

Tekoäly hammaslääketieteessä

Mikko Humalajoki HLK

Syventävien opintojen kirjallinen työ

Ohjaajat: yliopistonlehtori, EHL, HLT Niina Kuusisto,
Professori, data-analytiikka Timo Knuutila

TURUN YLIOPISTO
Hammaslääketieteen laitos

Laatija:
Mikko Humalajoki

1.4.2026
Turku

Turun yliopiston laatu järjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -järjestelmällä.

Syventävien opintojen opinnäyte

Tutkinto-ohjelma, oppiaine: Hammaslääketieteen koulutusohjelma

Tekijä: Mikko Humalajoki

Otsikko: Tekoäly hammaslääketieteessä

Ohjaaja: Yliopistonlehtori, EHL, HLT Niina Kuusisto

Sivumäärä: 24 sivua

Päivämäärä: 1.4.2026

Abstract

Tekoäly on kehittynyt nopeasti viime vuosina ja sen sovellukset ovat yleistyneet merkittäväksi osaksi arkea. Kehityksen myötä tekoälyllä on kasvava rooli myös terveydenhuollossa.

Tämä syventävien opintojen opinnäytetyö käsittelee tekoälyn roolia hammaslääketieteessä. Opinnäytetyön tavoitteena on selvittää tekoälyn yleisimpiä malleja sekä niiden käyttöä hammaslääketieteen eri osa-alueilla. Lisäksi pohditaan, millaisia mahdollisuuksia ja haasteita sen käyttöön liittyy.

Opinnäytetyö toteutettiin kirjallisuuskatsauksena. Aineisto pohjautuu PubMed-tietokannasta haettuihin tieteellisiin artikkeleihin sekä muihin aiheeseen olennaisesti liittyviin julkaisuihin. Tiedonhaussa hyödynnettiin aihepiiriin liittyviä hakusanoja ja haku rajattiin viimeiseen kuuteen vuoteen.

Kirjallisuuskatsauksen perusteella tekoäly näyttäytyy lupaavana työkaluna monilla hammaslääketieteen osa-alueilla ja tekoälyn kehitys jatkuu nopealla tahdilla. Tekoälyn ennustetaan säästävän aikaa ja resursseja ja tuottavan taloudellisia hyötyjä. Etenkin hammaslääketieteellisessä diagnostiikassa tekoälyn rooli vaikuttaa tulevaisuudessa olevan merkittävä. Sovellusten laajentumista ja käyttöönottoa rajoittavat kuitenkin eettiset näkökohdat, lait ja säädökset sekä ammattilaisten ja alan johtajien suhtautuminen tekoälyn käyttöön.

Avainsanat: tekoäly, AI, hammaslääketiede

Sisällysluettelo

1	Johdanto	4
2	Aineisto ja menetelmät	6
3	Tekoäly	7
3.1	Koneoppiminen	9
3.2	Syväoppiminen	10
3.3	Selitettävä tekoäly	11
3.4	GPT-kielimallit	12
4	Tekoäly hammaslääketieteen alalla	13
4.1	Radiologia – kariesdiagnostiikka, endodontia ja parodontologia	13
4.2	Protetiikka	14
4.3	Ortodontia	15
4.4	Purentafysiologia	16
4.5	Suu- ja leukakirurgia	16
4.6	Muut sovellukset	17
4.6.1	Opetus	17
4.6.2	Chatbotit	17
5	Lait ja säädökset	18
6	Pohdinta	19
7	Johtopäätökset	21
	Lähteet	22

1 Johdanto

Hammaslääketiedettä on harjoitettu arviolta tuhansien vuosien ajan, mutta erityisesti viimeisen sadan vuoden aikana ala on kehittynyt merkittävästi sekä kliinisten taitojen, että käytettävien välineiden ja materiaalien osalta (Rocha ym., 2026). Viime vuosikymmeninä tietotekniikka ja digitalisaatio ovat tuoneet useita erilaisia parannuksia hammaslääkärin työhön. Suomessa digitaalisiin hammaslääketieteen potilastietojärjestelmiin ja digitaaliseen kuvantamiseen on siirrytty 1990–2000-luvun taitteessa. Digitalisaation myötä tekoäly on kasvanut koko ajan isompaan rooliin, ja sen sovelluksia tutkitaan yhä laajemmin myös hammaslääketieteen alalla.

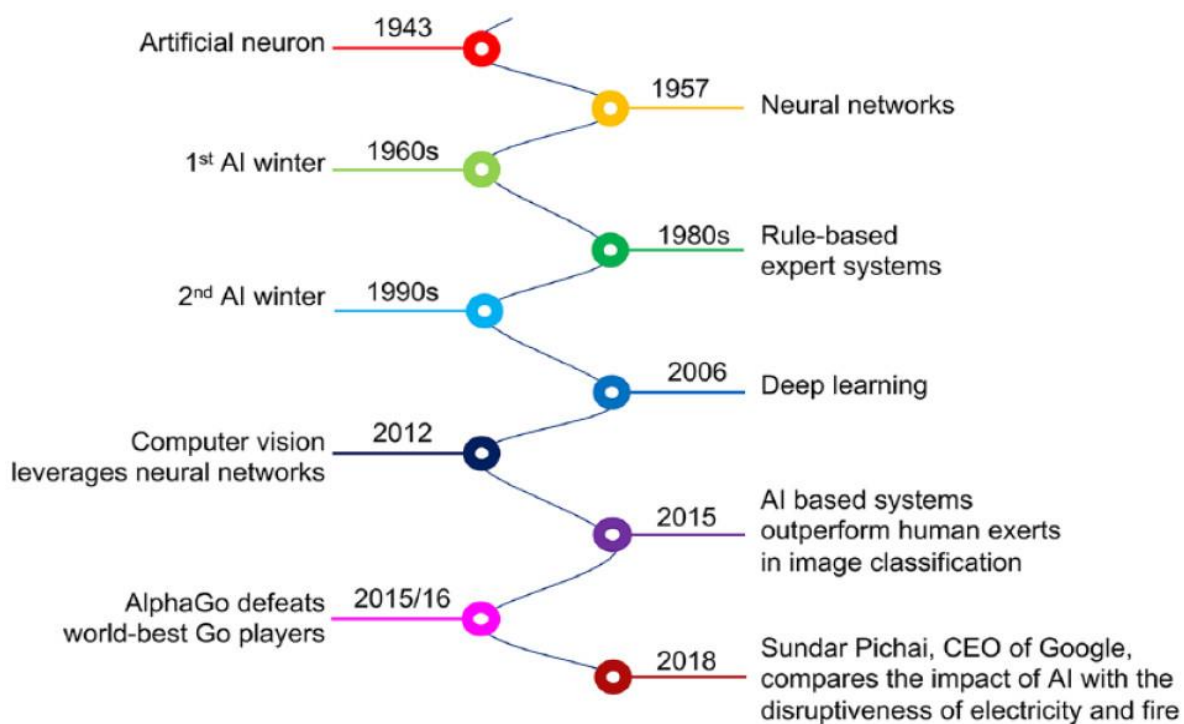
Tekoäly, artificial intelligence (AI), on käsite, joka otettiin käyttöön jo 1950-luvulla ja viittaa koneiden kehittämiseen niin, että ne pystyvät suorittamaan itsenäisesti tehtäviä, joita yleensä ihminen tekee. Tekoälyn osa-alueita ovat muun muassa koneoppiminen, machine learning (ML), syväoppiminen, deep learning (DL) ja neuroverkot, neural networks (NN).

Koneoppimisessa käytetään algoritmeja datan tilastollisten rakenteiden ja mallien oppimiseen, jotta voidaan tehdä ennusteita uusista, aiemmin näkemättömistä tiedoista. Syväoppiminen mahdollistaa monimutkaisen datan, esimerkiksi kuvien automaattisen oppimisen ja tulkinnan ilman, että ihminen määrittelee etukäteen, mitä ominaisuuksia datasta analysoidaan. Yksi koneoppimisen monimutkaisempi malli on neuroverkko (NN), joka ylittää perinteisemmät menetelmät laajemmissa aineistoissa, kuten kuvien ja kielen käsittelyssä. (Schwendicke, 2020)

Viimeisen 70 vuoden aikana tekoälyyn on suhtauduttu vaihtelevasti - se on nähty suurena mahdollisuutena, mutta myös uhkana (kuva 1). Tänä aikana tekoälyyn liittyen on koettu useita pettymyksiä, niin kutsuttuja ”tekoälytalvia”, jolloin teknologialle asetetut odotukset eivät ole täyttyneet ja kehityksen rajallisuus on ollut esteenä edistymiselle. Viimeisen vuosikymmenen aikana kehitys on kuitenkin ollut poikkeuksellisen nopeaa erityisesti koneoppimisen ja laajemmin tekoälyn saralla. Esimerkiksi uusimmat kielimallit, large language models (LLM), tuottavat niin luonnollista tekstiä, että niitä on vaikea erottaa ihmisen kirjoittamista.

Kasvojentunnistus on kehittynyt niin pitkälle, että sen vaikutukset ihmisen yksityisyyteen ja mahdollisuus väärinkäyttöön herättää huolta. Tekoäly ei ole enää vain tulevaisuuden visio, vaan sen kauaskantoisista vaikutuksista yhteiskuntaan, politiikkaan, talouteen ja terveydenhuoltoon käydään jo laajasti keskustelua eri aloilla. (Schwendicke, 2020)

Tämän opinnäytetyön tavoitteena on selvittää tekoälyn rooli tällä hetkellä hammaslääketieteessä sekä esittää meneillään olevien tutkimusten tavoitteita ja tuloksia. Lisäksi selvitetään tekoälyn keskeisiä periaatteita sekä analysoidaan sen hyötyjä hammaslääketieteellisessä kontekstissa.



Kuva 1. Tekoälyn historiaa. (Schwendicke, Samek, & Krois, 2020). 2018 jälkeen on tullut useita erilaisia open ai sovelluksia.

2 Aineisto ja menetelmät

Tätä kirjallisuuskatsausta varten haettiin aineistoa PubMed-tietokannasta vertaisarvioituista tieteellisistä artikkeleista sekä muista aiheeseen olennaisesti liittyvistä julkaisuista.

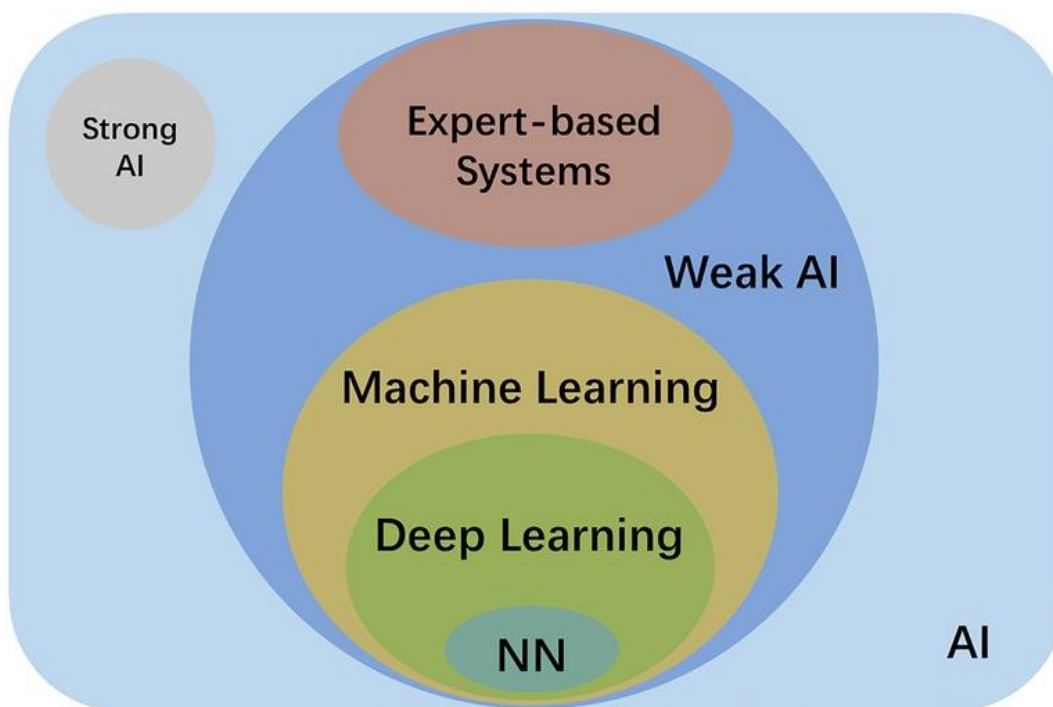
Tiedonhakua suoritettiin käyttäen yhdistelmiä hakusanoista ”artificial intelligence”, ”AI”, ”machine learning”, ”ML”, ”deep learning”, ”DL”, ”dental” ja ”dentistry”. Hakua täydennettiin MeSH-termeillä tiedonhaun tarkkuuden parantamiseksi.

PubMed-haku rajattiin koskemaan vain englanninkielisiä julkaisuja, jotka on julkaistu viimeisen kuuden vuoden aikana. Lisäksi kirjallisuuskatsaukseen sisällytettiin aiheeseen liittyviä muita julkaisuja, joissa hyväksyttiin myös suomenkieliset lähteet.

3 Tekoäly

Tekoäly on käsitteenä hyvin laaja ja sillä on useita eri alaluokkia. Suoraan käännettynä tekoäly voidaan määrittää ei-biologiseksi kyvyksi suorittaa monimutkaisia tehtäviä. (Leite, 2020)

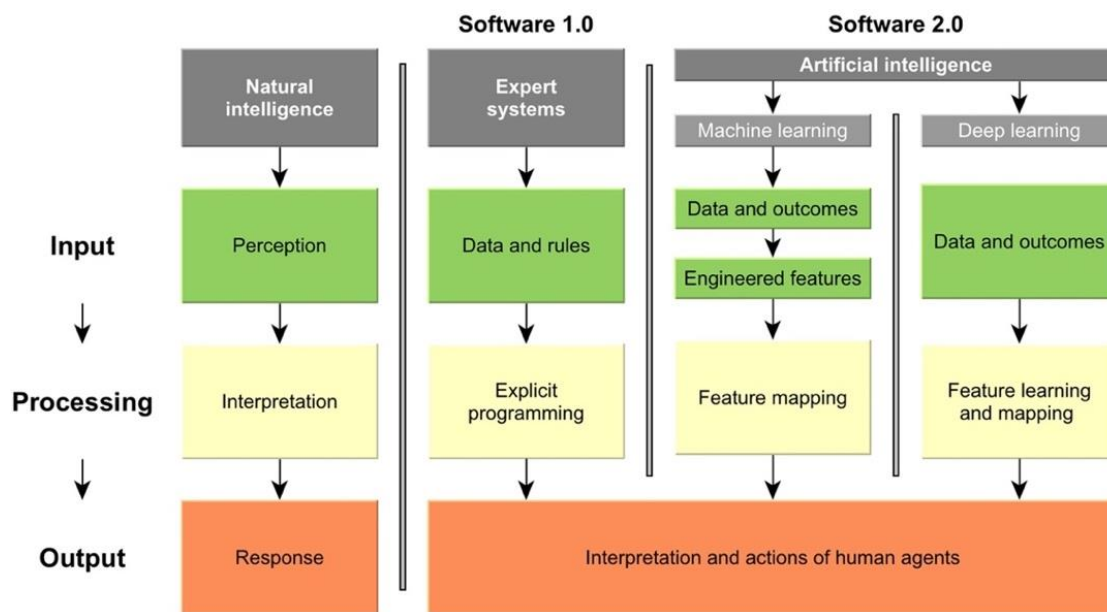
Tekoäly voidaan luokitella, joko vahvuuden mukaan (kuva 2) tai kyvykkyyden mukaan. Vahvuudessa on kaksi tasoa: heikko tekoäly ja vahva tekoäly. Heikkoa tekoälyä kutsutaan myös kapeaksi tekoälyksi ja se tarkoittaa ohjelmaa, joka on koulutettu ratkaisemaan yksittäisiä tai rajattuja tehtäviä. Nykyinen yleisesti käytössä oleva tekoäly on enimmäkseen heikkoa tekoälyä. Vahva tekoäly viittaa järjestelmiin, joilla olisi ihmisen kaltainen älykkyys ja kyky suoriutua monipuolisista tehtävistä. Sillä on tietoisuus ja käyttäytyminen, joka on yhtä joustava kuin ihmisillä. Vahvan tekoällyn tavoitteena on luoda monitehtävä algoritmeja, jotka pystyisivät tekemään päätöksiä useilla eri alueilla. Vahvan tekoällyn sovelluksia ei vielä toistaiseksi ole olemassa. (Ding, 2023)



Kuva 2 Tekoällyn erilaiset luokittelut. (Ding, Wu, Zhao, Matinlinna, Burrow & Tsoi, 2023).

Tekoälyn kyvykkyys perustuu kolmeen tasoon. Artificial super intelligence (ASI) on hypoteettinen kyky, jossa tekoälyn älykkyys ylittäisi huomattavasti kaikkein lahjakkaimpien ja älykkäimpien ihmisten tason. Artificial general intelligence (AGI) on hypoteettinen kyky, jossa tekoäly pystyisi oppimaan ja ymmärtämään mitä tahansa älyllisiä tehtäviä ihmisen tavoin. AGI on nykyisin monen tekoälytutkimuksen keskiössä. Artificial narrow intelligence (ANI), jota kutsutaan myös heikoksi tekoälyksi pystyvät suorittamaan vain yhden tehtävän esimerkiksi autolla ajaminen, shakin pelaaminen tai puheen tai tekstin tunnistaminen. ANI-järjestelmät ovat suunniteltu keskittymään omaan tehtäväänsä reaaliaikaisesti, ja ne voivat oppia ympäristöstään jatkuvasti, laajentaa osaamista ajan myötä ja erikoistua tehtävään, johon ne on suunniteltu. Ne eivät kuitenkaan pysty toimimaan oman tehtäväalueensa ulkopuolella. ANI on yleisin tekoälyn muoto tällä hetkellä ja siihen kuuluvat myös koneoppiminen ja syväoppiminen. (Abonamah, 2021)

Luonnollinen älykkyys perustuu havaitsemiseen, tulkintaan ja biologisiin vasteisiin. Tekoäly ei vielä korvaa ihmisen toimintaa, vaan toimii lähinnä tulkinnan ja päätöksenteon tukena (kuva 3). Varhainen ohjelmistoälykkyys ”Software 1.0” (kuva 3) perustui sääntöihin ja asiantuntijajärjestelmiin, joissa dataa käsiteltiin ennalta määriteltyjen logiikkasääntöjen avulla. Sen sijaan ”Software 2.0” (kuva 3) pohjautuu siihen, että säännöt johdetaan datasta: perinteisessä koneoppimisessa ominaisuudet määritellään ensin asiantuntijoiden toimesta, kun taas syväoppimisessa järjestelmä oppii ja mallintaa olennaiset piirteet itse, mikä mahdollistaa myös monimutkaisten aineistojen, kuten kuvien ja kielten käsittelyn. (Schwendicke, 2020)



Kuva 3. Luonnollinen älykkyys ja tekoäly. (Schwendicke, Samek, & Krois, 2020).

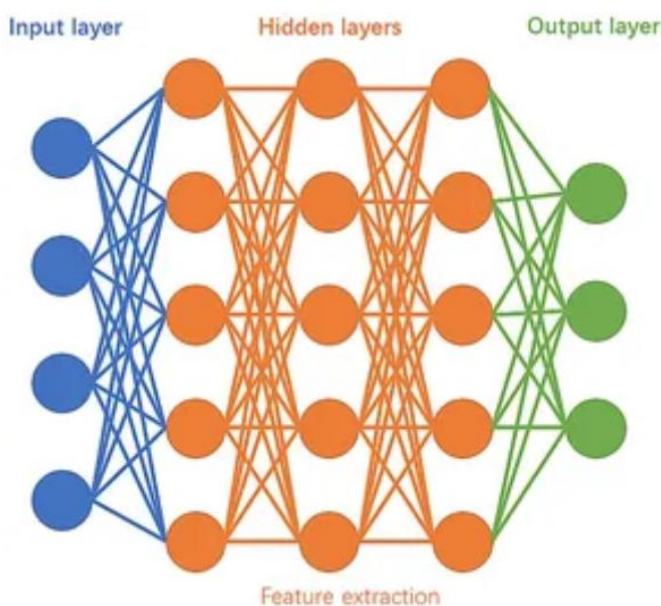
3.1 Koneoppiminen

Heikon tekoälyn keskeinen alaryhmä on koneoppiminen. Koneoppiminen voidaan karkeasti jakaa ohjattuun, ohjaamattomaan ja puoliohjattuun oppimiseen sekä vahvistusoppimiseen. Ohjatussa oppimisessa algoritmit koulutetaan merkityillä aineistoilla, mikä mahdollistaa tunnistamaan annetusta syötteestä keskeiset piirteet ja hyödyntää niitä tekemään ennusteita nimeämättömästä syötteestä. Esimerkkejä ohjatussa oppimisesta ovat k:n lähimmän naapurin menetelmä (K-nearest neighbors, KNN), logistinen regressio, satunnaismetsä ja tukiverkkokoneet (Ding, 2023). Ohjattu oppiminen on yleisin tapa koneoppimisen alalla. Tavoitteena on yleistää malli niin, että se toimii tehokkaasti myös sellaisille aineistoille, joita ei ollut mukana koulutusaineistossa (Al-Hamadani, 2024). Ohjaamattomassa oppimisessä algoritmit sen sijaan etsivät rakenteita ja yhteyksiä aineistosta ilman valmiiksi merkittyä aineistoa, kun taas puoliohjatussa oppimisessä algoritmit hyödyntävät pienen määrän merkittyä aineistoa yhdessä suuren määrän merkitsemätöntä aineistoa kanssa. Viime vuosina on yleistynyt myös heikosti ohjattu oppiminen, joka pyrkii vähentämään aineistojen merkitsemisestä aiheutuvia kustannuksia. Esimerkiksi kuvasegmentointi, jossa koulutuksessa käytetään ainoastaan kuvatason merkintöjä ilman tarkkaa sijainti- tai rajaustietoa. (Al-Hamadani, 2024).

Edellä mainituista poiketen vahvistusoppinen (RL) muodostaa oman kategorian. Siinä oppiminen perustuu kokeiluun ja erehdykseen ja tavoitteena on maksimoida kumulatiivinen palkkio tietyssä ympäristössä. Vahvistusoppi eroaa muista koneoppimisen muodoista siten, että se ei nojaa valmiiksi merkittyyn aineistoon, vaan oppii vuorovaikutuksessa ympäristönsä kanssa tekemällä toistuvia päätöksiä ja arvioimalla niiden seurauksia. (Ding, 2023)

3.2 Syväoppiminen

Syväoppiminen (DL) on yksi merkittävimmistä nykyajan tutkimusalueista ja se muodostaa koneoppimisen keskeisen alalajin. Syväoppiminen voi perustua sekä ohjattuun, että ohjaamattomaan oppimiseen. Termi ”syvä” viittaa keinotekoiseen neuroverkkoon, artificial neural network (ANN), joka koostuu vähintään kolmesta kerroksesta: syötekerroksesta (input), yhdestä tai useammasta piilokerroksesta (hidden layer) ja ulostulokerroksesta (output). Jokainen kerros sisältää useita toisiinsa kytkeytyneitä solmuja eli keinotekoisia neuroneita (kuva 4). (Ding, 2023)



Kuva 4 Pelkistetty kuva DL toiminnasta (Ding, Wu, Zhao, Matinlinna, Burrow & Tsoi, 2023).

Kullakin solmulla on siihen liittyvä painokerroin ja harhatermi, jotka määrittävät sen aktivoitumisen yksinkertaistetun lineaarisen regressiomallin perusteella. Kun solmu vastaanottaa syötteitä, painokertoimet ohjaavat laskentaa. Jos syötteiden ja painokertoimien yhteenlaskettu tulos ylittää tietyllä harhatermillä määritellyn raja-arvon, solmu aktivoituu ja välittää tiedon seuraavaan kerrokseen. Tätä prosessia, jossa tietoa etenee kerroksesta toiseen, kutsutaan syötteen etenemiseksi (feedforward) neuroverkossa. Menetelmä muistuttaa

periaatteeltaan päätöspuumenetelmiä, mutta mahdollistaa huomattavasti monimutkaisempien rakenteiden ja ilmiöiden mallintamisen. (Ding, 2023)

Syväneuroverkot kykenevät automaattisesti oppimaan ja erottamaan datasta merkityksellisiä piirteitä ilman ihmisen suoranaista ohjausta. Ne rakentavat oppimisen suurten aineistojen varaan, jolloin järjestelmä kehittää itse ominaisuuksien tunnistamisen ja mallintamisen. Tämä eroaa asiantuntijajärjestelmistä (expert systems), joissa oppiminen perustuu ihmisen panokseen: painokertoimet ja harhatermit säädetään manuaalisesti, minkä vuoksi ne voivat toimia pienemmänkin datamäärän avulla. Neuroverkot (NNs) muodostavat syväoppimisen keskeisen perustan ja niitä on kehitetty useita eri variaatioita. Tärkeimpiä ovat keinotekoiset neuroverkot (ANNs), konvoluutioneuroverkot, convolutional neural networks (CNNs) sekä generatiiviset kilpailevat verkot, generative adversarial networks (GANs), joista jokaisella on oma erityinen käyttötarkoituksensa koneoppimisen ja tekoälyn sovelluksissa. (Ding, 2023)

Monimutkaisten neuroverkkojen päätöksentekoprosessien ymmärtäminen ja selittäminen on osoittautunut haastavaksi. Neuroverkkojen piilokerroksien tapahtumia ei aina pystytä kunnolla selittämään. Neuroverkot löytävät datasta monimutkaisia yhteyksiä ja piilotettuja malleja, joita ihmiset eivät aina pysty helposti ymmärtämään. Tämän vuoksi niiden toimintaa kutsutaan usein ”mustaksi laatikoksi”. Vaikka neuroverkot voivat tuottaa tarkkoja ennusteita ja päätöksiä, tutkijoiden on usein vaikea selittää, miten yksittäinen lopputulos on muodostunut. (Ding, 2023)

3.3 Selitettävä tekoäly

AI ja sen osa-alueet kuten ML ja DL ovat viime vuosina kehittyneet nopeasti ja niitä hyödynnetään jo laajasti monilla eri aloilla. Näiden mallien vahvuus on kyvyssä käsitellä suuria ja monimutkaisia aineistoja ja tuottaa tarkkoja ennusteita. Haasteena on kuitenkin, että monimutkaiset ML- ja DL-mallit toimivat usein niin sanottuina ”mustina laatikkoina”. Ne tuottavat ennusteita ilman, että käyttäjä ymmärtää selkeästi, miten ja miksi tiettyyn lopputulokseen on päädytty. Tämä rajoittaa mallien hyväksyttävyyttä ja luotettavaa hyödyntämistä käytännössä. Tätä ongelmaa varten on kehitetty selitettävä tekoäly, explainable artificial intelligence (XAI). (Cateron, 2024)

XAI tarkoittaa menetelmiä ja tekniikoita, joiden avulla tekoälymallien toimintaa ja ennusteiden perusteita voidaan tulkita ja selittää. Selityksiä voidaan tarkastella esimerkiksi yksittäisen ennusteen tasolla (miksi tietty tulos saatiin) tai koko mallin tasolla (mitkä tekijät

vaikuttavat mallin toimintaan). Menetelmät voivat olla mallikohtaisia tai mallista riippumattomia sekä joko mallin rakenteeseen perustuvia tai jälkikäteisiä (post-hoc), jolloin ennusteita analysoidaan ilman, että alkuperäistä mallia tarvitsee muuttaa. (Cateron, 2024)

XAI lisää tekoälyn läpinäkyvyyttä, tukee päätöksentekoa ja auttaa käyttäjiä luottamaan mallien tuottamiin tuloksiin. Se mahdollistaa myös mallien valvonnan ja kehittämisen sekä auttaa havaitsemaan mahdollisia vinoumia datassa. Viime vuosina XAI käyttö on kasvanut nopeasti, ja tunnettuja menetelmiä ovat esimerkiksi SHAP-arvot (Shapley Additive Explanations), LIME (Locally Interpretable Model-agnostic Explanations) sekä erilaiset visualisointimenetelmät, kuten osittaisriippuvuuskäyrät. Vaikka XAI tarjoaa monia hyötyjä, menetelmien arviointi ja standardointi ovat edelleen kehitysvaiheessa. (Cateron, 2024)

XAI-malleja on käytetty esimerkiksi hammaslääketieteellisessä radiologiassa. Esimerkiksi panoraamaröntgenkuvia analysoivassa tutkimuksessa XAI syväoppimismalli tunnisti kariuksen noin 92 % tarkkuudella ja tuotti karttoja, jotka osoittivat kuvan alueet, jotka vaikuttivat tekoälyn päätökseen. (Oztekin ym., 2023)

3.4 GPT-kielimallit

Generative pre-trained transformer (GPT-kielimalli) on yksi laajojen kielimallien, LLM-tyypeistä. GPT-kielimallit pystyvät tuottamaan tai ennustamaan kieltä keskustelun omaisesti vastaamalla kysymyksiin. GPT-kielimallit ymmärtävät annetun tekstin, tunnistavat sen merkityksen ja muodostavat siihen sopivan tai todennäköisimmän vastauksen. Malli perustuu todennäköisyyslaskelmiin. Esimerkkejä saatavilla olevista GPT-malleista ovat muun muassa erilaiset Chatbotit, kuten ChatGPT, Google Gemini, Microsoft Copilot ja DeepSeek. Kielimalleja voidaan käyttää laajalti erilaisissa tehtävissä tekstin tuottamisessa yksilön tai yrityksen tarpeeseen. Kielimallien soveltuvuutta tutkitaan parhaillaan terveydenhuollon alalla potilaiden ohjaamiseen, kliiniseen päätöksen tekoon, toimenpiteen suunnitteluun ja diagnostiikkaan. (Haylaz ym., 2025) Eri tutkimusten tulokset samoilla kielimalleilla vaihtelevat laajalti. Kielimallit kehittyvät jatkuvasti, mutta niiden luotettavuus ja eettisyys eivät kuitenkaan ole vielä riittävällä tasolla ja käyttäjältä vaaditaan kriittisyyttä vastausten tulkintaan. Kielimallit saattavat tuottaa virheellistä tietoa hallusinoimalla eli malli keksii virheellisen tiedon ja esittää sen totuutena. (Bilan, 2023)

4 Tekoäly hammaslääketieteen alalla

Tekoälyn kehityksen myötä myös tekoälyn kehitys hammaslääketieteessä on viime vuosina lisääntynyt merkittävästi. Tekoälyn käyttöä on tutkittu useilla hammaslääketieteen erikoisaloilla ja sen sovellukset kohdistuvat erityisesti diagnostiikkaan, hoidon suunnitteluun ja ennustamiseen sekä kliinisten prosessien tehostamiseen. Aiemmat tutkimukset viittaavat siihen, että tekoäly voi parantaa diagnostista tarkkuutta, vähentää kliinistä vaihtelua ja tarjota tukea hammaslääkärin päätöksenteolle.

4.1 Radiologia – kariesdiagnostiikka, endodontia ja parodontologia

Tutkimuskirjallisuuden perusteella konvoluutioneuroverkot (CNNs) ovat tällä hetkellä yleisimmin käytetty tekoälymenetelmä hammaslääketieteellisessä diagnostiikassa. CNNs pystyvät oppimaan kuvien sisäisiä piirteitä ja rakenteita suoraan raakapikseleistä, mikä mahdollistaa merkityksellisten visuaalisten kuvioiden tunnistamisen ilman käsin suunniteltuja piirteitä. Tästä syystä CNNs ovat suosittuja myös hammaslääketieteellisessä kuvantamisessa, jossa ne mahdollistavat nopean ja tarkan tunnistuksen eri anatomisista rakenteista tai patologioista piirteistä. (Felek T ym., 2025)

Abbott ym. (2025) meta-analyysin perusteella tekoälypohjaisten menetelmien suorituskyky kariesen havaitsemisessa vaihtelee huomattavasti ja raportoidut tarkkuudet vaihtelevat 41,5 %:sta 98,6 %:iin. Keskimääräinen herkkyys kariesen havaitsemiselle oli noin 76 % ja spesifisyys noin 91 %, mikä viittaa siihen, että tekoäly kykenee tunnistamaan kariesen melko luotettavasti röntgenkuvista, vaikka tulokset eivät ole vielä yhdenmukaisia eri sovellusten ja kuvantamismenetelmien välillä. Osaryhmäanalyysissä kliinisistä kuvista saatu herkkyys on ollut hieman parempi kuin röntgenkuvista. Vaikka tekoäly osoittaa merkittävää potentiaalia kariesen diagnostiikassa, nykyisten tutkimusten perusteella se soveltuu toistaiseksi ensisijaisesti hammaslääkärin päätöksenteon tukivälineeksi. Tekoälyn täysimääräinen hyödyntäminen hammasdiagnostiikassa edellyttää menetelmien jatkokehittämistä sekä huolellista kliinistä validointia, jotta sovellusten suorituskyky olisi yhdenmukainen ja luotettava todellisissa kliinisissä toimintaympäristöissä. (Abbott ym., 2025)

Mohammad-Rahimi ym. (2024) tutkimuksen mukaan endodontiassa tekoälyä voidaan hyödyntää erityisesti periapikaalisten tulehduksien ja juurimurtumien tunnistamisessa, juurikanavien anatomian analysoinnissa sekä työskentelypituuden arvioinnissa. Lisäksi tekoälymalleja on käytetty hoitotulosten ennustamiseen ja kliinisen päätöksenteon tukena. Tekoälyä on suunniteltu käytettävän myös pedagogisena välineenä endodontian

koulutuksessa, esimerkiksi tapausperusteisen oppimisen tukena ja kliinisten päätösten harjoittelussa. Vaikka tekoälypohjaiset sovellukset ovat osoittaneet lupaavaa potentiaalia endodonttisessa diagnostiikassa ja hoidon suunnittelussa, niiden laajempi kliininen käyttö edellyttää edelleen menetelmien jatkokehittämistä, perusteellista validointia ja standardoitujen käytäntöjen luomista. (Mohammad-Rahimi ym., 2024)

Revilla-León ym. (2023) tutkimuksen mukaan parodontologisessa hoidossa tutkimusnäytön perusteella tekoälyllä on suurta potentiaalia parantaa diagnostiikan tarkkuutta ja tukea kliinistä päätöksentekoa. Tekoälymallien suorituskyky on kuitenkin vaihdellut sovellusalueittain. Plakin tunnistuksessa on raportoitu 73,6–99 % tarkkuus intraoraalisista valokuvista, kun taas ientulehduksen diagnostiikassa intraoraalisissa valokuvissa tarkkuus on ollut 74–78,2 %. Parodontiitin tunnistaminen intraoraalisten valokuvien perusteella tarkkuus on vaihdellut 47–81 % välillä. Sen sijaan alveolaarisen luukadon havaitsemisessa periapikaali-, bitewing- ja panoraamaröntgenkuvista tekoäly on osoittanut selvästi parempaa suorituskykyä ja raportoitu tarkkuus on vaihdellut 73,4–99 % välillä. Vaikka tekoälypohjaiset mallit ovat edelleen kehitysvaiheessa, tulokset viittaavat niiden merkittävään potentiaaliin parodontologisen diagnostiikan tukena kliinisessä työssä. (Revilla-León ym., 2023)

4.2 Protetiikka

Aljulayfi ym. (2024) tutkimuksen perusteella tekoälysovellukset protetiikassa liittyvät diagnostiikan lisäksi hoidon suunnittelun, valmistusprosesseihin sekä hoidon lopputuloksen ennustamiseen. Erityisesti syväoppimiseen perustuvat mallit, kuten konvoluutioneuroverkot (CNN) ovat osoittaneet lupaavaa potentiaalia hammasproteettisten rakenteiden, kuten kruunujen, siltojen ja implanttien tunnistamisessa röntgenkuvista. Lisäksi tekoälyä on hyödynnetty proteettisten rakenteiden suunnittelussa, värin ja sävyn määrittämisessä, parentapintojen rekonstruoinnissa sekä preparointilinjojen määrittämisessä osana CAD/CAM tekniikalla tehtyä proteettista työtä. Useissa tutkimuksissa tekoälypohjaiset järjestelmät ovat suoriutuneet annetuista tehtävistä hyvällä tarkkuudella, mikä viittaa niiden potentiaaliin kliinisen työn tukena. Tekoälyä on myös käytetty ennustamaan hoidon tuloksia sekä arvioimaan materiaalien ominaisuuksia ja mahdollisia komplikaatoriskejä, kuten esimerkiksi kruunujen irtoamisen todennäköisyyttä. Vaikka tulokset ovat lupaavia, suurin osa tutkimuksista perustuu rajallisiin aineistoihin ja vaihteleviin tutkimusasetelmiin, minkä vuoksi tekoälysovellusten laajempi kliininen käyttöönotto edellyttää laajempia tutkimusnäyttöjä ja huolellista kliinistä validointia. (Aljulayfi ym., 2024)

4.3 Ortodontia

Gracea ym. (2025) tutkimuksen mukaan tekoälysovellusten käyttö ortodonttisessa hoidossa käsittää diagnostiikan lisäksi digitaalisen työnkulun, tietokoneavusteisen suunnittelun sekä 3D-tulostuksen. Nämä mahdollistavat entistä nopeamman, tarkemman ja ennustettavamman hoidon. (Gracea ym., 2025)

Ortodonttinen diagnostiikka ja hoitosuunnittelu perustuvat edelleen pitkälti klinikon asiantuntemukseen, esimerkiksi kefalometristen mittapisteiden tunnistamiseen ja hoitopäätösten tekemiseen. Nämä prosessit ovat aikaa vieviä, alttiita inhimillisille virheille ja niihin liittyy huomattavaa tarkkailijakohtaista vaihtelua. Tekoälyyn perustuvat menetelmät pyrkivät automatisoimaan näitä työvaiheita luotettavasti ja tarkasti. Erityisesti syväoppimiseen perustuvat konvoluutiohermoverkot (CNN) ovat osoittaneet erinomaisen suorituskyvyn kuva-analyysissä ja niitä hyödynnetään laajasti diagnostiikassa, hoitosuunnittelussa ja ennusteen arvioinnissa. (Gracea ym., 2025)

Tekoälyä on sovellettu oikomishoidon diagnostiikassa useisiin tehtäviin korkealla tarkkuudella. Kliinisten ja radiologisten kuvien luokittelussa CNN-mallit ovat saavuttaneet jopa 98–99 % tarkkuuden, mahdollistaen tehokkaan kuvien indeksoinnin ja arkistoinnin. Kasvun ja kypsytyden arvioinnissa tekoälypohjaiset menetelmät ovat saavuttaneet 92–96 % tarkkuuden panoraamaröntgenkuvista tehdyssä ikäarvioinnissa, kun taas kaularangan nikamien kypsyysvaiheiden (CVM) tunnistuksen tarkkuudet ovat vaihdelleet noin 62–90 % käytetystä mallista riippuen. (Gracea ym., 2025)

Tekoälyä on hyödynnetty ortognaattisen kirurgian suunnittelussa ja anatomisten rakenteiden segmentoinnissa. CNN- ja ANN-pohjaiset mallit ovat mahdollistaneet kirurgisen päätöksenteon tukemisen, kuten ortognaattisen leikkauksen tarpeen arvioinnin jopa 96,3 %:n diagnostisella yhteneväsyydellä klinisen arvion kanssa. Tutkimukset ovat kuitenkin rajoittuneet pääosin ei-monimutkaisiin purentavirheisiin ja potilaisiin, joilla on täydellinen hampaisto. (Gracea ym., 2025)

Vaikka tekoäly osoittaa merkittävää potentiaalia oikomishoidon diagnostiikan ja hoitosuunnittelun automatisoinnissa, nykyiset sovellukset eivät kykene itsenäiseen päätöksentekoon. Tekoäly ei korvaa klinikon asiantuntemusta, vaan toimii tukena esimerkiksi kuva-analyysissä, tiedon tulkinnassa ja hoitosuunnitelmien simuloinnissa. Vaikka suorituskyky on usein verrattavissa asiantuntijoiden manuaalisiin arvioihin, tekoäly vaatii

edelleen ihmisen suorittamaa validointia. Erityisesti vähemmän kokeneille klinikoille tekoäly voi olla arvokas apuväline päätöksenteon tukemisessa, kun inhimillinen harkinta säilyy keskeisessä roolissa potilaskohtaisten tekijöiden arvioinnissa. (Gracea ym., 2025)

4.4 Purentafysiologia

Manek ym. (2025) tutkimuksen perusteella purentafysiologian alueella tekoälyä on hyödynnetty erityisesti leukanivelen (TMJ) magneettikuvien analysoinnissa, jossa sen sovellukset painottuvat välilevyn asennon arviointiin, sisäisten toimintahäiriöiden diagnostiikkaan sekä anatomisten rakenteiden segmentointiin. Syväoppimiseen perustuvat mallit, erityisesti CNN-mallit ovat osoittaneet hyvää suorituskkyä TMJ:n välilevyn siirtymien tunnistamisessa. Diagnostinen tarkkuus on vaihdellut noin 70–99 % välillä. Lisäksi tekoälyä on käytetty välilevyn perforaation ennustamiseen sekä nivelen rakenteiden, kuten nivellevyn ja kondyylin tunnistamiseen MRI-kuvista. Tulokset viittaavat siihen, että tekoäly voi toimia tehokkaana klinisen päätöksenteon tukena purentafysiologiassa, erityisesti diagnostiikan yhdenmukaistamisessa ja ajankäytön tehostamisessa. Kliinisessä käytössä tekoälyn hyödyntäminen edellyttää kuitenkin edelleen asiantuntijan tekemää arviointia sekä laajempaa validointia, jotta mallien luotettavuus ja yleistettävyyys potilastyössä voidaan varmistaa. (Manek ym., 2025)

4.5 Suu- ja leukakirurgia

Tekoälyä hyödynnetään yhä laajemmin suu- ja leukakirurgiassa erityisesti radiologisessa diagnostiikassa, virtuaalisessa leikkaussuunnittelussa sekä kliinisten töiden tukena. Rana ym. (2026) tutkimuksen perusteella tekoälypohjaiset menetelmät kuvantamisanalyysissä ja kirurgisessa suunnittelussa ovat suoriutuneet tehtävistään hyvin ja ennustetarkkuuksien on raportoitu olevan jopa noin 96 %. Lisäksi tekoälyn on todettu lyhentävän hoidon ja leikkausten suunnittelu-aikaa, tehostavan potilasviestintää sekä vähentävän hallinnollista kuormitusta kliinisessä työssä. Tulosten perusteella tekoälyllä on merkittävää potentiaalia parantaa hoidon laatua ja tehokkuutta suu- ja leukakirurgiassa, vaikka sen kliininen käyttöönotto edellyttää edelleen huolellista validointia ja ammattilaisen valvontaa. (Rana ym., 2026)

Abdali ym. (2025) tutkimuksessa on tutkittu tekoälyn käyttöä kirurgisten toimenpiteiden, kuten viisaudenhampaiden poiston suunnittelussa, perioperatiivisten riskien arvioinnissa sekä hoitotulosten ennustamisessa. Tehdyissä tutkimuksissa tekoälymallit onnistuivat arvioimaan viisaudenhampaan poistovaikeuden 78,9–90,2 % tarkkuudella ja postoperatiivisen

turvotuksen ennustamisessa jopa 98 % tarkkuudella. Kirurgisessa suunnittelussa tekoäly kykeni ennustamaan kasvojen pehmytkudosten sijainnin muutosta alle millimetrin virhemarginaalilla ylittäen perinteisten mallien suorituskyvyn. Lisäksi perioperatiivisia riskejä, kuten verenhukkaa, ennustettiin alle 10 ml:n keskimääräisellä virheellä. Kirurgisissa toimenpiteissä tekoälyä hyödynnettiin hoitotulosten kvantitatiiviseen arviointiin ja realististen simulaatioiden tuottamiseen. Vaikka tulokset ovat lupaavia, suurin osa tutkimuksista oli retrospektiivisiä, yksikeskustutkimuksia ja niihin liittyi kohonnut vääristymän riski. (Abdali ym., 2025)

4.6 Muut sovellukset

4.6.1 Opetus

Hammaslääketieteen opetuksessa kliininen harjoittelu on iso osa opintokokonaisuutta ja kädentaitoja on harjoiteltava paljon. Luultavasti juuri tämän vuoksi, erilaiset virtuaalipotilaat sekä virtuaaliset opetusympäristöt ovat kehittyneet hammaslääketieteessä viime vuosina. Virtuaalitodellisuuden käyttö opetuksessa saattaa tarjota mahdollisuuksia etenkin yksiköissä, joissa potilaita ei ole riittävästi opiskelijoiden harjoittelun tarpeisiin. (Bh MP ym., 2026)

4.6.2 Chatbotit

Tutkimuksissa on myös selvitetty tekoälypohjaisten chatbot-järjestelmien toimivuutta potilaiden tukena hammaslääketieteeseen liittyvissä kysymyksissä. Esimerkiksi eräässä tutkimuksessa arvioitiin useiden tekoälychatbottien, kuten ChatGPT-versioiden ja Google Geminin kykyä vastata potilaiden hammasvammoihin liittyviin kysymyksiin. Tulokset osoittivat, että uudempien chatbottien, kuten ChatGPT-4.0:n ja Google Geminin, antamat vastaukset olivat laadukkaampia ja luotettavampia kuin vanhempien versioiden, vaikka kaikkien chatbottien vastauksissa havaittiin luettavuuteen ja tarkkuuteen liittyviä puutteita. Tällaiset sovellukset voivat antaa potilaille alustavaa tietoa ja tukea, mutta ne eivät korvaa hammaslääkärin tekemää diagnoosia tai hoidon suunnittelua varsinkaan monimutkaisissa tapauksissa. (Guven, 2025)

5 Lait ja säädökset

Tekoälylle ei ole olemassa vielä riittävästi lakeja ja säädöksiä, jotka ohjaavat tutkimusta ja sovellusten käyttöönottoa. Euroopan Unionissa (EU) on otettu käyttöön tekoälyä koskeva asetus, EU AI act, 1.8.2024. Tämä luo yhtenäiset vaatimukset EU:ssa käytettäville tekoälysovelluksille. Asetus luokittelee sovellukset neljään riskiluokkaan: riskitön, rajoitettu, korkea riski ja kielletty. EU AI act pyrkii tuomaan EU:n alueelle turvallisempaa tekoälyn käyttöä säädösten ja suositusten avulla. (Euroopan parlamentti & neuvosto, 2024)

6 Pohdinta

Tekoäly on tullut kiinteäksi osaksi yksilön ja yhteiskunnan arkea. Tutkimukset tekoälyn roolista terveydenhuoltoalalla ovat lisääntyneet vauhdilla viime vuosina. Parhaimmillaan tekoälyn tavoite on varmistaa ja tehostaa ammattilaisen työtä. Ihmiset ovat alttiita häiriöille - kiire ja keskittymisvaikeudet saattavat altistaa inhimillisille virheille. Myös kokemus vaikuttaa ammattilaisen suoriutumiseen. Tekoälylle on siten perusteltu paikka työkaluna monilla eri ammattialoilla. Terveydenhuollon alalla tekoälyn käyttö vaatii kuitenkin kriittisempää ja tiukempaa säätelyä ensisijaisesti potilasturvallisuuden vuoksi.

Tekoälysovellukset osoittavat monella hammaslääketieteen alalla potentiaalista kyvykkyyttä päätöksen teon tukena tai niin sanottuna ”second opinion” työkaluna. Kliininen käyttöönotto edellyttää kuitenkin huolellista validointia ja ammattimaista valvontaa ja vastuuta. Lisäksi mahdolliset virheelliset tiedot ja epäeettisyys ovat vielä ongelmana ja sovellusten kliinisen käyttöönoton esteenä. Tekoäly tutkimusten tavoitteina terveydenhuollon alalla useimmiten mainitaan päätöksenteon nopeutuminen, hoitoketjujen sujuvoittaminen, ajankäytön optimoiminen ja kustannusten minimoiminen. Selkeää näyttöä näiden tavoitteiden toteutumisesta ei vielä ole ja lisätutkimuksia tarvitaan realistisista kliinisistä hyödyistä sekä taloudellisista hyödyistä. Vaikka tekoälyn sovellukset hammaslääketieteessä ovat osoittaneet lupaavia tuloksia, tutkimusnäyttöön liittyy merkittäviä metodologisia rajoitteita, kuten pienet otoskoot, aineiston laadun vaihtelu ja mahdolliset vinoumat, jotka heikentävät tulosten yleistettävyyttä. Lisäksi mallien validointi on usein puutteellista erityisesti kliinisissä ympäristöissä, mikä korostaa tarvetta systemaattisemmille tutkimusasetelmille sekä läpinäkyvämmälle raportoinnille.

Tekoälyn tutkimuksissa kokeellisten töiden tavoite ei aina palvele kliinikkoa tai käytäntöä. Tutkimuksia on kiire julkaista, sillä sovellukset kehittyvät niin nopeasti, että tutkimuksen julkaisun aikaan tilanne on voinut kehittyä jo merkittävästi eteenpäin. Riittävän tutkimusmateriaalin ja tutkimuskysymyksen olisi syytä kuitenkin olla etusijalla.

Tekoälytutkimusten laatimiseen on useita erilaisia ohjeita niin eettisiin näkökulmiin kuin itse materiaalin käyttöön liittyen. (Uribe SE ym., 2025) Kliinisestä näkökulmasta lisäksi toivottavaa on, etteivät tulevaisuuden sovellukset sekoita raskaita potilasohjelmia entisestään, pidennä hoitokäytien kirjauksiin käytettävää aikaa tai muutoin lisää työmäärää. Nykyiset terveydenhuollon organisaatioissa käytössä olevat tietokoneet eivät välttämättä työskentele samalla nopeudella kuin ne, joilla sovellusta alun perin kehitettiin. Tekoäly sovellusten

käyttöönotto vaatii myös henkilökunnan koulutusta ja perehdytystä. Hammaslääketieteen asiantuntijoiden tulisi olla tekoälyn kehityksessä ja sovellusten käyttöönotossa tiiviisti mukana.

Hammaslääketieteen opetuksessa tekoälyä käsitellään vaihtelevasti eri oppialoilla. Opiskelijat opettelevat pääosin itsenäisesti, mitä tekoälypohjaista sovellusta voi käyttää ja missä tilanteissa. Tulevaisuudessa tekoälypohjaisten sovellusten käytön ohjauksen tarve on otettava tarkemmin huomioon opetuksessa. Yliopisto ohjeistaa tekoälyn käytöstä opiskelussa ja kirjoitustehtävissä, kuten loppututkielman kirjoittamisessa. Näitä ohjeistuksia on kuitenkin jatkuvasti tarkennettava ja täydennettävä tulevaisuudessa. Vaikka tekoälypohjaiset sovellukset eivät vielä ole kliinisesti validoituja potilastyöhön, on niistä silti keskusteltava, etenkin sovellusten heikkouksista ja riskeistä. Potilastyöhön liittyvien tekoälysovellusten käytön vastuu tulee olemaan hoitavalla hammaslääkärillä sovelluksen suoriutumisesta riippumatta.

7 Johtopäätökset

Tarkasteltujen tieteellisten artikkeleiden perusteella tekoäly ja sen eri alamuodot ovat laajalti tutkimuksen kohteena hammaslääketieteen alalla. Tutkimustulokset viittaavat siihen, että tekoälysovelluksilla on merkittävää potentiaalia tukea esimerkiksi diagnostiikkaa ja hoidon suunnittelua. Kliininen käyttöönotto on kuitenkin vielä kesken ja sovellusten käytännön hyödyntäminen vaatii lisätutkimusta.

Tekoälyn käyttöön potilastyössä liittyy myös keskeisiä haasteita, kuten potilasturvallisuuteen, vastuukysymyksiin ja eettisyyteen liittyviä näkökulmia. Lisäksi tekoälyn käyttöä koskeva sääntely terveydenhuollossa on vielä puutteellista. Tulevaisuudessa tarvitaan selkeämpiä ohjeistuksia ja mahdollisesti erikoisalakohtaisia säädöksiä turvallisen ja vastuullisen käytön varmistamiseksi, sillä yhdet säännöt eivät ole sovellettavissa kaikille erikoisaloille.

Tällä hetkellä ei ole havaittavissa viitteitä tekoälyn kykyjen kehityksen hidastumisesta. Tulevaisuudessa tekoälyn suoritustaso voi parantua ja tämän myötä voi löytyä aivan uudenlaisia sovelluskohteita.

Lähteet

Abbott LP, Saikia A, Anthonappa RP. ARTIFICIAL INTELLIGENCE PLATFORMS IN DENTAL CARIES DETECTION: A SYSTEMATIC REVIEW AND META-ANALYSIS. *J Evid Based Dent Pract.* 2025 Mar;25(1):102077. doi: 10.1016/j.jebdp.2024.102077. Epub 2024 Dec 12. PMID: 39947783.

Abdali HM, Ayoub AY, Omer RA, Alanazi RA, Alsaedi BS, Almutairi LB, Alhakami BA, Alfifa AY, Alnasser NA, Hakami AH. Applications of Artificial Intelligence in Oral and Maxillofacial Cosmetic Surgery: A Systematic Review of Diagnostic, Planning, and Outcome Assessment Tools. *Cureus.* 2025 Sep 12;17(9):e92185. doi: 10.7759/cureus.92185. PMID: 41089122; PMCID: PMC12516020.

Abonamah AA, Tariq MU, Shilbayeh S. On the Commoditization of Artificial Intelligence. *Front Psychol.* 2021 Sep 30;12:696346. doi: 10.3389/fpsyg.2021.696346. PMID: 34659012; PMCID: PMC8514611.

A. F. Leite, K. de F. Vasconcelos, H. Willems, R. Jacobs, Radiomics and Machine Learning in Oral Healthcare. *Prot. Clin. Appl.* 2020, 14, 1900040. <https://doi.org/10.1002/prca.201900040>

Al-Hamadani MNA, Fadhel MA, Alzubaidi L, Balazs H. Reinforcement Learning Algorithms and Applications in Healthcare and Robotics: A Comprehensive and Systematic Review. *Sensors (Basel).* 2024 Apr 11;24(8):2461. doi: 10.3390/s24082461. PMID: 38676080; PMCID: PMC11053800.

Aljulayfi IS, Almatrafi AH, Althubaitiy RO, Alnafisah F, Alshehri K, Alzahrani B, Gufran K. The Potential of Artificial Intelligence in Prosthodontics: A Comprehensive Review. *Med Sci Monit.* 2024 Jun 6;30:e944310. doi: 10.12659/MSM.944310. PMID: 38840416; PMCID: PMC11178143.

Bh MP, Yellapurkar S, Chengappa K, Pentapati KC, Poudyal S. Personalized Learning With Artificial Intelligence in Dental Education: An Integrative Review. *Int J Dent.* 2026 Jan 16;2026:8928166.

Caterson J, Lewin A, Williamson E. The application of explainable artificial intelligence (XAI) in electronic health record research: A scoping review. *Digit Health.* 2024 Oct 30;10:20552076241272657. doi: 10.1177/20552076241272657. PMID: 39493635; PMCID: PMC11528818.

Euroopan parlamentti ja neuvosto. (2024). Asetus (EU) 2024/1234 tekoälyjärjestelmistä (AI Act).

Felek T, Tercanlı H, Gök RŞ. Evaluating vision transformers and convolutional neural networks in the context of dental image processing: a systematic review. *BMC Oral Health*. 2025 Oct 15;25(1):1626. doi: 10.1186/s12903-025-07036-5. PMID: 41094490; PMCID: PMC12522997.

Gracea RS, Winderickx N, Vanheers M, Hendrickx J, Preda F, Shujaat S, Cadenas de Llano-Pérula M, Jacobs R. Artificial intelligence for orthodontic diagnosis and treatment planning: A scoping review. *J Dent*. 2025 Jan;152:105442. doi: 10.1016/j.jdent.2024.105442. Epub 2024 Nov 4. PMID: 39505292.

Guyen Y, Ozdemir OT, Kavan MY. Performance of Artificial Intelligence Chatbots in Responding to Patient Queries Related to Traumatic Dental Injuries: A Comparative Study. *Dent Traumatol*. 2025 Jun;41(3):338-347. doi: 10.1111/edt.13020. Epub 2024 Nov 22. PMID: 39578674.

H. Ding, J. Wu, W. Zhao, J. P. Matinlinna, M. F. Burrow & J. K. H. Tsoi, Artificial intelligence in dentistry—A review. *Front. Dent. Med*. 2023, 4, 1085251. <https://doi.org/10.3389/fdmed.2023.1085251>

Haylaz, E., Gumussoy, I., Kalabalik, F. et al. Evaluation of the performance of four different large language models (ChatGPT, DeepSeek, Copilot, and Gemini) in answering oral, and maxillofacial radiology questions: pilot study. *BMC Oral Health* (2026).

Manek M, Maita I, Bezerra Silva DF, Pita de Melo D, Major PW, Jaremko JL, Almeida FT. Temporomandibular joint assessment in MRI images using artificial intelligence tools: where are we now? A systematic review. *Dentomaxillofac Radiol*. 2025 Jan 1;54(1):1-11. doi: 10.1093/dmfr/twae055. PMID: 39563454; PMCID: PMC11800278.

Maryna Bilan, 2023, Hallucinations in LLMs: What You Need to Know Before Integration <https://masterofcode.com/blog/hallucinations-in-llms-what-you-need-to-know-before-integration>.

Mohammad-Rahimi H, Sohrabniya F, Ourang SA, Dianat O, Aminoshariae A, Nagendrababu V, Dummer PMH, Duncan HF, Nosrat A. Artificial intelligence in endodontics: Data preparation, clinical applications, ethical considerations, limitations, and future directions. *Int*

Endod J. 2024 Nov;57(11):1566-1595. doi: 10.1111/iej.14128. Epub 2024 Jul 29. PMID: 39075670.

Oztekin F, Katar O, Sadak F, Yildirim M, Cakar H, Aydogan M, Ozpolat Z, Talo Yildirim T, Yildirim O, Faust O, Acharya UR. An Explainable Deep Learning Model to Prediction Dental Caries Using Panoramic Radiograph Images. *Diagnostics (Basel)*. 2023 Jan 7;13(2):226. doi: 10.3390/diagnostics13020226. PMID: 36673036; PMCID: PMC9858273.

Rana M, Sakkas A, Zimmermann M, Kostyuk M, Schwarz G. Artificial Intelligence in Oral and Maxillofacial Surgery: Integrating Clinical Innovation and Workflow Optimization. *J Clin Med*. 2026 Jan 6;15(2):427. doi: 10.3390/jcm15020427. PMID: 41598365; PMCID: PMC12841934.

Revilla-León M, Gómez-Polo M, Barmak AB, Inam W, Kan JYK, Kois JC, Akal O. Artificial intelligence models for diagnosing gingivitis and periodontal disease: A systematic review. *J Prosthet Dent*. 2023 Dec;130(6):816-824. doi: 10.1016/j.prosdent.2022.01.026. Epub 2022 Mar 14. PMID: 35300850.

Rocha AO, Anjos LMD, Miranda NO, Santos PS, Vitali FC, Henriques B, Watts DC, Cardoso M. 41 Years of Dental Materials (1985-2025): A Metrics-Based Perspective on Publication Trends. *Dent Mater*. 2026 Jan 12:S0109-5641(26)00002-3. doi: 10.1016/j.dental.2026.01.002. Epub ahead of print. PMID: 41529971.

Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. *Journal of Dental Research*. 2020;99(7):769-774. doi:10.1177/0022034520915714

Uribe SE, Hamdan MH, Valente NA, Yamaguchi S, Umer F, Tichy A, Pauwels R, Schwendicke F. Evaluating dental AI research papers: Key considerations for editors and reviewers. *J Dent*. 2025 Sep;160:105867. doi: 10.1016/j.jdent.2025.105867.