

Panoraamatomografiakuva – hammaslääketieteellisen diagnostiikan kivijalka

Syventävien opintojen kirjallinen työ
Turun yliopisto
Lääketieteellinen tiedekunta
Hammaslääketieteen laitos: Suupatologian ja suurradiologian oppiaine

Laatija:
Pihla Lindholm

9.4.2026
Turku

Syventävien opintojen kirjallinen työ

Oppiaine: Suupatologia ja suuradiologia

Tekijä: Pihla Lindholm

Otsikko: Panoraamatomografiakuva – hammaslääketieteellisen diagnostiikan kivijalka

Ohjaaja: EHL, HLT Niina Kuusisto

Sivumäärä: 29 sivua

Laajuus: 20 op

Päivämäärä: 9.4.2026

Tiivistelmän tyyli on **Abstract**.

Syventävien opintojen kirjallisen työn aiheena oli panoraamatomografia (PTG)-kuvauksen kehitys ja tekoälysovellukset diagnostiikassa. Tavoitteena oli esittää kuvauksen historiaa, kehitystä, sekä selvittää minkälaisia tekoälysovelluksia on kehitteillä PTG-kuvien diagnostiikan avuksi. Työ toteutettiin kirjallisuuskatsauksena PubMedin aineistoja hyödyntäen.

PTG-kuvaukset ovat säilyttäneet asemansa hammaslääketieteellisessä diagnostiikassa jo yli seitsemän vuosikymmenen ajan. Kuvauslaitteistot ovat kehittyneet parantaen kuvanlaatua ja tehden diagnostiikasta tarkempaa. Tällä vuosikymmenellä tekoäly on uutena ilmiönä tulossa avuksi diagnostiikkaan. Parhaimmillaan se voi nopeuttaa ja helpottaa klinikon työtä. Sovelluksia on kehitetty esimerkiksi kariksen, parodontiitin, leukanivelten, viisaudenhampaiden ja kasvainten diagnostiikkaan.

Katsauksen mukaan otetuissa tutkimuksissa tekoälysovelluksilla on saatu lupaavia tuloksia, joskin tarkkuudeltaan todella vaihtelevia. Suurimpia ongelmia sovellusten kehitykselle ovat koulutusaineiston määrä ja laatu, päällekkäin kuvautuvat rakenteet sekä diagnostiikan moninaisuus. Kehitetyt sovellukset keskittyvät usein vain yhteen aspektiin, esimerkiksi kariekseen, sillä koko PTG-kuvan diagnostiikan mahdollistaminen yhteen sovellukseen vaatisi huomattavan paljon suorituskykyä ja tutkimusta. Tulevaisuudessa tekoälyn ennustetaan olevan isossa roolissa diagnostiikassa, mutta vielä tarvitaan lisätutkimuksia ja sovellusten validaatiota kliiniseen työhön.

Avainsanat: PTG-kuvaukset, panoraamatomografia, tekoäly, diagnostiikka

Sisällysluettelo

1	Johdanto	4
2	Materiaalit ja metodit	5
3	Panoraamatomografiakuvan historia	6
4	Panoraamatomografiakuvauksen perusteet	8
4.1	Kuvausindikaatiot	10
4.2	Kuvanlaatu ja kuvausvirheet	11
5	Panoraamatomografian diagnostiikka	18
5.1	Tekoälysovellukset diagnostiikassa	18
5.1.1	Karies	19
5.1.2	Parodontiitti	21
5.1.3	Apikaaliparodontiitti	22
5.1.4	Leukanivelet	24
6	Pohdinta	26
7	Yhteenveto	28
	Lähteet	28

1 Johdanto

Panoraamatomografiakuvaus on ollut käytössä lähes muuttumattomana jo yli seitsemän vuosikymmenen ajan. Ensimmäinen panoraamatomografialaite (PTG) otettiin käyttöön Suomessa vuonna 1951 Helsingin yliopiston hammaslääketieteen laitoksessa¹. Sittenkin kuvauksessa on siirrytty digitaalisiin laitteistoihin, mutta peruseriaate on pysynyt samana.

Vuonna 2021 Suomessa tehtiin 2 204 935 hammasröntgentutkimusta, joista 386 184 oli PTG-kuvauksia². PTG-laitteita Suomessa oli vuoden 2023 lopussa 604³.

Yksi syy PTG-kuvauksen suosioon on sen indikaatioiden monipuolisuus. PTG-kuvaa voidaan käyttää muun muassa kariksen, parodontiitin, traumojen, kasvainten ja apikaaliparodontiitin diagnostiikassa sekä ortodonttisten ja proteettisten toimenpiteiden suunnittelussa. PTG-kuva on hyvä lähtökohta diagnostiikalle ja jatkotoimenpiteille. Lisäksi PTG-kuvauksesta aiheutuva säteilyannos on suhteellisen pieni, sillä se vastaa noin yhden vuorokauden taustasäteilyä tai kahta intraoraaliröntgenkuvaa (Taulukko 1).

PTG-kuvan diagnostiikkaan on lähiaikoina kehitetty tekoälyyn perustuvia ohjelmistoja lukuisiin eri tarkoituksiin, joista tässä katsauksessa käsitellään diagnostiikan kannalta keskeisimpiä ja tutkituimpia. Uutta tutkimusta tehdään tällä hetkellä runsaasti ja tekoälyllä on monipuolista potentiaalia kliinisen työn tehostajana ja avustajana. Tämän lopputyön tavoitteena on esittää PTG-kuvauksen taustaa ja hyötyjä, joiden vuoksi se on säilynyt pitkään hammaslääketieteellisen diagnostiikan perustana. Kirjallisuuskatsauksen tavoitteena on selvittää, minkälaisia tekoälyohjelmistoja on kehitteillä ja millaista hyötyä ne voivat potentiaalisesti tuoda klinikalle.

Taulukko 1. Suun alueen röntgentutkimusten efektiivisiä annoksia. (Hammasröntgentoiminnan laadunvalvonta ja kuvaushuoneen säteilynsuojaukset, STUK 2011)

Tutkimus	Efektiivinen annos / mSv
Intraoraaliröntgenkuvaus	0,01
Panoraamatomografiakuvaus	0,02
Pienen kentän KKT	0,05-0,7

2 Materiaalit ja metodit

Kirjallisuushaku suoritettiin PubMed-tietokannassa käyttäen MeSH hakutermejä ”AI”, ”artificial intelligence”, ”panoramic radiography”, ”dental caries”, ”apical periodontitis”, ”parodontitis” ja ”TMJ”. Lisäksi hyödynnettiin alan muuta kirjallisuutta.

3 Panoraamatomografiakuvan historia

Ensimmäiset PTG-kuvat toimivat yhden pyörähdysakselin mallilla, jossa filmi sijoitettiin potilaan suuhun ja röntgenputki kiersi potilaan ympäri. Ensimmäisinä menetelmää kokeilivat Alvin Zulauf Yhdysvalloissa vuonna 1922 ja Hisatugu Numata Japanissa vuonna 1933. Myöhemmin vuonna 1943 valmistettiin laite, jossa tilanne oli päinvastainen: röntgenputki oli suussa liikkumattomana ja filmi potilaan kasvoja vasten.¹

PTG-laitetta lähti jatkokehittämään suomalainen hammaslääkäri Yrjö Paatero (1901–1963) Suomessa (Kuva 1). Ensimmäisessä ekstraoraalilaitteessa kuvauslevy oli kiinnitetty potilaaseen, joka pyörähti röntgenputken edessä putken pysyessä paikoillaan. Tällainen laite otettiin ensimmäisenä PTG-laitteena käyttöön.¹

Nykyisenkaltaista kolmen pyörähdysakselin laitetta Paatero kehitti diplomi-insinööri Timo Niemisen (1921–2003) kanssa 1950-luvulla. Ensimmäinen prototyyppi valmistui vuonna 1957 ja kaupallinen tuotanto aloitettiin vuonna 1961¹. Tuotantoa varten perustettiin Lääkintäsähkö Oy:n tytäryhtiö Palomex vuonna 1964 ja Nieminen valittiin sen toimitusjohtajaksi⁴. Planmeca, Suomen tämän hetken suurin röntgenlaitteita valmistava yritys, perustettiin 1971⁵.

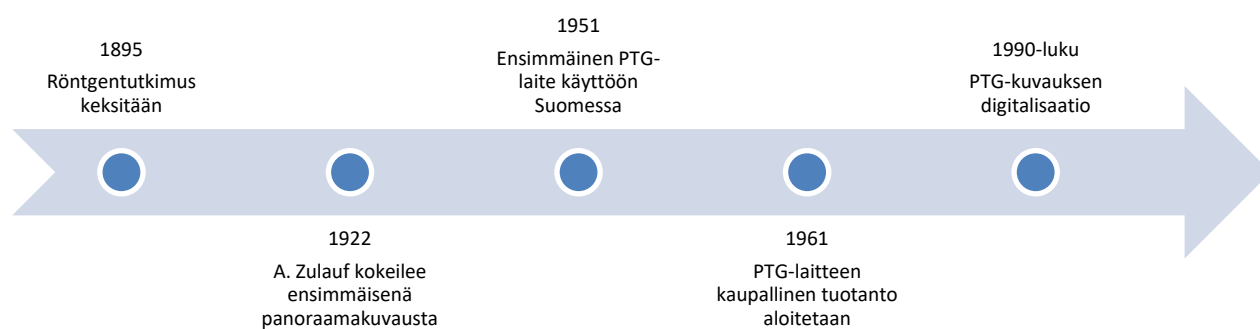
PTG-kuvat ovat alun perin olleet filmille kehitettyjä. Ne ovat muuttuneet sittemmin digitaalisiksi 1990-luvulla (Kuva 2), mikä on mahdollistanut nopeamman kuvauksen ja paremman kuvanlaadun (Kuva 3)¹. Planmeca on ollut mukana tuottamassa digitaalikuvantamisjärjestelmää 90-luvulla⁵.



Kuva 1. Yrjö Paatero työssään varhaisen PTG-laitteen parissa. (Pekka Kyytinen, 1950–1959, [Museovirasto](#), CC BY 4.0)



Kuva 2. Nykyaikainen PTG-laite. Kuvassa Planmecan ProMax® 2D S3 (Planmeca)




Kuva 3. Aikajana PTG-laitteen kehityksestä. (Oma kuva, tehty Wordilla)

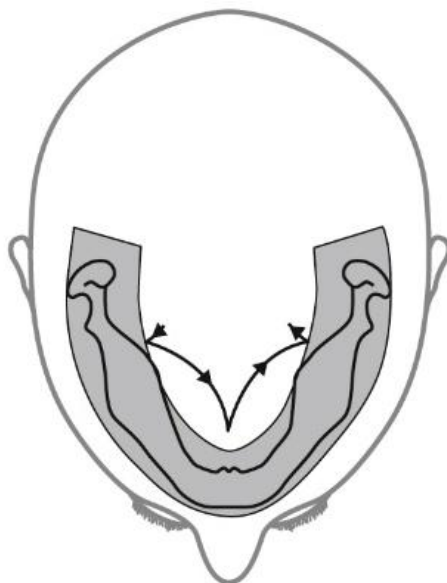
4 Panoraamatomografiakuvauksen perusteet

PTG-kuvaus perustuu kerroskuvaukseen, jossa tarkasti kuvautuva kerros on leukojen muotoinen alue (Kuva 4). Kerros on etualueella n. 8–12 mm paksu ja taka-alueella 28 mm. Muissa syvyyksissä olevat rakenteet kuvautuvat epätarkasti, eivätkä suurilta osin näy kuvassa, mikä mahdollistaa selkeän kuvan leuoista muista ympäröivistä rakenteista huolimatta. ⁶

Kuvauksessa röntgenputki ja kuvavastaanotin pyörähtävät potilaan pään ympäri synkronoidusti. Leuat ovat enemmän V-kirjaimen kuin puoliympyrän muotoiset, joten kuvauskeskipisteen täytyy muuttua pyörähdysten aikana tarkkan kuvan saavuttamiseksi. Nykyaikaisissa laitteissa kuvauskeskipiste muuttuu tasaisesti koko pyörähdysten ajan (Kuva 5). ⁶




Kuva 4. Tarkasti kuvautuva kerros alaleuassa. (Kirjasta White and Pharoah's Oral Radiology : Principles and Interpretation, 2019 ⁶)



Kuva 5. Kuvauskeskipisteen liike panoraamatomografiakuvauksen aikana. (Kirjasta Whites ja Drage, Essentials of Dental Radiography and Radiology, 2021 7)

Röntgenlähteestä tulevat säteet rajataan kapeaksi pystysuuntaiseksi palkiksi lyijykollimaattorilla. Toinen kollimaattori kuvauskohteen ja kuvavastaanottimen välillä rajaa pois kohteesta sironnutta säteilyä (Kuva 6).⁶



Kuva 6. Panoraamatomografiakuvan muodostuminen. (Kirjasta White and Pharoah's Oral Radiology : Principles and Interpretation, 2019 6)

Tarkasti kuvautuva kerros on se puoli leuoista, joka on kuvauskeskipisteen ja vastaanottimen välissä. Tämä kerros on siis todellista kuvaa. Kuvauskeskipisteestä posteriorisesti sijaitsevat rakenteet (kieliluu, kurkunkansi ja niskanikamat) kuvautuvat pyörähdysliikkeen aikana kaksi kertaa. Ne kuvautuvat siis oikealle ja vasemmalle puolelle aiheuttaen kaksoiskuvia.

Röntgenputken ja kuvauskeskipisteen välissä olevat rakenteet aiheuttavat haamukuvia vastakkaiselle puolelle niiden oikeasta sijainnista. Ne näkyvät kuvassa ylempänä kuin oikea rakenne, sillä röntgenputki on suunnattu 8 astetta ylöspäin. Haamukuvia aiheuttavat alaleuan ramukset, kova suulaki, potilaan korut sekä etualueelle kieliluu ja niskanikamat. ⁶

PTG-kuvausta on mahdollista myös rajata kattamaan vain tietyt alueet leuoista. Esimerkiksi lapsilla voidaan rajata kuvaus kattamaan vain hampaiston alue tai vain leukanivelten alueet. Rajaamalla saadaan pienennettyä potilaan sädeannosta.

4.1 Kuvausindikaatiot

Panoraamatomografiakuvasta saadaan nopeasti ja helposti kokonaiskuva hampaistosta ja potilaan suun terveyden tilasta. Kuvasta saadaan myös tietoa hampaiden hoitohistoriasta. Kuvaus on nopea suorittaa, mutta se vaatii potilaalta kooperaatiota kuvausasettelua varten. PTG-kuvaus on usein helpompi suorittaa potilaalla, joka sietää huonosti intraoraalikuvausta. ⁶

Kariesdiagnostiikassa PTG-kuva antaa hyvän yleisnäkymän hampaiston kunnosta, mutta päällekkäin kuvautumisen vuoksi tarvitaan usein myös tarkentavia intraoraalikuvia ⁶.

Intraoraalikuvienv resoluutio on PTG-kuvaa parempi ja siksi ne sopivat paremmin kariesdiagnostiikkaan. Parodontitiin diagnostiikassa PTG-kuva antaa yleiskuvan luurajan kulusta, luudefekteistä ja furkaatioleesioista ⁸.

Viisaudenhampaiden diagnostiikassa PTG-kuva on ensisijainen tutkimus erityisesti alaviisaudenhampaiden ja mandibulaarikanavan suhteen arvioimisessa. Se on suositeltavin tutkimus kaikkien viisaudenhampaiden puhkeamisasteen, asennon, perikoronaali- tai follikkelitilan arviointiin. ⁹

PTG-kuvausta käytetään lisäksi infektiotokusten yksilöllisessä arvioinnissa leikkauksia edeltävästi sekä joidenkin lääkitysten aloitusta edeltävästi. Näissä tilanteissa PTG-kuvaa täydennetään tarvittaessa intraoraali- tai kartiokeilatietokonetomografia (KKTT)-tutkimuksilla ⁷. Kuvauksella voidaan tutkia myös muita luunsisäisiä kystia ja kasvaimia ⁶.

Päivystyksellisesti PTG-kuvaus on käytössä äkillisissä hammasperäisissä infektioiden tai niiden epäilyissä¹⁰. Myös alaleuan murtumaepäilyissä PTG on hyvä alkukuva⁶. Hammastraumat sen sijaan suositellaan kuvattavan intraoraalikuvien paremman resoluution vuoksi.

Leukanivelten oireet voidaan tutkia alkuun PTG-kuvalla diagnoosin vahvistamiseen tai poissulkuun. Leukanivelten pidempiaikaisemman oireilun tai sairauden tutkimukseen tarvitaan usein kolmiulotteinen KKTT- tai magneettitutkimus.¹¹

PTG-kuvausta käytetään laajalti oikomishoidon suunnittelun ja hoidon tulosten arvioinnin apuna. Puhkeamattomien tai osittain puhjenneiden hampaiden paikallistaminen ja asennon luotettava arviointi vaatii usein kolmiulotteisen KKTT-tutkimuksen, mutta PTG toimii alkutilanteessa hyvin. Se ei kuitenkaan pääsääntöisesti sovi alle 6-vuotiaille lapsille säteilyaltistuksen ja vaadittavan kooperaation vuoksi. Lapsilla säteilyaltistusta voidaan pienentää rajaamalla kuvattavaa aluetta pienemmäksi.⁷

Kuvaus on kontraindisoitu, mikäli potilasta ei pystytä asettelemaan kuvauksen ajaksi oikein. Tällaisia tilanteita voi olla esimerkiksi, mikäli potilas ei liikuntarajoitteen vuoksi pysty olemaan laitteessa oikeassa asennossa. Potilaan täytyisi myös pystyä olemaan paikallaan kuvauksen ajan.⁵

4.2 Kuvanlaatu ja kuvausvirheet

Hyvässä PTG-kuvassa tulisi näkyä kokonaan ylä- ja alaleuka hampaineen sekä leukanivelet. Oikean- ja vasemmanpuoleisten molaarien tulisi olla keskenään yhtä leveitä mesiodistaalisuunnassa, leuan muodon tulisi olla symmetrinen ja leukanivelten samassa horisontaalisessa tasossa. Ylä- ja alahampaat tulisi olla tarkasti kuvautuvassa kerroksessa. Kuvassa ei saisi näkyä koruista tai irtoproteeseista johtuvaa artefaktaa eikä kielen väärästä asettelusta johtuvaa varjostumaa ylätuhampaiden juurten päällä. Kuvasta tulisi olla erotettavissa hampaiden juuret ja parodontaaliraot, lisäksi kiilteen ja dentiinin tulisi erottua toisistaan. Kokonaisuutena kuvan tulisi olla diagnostinen niin, että pystytään vastaamaan taustalla olevaan kliiniseen kysymykseen. Kuvausvirheet voivat johtua laitteistosta, potilaan asettelusta tai potilaan yllä olevista metalliesineistä.⁷

PTG-laitteen kuvanlaatua mitataan testauslevyllä (Kuva 7), jossa on ohuita lyijynauhoja eri etäisyyksillä erotustarkkuuden määrittämiseksi sekä reikiä (1,0; 1,5; 2,0 ja 2,5 mm) matalan

kontrastin tarkkuuden määrittämiseksi. Panoraamakuvassa tulisi erottua ainakin 2,5 lyijyviivaparia millimetrillä sekä 2,0 mm:n ja 2,5 mm:n reiät. ⁷




Kuva 7. Kuvanlaadun testauslevy. (Kirjasta Whites ja Drage, Essentials of Dental Radiography and Radiology, 2021 ⁷)

PTG-kuvan onnistumiseksi potilas on asetettava oikein. Hänen tulisi purra laitteen purutikkua inkisaalikärjet vastakkain siirtämättä samalla leukaa sivusuunnassa. Kasvojen keskiviivan tulisi olla suoraan keskellä ja pään asennon suoraan eteenpäin. Laitteen laservalot (Kuva 8) tulisi asetella kasvojen keskiviivaan, kulmahammastasoon ja horisontaalinen laservalo Frankfort tason mukaisesti. Potilaan tulisi kallistaa leukaa hieman alaspäin, jotta purentataso on kallistuneena noin 20 astetta alas eteen. Niskan tulisi olla suorassa, mikä onnistuu tuomalla rintakehää eteenpäin. Potilaan tulisi kuvauksen ajaksi viedä kieli tasaisesti kitalakea vasten ja pysyä liikkumatta. ⁶




Kuva 8. PTG-laitteen laservalot kasvojen keskiviivassa, Frankfort tasolla ja kulmahammastasossa. (Kirjasta Whites ja Drage, Essentials of Dental Radiography and Radiology, 2021 ⁷)

Jos etuhampaat purevat purentatikkua liian anteriorisesti, ne jäävät tarkasti kuvautuva kerroksen ulkopuolelle ja näkyvät kuvassa epätarkkoina ja kapeina (Kuva 9). Jos etuhampaat purevat liian posteriorisesti, ne näkyvät epätarkkoina ja leventyneinä (Kuva 10). ⁷




Kuva 9. Etuhampaat kuvautuvan kerroksen edessä. (Kirjasta Langland O. et al. Panoramic Radiology. 1982.)




Kuva 10. Etuhampaat kuvautuvan kerroksen takana. (Kirjasta Langland O. et al. Panoramic Radiology. 1982.)

Mikäli okklusaalitaso on kallistunut liikaa eteenpäin, eli leuka on liian alhaalla, kuvassa leuat näkyvät jyrkkänä kaarena ja alaetuhampaat kuvautuvat sumeina (Kuva 11). Tällöin esimerkiksi kondyyliit voivat jäädä kuvan ulkopuolelle. Jos taas okklusaalitaso on liian suorassa horisontaaliseen tasoon nähden, eli leuka on liian ylhäällä, leuat näkyvät kuvassa suorina ja leveinä ja yläetuhampaat jäävät epätarkoiksi (Kuva 12).⁷



Kuva 11. Leuan asettelu liian alhaalla. (Kirjasta Langland O. et al. Panoramic Radiology. 1982.)




Kuva 12. Leuan asettelu liian ylhäällä. (Kirjasta Langland O. et al. Panoramic Radiology. 1982.)

Mikäli sagittaalitaso on kallistunut, eli potilas on kallistanut päätään sivulle, kuvasta tulee vino ja rakenteita saattaa jäädä kuvan ulkopuolelle (Kuva 13). Mikäli taas potilas on kiertänyt päätään sivulle, sen puolen hampaat, jonka suuntaan päätä on kierretty, näyttävät leveiltä ja etualue epätarkalta ja toisen puolen hampaat taas kuvautuvat kapeina (Kuva 14).⁷




Kuva 13. Sagittaalitaso kallistunut oikealle. (Kirjasta Langland O. et al. Panoramic Radiology. 1982.)




Kuva 14. Sagittaalitaso kiertynyt vasemmalle. (Kirjasta Langland O. et al. Panoramic Radiology. 1982.)

Mikäli potilaan niska on ollut etukumaramassa eikä suorana, kuvan keskelle jää niskanikamien varjostuma, jonka vuoksi etuhampaita on haastava erottaa kuvasta (Kuva 15). Mikäli potilaan kieli ei ole ollut kiinni kitalaessa kuvauksen aikana, syntyy kielestä varjo, mikä hankaloittaa ylähampaiden juurenkärkien arviointia (Kuva 16).⁷



Kuva 15. Niska ei ole ollut suorassa. (Kirjasta Langland O. et al. Panoramic Radiology. 1982.)



Kuva 16. Kieli ei ole ollut kiinni kitlaessa. (Kirjasta Langland O. et al. Panoramic Radiology. 1982.)

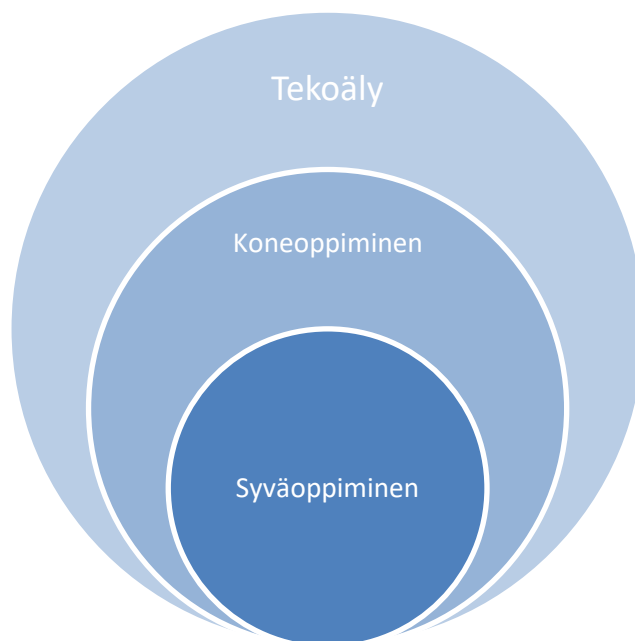
5 Panoraamatomografian diagnostiikka

PTG-kuvan diagnostiikkaa hankaloittavat päällekkäin kuvautuvat rakenteet eli summaatio ja haamukuvat, vierasesineet sekä potilasasettelusta johtuvat kuvausvirheet. Diagnostiikkaa varten tarvitaan myös tarkoituksenmukainen näyttö, joka on tarpeeksi suuri, kirkas ja tarkka¹². Hammaslääkäriltä vaaditaan tarkkaa tietoa anatomiasta ja patologisten löydösten tunnistamisesta röntgenkuvassa⁷.

5.1 Tekoälysovellukset diagnostiikassa

PTG-kuvan diagnostiikkaan on kehitetty ja kehitetään parhaillaan erilaisia tekoälypohjaisia sovelluksia, jotka auttavat diagnostiikassa ehdottamalla löydöksiä kuvasta. Tekoälyllä tarkoitetaan sovellusta tai teknologiaa, joka kykenee suorittamaan tehtäviä tai ongelmanratkaisua. Tekoälymalleja on useita erilaisia.

Diagnostiikan alalla tekoälysovellukset perustuvat pitkälti koneoppimiseen ja syväoppimiseen (Kuva 17). Koneoppimisessa ohjelmalle annetaan aineisto, joka on jo valmiiksi luokiteltua ja ohjelma oppii tekemään päätöksiä esimerkin kautta. Syväoppimisessä ohjelma oppii itse luokittelemaan tietoa vähemmällä ihmisen avulla. Syväoppimisen alle kuuluvat esimerkiksi neuroverkot, joista konvoluutioneuroverkkoja käytetään paljon hammaslääketieteen diagnostiikkaan. Neuroverkot matkivat aivojen neuronien ja synapsien toimintaa ja oppivat tunnistamaan kuvioita. Nämä mallit on tarkoitettu erityisesti visuaalisen tiedon, kuten röntgenkuvien analysointiin. PTG-kuvien diagnostiikan sovellukset hyödyntävät kone- ja syväoppimista, joiden avulla sovellukset oppivat tunnistamaan kuvista patologisia löydöksiä.¹³



Kuva 17. Kaavio tekoölyn käsitteiden välisistä suhteista. (Oma kuva, tehty Wordilla)

5.1.1 Karies

Puolalaisessa tutkimuksessa tutkittiin jo markkinoilla olevan Diagnocat-sovelluksen luotettavuutta PTG-kuvien diagnosoinnissa. Aineistona oli 30 PTG-kuvaa, joissa kaikissa näkyi vähintään kuusi hammasta. Tekoölyn lisäksi kolme hammaslääkärinä kävivät kuvat läpi. Kuvista analysoitiin puuttuvien hampaiden määrä, karies, paikatut hampaat, proteettiset rakenteet, juurihoidetut hampaat, jäännösjuuret, periapikaalileesiöt ja luukato. Luotettavuuden arvioimiseksi pohjatotuudeksi määritettiin havainnot, joista vähintään kaksi kolmesta ammattilaisesta olivat samaa mieltä. Kuvan analysoimiseen meni tekoölyllä korkeintaan 2 minuuttia ja ihmisellä korkeintaan 8,5 minuuttia. Kariuksen ja paikattujen hampaiden osalta sovelluksen spesifisyys oli todella korkea ($>0,9$), ja sensitiivisyys paikattujen hampaiden osalta korkea (0,83). Kariuksen osalta sensitiivisyys oli kuitenkin matala (0,45), joka aiheuttaa riskin alidiagnosointiin. Tutkimuksessa todetaan sovelluksen olevan hyödyllinen alku diagnosoille, mutta se vaatii ammattilaisen tarkistusta.¹⁴

Alankomaalaisessa tutkimuksessa tutkittiin konvoluutioneuroverkkoihin perustuvan MobileNet V2 -mallin luotettavuutta viisaudenhampaiden kariuksen arvioinnissa. Tutkimukseen otettiin mukaan 253 PTG-kuvaa, joista rajattiin yhteensä 500 kuvaa yksittäisistä viisaudenhampaista, joista puolessa kuvista oli kariesta ja puolessa ei. Luokittelun teki kaksi hammaslääkärinä ja mikäli he olivat eri mieltä kuvasta, se jätettiin pois.

Ohjelman koulutukseen käytettiin 320 kuvaa, validointiin 80 ja testaukseen 100. Ohjelman tulokset olivat korkeita: positiivinen ennustearvo oli 0,88; sensitiivisyys 0,86 ja spesifisyys 0,88. Tutkimus kuvaa tuloksia lupaaviksi ja tekoäly voikin jatkossa helpottaa karioituneen viisaudenhampaan poistopäätöksen tekemistä. ¹⁵

Turkkilainen tutkimus tutki konvoluutioneuroverkkoihin perustuvan YOLOv7 -mallin luotettavuutta kiinteiden proteettisten rakenteiden alla olevan kariksen tunnistamisessa. Ohjelman kouluttamiseen käytettiin 904 PTG-kuvaa ja testaukseen 100 kuvaa. Kaksi proteetikkoa luokittelivat kuvista hampaat karioituneiksi ja ei-karioituneiksi, joista tutkimukseen hyväksyttiin vain kuvat, joista he olivat samaa mieltä. Kuvista rajattiin hampaat, joissa oli kiinteä proteettinen rakenne ja rajattuja kuvia tuli koulutusmateriaaliin 2248 ja testimateriaaliin 219. Sensitiivisyys oli tutkimuksessa kariksen osalta 0,79 ja positiivinen ennustearvo 0,84. Tutkimustulokset ovat lupaavia, mutta jatkotutkimuksia tarvitaan. ¹⁶

Thaimaalainen tutkimus selvitti konvoluutioneuroverkkoihin perustuvan Attention U-Net -mallin kykyä segmentoida kariesleesioita PTG-kuvista. Tutkimukseen otettiin mukaan 500 PTG-kuvaa potilailta, joista oli saatavilla myös Bitewing-kuvat samalta päivältä diagnostiikan tarkentamiseksi. Kaksi radiologia merkkasi kuvista kariokset pinta-aloina pikselin tarkkuudella ja tilanteissa, joissa he olivat eri mieltä, kolmas kokeneempi radiologi teki päätöksen. Kuviiin käytettiin ensin YOLOv5s -mallia yksittäisten hampaiden tunnistukseen ja rajaukseen omiksi kuvikseen (positiivinen ennustearvo 1,00 ja sensitiivisyys 0,99), joista sitten toinen malli tunnisti kariesta. Yhteensä yksittäisiä hampaita kuvissa oli 14997, joista 2161 hammasta, joissa oli kariesta, käytettiin koulutukseen ja 737 validointiin ja testaukseen. Kariksen tunnistamiseen testattiin aluksi useampaa mallia, joista Attention U-Net suoriutui parhaiten. Malli luokitteli hampaat karioituneisiin ja ei-karioituneisiin. Kaikkien hampaiden osalta positiivinen ennustearvo oli 0,68; sensitiivisyys 0,96 ja spesifisyys 0,94. Pelkkiä molaareja tarkastellessa positiivinen ennustearvo oli korkeampi (0,77). Kun tarkasteltiin kariesta sen levinneisyyden mukaan, malli tunnisti parhaiten pulpaan asti ulottuvat leesiot ja heikoiten kiillekariokset. Tulokset ovat lupaavia ja tekoäly voi auttaa klinikoita alkuun kariesdiagnostiikassa. Malli oli enemmän sensitiivinen kuin spesifinen, jolloin riskinä on pikemminkin ylidiagnosointi, kuin että leesioita jäisi huomaamatta. ¹⁷

Taulukko 2. Tutkimuksissa löydetty sensitiivisyys ja spesifisyys kariksen tunnistamisessa.

Tutkimus	Testausaineiston lkm.	Sensitiivisyys	Spesifisyys
Zadrožny, Ł. et al.	30	0,45	>0,9
Vinayahalingam, S. et al.	100	0,86	0,88
Ayhan, B. et al.	100	0,79	-
Pornprasertsuk-Damrongsri, S. et al.	737	0,96	0,94

5.1.2 Parodontiitti

Puolalaistutkimuksessa Diagnocat-sovellus luokitteli hampaat sen mukaan, oliko niissä alveoliluukatoa. PTG-kuvia oli 30. Sensitiivisyys (0,80) ja spesifisyys (0,85) olivat molemmat korkeita. ¹⁴

Turkkilaisessa tutkimuksessa tutkittiin U-Net sovellukseen pohjautuvan konvoluutioneuroverkon luotettavuutta koko leuan alveoliluukadon, yksittäisten luutaskujen ja furkaatiovaurioiden tunnistuksessa. Luutaskut luokiteltiin vielä horisontaalisiin ja vertikaalisiin. Kolme parodontologia ja yksi suurradiologi kävivät kuvat läpi ja mukaan otettiin ne, joista kaikki heistä olivat yhtä mieltä. Vaurioita merkittiin kuviin pinta-aloina. Kokonaisluukadon mittauksessa kuviin merkittiin alueet ylä- ja alaleukaan, jotka kulkivat luurajaa ja hampaiden kiille-sementtirajaa pitkin. Luutaskut merkittiin kahden vierekkäisen hampaan kiille-sementtirajan ja niiden välisen luurajan mukaan. Kokonaisluukadon arvioinnissa käytettiin 1028 kuvaa koulutukseen ja 93 kuvaa testaukseen. Sensitiivisyys oli 1,00; spesifisyys 0,99 ja positiivinen ennustearvo 1,00. Horisontaalisten luutaskujen arvioinnissa koulutukseen käytettiin 759 kuvaa ja testaukseen 93 kuvaa. Sensitiivisyys oli 0,95; spesifisyys 0,89 ja positiivinen ennustearvo 0,94. Vertikaalisten luutaskujen arvioinnissa koulutukseen käytettiin 759 kuvaa ja testaukseen 69 kuvaa. Sensitiivisyys oli 0,56; spesifisyys 0,51 ja positiivinen ennustearvo 0,85. Furkaatioleesioiden arvioinnissa koulutukseen käytettiin 1780 kuvaa ja testaukseen 161 kuvaa. Sensitiivisyys oli 0,89; spesifisyys 0,84 ja positiivinen ennustearvo 0,93. Tulokset ovat hyviä, mutta tutkimuksessa mainitaan lisatarve erityisesti luutaskujen tutkimukselle ja koulutusmateriaalin lisäämiselle. Mallin ongelmana luutaskujen tunnistamisessa oli, että se luokitteli liian herkästi horisontaalisen luukadon vertikaaliseksi, mikäli taskussa oli yhtään kulmaa. Huomioitavaa on myös, että malli ei tehnyt parodontiitin diagnostiikkaa, vaan ainoastaan maalasi vaurioiden pinta-alat kuviin, joten kliinisen hyödyn saamiseksi tarvitaan lisätutkimuksia. ¹⁸

Kiinalaisessa tutkimuksessa syväoppimista hyödyntävän Visual Transformer -ohjelman (ViT) luotettavuutta tutkittiin furkaatioleesioiden ja niiden vakavuusasteen tunnistuksessa. Tutkimuksessa testattiin myös muiden syväoppimiseen perustuvien ohjelmien, konvoluutioneuroverkkojen ja Multilayer perceptronin (MLP), toimintaa, mutta ViT osoittautui parhaaksi tehtävään. Materiaalina oli 506 PTG-kuvaa, jotka rajattiin 1568 kuvaksi yksittäisistä molaareista. Kaksi parodontologia kävivät kuvat läpi ja luokittelivat ne kolmeen eri parodontiitin vakavuusasteen kategoriaan: terve tai FI, FII ja FIII tai FIV. Ohjelman koulutusmateriaalina käytettiin 1330 kuvaa ja testausmateriaalina 238 kuvaa. Tuloksissa ViT:n luokittelun spesifisyys ylä- ja alaleuan molaarien keskiarvona oli 0,92 ja sensitiivisyys 0,92. Positiivinen ennustearvo oli jopa 0,98. Saadut tulokset olivat todella hyviä ja tutkimuksessa huomioidaankin ViT-ohjelman ylivoimaisuus useammin käytettyihin muihin syväoppimisen ohjelmiin. Tulokset olivat yläleuan hampaissa hieman heikompia kuin alaleuassa päällekkäin kuvautuvien rakenteiden ja juurten anatomian vuoksi.¹⁹

Vietnamlainen tutkimus rakensi YOLOv8 -arkkitehtuurin avulla kolmivaiheisen mallin, jolla voitaisiin PTG-kuvista luokitella parodontiitin vaihe ja riskiluokka. Yksi ohjelma rajasi PTG-kuvista luurajan kulun, toinen hampaiden kiille-sementtirajat ja kolmas hampaiden ääriiviat. Näiden avulla pystytään laskemaan luukato prosentteina ja kun lisäksi mallille annetaan tietoa potilaan iästä, pitkäaikaisverensokerista ja tupakoinnista, saadaan selvitettyä parodontiitin tarkka diagnoosi. Tutkimukseen otettiin mukaan 500 PTG-kuvaa, joista kokenut parodontologi määrittä parodontiitin vaiheen ja riskiluokan. 375 kuvaa käytettiin testaukseen, 75 validointiin ja 50 testaukseen. Kaikkien ohjelmien tulokset olivat korkeita. Luurajan kulkua tutkivan ohjelman spesifisyys oli 0,99; sensitiivisyys 0,94 ja positiivinen ennustearvo 0,95. Kiille-sementtirajaa tutkivan ohjelman spesifisyys oli 1,00; sensitiivisyys 0,94 ja positiivinen ennustearvo 0,93. Hampaiden ääriivioja tutkivan ohjelman spesifisyys oli 1,00; sensitiivisyys 0,81 ja positiivinen ennustearvo 0,82. Tutkimustulokset olivat todella hyviä. Hampaiden ääriivioja rajaavalla mallilla tulokset olivat hieman heikompia kuin kahdella muulla mallilla, mutta tehtävä oli myös monimutkaisempi ja luvut olivat silti korkeita.²⁰

5.1.3 Apikaaliparodontiitti

Kyproslainen tutkimus selvitti syväoppimiseen perustuvan U²-Net sovelluksen tarkkuutta periapikaalileesioiden löytämisessä PTG-kuvista. Tutkimuksessa käytettiin 400 PTG-kuvaa, joissa oli yhteensä 780 periapikaalimuutosta. Kaksi radiologia luokitteli kuvista periapikaalileesiot, joissa lamina dura oli katkennut ja juuren ympärillä oli nähtävissä

radiolusenttisuutta. Kolmas radiologi oli mukana ratkaisemassa epäselvät tapaukset. Samat radiologit kävivät kuvat uudelleen läpi kuukauden kuluttua aiemman luokittelun varmistamiseksi. Kuvista 380 käytettiin ohjelman koulutukseen ja 20 testaukseen. Ohjelmalla saatiin hyvä sensitiivisyys (0,85) ja positiivinen ennustearvo (0,78). Ohjelmalla kesti vain 1,2 sekuntia arvioida periapikaalileesiot PTG-kuvasta ja tutkimuksessa todetaankin tekoälyohjelmien tehostavan tulevaisuudessa klinikoiden työtä.²¹

Nigerialaistutkimuksessa käytettiin konvoluutioneuroverkkoihin perustuvaa YOLO-algoritmia. Ohjelman testaukseen käytettiin 306 PTG-kuvaa, joissa oli yhteensä 400 periapikaalileesiota. Kaksi radiologia luokitteli kuvista vielä erikseen selvät ja epävarmat leesiot. Positiivinen ennustearvo oli ylä- ja alaleuassa selvissä ja epävarmoissa tapauksissa korkea (0,95–1,00). Sensitiivisyys taas vaihteli leukojen välillä huomattavasti. Yläleuassa sensitiivisyys oli selvien leesioiden osalta 0,36 ja epävarmojen osalta 0,2. Alaleuassa sensitiivisyys oli selvissä leesioissa korkea 0,93 ja epävarmoissa 0,76. Yläleuan osalta ohjelma toimi siis selkeästi huonommin, johtuen päällekkäin kuvautuvista rakenteista. Keskiarvoltaan ohjelman positiivinen ennustearvo oli 0,98 ja sensitiivisyys 0,56. Ohjelman hyväksi puoleksi tutkimuksessa mainitaan sen kyky arvioida koko PTG-kuva kerralla, verrattuna yksinkertaisiin konvoluutioverkkoihin, jotka vaativat kuvien pilkkomista pienempiin osiin. Yläleuan osalta tulokset eivät olleet luotettavia, mutta ohjelmat voivat kuitenkin jatkossa auttaa ihmistä diagnostiikassa.²²

Turkkilaisessa tutkimuksessa käytettiin konvoluutioneuroverkkoihin perustuvaa U-Net -algoritmia periapikaalileesioiden löytämiseen. Tutkimuksessa käytettiin yhteensä 470 PTG-kuvaa, joista kolme radiologia luokitteli leesioiden sijainnit. Kuvia muokattiin kääntämällä horisontaali- ja vertikaalisuunnassa ja ne jaettiin neljään sektoriin, jolloin saatiin yhteensä 4779 kuvaa. Kuvista poistettiin sellaiset, joissa ei ollut yhtäkään leesiota ja jäljelle jäi 1735 kuvaa, joista 47 toimi testauskuvina. Ohjelman sensitiivisyys (0,92) ja positiivinen ennustearvo (0,84) olivat molemmat korkeita. Tulokset ovat lupaavia ja tutkimuksessa arvellaan tekoälyn helpottavan tulevaisuudessa klinikoiden taakkaa.²³

Toinen turkkilainen tutkimus selvitti konvoluutioneuroverkkoihin perustuvan YOLOv5 -ohjelman kykyä erottaa periapikaaliset tulehdukset PTG-kuvista. Tutkimukseen valittiin 1500 PTG-kuvaa, joista 80 % käytettiin koulutukseen, 10 % validointiin ja 10 % testaukseen. Yksi hammaslääketieteen opiskelija, kaksi tutkimuksen kirjoittajaa ja kaksi suurradiologia kävivät kuvat läpi ja luokittelivat periapikaalileesiot. Testikuvissa oli yhteensä 417

periapikaalileesiota, ja ohjelma saavutti melko korkean sensitiivisyyden (0,68) ja positiivisen ennustearvon (0,78). Tutkimuksessa arvioidaan tekoälyn olevan hyvä työkalu erityisesti aikapaineen alla työskenneltäessä, mutta klinikkoja tarvitaan edelleen tekemään lopulliset diagnoosit.²⁴

Taulukko 3. Tutkimuksissa löydetty sensitiivisyys ja spesifisyys periapikaalileesioiden tunnistamisessa.

Tutkimus	Testausaineiston lkm.	Sensitiivisyys	Positiivinen ennustearvo
Boztuna, M. et al.	20	0,85	0,78
İçöz, D. et al.	306	0,56	0,98
Bayrakdar, I. et al.	47	0,92	0,84
Pekiner, MY. et al.	150	0,68	0,78

5.1.4 Leukanivelet

Eteläkorealainen tutkimus selvitti siirto-oppimista hyödyntävien ohjelmien ResNet-152:n ja EfficientNet-B7:n kykyä erottaa PTG-kuvista artroottiset leukanivelet terveistä. Kuvia otettiin mukaan tutkimukseen 518 potilaalta, joista rajaamalla kuvia yksittäisiin leukaniveleihin saatiin yhteensä 858 kuvaa, joista 395:ssä oli terve leukanivel ja 463:ssa artroottinen. Luokittelun teki kaksi kokenutta parentafysiologian asiantuntijaa. Diagnoosin varmistamiseksi potilaista piti olla käytettävissä KKTT-kuva, joka oli otettu korkeintaan kahden kuukauden sisällä PTG:stä. Kuvat jaettiin koulutus-, validointi- ja testausetteihin suhteessa 6:2:2. ResNet-152 saavutti korkean positiivisen ennustearvon (0,85), sensitiivisyyden (0,94) ja spesifisyyden (0,80). EfficientNet-B7 saavutti samankaltaiset tulokset ja positiivinen ennustearvo (0,92), sensitiivisyys (0,86) ja spesifisyys (0,91) olivat kaikki korkeita. Tutkimuksessa mallien tulokset olivat heikompia kuin parentafysiologian asiantuntijoiden luokittelu, mutta parempia kuin tavallisen hammaslääkärin. Ohjelmista voisi siis olla hyötyä klinikoiden apuna.²⁵

Toinen eteläkorealainen tutkimus selvitti konvoluutioneuroverkkoihin perustuvan ResNet-mallin kykyä erottaa PTG-kuvista artroottiset leukanivelet terveistä. PTG-kuvia otettiin tutkimukseen mukaan 1189. Potilaista piti olla myös KKTT-kuva otettuna alle kolmen kuukauden sisällä PTG:stä diagnoosin varmistamiseksi. Kuvat rajattiin vielä kattamaan vain yhden leukanivelen, jolloin yhteensä kuvia saatiin 2378. Asiantuntija jakoi kuvat kolmeen ryhmään: terveet (800), epävarmat (779) ja artroottiset (799). 1478 kuvaa käytettiin koulutukseen, 450 validointiin ja 450 testaukseen. Positiivinen ennustearvo oli melko korkea (0,72) ja sensitiivisyys korkea (0,94) mutta spesifisyys oli heikko (0,55). Luvuissa on jätetty pois epävarmat tapaukset ja käytetty ainoastaan terveiden ja artroottisten nivelten lukuja.

Tutkimuksen mukaan tekoälysovellus voisi olla hyvä pohja diagnostiikalle, mutta ei riittävä yksinään. Tutkimuksessa kolmen kategorian käyttäminen myös sekoitti tuloksia, ja kun kokeiltiin jättää pois epävarman luokituksen kuvat, tulokset paranivat. ²⁶

Kolmas eteläkorealainen tutkimus tutki kuuden eri konvoluutioneuroverkkosovelluksen kykyä erottaa terve leukanivel artroottisesta. Tutkimukseen otettiin mukaan yhteensä 3908 yhteen leukaniveleen rajattua PTG-kuvaa, joista 2127 oli terveitä ja 1781 artroottisia. Potilaista oli saatavilla myös KKTT-kuvat, joita asiantuntijat käyttivät apuna kuvien luokittelussa. Kuvista 60 % käytettiin koulutukseen ja 40 % testaukseen. Kuvien lisäksi potilaista oli käytettävissä tieto klinikon tutkimasta leukanivelen rahinasta ja potilaan itsearvioimasta leukaniveläänestä. Kaikilla sovelluksilla lisätiedot leukaniveläänistä paransivat luokittelua. GoogleNet pärjäsikin parhaiten kaikissa testeissä. Vain PTG-kuvaan perustuvassa luokittelussa sen sensitiivisyys oli 0,53; spesifisyys 0,72 ja positiivinen ennustearvo 0,78. Arvot eivät ole kovin korkeita, mutta kuitenkin parempia kuin vastaavat luvut kun testattiin kahdeksan ammattilaisen luokittelukykyä. Heidän keskiarvoikseen saatiin sensitiivisyyden osalta 0,5; spesifisyyden osalta 0,64 ja positiivisen ennustearvon osalta 0,69. Tutkimuksessa tekoälyn ammattilaisia parempia lukuja perusteltiin sillä, että tavallisesti klinikolla on saatavilla muutakin dataa diagnoosin pohjalla, kuten hoitohistoria ja palpaatiotutkimukset. Tekoälyn luvut jäivät kuitenkin silti matalammiksi kuin odotettiin ja sovellukset vaativat vielä kehitystä. ²⁷

Taulukko 4. Tutkimuksissa löydetty sensitiivisyys ja spesifisyys artroottisen leukanivelen tunnistamisessa terveestä.

Tutkimus	Testausaineiston lkm.	Sensitiivisyys	Spesifisyys
Jung, W. et al. (ResNet-152)	172	0,94	0,8
Jung, W. et al. (EfficientNet-B7)	172	0,86	0,91
Choi, E. et al. (2021)	450	0,94	0,55
Choi, E. et al. (2025)	1563	0,53	0,72

6 Pohdinta

PTG-kuvaus on varsin vanha menetelmä, joka on säilyttänyt asemansa lähes muuttumattomana hammaslääketieteellisessä diagnostiikassa. Laitteet ovat ajan saatossa kehittyneet ja nykylaitteistot mahdollistavat suhteellisen pienen sädeannoksen. Kuvanlaatu on myös parantunut tehden diagnostiikasta tarkempaa. PTG-kuvauksen rajoitusten vuoksi avuksi tarvitaan kuitenkin usein intraoraalikuvia tai KKTT-tutkimuksia. Suurin ongelma PTG-kuvauksessa liittyy asetteluvirheisiin sekä päällekkäin projisoitumiseen ja siksi kuvan tulkinnassa vaaditaan kriittisyyttä.

Tekoäly on tullut viime vuosina nopeasti mukaan diagnostiikan alan tutkimuksiin ja markkinoilla on jo joitakin tekoälypohjaisia sovelluksia olemassa. Tekoäly sovellusten kehitys lääketieteen aloilla on kuitenkin hidasta eettisten näkökulmien ja rajoittavien lakien vuoksi. Sovellusten kliinistä käyttöönottoa rajoittaa toisiolaki sekä Euroopan Unionissa käyttöönottoa ohjaa EUAI act ²⁸.

Diagnostiikassa syväoppimismallien lisäksi avoimena saatavilla olevat tekoälysovellukset, kuten kielimalli ChatGPT (OpenAI, 2022), on tutkimusten kohteena muun muassa radiologisten lausuntojen laatimisessa ja potilastapausten diagnostiikassa. ChatGPT ei ole validoitu lääketieteelliseen käyttöön, mutta sen laaja saatavuus ja helppokäyttöisyys on tehnyt siitä varsin suosituksen lääketieteen ammattilaisten ja potilaiden keskuudessa ²⁹. Kielimalleja tutkitaan monipuolisesti lääketieteen alalla potilaiden ohjaamiseen, päätöksen teon tukemiseen, toimenpiteiden suunnitteluun ja diagnostiikkaan ³⁰. Tutkimusten tulokset kielimalleista kuitenkin vaihtelevat laajalti. Kielimallit saattavat hallusinoita, eli se keksii tiedon esittäen sen totuutena, ja siksi käyttäjältä vaaditaan kriittisyyttä vastausten tulkintaan.²⁹

Tekoälysovelluksiin liittyvät virhemahdollisuudet ja kielimallien tuottamat hallusinaatiot ovat vielä todellinen ongelma ja etenkin lääketieteen aloilla tällä saattaa olla vakavat seuraukset. Potilasturvallisuuden varmistaminen on lääkärin tai hammaslääkärin vastuulla. Lisäksi tekoälyn negatiivisiin vaikutuksiin liittyvät ympäristövaikutukset. Tekoälyn käyttöön vaadittavat datakeskukset käyttävät runsaasti materiaaleja ja resursseja, ja niiden toiminta käyttää huomattavan paljon sähköä sekä vettä laitteistojen jäähdytykseen. Verrattuna yhteen Google-hakuun, yksi ChatGPT-vastaus käyttää lähes kymmenkertaisen määrän sähköä ³¹, jonka tuotantoon taas käytetään paljon fossiilisia polttoaineita. Vettä ChatGPT taas käyttää noin puoli litraa per 10-50 vastausta riippuen haun ajasta ja paikasta, ja vuonna 2027 tekoälyn

ennustetaan käyttävän maailmanlaajuisesti 4,2-6,6 miljardia kuutiometriä vettä, joka vastaa suunnilleen puolta koko Iso-Britannian vuosittaisesta vedenkulutuksesta³².

Tässä katsauksessa esitetyt diagnostiikkaan rajatut tekoälysovellukset käyttävät kuitenkin huomattavasti vähemmän resursseja toimiakseen, kuin avoimena saatavilla olevat generatiiviset tekoälyt, jolloin hyöty-haittasuhde jää edullisemmaksi. Lisäksi lääketieteeseen kehitetyt tekoälysovellukset voivat parhaimmillaan edistää terveyttä ja säästää ammattilaisten aikaa potilaille. Tekoälylle on tarve etenkin ajan säästön ja taloudellisten hyötyjen suhteen, mutta uutena ilmiönä se hakee vielä paikkaansa.

Tekoälysovellusten kehitys ja tutkimus PTG-kuvien diagnostiikassa on ollut nopeatahtista – sovelluksia on kehitetty laajasti eri tarpeisiin. Kokosimme tähän opinnäytetyöhön tutkimuksia yleisimmistä hammassairauksien diagnostiikasta PTG-kuvista. Esimerkiksi anatomian, kystien ja kasvainten sekä muun patologian tunnistamiseen sekä ikäarviointiin liittyviä tutkimuksia löytyy useita. Tekoälysovellukset voivat parhaimmillaan nopeuttaa ja helpottaa hammaslääkärin työtä ja diagnostiikkaa.

Luotettavuuden pohjana on pitkälti koulutukseen käytetyn aineiston laatu ja määrä. PTG-kuvista voi kuitenkin löytää todella monia erilaisia löydöksiä, joten haasteena on kerätä tarpeeksi aineistoa ja saada diagnostiikka yhdistettyä yhteen sovellukseen. Esimerkiksi kuvausasetteluun ja kuvanlaatuun liittyen löytyi vain vähän tutkimuksia tekoälyn mahdollisuuksista.

Tekoälysovelluksen vaatima suorituskyky tietokoneelta voi toistaiseksi olla liikaa muiden, jo valmiiksi hitaiden, potilasohjelmien ohella. Sovelluksista tulisi kehittää tarpeeksi käyttäjäystävällisiä ja itseopeteltavia, jotta niitä voitaisiin hyödyntää nopeasti muun työn ohessa. Katsaukseen mukaan otetuissa tutkimuksissa kehityskohteiksi nousivat koulutusaineiston lisääminen sekä yläleuan diagnostiikan ongelmat päällekkäin kuvautuvien rakenteiden vuoksi. Joissain tutkimuksissa myös huomattiin, että vaikka tekoälyn tulokset eivät olleet täydellisiä, ne olivat silti parempia kuin hammaslääkärin, sillä PTG-kuvien diagnostiikka on usein haastavaa.

7 Yhteenveto

PTG-kuvaus on keskeinen menetelmä hammaslääketieteen diagnostiikassa ja sitä käytetään lähtökohtana kokonaišhoidolle ja täydennetään tarvittaessa lisäkuvilla. Tekoälysovelluksia diagnostiikkaan on jo markkinoilla, mutta haasteena on tulosten luotettavuus ja kokonaisvaltaisen diagnostiikan vaatima suorituskyky. Tutkimuksissa kehitetyillä yhteen näkökulmaan keskittyvillä ohjelmilla on saatu lupaavia tuloksia. Yksinkertaisissa kysymyksissä ja aiheissa, esimerkiksi periapikaaliparodontiitin suhteen (on tai ei ole), on saatu hyviä tuloksia, mutta esimerkiksi parodontiitin vakavuusastetta arvioitaessa sovelluksilla on haasteita. Tekoälyohjelmat toimivat jo hyvänä alkuna diagnostiikalle ja voivat tulevaisuudessa nopeuttaa hammaslääkärin työtä. Toistaiseksi ohjelmien tuottamat tulokset vaativat aina ammattilaisen tarkistusta ja vastuuta.

Lähteet

1. Rosberg Jukka. *Hammaslääketieteellinen Radiologia : Tekniikka Ja Diagnostiikka*. [J. Rosberg]; 1997.
2. Ruonala V. *Radiologisten Tutkimusten Ja Toimenpiteiden Määrät Vuonna 2021 : Terveysthuollon Valvontaraportti*. STUK; 2022. <https://urn.fi/URN:ISBN:978-952-309-543-4>
3. Eija Venelampi. *Säteilyn Käyttö Ja Muu Säteilylle Altistava Toiminta, Vuosiraportti 2023*. STUK; 2024.
4. Jalas A, Laakso M, Instrumentarium (yhtiö), Instrumentarium (yhtymä). *Instrumentarium : Ensimmäinen Vuosisatamme 1900-2000*. [Instrumentarium]; 2000.
5. Planmeca. Planmeca - Yritys. <https://www.planmeca.com/fi/yritys/>
6. Mallya SM, Lam EWN. *White and Pharoah's Oral Radiology : Principles and Interpretation*. 8th edition. Elsevier; 2019.
7. Whaites E, Drage N. *Essentials of Dental Radiography and Radiology*. Sixth edition. 2021.
8. Suomalaisen Lääkäriseuran Duodecimin ja Suomen Hammaslääkäriseura Apollonia ry:n asettama työryhmä. Parodontiitti. Käypä hoito -suositus. Published online 2025. <https://www.kaypahoito.fi/hoi50086#s24>
9. Suomalaisen Lääkäriseuran Duodecimin ja Suomen Hammaslääkäriseura Apollonia ry:n asettama työryhmä. Viisaudenhammas. Käypä hoito -suositus. Published online 2020. <https://www.kaypahoito.fi/hoi50074#K1>
10. Suomalaisen Lääkäriseuran Duodecimin ja Suomen Hammaslääkäriseura Apollonian asettama työryhmä. Hammasperäiset äkilliset infektiot ja mikrobilääkkeet. Käypä hoito -suositus. Published online 2017. <https://www.kaypahoito.fi/hoi50090#s17>
11. Suomalaisen Lääkäriseuran Duodecimin ja Suomen Hammaslääkäriseura Apollonia ry:n asettama työryhmä. Purentaelimistön kipu ja toimintahäiriöt (TMD). Käypä hoito -suositus. Published online 2021. <https://www.kaypahoito.fi/hoi50057#s14>
12. Heikkilä, Janne. *Suositus Kuvankatselelunäytöille Ja Niiden Laadunvalvontaan*. STUK; 2022. <https://urn.fi/URN:ISBN:978-952-309-546-5>
13. Ali M, Irfan M, Ali T, Wei CR, Akilimali A. Artificial intelligence in dental radiology: a narrative review. *Ann Med Surg* 2012. 2025;87(4):2212-2217. doi:10.1097/MS9.00000000000003127
14. Zadrożny Ł, Regulski P, Brus-Sawczuk K, et al. Artificial Intelligence Application in Assessment of Panoramic Radiographs. *Diagn Basel Switz*. 2022;12(1). doi:10.3390/diagnostics12010224
15. Vinayahalingam S, Kempers S, Limon L, et al. Classification of caries in third molars on panoramic radiographs using deep learning. *Sci Rep*. 2021;11(1):12609. doi:10.1038/s41598-021-92121-2
16. Ayhan B, Ayan E, Atsü S. Detection of dental caries under fixed dental prostheses by analyzing digital panoramic radiographs with artificial intelligence algorithms based on deep learning methods. *BMC Oral Health*. 2025;25(1):216. doi:10.1186/s12903-025-05577-3

17. Pornprasertsuk-Damrongsri S, Vachmanus S, Papasratorn D, et al. Clinical application of deep learning for enhanced multistage caries detection in panoramic radiographs. *Sci Rep*. 2025;15(1):33491. doi:10.1038/s41598-025-16591-4
18. Kurt-Bayrakdar S, Bayrakdar İŞ, Yavuz MB, et al. Detection of periodontal bone loss patterns and furcation defects from panoramic radiographs using deep learning algorithm: a retrospective study. *BMC Oral Health*. 2024;24(1):155. doi:10.1186/s12903-024-03896-5
19. Zhang X, Guo E, Liu X, et al. Enhancing furcation involvement classification on panoramic radiographs with vision transformers. *BMC Oral Health*. 2025;25(1):153. doi:10.1186/s12903-025-05431-6
20. Do KQ, Thai TT, Lam VQ, Nguyen TT. Development and validation of artificial intelligence models for automated periodontitis staging and grading using panoramic radiographs. *BMC Oral Health*. 2025;25(1):1623. doi:10.1186/s12903-025-07025-8
21. Boztuna M, Firinciogullari M, Akkaya N, Orhan K. Segmentation of periapical lesions with automatic deep learning on panoramic radiographs: an artificial intelligence study. *BMC Oral Health*. 2024;24(1):1332. doi:10.1186/s12903-024-05126-4
22. İçöz D, Terzioğlu H, Özel M, Karakurt R. Evaluation of an Artificial Intelligence System for the Diagnosis of Apical Periodontitis on Digital Panoramic Images. *Niger J Clin Pract*. 2023;26(8). https://journals.lww.com/njcp/fulltext/2023/08000/evaluation_of_an_artificial_intelligence_system.6.aspx
23. Bayrakdar IS, Orhan K, Çelik Ö, et al. A U-Net Approach to Apical Lesion Segmentation on Panoramic Radiographs. *BioMed Res Int*. 2022;2022:7035367. doi:10.1155/2022/7035367
24. Pekiner MY, Yulek H, Talmac AGO, Keser G, Pekiner FN, Bayrakdar IS. A Deep Learning Approach for Detecting Periapical Lesions on Panoramic Radiographic Images. *J Coll Physicians Surg--Pak JCPSP*. 2025;35(11):1461-1465. doi:10.29271/jcpsp.2025.11.1461
25. Jung W, Lee KE, Suh BJ, Seok H, Lee DW. Deep learning for osteoarthritis classification in temporomandibular joint. *Oral Dis*. 2023;29(3):1050-1059. doi:10.1111/odi.14056
26. Choi E, Kim D, Lee JY, Park HK. Artificial intelligence in detecting temporomandibular joint osteoarthritis on orthopantomogram. *Sci Rep*. 2021;11(1):10246. doi:10.1038/s41598-021-89742-y
27. Choi E, Shin S, Lee K, et al. Artificial intelligence-enhanced diagnosis of degenerative joint disease using temporomandibular joint panoramic radiography and joint noise data. *Sci Rep*. 2025;15(1):1823. doi:10.1038/s41598-024-83750-4
28. *Euroopan Parlamentin Ja Neuvoston Asetus (EU) 2024/1689 Tekoälyä Koskevistä Yhdenmukaistetuista Säännöistä Ja Asetusten (EY) N:O 300/2008, (EU) N:O 167/2013, (EU) N:O 168/2013, (EU) 2018/858, (EU) 2018/1139 Ja (EU) 2019/2144 Sekä Direktiivien 2014/90/EU, (EU) 2016/797 Ja (EU) 2020/1828 Muuttamisesta (Tekoälysäädös) (ETA:N Kannalta Merkityksellinen Teksti)*. 2024. <http://data.europa.eu/eli/reg/2024/1689/oj>
29. Maryna Bilan. Hallucinations in LLMs: What You Need to Know Before Integration. 2023. <https://masterofcode.com/blog/hallucinations-in-llms-what-you-need-to-know-before-integration>.
30. Haylaz E, Gumussoy I, Kalabalik F, Say Ş, Can Eren M, Geduk G. 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;26(1). doi:10.1186/s12903-026-07790-0

31. de Vries A. The growing energy footprint of artificial intelligence. *Joule*. 2023;7(10):2191-2194. doi:10.1016/j.joule.2023.09.004
32. Li P, Yang J, Islam M, Ren S. *Making AI Less “Thirsty”: Uncovering and Addressing the Secret Water Footprint of AI Models*. 2023. doi:10.48550/arXiv.2304.03271