bisdasin ym. (2021) tutkimuksessa kehitysmaiden opiskelijat vastasivat huomattavasti pienemmällä todennäköisyydellä, että tekoäly mullistaa lääketieteen harjoittamisen.

Myös Karan-Romeron, Salazar-Gamarran ja Leon-Riosin (2023) kyselyssä opiskelijat kokivat, että yliopistojen tulisi sisällyttää tekoälyn opettamista opetussuunnitelmaan. Lisäksi myös heidän tutkimuksessansa nousi esille hammaslääketieteen opiskelijoiden pääosin positiivinen suhtautuminen tekoälyn hyödyntämiseen työssään, mutta yllättävää kyllä, vain 45 prosenttia vastanneista opiskelijoista ei usko, että hammaslääkärit korvataan tulevaisuudessa tekoälyllä (Karan-Romero ym., 2023). Tätä tulosta tukee myös Yüzbaşıoğlun (2021) tutkimus, jossa on havaittavissa, että noin puolet hänen tutkimukseensa vastanneista hammaslääketieteen opiskelijoista on myös eri mieltä väitteen kanssa. Näiden tutkimusten vastauksista voidaan päätellä, että hammaslääketieteen opiskelijoilla voi olla pelkoa, syrjäyttääkö tekoäly heidän ammattinsa. Jos tällaista pelkoa on, se voi johtaa tekoälyn käyttöönoton haasteisiin suun terveydenhuollossa ja

siten hidastaa ja vaikeuttaa koneoppimisen mallien kehittymistä alalla. Haasteita voi tuottaa esimerkiksi pelosta johtuva koneoppimisen mallien käytön haluttomuus, jonka seurauksena mallien käyttöönotto vastaanotoilla voi hidastua. Tämän estämiseksi tekoälyn mahdollisuuksien opettaminen jo opintojen aikana voisi lisätä tietämystä, kuinka tekoälyä voidaan käyttää hammaslääkärin työkaluna, eikä ammattiryhmän syrjäyttämisen välineenä.

Toisena tarkasteltavana näkökulmana tutkitaan suun terveydenhuollon potilaiden asenteita tekoälyä kohtaan. Esimerkiksi Kosanin ym. (2022) kontrolloidussa tutkimuksessa on tutkittu potilaiden suhtautumista tekoälyn käyttämiseen kariksen diagnosoimisessa. Tutkimuksessa tutkittavat potilaat jaettiin kahteen eri ryhmään, joista toiselle esitettiin bitewing-kuva, josta konvoluutioverkkoja hyödyntävä malli oli värittänyt kariesalueen. Kontrolliryhmälle puolestaan esitettiin sama kuva, johon hammaslääkäri oli merkinnyt pelkällä nuolella kariksen sijainnin. Molempien ryhmien tutkittavilta kysyttiin heidän kykyänsä havaita karies kuvasta. Lisäksi heiltä kysyttiin useita kysymyksiä liittyen tekoälyn ja hammaslääkärin luottamukseen, arviointikykyyn, hoidon tarpeen ymmärtämiseen sekä informoiduksi tulemisen tunteeseen. Tutkimustulokset osoittavat, että potilaat näyttävät korkeaa luottamustasoa hammaslääkärin tekemiin diagnooseihin ja hoitosuunnitelmiin riippumatta siitä, käytetäänkö tekoälyä jatkohoidon päättämisessä vai ei. Lisäksi tutkimuksesta selviää, että erityisesti nuoret, korkeakoulun käyneet sekä opiskelijat havaitsivat kuvista kariksen paremmin tekoälyn avulla ja luottavat tekoölyyn enemmän, kuin esimerkiksi alhaisemman koulutuksen käyneet ja ikääntyneet ihmiset (Kosan ym., 2022). Näistä löydöksistä voidaan päätellä, että erityisesti nuoret suhtautuvat tekoälyn hyödyntämiseen vastaanotoilla positiivisemmin ja luottavaisemmin, kuin iäkkäämmät ihmiset. Tämä voi osaltaan johtua siitä, että nuoret ovat kasvaneet teknologian kehityksen keskellä ja ovat siten luottavaisempia myös tekoälyn sovelluksia kohtaan. Toisaalta Kosanin ym. (2022) tutkimusasettelussa tutkittavilla oli mukana myös ihmiskontakti, joka voi osaltaan vaikuttaa suopeampaan asennoitumiseen tekoälyä kohtaan ja siten parantaa tutkimuksen tuloksia. Lisäksi Kosanin ym. (2022) tutkimusasettelu oli kuviteltu, mikä voi myös vaikuttaa tuloksiin.

Myös Ayadin ym. (2023) Saksassa toteutetun alueellisen kyselyn tulosten mukaan potilaiden suhtautuminen tekoälyn hyödyntämiseen suun terveydenhuollossa on pääosin positiivinen. Potilaiden odottamista tekoälyn tuomista mahdollisuuksista nousi esille diagnostiikan luotettavuuden parantuminen, ajan säästyminen sekä entistä henkilökohtaisemman ja todisteisiin pohjautuvien hoitopäätösten tekeminen. Toisaalta hieman yli puolet vastaajista ovat epävarmoja, parantaisiko tekoälyn käyttäminen julkista terveydenhuoltoa. Lisäksi potilaat kokevat ongelmaksi tekoälyn hyödyntämisessä hammaslääkärin ja potilaan välisen luottamussuhteen haasteet sekä mahdollisesti kohoavat hoitokulut (Ayad ym., 2023). Näistä tuloksista voidaan päätellä, että vaikka pääosin tutkimuksen mukaan potilaat suhtautuvat positiivisesti ja luottavaisesti tekoälyn hyödyntämiseen, erityisesti diagnostiikassa, on useilla potilailla kuitenkin epäilyksiä ja epävarmuutta tekoälyä kohtaan. Pääosin epävarmuuksien voidaan nähdä kohdistuvan hammaslääkärin ja potilaan väliseen suhteeseen. Tätä väitettä tukee

myös Ayadin ym. (2023) tutkimus, jossa nousee ilmi, että yli 35 prosenttia vastanneista kokee tekoälyn erääksi haitaksi hammaslääkärin ja potilaan luottamussuhteen haasteet. Lisäksi vain noin 9 prosenttia vastanneista kokee, että tekoälyllä voidaan parantaa luottamussuhdetta (Ayad ym., 2023).

Kosanin ym. (2022) ja Ayadin ym. (2023) tutkimusten tuloksia vertailemalla, voidaan huomata, että molemmissa tutkimuksissa potilaat suhtautuvat positiivisesti tekoälyn hyödyntämiseen erityisesti hoitopäätösten tekemisessä. Toisaalta Ayadin ym. (2023) tutkimuksesta voidaan kuitenkin havaita, että monet potilaat kokevat epävarmuutta koskien potilaan ja hammaslääkärin välistä vuorovaikutusta ja luottamusta. Tätä ei havaittu Kosanin ym. (2022) tutkimuksessa, mutta koska heidän tutkimusasettelussaan potilaat pystyivät kommunikoimaan hammaslääkäreiden kanssa, voidaan tutkimuksessa nähdä olleen ihmiskontakti, toisin kuin Ayadin ym. (2023) tutkimuksessa. Tämä voi selittää, miksi luottamussuhteen muodostuminen ei noussut esille Kosanin ym. (2022) tutkimusasettelussa. Tästä voidaankin päätellä, että onnistunut tekoälyn implementoiminen suun terveydenhuollossa vaatii ihmiskontaktin ja siihen tulee kiinnittää huomiota, kun malleja otetaan vastaanotoilla käyttöön. Tämä voidaan toteuttaa esimerkiksi niin, että hammaslääkäri selittää potilaalle tekoälyn tuotoksen ja sen merkityksen, jotta potilas ymmärtää, mistä on kyse.

## 5 YHTEENVETO JA JOHTOPÄÄTÖKSET

Tämän tutkielman tavoitteena oli perehtyä koneoppimisen mahdollisuuksiin hammaslääkärin näkökulmasta kariksen ehkäisyssä, havaitsemisessa ja hampaiston määrittämisessä. Lisäksi tutkielmassa pohdittiin ihmisen roolia koneoppimisen mallien opettamisessa sekä tarkasteltiin, millaisia haasteita liittyy koneoppimismallien kehittämiseen suun terveydenhuollon kontekstissa. Tutkielma toteutettiin kuvailevana kirjallisuuskatsauksena ja löydetyt kirjallisuuden perusteella pyrittiin vastaamaan kahteen tutkimuskysymykseen:

- Millä tavoin hammaslääkäri voisi hyödyntää koneoppimista työssään kariologiassa ja hampaiston määrittämisessä?
- Mikä on ihmisen rooli koneoppimisen opettamisprosessissa, ja mitkä ovat koneoppimisen kehittämisen haasteita tällä hetkellä suun terveydenhuollossa?

Tutkielmassa käytettiin lähteinä pääasiassa kansainvälisiä vertaisarvioituja tieteellisiä artikkeleita, mutta lisäksi lähteisiin valittiin esimerkiksi aiheita käsitteleviä e-kirjoja sekä GDPR-asetus. Valittuja lähteitä etsittiin useista eri tietokannoista, kuten JYKDOK ja Scopus, sekä muista luotettavista lähteistä, kuten tieteellisen yhdistyksen sivulta ja EU:n tietosuojasetuksesta. Tutkimuksia etsittiin käyttämällä hakutermejä, kuten "machine learning", "deep learning", "caries" ja "dentistry". Hauissa eri termejä käytettiin yhdessä ja erikseen. Myös lähteiden soveltuvuutta tutkielmaan arvioitiin lukemalla niiden tiivistelmät ja otsikot ennen koko artikkelin lukemista. Erityisesti tutkimuksien valitsemisessa painotettiin viimeisen viiden vuoden aikana julkaistuja artikkeleita, jotta tieto olisi mahdollisimman uutta ja ajankohtaista.

Tutkielmassa löydetyistä mahdollisuuksista voidaan havaita, että erityisesti päättelypuihin pohjautuvat koneoppimisen mallit tarjoavat mahdollisuuden ennustaa potilaan kariksen muodostumisriskin sekä määrittää tärkeimmät riskitekijät. Täten koneoppimista hyödyntämällä voidaan mahdolliset riskitekijät havaita entistä aiemmin, minkä seurauksena potilaan omahoitotottumuksiin voidaan reagoida hammaslääkärin vastaanotolla jo varhaisemmassa vaiheessa.

Ennakoivasti toimimalla, kuten pinnoittamalla riskihampaita tai tarjoamalla harjausopetusta, voidaan siten mahdollisesti välttää tulevaisuuden korjaavan karieshoidon tarve. Lisäksi ennakoivilla toimenpiteillä voi olla alentavia vaikutuksia suun terveydenhuollon kustannuksiin tulevaisuudessa sekä hoitojonojen lyhentymiseen. Tämä johtopäätös perustuu siihen, että kun yhä useammalle potilaalle kehittyy vähemmän korjaavaa hoitoa vaativia karieksiä varhaisen havaitsemisen seurauksena, on myös hammaslääkäreiden korjaavalle hoidolle vähemmän tarvetta. Tähän perustuen potilaiden määrä vastaanotoilla voi mahdollisesti laskea pitkällä aikavälillä, ja siten koneoppimisen mallia hyödyntämällä voidaan mahdollisesti lyhentää hoitojonoja ja kuluja.

Lisäksi tutkielmassa käy ilmi, että koneoppimisen mahdollisuudet painottuvat erityisesti erilaisten kuvien tulkitsemiseen suun terveydenhuollossa. Tähän mahdollisuuteen liittyen tutkimuksista nousevat esille erilaiset konvoluutioverkkoihin pohjautuvat mallit, erityisesti yhdistetyt mallit. Malleja voidaan hyödyntää esimerkiksi plakin tunnistamiseen, initiaalirikaroksen havaitsemiseen sekä hampaiden tunnistamiseen ja numeroimiseen. Esimerkiksi malli, joka tunnistaa plakin valokuvasta voi olla hyödyllinen vastaanotolla erityisesti pelko- ja kipupotilaiden kanssa, jotka eivät halua tai kykene antaa hammaslääkärin tehdä suun tutkimusta. Tällöin koneoppimisen mallin analysoiman kuvan perusteella hammaslääkäri voi arvioida suuntaa antavan hoitosuunnitelman ja samalla auttaa potilasta totuttelemaan hammashoitoon. Lisäksi jatkokehittelemällä ideaa voitaisiin mallista hyötyä myös etävastaanotoilla, joissa potilas voisi itse ottaa ja lähettää kuvan hammaslääkärille. Kuva voitaisiin antaa mallille tulkittavaksi ja sen analysoimaan kuvaan tukeutuen hammaslääkäri voisi määrittellä omahoidon ohjauksen tarpeen ja siten edistää potilaan terveyttä.

Toisena mahdollisuutena konvoluutioverkkoja hyödyntävissä tutkimuksissa nousee esille mallit, jotka tunnistavat automaattisesti initiaalirikaroksen röntgenkuvista. Näiden mallien tuottamat havainnot rikaroksen sijainnista voivat auttaa hammaslääkärinä ohjaamaan huomiota oleellisiin kohtiin, jotka muuten voisivat jäädä huomaamatta. Näin tarkemmalla havaitsemisella hammaslääkäri voi esimerkiksi ohjata potilaan kiinnittämään omahoidossa huomiota keskeisiin kohtiin ja siten estää rikaroksen varhaista etenemistä entistä tehokkaammin.

Kolmas konvoluutioverkkoja hyödyntävä mahdollisuus on hampaiston segmentoivat ja hampaita luokittelevat mallit, joiden avulla voidaan määrittellä suussa oleva hampaisto. Tällaisten mallien avulla voidaan mahdollisesti nopeuttaa hammaslääkärin työnkulkua. Tämä perustuu siihen, että mallien automaattisen hampaiden luokittelun myötä OPG-kuvien tulkitsemiseen kuluu entistä vähemmän aikaa. Näin koneoppimisen mallia hyödyntämällä hammaslääkäriltä voi vapautua lisää aikaa kliiniseen työhön. Lisäksi mallit voivat tarjota tukea päätöksentekoon tilanteissa, joissa hammaslääkäri ei ole varma hampaan luokittelusta. Tällöin hammaslääkäri voi verrata mallin luomia luokitteluja omiin päätelmiinsä ja siten saada tukea päätöksentekoon.

Vaikka tutkimusten tulokset koneoppimisen mahdollisuuksista ovat lupaavia, on tutkimuksissa nähtävissä myös rajoituksia. Useiden tutkimusten tutkimusotannot ovat suppeita ja tarkkaan valikoituja, minkä voidaan nähdä



rajoittavan tulosten yleistettävyyttä. Lisäksi tutkimustulosten vertailu on haastavaa, sillä useat tutkimukset ovat luoneet oman mallin, jota kyseisessä tutkimuksessa on testattu. Vertailua vaikeuttaa myös tutkimusten erilaiset mittarit mallien suoriutumisen arvioimisessa. Näihin rajoituksiin perustuen tutkielmassa ehdotetaan jatkotutkimuksia suuremmilla otantajoukoilla sekä toisteisia tutkimuksia, jotta mallien suoriutumista ja luotettavuutta voitaisiin arvioida entistä luotettavammin. Lisäksi tulosten luotettavamman vertailun kohentamiseksi alalle olisi tärkeää luoda yhteiset mittarit ja standardit.

Mahdollisuuksien lisäksi tutkielmassa on pohdittu esiteltyjen tutkimusten pohjalta ihmisen roolia koneoppimisen mallien opettamisessa. Tutkimuksista voidaan päätellä, että eniten mallien opettamisessa on hyödynnetty ohjattua oppimistyyliä, mutta myös muita oppimistyyliä on havaittavissa. Esimerkiksi päättelypuita käytettäessä on päätelty kyseessä olevan ohjattu oppimistyyli, jolloin ihminen antaa opetusvaiheessa mallille perustotuuden, eli karieksen esiintyvyyden, sekä alkuperäiset arvot, eli mahdolliset riskitekijät, jotta malli oppii tekemään havaintoja. Konvoluutioverkkomalleja koulutettaessa puolestaan voidaan nähdä, että tutkimuksissa on käytetty ohjaamatonta, puoli-ohjattua tai ohjattua oppimistyyliä. Tyylin voidaan nähdä olevan riippuvainen tutkimuksessa käytetystä teknologiasta. Täten voidaan päätellä, että ihmisen rooli mallien opettamisessa vaihtelee suuresti pelkästä opetuskuvien valitsemisesta ja syöttämisestä aina perustotuuskuvien manuaaliseen piirtämiseen ja hampaiden tai plakin merkitsemiseen. Näistä päätelmistä voidaan todeta, että ihmisen roolille koneoppimisen mallien opettamisessa ei voida nähdä olevan vain yhtä määritelmää, vaan ihmisen tehtävät ja niiden laajuus vaihtelevat riippuen valitusta mallista sekä opetustyylistä.

Koneoppimisen kehittämisen haasteista puolestaan tutkimuksissa nousee esille erityisesti GDPR-asetuksen tuomat korkeat vaatimukset henkilötietojen käsittelylle, ja siten asetuksen luomat kriteerit mallien tietoturvasolulle. Tähän haasteeseen on esitetty useita ratkaisuja, kuten yhdistettyä oppimista, eriytettyä yksinäisyyttä ja turvallista moniarvoista laskemista. Koska näiden tekniikoiden käyttäminen voi kuitenkin alentaa mallin luotettavuutta, tulee tämä rajoite siten ottaa huomioon jo mallia kehitettäessä ja opettaessa. Täten turvallisuuden ja luotettavuuden välisen tasapainon sekä mahdollisten uusien tekniikoiden löytämiseksi tulevaisuudessa tarvitaan lisää tutkimusta mallien turvallisuuteen liittyen. Lisäksi voidaan havaita, että tarkastelluissa koneoppimisen mallien mahdollisuuksia käsittelevissä tutkimuksissa ei ole tuotu ilmi henkilötietojen käsittelyyn liittyviä toimenpiteitä. Tämä voi johtua esimerkiksi siitä, että niitä ei ole koettu tarpeelliseksi kertoa artikkeleissa, mutta niiden mainitsemattomuus saa pohtimaan, onko toimenpiteitä toteutettu lainkaan.

Toinen esille nouseva haaste mallien kehittämisessä koskee mustan laatikon ongelmaa ja sen eettisiä haasteita liittyen mallin toiminnan ymmärtämättömyyteen ja potilaan yksilöllisyyden hävittämiseen. Näiden haasteiden voidaan nähdä koskevan erityisesti ohjaamatonta oppimista hyödyntäviä malleja, koska tällöin ei voida olla varmoja, miksi malli tuottaa tietyn vastauksen. Tähän ratkaisuna on ehdotettu esimerkiksi tulkittavuustekniikoita ja asteittaista opettamista,

eli puoliohjattua oppimista. Puoliohjatun oppimisen ja tulkittavuustekniikoiden avulla voidaan saada tietoon ainakin osittain, miksi kone tuottaa tietyn tuloksen ja siten hieman ratkoa mustaan laatikkoon liittyviä ongelmia. Aihetta ei kuitenkaan ole tutkittu laajasti, minkä vuoksi tämän tekniikan voidaan nähdä olevan vielä kyseenalainen suun terveydenhuollon kontekstissa. Tämän vuoksi jatkotutkimus aiheesta on tarpeellista, jotta tekniikan toimivuudesta voidaan saada lisää luotettavaa tietoa ja siten mahdollisesti soveltaa sitä käytäntöön.

Kolmantena haasteena ammattilaisten näkökulmasta voidaan nähdä olevan erityisesti kehitysmaiden ammattilaisten puutteellinen tieto tekoälystä. Puolestaan potilaiden näkökulmasta isoimpana haasteena nousee esiin potilaiden pelko potilaan ja hammaslääkärin välisen luottamuksen heikentymisestä. Tämän haasteen voidaan siten nähdä tuovan esille ihmiskontaktin tarve suun terveydenhuollossa. Lisäämällä tietoa potilaiden ja ammattilaisten keskuudessa tekoälyn toiminnasta ja mahdollisuuksista, voidaan myös lievittää potilaiden pelkoa siitä, että inhimillisuus katoaa vastaanotoilta tekoälyä hyödynnettäessä. Tietoisuutta voidaan parantaa esimerkiksi sisällyttämällä tekoälyn opettaminen osaksi hammaslääkäreiden opetussuunnitelmaa tai pitämällä luentoja jo valmistuneille hammaslääkäreille. Kun ammattilaiset ovat tietoisia mallien mahdollisuuksista ja toiminnasta, voivat he myös informoida potilaita malleista ja siten mahdollisesti parantaa myös potilaiden asenteita ja suhtautumista.

On kuitenkin huomioitavaa, että myös tällä tutkielmalla on omat rajoituksensa. Tutkielma on vain pintapuolinen katsaus suurimmista mahdollisuuksista ja haasteista liittyen koneoppimisen malleihin suun terveydenhuollossa. Täten kirjallisuuskatsaus ei kata kaikkia eri koneoppimisen mahdollisuuksia ja haasteita, jotka liittyvät kariologiaan ja hampaiston määrittelyyn. Lisäksi tutkielman laajuuden ja valittujen hakukriteereiden vuoksi tutkielma ei sisällä kaikkia aiheeseen liittyviä tutkimuksia ja siten joitakin tärkeitä tutkimuksia ja lähteitä on voinut jäädä käyttämättä. Myös tutkimusten mallien oppimistyylien luokittelussa voi olla tulkintavirheitä, sillä osassa tutkimuksista ei kartoitettu opetusprosessia yhtä tarkasti kuin toisissa. Täten tutkielmassa esitetyt päätelmät oppimistyyleistä on tehty yhdistämällä artikkeleissa annettuja tietoja teorian tietoon, ja siten tulokset voivat olla osittain virheellisiä puutteellisten tietojen vuoksi. Näin ollen tämä kandidaatintutkielma voidaan nähdä olevan suuntaa antava yleiskäyttö ja avaus aihepiirin keskustelulle ja tarkastelulle.

Johtopäätöksinä voidaan siten todeta, että koneoppimisen malleilla on useita mahdollisuuksia suun terveydenhuollon kontekstissa, mutta myös haasteita on havaittavissa paljon ja ne on otettava huomioon malleja kehittäessä. Jotta malleja voidaan mahdollisesti ottaa tulevaisuudessa laajemmin käyttöön, ehdotetaan toisteisten ja laajempien jatkotutkimusten tekemistä, alan yhteisten standardien luomista, mallien riittävien tietoturvatöiden tutkimista sekä ammattilaisten tietämyksen kohentamista.

## LÄHTEET

- Alpaydin, E. (2016). *Machine Learning: The New AI*. MIT Press.  
<http://ebookcentral.proquest.com/lib/jyvaskyla-ebooks/detail.action?docID=4714219>
- Ayad, N., Schwendicke, F., Krois, J., van den Bosch, S., Bergé, S., Bohner, L., Hanisch, M. & Vinayahalingam, S. (2023). Patients' perspectives on the use of artificial intelligence in dentistry: a regional survey. *Head & Face Medicine*, 19, 1–10. <https://doi.org/10.1186/s13005-023-00368-z>
- Bisdas, S., Topriceanu, C.-C., Zakrzewska, Z., Irimia, A.-V., Shakallis, L., Subhash, J., Casapu, M.-M., Leon-Rojas, J., Pinto dos Santos, D., Andrews, D. M., Zeicu, C., Bouhuwaish, A. M., Lestari, A. N., Abu-Ismaïl, L., Sadiq, A. S., Khamees, A., Mohammed, K. M. G., Williams, E., Omran, A. I., ... Ebrahim, E. H. (2021). Artificial Intelligence in Medicine: A Multinational Multi-Center Survey on the Medical and Dental Students' Perception. *Frontiers in Public Health*, 9. <https://doi.org/10.3389/fpubh.2021.795284>
- Bjerring, J. C. & Busch, J. (2021). Artificial Intelligence and Patient-Centered Decision-Making. *Philosophy & Technology*, 34(2), 349–371.  
<https://doi.org/10.1007/s13347-019-00391-6>
- Bonaccorso, G., Fandango A. & Shanmugamani R. (2018). *Introduction to Semi-Supervised Learning*. Packt Publishing Ltd.  
<https://ebookcentral.proquest.com/lib/jyvaskyla-ebooks/reader.action?ppg=63&docID=5626921>
- Brauneck, A., Schmalhorst, L., Majdabadi, M. M. K., Bakhtiari, M., Völker, U., Baumbach, J., Baumbach, L. & Buchholtz, G. (2023). Federated Machine Learning, Privacy-Enhancing Technologies, and Data Protection Laws in Medical Research: Scoping Review. *Journal of Medical Internet Research*, 25(1), e41588. <https://doi.org/10.2196/41588>
- Cantu, A. G., Gehrung, S., Krois, J., Chaurasia, A., Rossi, J. G., Gaudin, R., Elhennawy, K. & Schwendicke, F. (2020). Detecting caries lesions of different radiographic extension on bitewings using deep learning. *Journal of Dentistry*, 100, 103425. <https://doi.org/10.1016/j.jdent.2020.103425>
- Estai, M., Tennant, M., Gebauer, D., Brostek, A., Vignarajan, J., Mehdizadeh, M. & Saha, S. (2022). Deep learning for automated detection and numbering of permanent teeth on panoramic images. *Dentomaxillofacial Radiology*, 51(2), 20210296. <https://doi.org/10.1259/dmfr.20210296>
- Euroopan parlamentin ja neuvoston asetus (EU) 2016/679. (2016). Euroopan parlamentin ja neuvoston asetus (EU) 2016/679 (4.5.2016) luonnollisten henkilöiden suojelusta henkilötietojen käsittelyssä sekä näiden tietojen vapaasta liikkuvuudesta ja direktiivin 95/46/EY kumoamisesta (yleinen

- tietosuoja-asetus) (ETA:n kannalta merkityksellinen teksti). *Official Journal of the European Union*. <http://data.europa.eu/eli/reg/2016/679/oj/fin>
- Goodfellow, I., Bengio, Y. & Courville, A. 2016. *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J. & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>
- Haenlein, M. & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Ibtehaz, N. & Rahman, M. S. (2020). MultiResUNet : Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural Networks*, 121, 74–87. <https://doi.org/10.1016/j.neunet.2019.08.025>
- Isensee, F., Jaeger, P. F., Kohl, S. A. A., Petersen, J. & Maier-Hein, K. H. (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature Methods*, 18(2), 203–211. <https://doi.org/10.1038/s41592-020-01008-z>
- Karan-Romero, M., Salazar-Gamarra, R. E. & Leon-Rios, X. A. (2023). Evaluation of Attitudes and Perceptions in Students about the Use of Artificial Intelligence in Dentistry. *Dentistry Journal*, 11(5), 125. <https://doi.org/10.3390/dj11050125>
- Karies (hallinta): Käypä hoito -suositus*. (10.1.2023). Suomalaisen Lääkäriseuran Duodecimin ja Suomen Hammaslääkäriseura Apollonia ry:n asettama työryhmä. Helsinki: Suomalainen Lääkäriseura Duodecim. <https://www.kaypahoito.fi/hoi50127>
- Khanagar, S. B., Al-ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., Sarode, S. C. & Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Journal of Dental Sciences*, 16(1), 508–522. <https://doi.org/10.1016/j.jds.2020.06.019>
- Kosan, E., Krois, J., Wingenfeld, K., Deuter, C. E., Gaudin, R. & Schwendicke, F. (2022). Patients' Perspectives on Artificial Intelligence in Dentistry: A Controlled Study. *Journal of Clinical Medicine*, 11(8), 2143. <https://doi.org/10.3390/jcm11082143>
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lee, S., Oh, S., Jo, J., Kang, S., Shin, Y. & Park, J. (2021). Deep learning for early dental caries detection in bitewing radiographs. *Scientific Reports*, 11(1), 16807. <https://doi.org/10.1038/s41598-021-96368-7>

- Li, S., Guo, Y., Pang, Z., Song, W., Hao, A., Xia, B., & Qin, H. (2022). Automatic Dental Plaque Segmentation Based on Local-to-Global Features Fused Self-Attention Network. *IEEE Journal of Biomedical and Health Informatics*, 26(5), 2240–2251. <https://doi.org/10.1109/JBHI.2022.3141773>
- Lian, L., Zhu, T., Zhu, F. & Zhu, H. (2021). Deep Learning for Caries Detection and Classification. *Diagnostics*, 11(9), 1672. <https://doi.org/10.3390/diagnostics11091672>
- Mohammed, M., Khan, M. B. & Bashier, E. B. M. (2016). *Machine Learning: Algorithms and Applications*. Taylor & Francis Group. <http://ebookcentral.proquest.com/lib/jyvaskyla-ebooks/detail.action?docID=4683300>
- Qu, X., Zhang, C., Houser, S. H., Zhang, J., Zou, J., Zhang, W. & Zhang, Q. (2022). Prediction model for early childhood caries risk based on behavioral determinants using a machine learning algorithm. *Computer Methods and Programs in Biomedicine*, 227, 107221. <https://doi.org/10.1016/j.cmpb.2022.107221>
- Poon, A. I. F. & Sung, J. J. Y. (2021). Opening the black box of AI-Medicine. *Journal of Gastroenterology and Hepatology*, 36(3), 581–584. <https://doi.org/10.1111/jgh.15384>
- Potilas- ja asiakastietojen ja henkilötietojen käsittely*. (ei pvm.). Valvira. Noudettu 15. huhtikuuta 2024, osoitteesta <https://valvira.fi/sosiaali-ja-terveydenhuolto/potilas-ja-asiakastietojen-ja-henkilotietojen-kasittely>
- Regulation (EU) 2016/679 (2016). Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC (General Data Protection Regulation) (Text with EEA relevance). *Official Journal of the European Union*. <https://eur-lex.europa.eu/eli/reg/2016/679/oj>
- Russell, S. J., Chang, M.-W., Devlin, J., Dragan, A., Forsyth, D., Goodfellow, I., Malik, J. M., Mansinghka, V., Norvig, P., Pearl, J. & Wooldridge, M. (2022). *Artificial intelligence: a modern approach (Fourth edition)*. Pearson.
- Sadegh-Zadeh, S.-A., Rahmani Qeranqayeh, A., Benkhalifa, E., Dyke, D., Taylor, L. & Bagheri, M. (2022). Dental Caries Risk Assessment in Children 5 Years Old and under via Machine Learning. *Dentistry Journal*, 10(9), 164. <https://doi.org/10.3390/dj10090164>
- Asiakas- ja potilastietojen hallinta*. (2.2.2024). Sosiaali- ja terveystieteiden ministeriö. <https://stm.fi/asiakas-potilastietojen-hallinta>
- Schwendicke, F., Samek, W. & Krois, J. (2020). Artificial Intelligence in Dentistry: Chances and Challenges. *Journal of Dental Research*, 99(7), 769–774. <https://doi.org/10.1177/0022034520915714>

- Toledo Reyes, L., Knorst, J. K., Ortiz, F. R., Brondani, B., Emmanuelli, B., Saraiva Guedes, R., Mendes, F. M. & Ardenghi, T. M. (2023). Early Childhood Predictors for Dental Caries: A Machine Learning Approach. *Journal of Dental Research*, 102(9), 999–1006.  
<https://doi.org/10.1177/00220345231170535>
- Tuzoff, D. V., Tuzova, L. N., Bornstein, M. M., Krasnov, A. S., Kharchenko, M. A., Nikolenko, S. I., Sveshnikov, M. M. & Bednenko, G. B. (2019). Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial Radiology*, 48(4), 20180051.  
<https://doi.org/10.1259/dmfr.20180051>
- Wenzel, A. (2004). Bitewing and Digital Bitewing Radiography for Detection of Caries Lesions. *Journal of Dental Research*, 83(1\_suppl), 72–75.  
<https://doi.org/10.1177/154405910408301s14>
- Yang, Q., Liu, Y., Chen, T. & Tong, Y. (2019). Federated Machine Learning: Concept and Applications. *ACM Transactions on Intelligent Systems and Technology*, 10(2), 12:1-12:19. <https://doi.org/10.1145/3298981>
- You, W., Hao, A., Li, S., Wang, Y. & Xia, B. (2020). Deep learning-based dental plaque detection on primary teeth: a comparison with clinical assessments. *BMC Oral Health*, 20(1), 141. <https://doi.org/10.1186/s12903-020-01114-6>
- Yüzbaşıoğlu, E. (2021). Attitudes and perceptions of dental students towards artificial intelligence. *Journal of Dental Education*, 85(1), 60–68.  
<https://doi.org/10.1002/jdd.12385>