



Tekoälyn hyödyntäminen lääketieteellisessä kuvantamisessa

Jenni Heinonen

Haaga-Helia ammattikorkeakoulu

Tradenomi tutkinto

Amk-opinnäytetyö

2025

Tiivistelmä

Tekijä(t) Jenni Heinonen
Tutkinto Tradenomi
Raportin/Opinnäytetyön nimi Tekoälyn hyödyntäminen lääketieteellisessä kuvantamisessa
Sivu- ja liitesivumäärä 31 + 3
<p>Tulevaisuuden terveydenhuolto kohtaa merkittäviä haasteita väestön ikääntyessä ja ammatti-laisten resurssien ollessa rajalliset. Palveluiden saatavuuden ja tehokkuuden varmistamiseksi diagnosoinnin tueksi tarvitaan tehokkaita ja automatisoituja työkaluja. Kuvantaminen on diagnosoinnin kulmakivi. Lääketieteellisen kuvantamisen yksi lupaavimmista kehityskohteista on tekoäly, jonka hyödyntäminen on alati kasvava tutkimuskohde – erityisesti syväoppimismenetelmien osalta.</p> <p>Tämän työn tavoitteena oli selvittää, millaisia tekoälyyn sisältyviä syväoppimisen menetelmiä lääketieteellisessä kuvantamisessa voidaan hyödyntää, sekä millaisia algoritmeja käytetään. Lisäksi työssä tarkastellaan syväoppimismenetelmien haasteita eri näkökulmista. Lähteinä käytetään pääasiassa viimeisen kymmenen vuoden aikana julkaistuja systemaattisia kirjallisuuskatsauksia.</p> <p>Opinnäytetyön teoriaosuudessa perehdytään tekoälyn eri osa-alueisiin, kuten koneoppimiseen ja syväoppimiseen, sekä näihin liittyviin algoritmeihin. Lisäksi tarkastellaan lääketieteellisen kuva-analyysin eri vaiheita, joissa tekoälymenetelmiä voidaan hyödyntää. Empiirisessä osiossa tutkitaan kuva-analyysin osa-alueita, joilla syväoppimista on jo hyödynnetty, sekä selvitetään, millaisia etuja sen avulla on saavutettu. Etujen ohella tarkastellaan myös tekoälyn keskeisiä haasteita, jotka liittyvät muun muassa mallien selitettävyyteen ja opettamiseen.</p> <p>Pohdinnassa todetaan, että tulevaisuudessa syväoppimismenetelmillä on potentiaalia tehostaa kuvien segmentointia ja luokittelua. Niiden avulla voitaisiin myös tuottaa synteettistä kuvadataa esimerkiksi tekoälymallien opetukseen. Tekoäly voisi vapauttaa asiantuntijan aikaa kuvien tulokinnasta enemmän päätöksentekoon. Haasteena on kuitenkin syväoppimismallien siirtäminen kliiniseen käyttöön. Hyödyntämiseen liittyy myös yksityisyyteen ja eettisyyteen kohdistuvia haasteita, jotka edellyttävät yhteisiä linjauksia.</p>
Asiasanat Tekoäly, kuvantaminen, syväoppiminen, neuroverkot

Sisällys

1	Johdanto	1
1.1	Keskeiset käsitteet	1
2	Tekoäly ja sen algoritmit	3
2.1	Koneoppiminen	3
2.2	Koneoppimisen yleisimmät algoritmit	5
2.2.1	K lähintä naapuria (K-Nearest Neighbour)	5
2.2.2	Tukivektorikone (Support Vector Machine).....	6
2.2.3	Naïve Bayes	7
2.2.4	Päätöspuu (Decision Tree)	7
2.2.5	Satunnainen metsä (Random Forest)	8
2.3	Syväoppiminen ja sen yleisimmät algoritmit	8
2.3.1	Konvoluutioneuroverkko (CNN, convolutional neural network).....	9
2.3.2	Generatiivinen kilpaileva verkosto (GAN, generative adversial network)	11
3	Tekoälyn hyödyntäminen kuvien analysoinnissa	12
3.1	Kuvien esikäsittely.....	12
3.2	Segmentointi	13
3.3	Luokittelu.....	14
3.4	Kuvien rekisteröinti.....	14
4	Opinnäytetyön toteutus.....	15
4.1	Tutkimustyyppin määritelmä.....	15
4.2	Aineiston keruu ja analysointi	15
5	Syväoppimismallien hyötyjä ja haasteita	17
5.1	Syväoppimismallien hyödyt	17
5.1.1	Diagnostinen tarkkuus ja tehokkuus.....	17
5.1.2	Synteettinen data ja kuvanlaadun parantaminen.....	18
5.2	Syväoppimismallien haasteet	19
5.2.1	Mallien läpinäkyvyys ja selitettävyys	19
5.2.2	Datan laatu ja saatavuus.....	20
5.2.3	Eettisyys ja yksityisyys.....	21
6	Pohdinta.....	22
6.1	Jatkotutkimus	23
6.2	Oman projektin ja oppimisen arviointi.....	23
	Lähteet.....	25
7	Liitteet	28
7.1	Liite 1. Opinnäytetyössä hyödynnetyt tieteelliset julkaisut.....	28

1 Johdanto

Diagnostiikka on terveydenhuollon kulmakivi, joka mahdollistaa sairauksien ja terveysongelmien tunnistamisen varhaisessa vaiheessa. Tulevaisuudessa terveydenhuolto on kuitenkin haasteiden edessä, sillä väestön ikärakenne on murroksessa. Tällä hetkellä maailman väestöstä yli 65-vuotiaita on enemmän kuin alle 5-vuotiaita. Vuoteen 2050 mennessä yli 65-vuotiaiden määrän väestöstä arvioidaan olevan noin 16 %. (Bohr & Memarzadeh 2020.) Ikääntymisen seurauksena terveydenhuolto on kuormituksen alla, joten sairauksien varhaiseen havaitsemiseen ja tunnistamiseen kaivataan tehokkaita apuvälineitä.

Tunnistamiseen liittyvään työhön tarvitaan väsymätöntä työvoimaa, joka pystyy analysoimaan dataa nopeasti ja tehokkaasti, mielellään kellon ympäri. Tekoäly on arjessakin kasvava trendi, jonka käyttö yleistyy terveydenhuollossa. Tämän työn tarkoituksena on selvittää, miten tekoälyä voidaan hyödyntää lääketieteellisessä kuvantamisessa, ja mitä keskeisiä haasteita sen käyttöön liittyy. Tutkimus toteutetaan kvalitatiivisena, kuvailevana kirjallisuuskatsauksena.

Tutkimuskysymykset ovat:

1. Miten tekoälyä voidaan hyödyntää lääketieteellisessä kuvantamisessa
2. Millaisia tekoälyalgoritmeja käytetään?
3. Mitkä ovat tekoälyn keskeisimmät haasteet?

Tässä opinnäytetyössä keskitytään erityisesti kahteen syväoppimismenetelmään: konvoluutioneuroverkkoihin (Convolutional Neural Networks, CNN) sekä generatiivisiin kilpaileviin verkkoihin (Generative Adversarial Networks, GAN). Näiden menetelmien valinta perustuu niiden keskeiseen asemaan nykyaikaisessa kuvantamisessa, sekä kasvaneeseen tutkimukselliseen kiinnostukseen. Tutkimuksen painopisteenä ovat erityisesti lääketieteellisten kuvien segmentointi ja luokittelu, koska ne muodostavat olennaisen osan lääketieteellistä kuva-analyysia. Tutkimusta voivat hyödyntää lääketieteen ammattilaiset ja tekoälyn tulevaisuuden potentiaalista kiinnostuneet henkilöt.

1.1 Keskeiset käsitteet

Algoritmi on yksityiskohtainen kuvaus tai ohje siitä, miten jokin tehtävä tai toiminto suoritetaan (Merilehto 2018, 17).

Generatiivinen kilpaileva verkosto (GAN, generative adversarial network) GAN-verkot ovat ohjaamaton syväoppimismenetelmä, jossa kaksi hermoverkkoa kilpailevat toisiaan vastaan nollasummapelissä (Alom ym. 2018, 24).

K lähintä naapuria (K-Nearest Neighbour) on koneoppimisen algoritmi, joka ennustuksen tuloksena tuottaa luokan, jolla on eniten havaintopisteitä lähellään tietyn etäisyyden perusteella määritettynä (Alnaggar ym. 2024, 78).

Koneoppiminen on tekoälyn muoto, jossa kone oppii uusia asioita sille syötettävän datan perusteella (Kolari & Kallio 2023, alaluku Perustermit tutuksi).

Naïve Bayes on ohjatun oppimisen menetelmä, jota käytetään luokittelussa (Alnaggar ym. 2024, 82).

Neuroverkko on rakenne, joka koostuu joukosta neuroneita, jotka on kytketty toisiinsa ja niiden välillä on kommunikaatiota (Merilehto 2018, 20).

Konvoluutioneuroverkko (CNN, convolutional neural network) on syväoppimismalli datan käsittelemiseen, ja se jäljittelee eläinten näköjärjestelmää. Se on suunniteltu oppimaan automaattisesti ja adaptiivisesti avaruudellisia rakenteita piirteistä. (Yamashita, Nishio, Do & Togashi 2018, 612.)

Päätöspuu (DT, decision tree) Päätöspuu on valvottu oppimisalgoritmi, jolla ei ole parametreja. Sillä on hierarkkinen puun rakenne, joka koostuu juurisolmista, oksista, sisäisistä solmuista ja lehtisolmuista. (IBM.)

Satunnaismetsä (RF, random forest) on yleisesti käytetty koneoppimisen algoritmi, joka yhdistää useamman päätöspuun suorituksen saavuttaakseen yhden tuloksen. Se käsittelee sekä luokittelu-, että regressio-ongelmia. (IBM.)

Segmentointi on lääketieteellisen kuvantamisen prosessi, jossa kuva jaetaan eri anatomisiin alueisiin, kuten elimiin, kudoksiin tai vaurioihin (Xu ym. 2024, 1).

Syväoppiminen tarkoittaa tekoälyn koneoppimismenetelmää, jossa hyödynnetään eri tasoista koostuvia kerroksellisia neuroverkkoja (Kolari & Kallio 2023, alaluku Perustermit tutuksi).


Tekoäly on ohjelmisto, joka matkii ihmisen tapaa oppia ja tehdä päätöksiä (Kolari & Kallio 2023, alaluku Perustermit tutuksi).

Tukivektorikone (SVM, support vector machine) on yleisesti käytetty koneoppimisen algoritmi, jota hyödynnetään luokittelussa (IBM).

2 Tekoäly ja sen algoritmit

Tekoäly viittaa ohjelmistoon, joka pyrkii matkimaan ihmisen tapaa oppia ja tehdä päätöksiä. Ohjelmistot perustuvat ihmisen rakentamiin algoritmeihin, mutta ne voidaan myös opettaa oppimaan uutta ja kehittämään suorituskykyään itsenäisesti. Tekoälyn tarkoitus on tukea ja tehostaa ihmisten työntekoa, esimerkiksi käsittelemällä niin suuria määriä tietoa, että se veisi ihmiseltä vuosia. (Kolari & Kallio 2023, alaluku Perustermit tutuksi.) Tekoäly ei kuitenkaan kykene kuvaamaan kausaalisuhteita eli syy-seuraussuhteita (Kananen & Puolitaival 2019, 37). Näin ollen tekoäly ei kykene kuvaamaan ongelmaa, vaan tämä tehtävä jää ihmiselle (Kananen & Puolitaival 2019, 37).

Kanasen ja Puolitaipaleen (2019, 37) mukaan tekoäly on rajatuissa tehtävissä ihmiseen verrattuna nopeampi, tarkempi, kykenevä rajattomaan toistoon, ajallisesti muuttumaton ja puolueeton (jos harjoitusdata on puolueeton). Tekoäly on selvästi määriteltyyn, tarkkarajaiseen tehtävään tarkoitettu työkalu (Kananen & Puolitaival 2019, 37). Rajatussa tehtävässään se kykenee jopa ihmistä parempaan suoritukseen (Kananen & Puolitaival 2019, 37). Kuvassa 1 on havainnollistettu tekoälyn eri osa-alueet. Nykyisin tekoäly yhdistetään pitkälti sen erityiseen osa-alueeseen, syväoppimiseen ja keinotekoisiiin hermoverkkoihin (Huhtanen, Nyman, Karlsson & Hirvonen 2020, 1957).



Kuva 1. Tekoälyn osa-alueet (mukaillen Alzubaidi ym. 2021, 7).

2.1 Koneoppiminen

Koneoppiminen on tekoälyn osa-alue, jossa luodaan tietokonemalleja, jotka pystyvät oppimaan ja ennustamaan, tai tekemään päätöksiä niille annettujen tietojen perusteella (Kufel ym. 2023, 3). Koneoppiminen käyttää dataa oppimiseen ja luokitteluun sen sijaan, että toiminta olisi ohjelmoitu valmiiksi (Merilehto 2018, 27). Merilehdon (2018, 27) mukaan koneoppiminen hyödyntää algoritmeja, jotka oppivat annetusta datasta vaihe vaiheelta. Mitä enemmän dataa on käytettävissä, sitä

tarkemman kuvan malli pystyy luomaan (Merilehto 2018, 28). Koneoppiminen voi tuottaa tuloksia, jotka ovat manuaalisia ihmisarvioita tarkempia (Quanyang ym. 2024, 3).

Barragán-Monteron ja kumppaneiden (2021, 4) mukaan koneoppiminen voidaan jakaa karkeasti kahteen kategoriaan: ohjattuun ja ohjaamattomaan oppimiseen. Ohjattu oppiminen on näistä kaikista yksinkertaisin ja tarjoaa tiukimman kehyksen (Barragán-Montero ym. 2021, 4). Siinä oppiminen tapahtuu siten, että koneelle näytetään merkittyjä esimerkkejä, joihin on yhdistetty valmis vastaus (Kananen & Puolitaival 2019, 49). Näin ollen koneen ”isännän” on annettava syötteet ja valvottava tuloksia (Barragán-Montero ym. 2021, 4). Tällaisia esimerkkejä, eli data-vastaus-pareja tarvitaan suuri määrä (Kananen & Puolitaival 2019, 49). Tämän jälkeen algoritmin avulla luodaan säännöstö, joka kuvaa asian. Malliin kuvataan kaikki datasta löydettävät ominaisuudet eli attribootit. Kun kone on koulutettu, algoritmille annetaan täysin uutta dataa ilman merkintöjä. Aiemmin opitun perusteella se osaa tehdä päätöksiä ja antaa vastauksen ennusteena. (Kananen & Puolitaival 2019, 49.) Suurin osa nykyisistä sovelluksista hyödyntää ohjattua oppimista (Merilehto 2018, 28).

Tyypillinen ohjatun oppimisen tehtävä on regressio tai luokittelu (Barragán-Montero ym. 2021, 4). Barragán-Montero ja kumppanit toteavat, että luokittelu voi olla binääristä, eli voidaan esimerkiksi määrittää, löytyykö jokin poikkeama kuvasta vai ei. Se voi myös sisältää useita luokkia, kun halutaan määrittää tiettyä poikkeamaa useiden merkintöjen joukosta. (Barragán-Montero ym. 2021, 4.) Luokittelu voi myös kokonaisen kuvan sijasta käsittää jokaisen pikselin (Barragán-Montero ym. 2021, 4).

Kanasen ja Puolitaipaleen (2019, 51) mukaan ohjaamattomassa oppimisessä ei ole niin kutsuttua oikeaa vastausta, jota malli pyritään saada toistamaan. Kun dataa ei ole nimetty, ohjaamaton oppiminen pyrkii löytämään siitä johdonmukaisuuksia (Barragán-Montero ym. 2021, 4). Algoritmia siis pyydetään etsimään koneelle annetusta datasta malleja, eli säännönmukaisuuksia (Kananen & Puolitaival 2019, 51). Ohjaamattoman oppimisen päämäärä on, että kone järjestää datan itsenäisesti (Kananen & Puolitaival 2019, 51). Sen hyöty on siinä, että kaikkia erikoistapauksia ei tarvitse merkitä dataan, vaan algoritmi kykenee löytämään poikkeukset itse (Kananen & Puolitaival 2019, 51).

Useimmat ohjaamattoman oppimisen tehtävät liittyvät todennäköisyystiheyden arvioimiseen, kuten klusterointiin (samankaltaisten tietojen erillisten ryhmien löytäminen), poikkeamien tai poikkeavuuksien havaitsemiseen (yksittäiset kohteet) tai jopa monimuotoisuuksien oppimiseen ja ulottuvuuksien pienentämiseen (osa-alueet, joihin tieto kasaantuu) (Barragán-Montero ym. 2021, 4). Tähän mennessä ohjaamaton oppiminen on ollut rajallisempaa kuin ohjattu oppiminen. (Barragán-Montero ym. 2021, 4.)

2.2 Koneoppimisen yleisimmät algoritmit

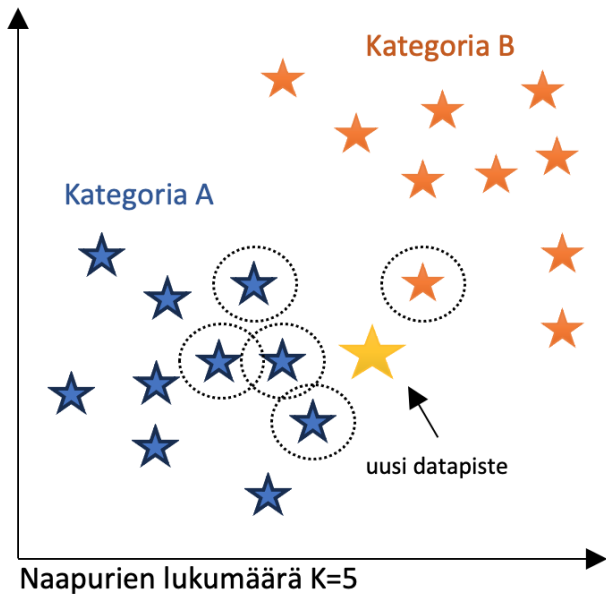
Koneoppimisen alustavana vaiheena on poimia esimerkiksi kuva-aineistosta olennaiset piirteet eli kvantitatiiviset ominaisuudet, jotka tiivistävät aineiston välittämää tietoa suureiksi tai taulukoiksi. Tämän jälkeen nämä tiedot syötetään yleisille ennustemalleille, kuten luokittelijoille tai regressoreille, jotka oppivat suorittamaan valitun tehtävän. (Barragán-Montero ym. 2021, 6.) Yksinkertaistettuna luokittelijat ovat algoritmeja, jotka voivat lajitella aineiston ryhmiin tai luokkiin, lisäksi niitä on olemassa lukuisia erilaisia. Jotkin suosituimmista algoritmeista ovat hyvin intuitiivisia ja helppotulkintaisia, kuten päätöspuut. (Barragán-Montero ym. 2021, 8.) Merilehto (2018, 34) tiivistää koneoppimisen mallit viiteen eri kategoriaan, jotka löytyvät taulukosta 1.

Taulukko 1. Koneoppimisen mallit (mukaillen Merilehto 2018, 34)

Koneoppimisen malli	Selitys
Luokittelu (<i>Classification</i>)	Luokitellaan kohde ennalta määrättyihin kahteen tai useampaan kategoriaan (esim. kuvan tunnistaminen)
Ryhmittely (<i>Clustering</i>)	Analysoidaan luokittelematon data ja tunnistetaan siitä erilliset ryhmät
Regressio (<i>Regression</i>)	Ennustetaan numeerista arvoa
Suosittelu (<i>Recommendation</i>)	Arvioidaan esim. mistä tuotteista asiakas pitää
Poikkeamien etsiminen (<i>Anomaly Detection</i>)	Löydetään selkeästi normaalista poikkeava data aineistosta

2.2.1 K lähintä naapuria (K-Nearest Neighbour)

Yksi koneoppimisen luokittelukeinoista on KNN-menetelmä (Kananen & Puolitaival 2019, 118). Kananen ja Puolitaipaleen (2019, 118) mukaan sitä voidaan käyttää, kun halutaan tietää, mihin luokkaan uusi havainto kuuluu. Jos esimerkiksi halutaan tietää, onko uusi havainto sairautta vai ei, KNN-algoritmia voidaan käyttää tunnistamaan, kumpaa luokkaa lähempänä uusi havainto on (Kananen & Puolitaival 2019, 118). Havainnon voidaan päätellä kuuluvan tietyllä todennäköisyydellä siihen luokkaan, kumman luokan aiempia havaintopisteitä, "naapureita", lähempänä uusi havainto on (Kananen & Puolitaival 2019, 118).



Kuva 2. KNN-algoritmi etsii uuden havainnon lähimmät naapurit. Uusi datapiste sijoitetaan kategoriaan A, koska siihen kuuluu suurin osa naapurihavainnoista (mukaillen Kananen & Puolitaival 2019, 119.)

KNN-menetelmän yksi vahvuuksista on, että se on yksinkertainen selittää, ymmärtää ja tulkita (Kananen & Puolitaival 2019, 119). Algoritmi käy myös monenlaisille tietoaaineistoille, ja on tehokas silloin, kun dataa on paljon (Kananen & Puolitaival 2019, 119). Algoritmin käyttöä kuitenkin rajoittaa, että se on laskennallisesti raskas, koska jokaiselle datapisteelle lasketaan erikseen etäisyys (Kananen & Puolitaival 2019, 119). Lisäksi menetelmälle on valittava K-arvo, eli valitaan, montako naapurihavaintoa laskennassa huomioidaan. Mikäli tämä valitaan huonosti, myös tulokset ovat huonoja (Kananen & Puolitaival, 120).

2.2.2 Tukivektorikone (Support Vector Machine)

Tukivektorikonetta hyödynnetään laajasti sekä luokitteluun että regressioon (Zhang ja Sejdić, 2019, 4). Kananen ja Puolitaipaleen (2019, 120) mukaan sen yleisin käyttökohde on luokittelussa. Tukivektorikoneella pyritään luomaan niin kutsuttu hypertaso, joka erottelee eri havainnot toisistaan (Kananen & Puolitaival 2019, 120). Linearisesti erottuvalla datalla, eli suoralla janalla, on ääretön määrä erilaisia tasojia, jotka luokittelevat opetusaineiston oikein (Kananen & Puolitaival 2019, 120).

Yksinkertaisimmillaan hypertaso kuvaa rajaviivaa, joka erottaa kaksi tietoaaineistoa toisistaan. Luontevasti ajateltuna, mitä kauempana yksittäiset datapisteet ovat rajaviivasta, sitä "oikeammin" nämä pisteet on luokiteltu. Näin ollen halutaan, että hypertaso asettuu kohtaan, jossa kaikki datapisteet ovat mahdollisimman kaukana siitä ja vielä siten, että nämä pisteet ovat hypertason suhteen oikein luokiteltuja. Hypertason ja lähimmän datapisteen välistä etäisyyttä kutsutaan

marginaaliksi, ja se lasketaan algoritmin avulla. Päämääränä on valita hypertaso niin, että marginaali on mahdollisimman iso. (Kananen & Puolitaival 2019, 121.)

Harvemmin data on kuitenkaan näin puhdasta. Usein sitä ei voi erottaa suoralla janalla niin, että tarkkuus olisi riittävä. Tietoaineistoon on mahdollista lisätä ulottuvuuksia eli dimensioita. Tästä käytetään nimitystä ”kernelöinti” (*eng. kernel trick*). (Kananen & Puolitaival 2019, 122.) Tukivektorikoneen perusajatus on sijoittaa näytejoukon väliin sellainen taso, että sen kanssa yhdensuuntaisten marginaalitasojen välimatka on mahdollisimman suuri, eikä yksikään näytteistä jää marginaalitasojen väliin. Tukivektoreiksi kutsutaan marginaalitasojen välimatkaa rajoittavia näytevektoreita. Tukivektorikoneen vahvuuksia ovat tarkkuus ja sen kyky toimia pienillä ja kohtuullisen puhtailla data-seteillä. Isoilla tietoaineistoilla laskeminen taas voi viedä paljon tehoa ja aikaa, lisäksi suorituskyky heikkenee, jos aineistossa on kohinaa ja päällekkäisiä luokkia. Tukivektorikoneetta käytetään esimerkiksi väriin perustuvassa luokittelussa kuvantunnistuksessa. (Kananen & Puolitaival 2019, 123.)

2.2.3 Naïve Bayes

Kanasen ja Puolitaipaleen (2019, 124) mukaan Bayesin väittämä kuvaa ehdollisia todennäköisyyksiä. Siinä idea on, että teema vastaa kysymykseen, millä todennäköisyydellä tapahtuma A toteutuu, sillä ennakkoehdolla, että tapahtuma B havaitaan (Kananen & Puolitaival 2019, 124). Teoreemalle on annettu etuliitteeksi ”naïvi”, koska luokittelussa tehdään lähtöoletus, että jokainen ominaisuus on toisistaan riippumaton (Kananen & Puolitaival 2019, 124). Todellisissa ongelmissa nämä harvoin ovat täysin itsenäisiä. Tämä ominaisuus onkin teoreeman heikkous. Naïve Bayesilla voidaan kuitenkin saada selkeästi parempia tuloksia kuin muilla hienostuneemmilla algoritmeilla. Se on hyödyllinen sovelluksissa kuten dokumenttien luokittelussa. (Kananen & Puolitaival 2019, 124.)

2.2.4 Päätopuu (Decision Tree)

Päätopuu on yksi koneoppimisen suosituimmista menetelmistä, jota voidaan käyttää luokittelu- ja regressio-ongelmiin (Kananen & Puolitaival 2019, 125, Zhang & Sejdić 2019, 5). Yleensä tämä rakenne matkii ihmisen päättelyketjua (Kananen & Puolitaival 2019, 125). Kanasen ja Puolitaipaleen (2019, 125) mukaan päätopuun tapa toimia on helppo ymmärtää ja sen tuloksia on helppo tulkita. Päätopuu voidaan havainnollistaa esimerkiksi taulukkolaskentaohjelmissa. Algoritmi koostuu niin kutsutuista solmuista, oksista ja lehdistä. Päätopuun solmukohta esittää ominaisuutta, haara päätössiäntöä ja lehti päättelyn tulosta (Kananen & Puolitaival 2019, 125). Lehti voi edustaa sopivinta tavoitearvoa tai osoittaa todennäköisyyden sille, että kohteella on tietty arvo (Zhang & Sejdić 2019, 5). Ennustettava arvo voi olla jatkuva tai kategorinen arvo (Kananen & Puolitaival 2019, 125).

Kun tietoaineisto annetaan algoritmille, se lähtee jakamaan dataa siten, että ns. informaatiohyöty (*eng. information gain*) on maksimi jokaisessa jaossa. Tämä hyöty perustuu saatavilla olevaan tietoon tai informaatioon. Tiedonpuutteesta on vaikea ennustaa tulevaisuutta. Jos taas tietoa on saatavilla, siitä on helpompi muodostaa päätelmiä tai ennusteita. Päättöspuu yrittää tehdä jokaisen jaon siten, että tietoaineisto olisi ”paremmassa järjestyksessä”. (Kananen & Puolitaival 2019, 126.) Päättöspuut pystyvät käsittelemään tietoaineistoja, joissa voi olla puuttuvia arvoja ja virheitä, mutta tämä menetelmä voi kuitenkin ylisovittaa opetusdatan ja lisätä tarpeettomia ominaisuuksia (Zhang & Sejdić 2019, 5).

2.2.5 Satunnainen metsä (Random Forest)

Tämä algoritmi koostuu satunnaisten päättöspuiden muodostomasta kokoelmasta. Ideana on, että yksittäiseen päättöspuuhun otetaan sattumanvaraisesti tietoa tietoaineistosta. Tällöin käytetään ns. bootstrap-menetelmää, jossa jokaisella havainnoilla on yhtä suuri todennäköisyys tulla valituksi päättöspuuhun. Lopullinen tulos on satunnainen metsä. Se keskiarvoistaa kaikkien yksittäisten päättöspuiden lopputulokset. (Kananen & Puolitaival 2019, 126.)

2.3 Syväoppiminen ja sen yleisimmät algoritmit

Syväoppiminen on koneoppimisen alaryhmä (Alzubaidi ym. 2021, 4). Perinteiseen koneoppimiseen verrattuna syväoppiminen hyödyntää käsittelemätöntä dataa ja kykenee oppimaan vaadittavien mallien esitystavat itsenäisesti (Quanyang ym. 2024, 3). Syväoppiminen mahdollistaa monikerroksiset neuroverkkorakenteet (Quanyang ym. 2024, 3). Nämä lukuisat algoritmikerrokset, eli keino-koiset neuroverkot (ANN, artificial neural network) antavat kukin erilaisen tulkinnan niille syötetyistä tiedoista (Alzubaidi ym. 2021, 4). Samanaikaisesti tapahtuva ominaisuuksien valinta ja mallien sovitustekniikka on tehokas keino automatisoitujen mallien rakentamiseen ja valtavan datamäärän hyödyntämiseen (Quanyang ym. 2024, 3). Merilehdon (2018, 51) mukaan neuroverkon hienous tulee esiin vain silloin, kun sille pystytään syöttämään tarpeeksi dataa, tarkoittaen yleensä kymmeniä tai satojatuhansia esimerkkejä.

Alzubaidin ym. (2021, 4) mukaan syväoppimisesta on tullut erittäin suosittu viime vuosina johtuen massadata-alan (big data) valtavasta kasvusta ja kehityksestä. Syväoppiminen on edelleen jatkuvassa kehityksessä, ja onkin yksinkertaistanut useiden oppialojen kehitystä esimerkiksi kuvan superresoluutiota, objektien havaitsemista ja kuvantunnistusta (Alzubaidi ym. 2021, 5). Syväoppimisjärjestelmät kykenevät muuttamaan niille syötetyt kuvat arvokkaiksi tulosteiksi, kuten paikantamalla tietyn alueen, lokeroimalla pikseleitä kuvien segmentointiin, ja luokittelemalla kuvia erilaisiin kategorioihin (Alzubaidi ym. 2021, 5). Merilehdon (2018, 56) mukaan syväoppimisen merkittävimpiä hyötyjä on, että kyseinen järjestelmä kykenee oppimaan raakadatasta. Tiedon tai datan ei siis

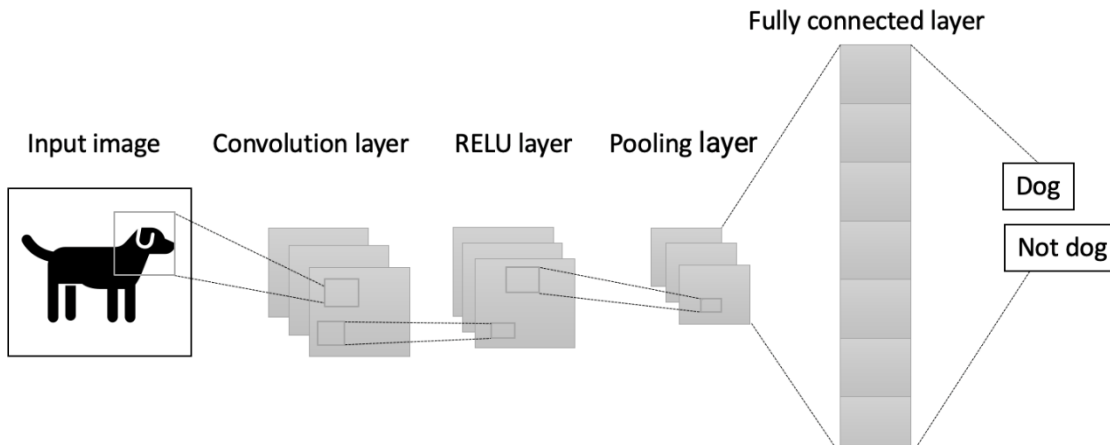
tarvitse olla tykkänään puhdasta, vaan siinä saa olla paljonkin ”hälyä”, siitä huolimatta syväoppimisjärjestelmä kykenee hahmottamaan ja käyttämään sitä oppimisessaan (Merilehto 2018, 56).

Lääketieteellisten kuvien analysoinnissa yleisimmin käytetty syväoppimisen arkkitehtuuri on konvoluutioneuroverkko (CNN, convolutional neural network) (Quanyang ym. 2024, 3). Se sisältää monimuotoisen ja runsaan määrän eri algoritmeja (Quanyang ym. 2024, 3).

2.3.1 Konvoluutioneuroverkko (CNN, convolutional neural network)

Erityisesti viime vuosina huomio on siirtynyt tukivektorikoneiden ja satunnaismetsän kaltaisista koneoppimismenetelmistä konvoluutioneuroverkkoihin (Barragán-Montero ym. 2021, 8). CNN-verkot alkoivat saada suosiota vuonna 2012, johtuen AlexNet arkkitehtuurista, joka kukisti kaikki muut mallit ennätysellisellä tarkkuudella ja alhaisella virheprosentilla imageNet-haasteessa 2012 (Sarvamangala & Kulkarni 2022, 2). CNN-verkot luetaan neuroverkkojen alalajiksi, jotka ovat erityisen hyviä käsittelemään kuvista koostuvaa dataa (Merilehto 2018, 53). CNN-verkot ovat saaneet inspiraationsa ihmisen näköjärjestelmästä, ja ne hyödyntävät kuvien sisältämän datan tilajärjestystä (Barragán-Montero ym. 2021, 9). Niiden huomattava kyky havaita hierarkkisia tietorakenteita on vaikuttanut niiden suosioon nykyisissä lääketieteellisissä kuvankäsittelysovelluksissa (Barragán-Montero ym. 2021, 9).

CNN-verkot, jotka hyödyntävät syväoppimisen algoritmeja, kuvaavat kerroksellista arkkitehtuuria, jossa ensimmäiset kerrokset kaappaavat alkeellisia piirteitä, kuten reunoja ja tekstuureja, kun taas myöhemmät kerrokset erottelevat asteittain monimutkaisempia ja abstraktimpia ominaisuuksia (Li, Jiang, Zhang & Zhu 2023, 2). Tällöin verkko pystyy itsenäisesti poimimaan kuvista asiaankuuluvaa tietoa, esimerkiksi segmentointia ja luokittelua varten (Li ym. 2023, 2). Kuvassa 4 näkyy yksinkertaistetusti, miten konvoluutioneuroverkkoa hyödynnetään kuvan luokittelussa.



Kuva 3. Esimerkkirakenne konvoluutioneuroverkon arkkitehtuurista kuvan luokitteluun (mukaillen Alzubaidi ym. 2021, 14).

CNN-verkon ydinrakenne koostuu kolmesta pääosasta: konvoluutiokerroksesta, yhdistämiskerroksesta/koontikerroksista (*eng. pooling layer*) ja täysin kytketystä kerroksesta (*eng. fully connected layer*) (Xu ym. 2024, 10). Prosessi alkaa syötekuvalla, joka kulkee useiden konvoluutiokerrosten läpi. Näissä kerroksissa käytetään erilaisia konvoluutiosuodattimia, joiden avulla kuvasta poimitaan keskeisiä ominaisuuksia, kuten reunoja, tekstuureja ja kuvioita. Jokaisen konvoluution jälkeen kuvaa pienennetään käyttämällä yhdistämiskerroksia, jotka vähentävät piirrekarttojen (feature map) tilaulottuvuuksia. Se auttaa säilyttämään olennaiset tiedot ja samalla vähentämään laskennallista monimutkaisuutta. Tämä konvoluution ja yhdistämiskerroksen sarja toistuu useita kertoja yhä monimutkaisempien ja abstraktimpien piirteiden vangitsemiseksi. Lopuksi verkko tasoittaa piirrekartat ja siirtää ne täysin yhdistettyjen kerrosten läpi. Niissä opitut ominaisuudet yhdistetään ylätason päätöksen tekemiseksi. Näin syntyy tuotos, joka on tyypillisesti luokittelumerkintä tai ennuste. (Xu ym. 2024, 10.)

Esimerkkejä yleisistä CNN-verkkoarkkitehtuureista ovat muun muassa LeNet, AlexNet, VGGNET. Useista arkkitehtuureista AlexNetiä, VGG:tä, GoogLeNetiä ja Dense CNN:ää pidetään yleisesti suosituimpina, koska niiden suorituskyky on huippuluokkaa kohteentunnistustehtävissä (Alom ym. 2020, 10.) Taulukossa 2 on kuvattu yleisimpiä CNN-arkkitehtuureja niiden julkaisuvuoden järjestyksessä.

Taulukko 2. Yleiset CNN-arkkitehtuurit (mukaillen Alom ym. 2020, 10–13).

Arkkitehtuuri	vuosi
LeNet	1998
AlexNet	2012

Arkkitehtuuri	vuosi
ZFNet / Clarifai	2013
VGGNET	2014
GoogLeNet	2014
Residual Network (ResNet)	2015
Densely Connected Network (DenseNet)	2017

2.3.2 Generatiivinen kilpaileva verkosto (GAN, generative adversarial network)

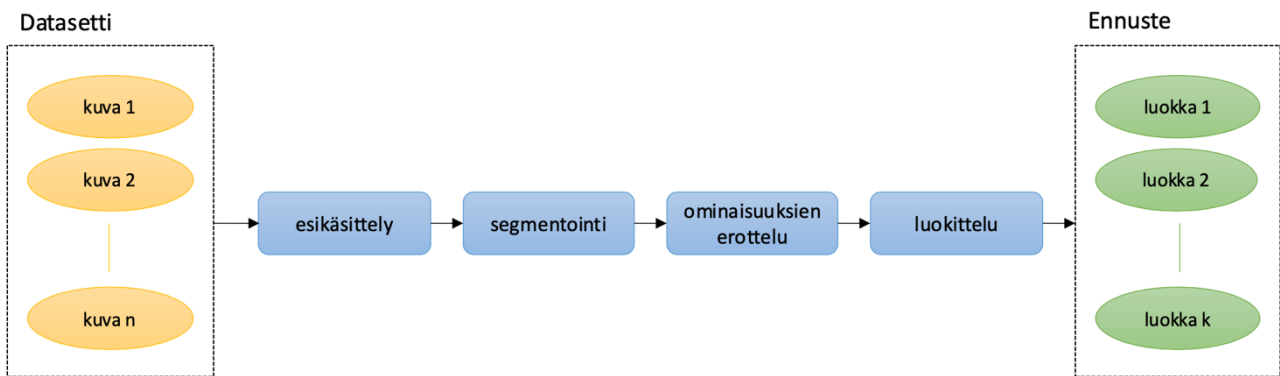
Syväoppiminen on tietopohjainen tekniikka, joka toimii paremmin, kun syötteiden määrä kasvaa. Tästä syystä merkkamattomasta datasta uudelleen käytettävien ominaisuuksien oppimisesta on tullut aktiivinen tutkimusalue. Suuret määrät merkittävää dataa on yritetty ratkaista luomalla samanlaisia näytteitä generatiivisella mallilla. (Alom ym. 2018, 23.) GAN-verkko on Goodfellown vuonna 2014 kehittämä syväoppimismenetelmä. Nämä verkot tarjoavat vaihtoehdoisen lähestymistavan maksimaalisen todennäköisyyden arviointitekniikoihin. GAN-verkot ovat ohjaamaton syväoppimismenetelmä, jossa kaksi hermoverkkoa kilpailevat toisiaan vastaan nollasummapelissä. (Alom ym. 2018, 24.)

GAN siis koostuu kahdesta verkosta: generaattorista g ja diskriminaattorista d . Toinen verkoista (generaattori) luo koko ajan realistisempaa dataa ja yrittää harhauttaa diskriminaattoria luulemaan sitä aidoksi (Merilehto 2018, 55). Lähtökohtana g yrittää iteratiivisesti kartoittaa satunnaista syöttöjakaumaa annettuun datajakaumaan luodakseen uutta dataa (Barragán-Montero ym. 2021, 11). Diskriminaattori arvioi tämän, ja riippuen palautteesta, generaattori pyrkii minimoimaan näiden kahden jakauman erot, tuottaen samanlaisia näytteitä syötteenä (Barragán-Montero ym. 2021, 11). Tavoite on huijata diskriminaattoria luokittamaan tuotettu data aidoksi (Barragán-Montero ym. 2021, 11). Molempia verkkoja koulutetaan samanaikaisesti parantamaan toimintaansa: kun generaattori oppii huijaamaan diskriminaattoria, d oppii samalla erottamaan paremmin tuotetun datan aidosta syötteestä (Barragán-Montero ym. 2021, 11). GAN-verkko poikkeaa monista muista verkoista siinä, että se tuottaa oman harjoitusdatansa (Merilehto 2018, 55).

GAN-verkkojen kyky matkia tiedonjakelua ja syntetisoida kuvia ennennäkemättömällä realismin tasolla, on luonut avoimia, uusia tapoja kuroa umpeen kuilua ohjatun oppimisen ja kuvanmuodostuksen välillä (Kazeminiä ym. 2020, 2).

3 Tekoälyn hyödyntäminen kuvien analysoinnissa

Lääketieteellinen kuva-analyysi on tutkimusala, joka sisältää lääketieteellisten kuvien käsittelyn, tulkinnan ja analysoinnin (Li ym. 2023, 2). Digitaalista kuvankäsittelyä käytetään yhä enemmän terveydenhuollossa, jotta lääketieteellisistä kuvista, kuten röntgenkuvista, magneettikuvista ja tietokonetomografiasta voidaan poimia hyödyllistä tietoa (Alnaggar ym. 2024, 2). Tämä asiaankuuluvan tiedon poimiminen helpottaa diagnosointia, sekä hoidon suunnittelua että toteuttamista (Li ym. 2023, 2). Lääketieteelliseen kuvankäsittelyyn kuuluu erilaisia tehtäviä kuten kuvan segmentointi, kuvan rekisteröinti, ominaisuuksien poisto, luokittelu ja visualisointi (Li ym. 2023, 2). Alnaggar ja kumppanit (2024, 5) nostavat näiden lisäksi esiin yhdeksi tärkeäksi vaiheeksi kuvien esikäsittelyn. Kuvassa 4 on esitelty kuva-analyysin eri vaiheita järjestyksessä. Koneiden tietokapasiteetin kasvetua, etenkin grafiikan käsittelyssä, syväoppiminen on lunastanut paikkansa lääketieteellisten kuvien analysoinnissa (Quanyang ym. 2024, 3).



Kuva 4. Lääketieteellisen kuva-analyysin prosessin eteneminen (mukaillen Alnaggar ym. 2024, 7).

3.1 Kuvien esikäsittely

Kuvien esikäsittely on ratkaiseva osa, johon kuuluu tekniikoita, kuten kohinan vähentäminen, kuvien parantaminen ja normalisointi, joilla pyritään parantamaan kuvien laatua ja yhdenmukaisuutta. (Li ym. 2023, 3). Alnaggarin ja kumppanien (2024, 13) mukaan kuvien esikäsittelyn lähestymistavat voidaankin ryhmitellä kolmeen päätyyppiin: väriavaruuden muuntamiseen, kohinan poistoon ja kuvan parantamiseen. Väriavaruuden muuntaminen on olennainen vaihe, joka auttaa parantamaan kuvien laatua parempaa analysointia ja diagnosointia varten (Alnaggar ym. 2024, 13). Väriavaruus sisältää värimallin, joka merkitsee pikselin arvoa, sekä kartoitusmenetelmän, joka yhdistää värin tiettyyn ryhmään värejä, jotka voidaan suorittaa (Alnaggar ym. 2024, 13). Alnaggarin ja kumppaneiden (2024, 13) mukaan RGB on yksi käytetyimmistä väriavaruuksista. Yleensä värikuvat suoritetaan kolmella kaistalla, jotka ovat punainen, vihreä ja sininen. (Alnaggar ym. 2024, 13.)

Kohinan korruptioimat kuvat ovat yleinen ongelma (Alnaggar ym. 2024, 13). Kohina vahingoittaa kuvaa yleensä sen hankinta- ja lähetysvaiheessa. Kohinanpoistotekniikoita käytetään kohinan minimoimiseksi siten, että kuvassa oleva tärkeä tieto säilyy. Kuva korruptoituu myös lähetyksen aikana, eikä kohinan korruptioimaa kuvaa yleensä yksinkertaisesti poisteta sen käsittelyssä. Kohinaksi kutsutaan kuvan pikseleiden arvon muutoksia. Lääketieteellisissä kuvissa on yleensä alhainen kontrasti verrattuna muihin sovelluskuviin. (Alnaggar ym. 2024, 13.)

3.2 Segmentointi

Lääketieteelliset kuvat sisältävät monia normaaleja rakenteita, kuten elimiä, luita, lihaksia ja rasvaa, sekä epänormaaleja rakenteita, kuten kasvaimia ja murtumia. Segmentointi on prosessi, jossa kuvista tunnistetaan ja erotellaan sekä normaalit että poikkeavat alueet. (Wang & Summers 2012, 13.) Tämä tarkoittaa kuvan jakamista erillisiin alueisiin, jotka vastaavat anatomisia rakenteita tai patologisia muutoksia, kuten kudoksia tai vaurioita. Segmentointi on keskeinen vaihe lääketieteellisessä kuvantamisessa, sillä se muodostaa perustan tarkalle diagnoosille, hoidon suunnittelulle ja erilaisille kliinisille analyyseille. (Xu ym. 2024, 1.)

Segmentoinnin onnistuminen on olennaista kuvien tulkinnan kannalta, mutta se on usein haastavaa alueiden monimutkaisuuden ja vaihtelun vuoksi. Ongelmina voivat olla esimerkiksi normaalista tai leikkausten jälkeisestä anatomiasta johtuva vaihtelu, epämääräiset ja puutteelliset rajat, riittämätön kontrasti, kuvissa esiintyvä kohina, sekä ulkopuoliset esineet. (Wang & Summers 2012, 13.) Nämä rajoitteet korostavat tarvetta yhä mukautuvammille ja vakaammille segmentointimenetelmille (Xu ym. 2024).

Segmentoinnin tavoitteena on yksinkertaistaa ja järjestää kuvadata käyttökelpoisempaan ja helpommin arvioitavaan muotoon (Alnaggar ym. 2024, 18). Jokaiselle kuvapikselille annetaan merkintä, jonka perusteella samanlaiset pikselit ryhmitellään, mahdollistaen rakenteiden ja poikkeamien tarkan tunnistamisen ja jatkokäsittelyn, kuten mittauksen suorittamisen (Alnaggar ym. 2024, 18; Soimakallio ym. 2005, 29). Kuvan jakaminen samankaltaisiin osiin tukee mielekästä arviointia ja auttaa tunnistamaan esimerkiksi anatomisia rakenteita tai mahdollisia poikkeavuuksia (Lloyd, Monaco & Bui 2016, 3; Galić, Habijan, Leventić & Romić 2023, 10).

Segmentointi toimii myös lähtökohtana piirteiden rajaamiselle, jossa kuvista poimitaan olennaisia ominaisuuksia ja malleja, joiden avulla voidaan havaita ja luokitella anatomisia rakenteita tai poikkeavuuksia (Li ym. 2023, 3–4). Segmentoinnin avulla voidaan paikantaa ja mitata tarkasti esimerkiksi kasvaimia, vaurioita tai elimiä, mikä edistää diagnostiikkaa ja hoidon suunnittelua. Sitä sovelletaan laajasti rakenteiden, kuten elinten, luiden, lihasten ja murtumien tunnistamisessa. (Zhang &

Sejdić 2019, 8; Li ym. 2023, 4.) Lopuksi luokittelu- ja tunnistustekniikoiden avulla erotellaan normaalit ja epänormaalit alueet, mikä tukee diagnosointia ja hoidon suunnittelua (Li ym. 2023, 4).

3.3 Luokittelu

Kuvien luokittelussa kuvat jaetaan ennalta määriteltyihin luokkiin tai kategorioihin, jotta voidaan määrittellä, mihin luokkaan tietty kuva kuuluu sen visuaalisten ominaisuuksien perusteella (Galić ym. 2023, 9). Galićin ja kumppaneiden (2023, 9) mukaan lääketieteellisen kuvantamisen kuva-analyysissä luokittelulla on kaksi ensisijaista tarkoitusta: kohteiden ja tutkimusten luokittelu. Kohteiden luokittelun tavoitteena on luokitella ennalta tunnistetut objektit johonkin useista selväpiirteisistä luokista (Galić ym. 2023, 9). Tutkimusluokittelussa taas keskitytään luokittelemaan diagnostinen kuva joko normaaliksi tai poikkeavaksi, tai kuvasta voidaan todeta sairaus tai sen puute. (Galić ym. 2023, 9).

Nykyään kuvien luokittelu sairauksien ennustamista, diagnosointia ja hoitoa varten saavutetaan pohjimmiltaan koneoppimis- ja syväoppimistekniikoita hyödyntäen. Syväoppimisen tekniikat ovat yhä suosituimpia, koska ne ovat erittäin tarkkoja ja ne vievät vähemmän aikaa, kun käsitellään valtavia tietokokonaisuuksia ja monimutkaisia tehtäviä. Luunmurtumien havaitseminen ja luokittelu ovat esimerkkejä lääketieteellisten kuvien luokittelusta. (Alnaggar ym. 2024, 65.) Kuva- ja tutkimusluokittelu olivat ensimmäisiä osa-alueita, joilla syväoppiminen vaikutti merkittävästi kuvien analyysiin (Litjens ym. 2017, 65).

3.4 Kuvien rekisteröinti

Kuvien rekisteröinti on myös kuva-analyysin kriittinen tehtävä. Tämä tehtävä tarkoittaa kahden tai useamman kuvan kohdistamista. (Galić ym. 2023, 10.) Kuvat voivat olla peräisin samasta potilaasta, mutta niiden ottoajat voivat olla erilaiset, tai ne voivat olla peräisin eri potilaista tai eri kuvantamismenetelmistä (Galić ym. 2023, 10). Kuvan rekisteröinnistä on valtavasti hyötyä erilaisissa lääketieteellisissä kuvantamissovelluksissa, jotka käsittävät monimuotoisen ja muotoaan muuttavan kuvan rekisteröinnin (Galić ym. 2023, 10). Vaikka segmentointi on ollut yksi suosituimpia syväoppimisen aiheita, tutkijat ovat havainneet, että neuroverkoista voi olla hyötyä parhaan mahdollisen rekisteröintituloksen saavuttamisessa (Litjens ym. 2017, 68).

4 Opinnäytetyön toteutus

4.1 Tutkimustyyppin määritelmä

Salmisen (2011, 6) mukaan kuvaileva kirjallisuuskatsaus on yksi yleisimmistä kirjallisuuskatsauksen perustyypeistä. Se voidaan määritellä yleiskatsaukseksi ilman tiukkoja ja tarkkoja sääntöjä (Salminen 2011, 6). Kuvailevaan kirjallisuuskatsaukseen käytetyt aineistot ovat laajoja eivätkä aineiston valintaa rajaa metodiset säännöt (Salminen 2011, 6). Ilmiö, jota tutkitaan, pystytään kuitenkin kuvaamaan laaja-alaisesti (Salminen 2011, 6). Salmisen (2011, 6) mukaan kuvailevan kirjallisuuskatsauksen tutkimuskysymykset ovat väljempiä kuin systemaattisessa katsauksessa tai meta-analyysissä.

Kangasniemi ja kumppanit (2013, 294) jäsentävät menetelmän neljän vaiheen kokonaisuudeksi: tutkimuskysymyksen muodostaminen, aineiston valitseminen, kuvailun rakentaminen ja tuotetun tuloksen tarkasteleminen. Vaikka tämä menetelmä on eriteltävissä erilaisiin vaiheisiin, sen tyypillinen piirre on, että vaiheet etenevät hermeneuttisesti ja päällekkäisesti suhteessa toisiinsa. (Kangasniemi ym. 2013, 294). Kuvaileva kirjallisuuskatsaus on tutkimusmenetelmä, jossa aikaisempaa tietoa kootaan, kuvaillaan ja jäsenellään tarkastelua varten (Kangasniemi ym. 2013, 298). Kuvaileva kirjallisuuskatsaus on aineistopohjaista ja tähtää ymmärtämään ilmiön kuvausta (Kangasniemi ym. 2013, 298). Kuvailevalla kirjallisuuskatsauksella on kaksi orientaatiota, jotka ovat narratiivinen ja integroiva katsaus (Salminen 2011, 6).

Tässä tutkimuksessa hyödynnetään integroivaa kirjallisuuskatsausta. Salmisen (2011, 8) mukaan sitä käytetään, kun tutkittavaa ilmiötä halutaan kuvata mahdollisimman monipuolisesti. Integroiva kirjallisuuskatsaus onkin hyvä tapa luoda uutta tietoa jo tutkitusta aiheesta (Salminen 2011, 8).

4.2 Aineiston keruu ja analysointi

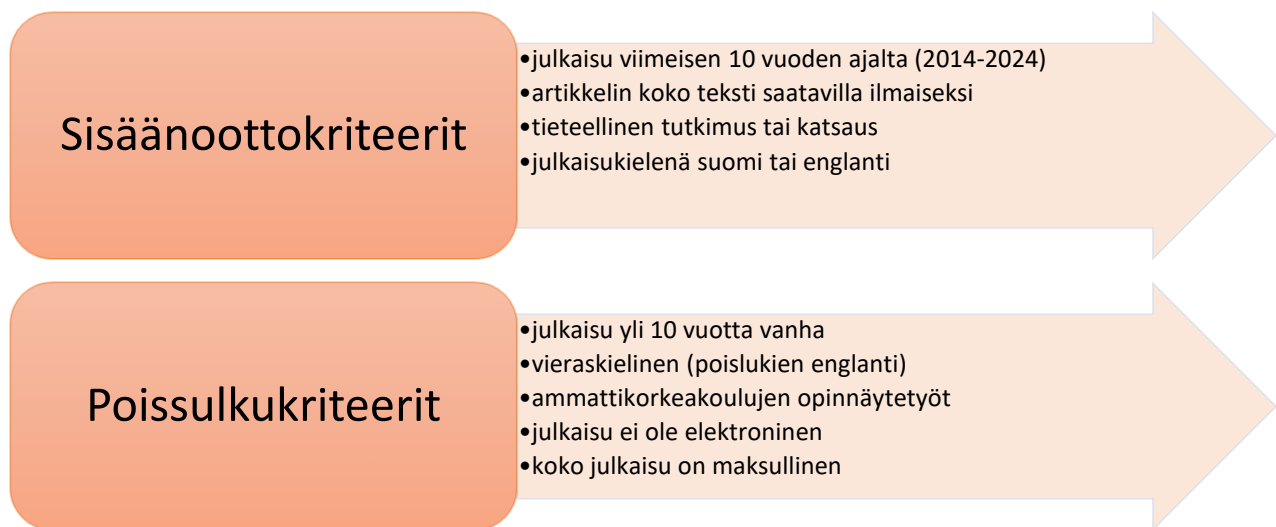
Tutkimuksessa käytetyt tieteelliset lähteet on haettu HH Finna -hakupalvelun, PubMedin ja Google Scholarin kautta. Tiedonhaussa on keskitytty erityisesti laajoihin kirjallisuuskatsauksiin, jotta aiheesta saadaan mahdollisimman kattava ja moniulotteinen kuva. Hakutuloksia seulottiin alkuvaiheessa tutkimusten otsikoiden ja tiivistelmien perusteella, minkä jälkeen relevantit julkaisut otettiin tarkempaan analyysiin.

Koska syväoppimisen algoritmeihin, kuten CNN- ja GAN-verkkoihin liittyvät sovellukset ovat yleistyneet merkittävästi kuvantamisen tutkimuksissa vuoden 2014 jälkeen, rajattiin tarkasteltavat julkaisut viimeiseen kymmeneen vuoteen. Hakusanoina käytettiin muun muassa seuraavia yhdistelmiä:

- "Deep learning" AND "Medical image analysis"
- "Machine learning" AND "Medical image analysis"

- "Medical imaging" AND "Artificial intelligence"
- "Medical image analysis" AND "GAN"
- "Medical image analysis" AND "CNN"

Lähteiksi valikoituivat pääosin englanninkieliset julkaisut, sillä suomenkielisiä, tieteellisesti luotettavia tutkimuksia aiheesta on saatavilla vain rajoitetusti. Kuvassa 5 on esitetty tarkemmin sisäänotto- kriteerit ja poissulkukriteerit. Tiedonhaku on toteutettu systemaattisesti ja se kattaa keskeiset tutkimuskysymykset liittyen tekoälyn hyödyntämiseen, sekä soveltamiseen liittyviin haasteisiin lääketieteellisessä kuvantamisessa.



Kuva 5. Tutkimuksen sisäänotto- ja poissulkukriteerit.

5 Syväoppimismallien hyötyjä ja haasteita

5.1 Syväoppimismallien hyödyt

Syväoppimisen, erityisesti CNN-verkkojen hyödyntäminen on mullistanut lääketieteellistä kuvantamista. Hyötyjä voidaan tarkastella erityisesti kahdesta näkökulmasta: ne ovat parantaneet diagnostiikkaan liittyvää tarkkuutta ja tehostaneet työnkulkua. GAN-verkot myös mahdollistavat synteettisen datan tuottamisen ja kuvanlaadun parantamisen. Seuraavissa alaluvuissa käsitellään näitä tarkemmin.

5.1.1 Diagnostinen tarkkuus ja tehokkuus

Syväoppimismenetelmät, erityisesti CNN-verkot, ovat parantaneet lääketieteellisten kuvien segmentoinnin tarkkuutta verrattuna perinteisiin menetelmiin (Xu ym. 2024, 15; Li ym. 2023, 6). CNN-verkot suoriutuvat tehokkaasti myös tehtävissä, kuten kohteiden paikantamisessa ja luokittelussa, mikä johtuu niiden kyvystä poimia olennaisia piirteitä monimutkaisista kuvista automaattisesti (Xu ym. 2024, 15; Li ym. 2023, 6). CNN-verkkojen avulla voidaan tunnistaa poikkeamia, diagnosoida kasvaimia sekä segmentoida elimiä rajaamalla monimutkaisia kuvioita ja rakenteita (Li ym. 2023, 69). Tällaiset ominaisuudet ovat parantaneet diagnostiikan tarkkuutta sekä mahdollistaneet prosessien automatisointia (Li ym. 2023, 6).

Perinteiset segmentointimenetelmät perustuvat usein ennalta määriteltyihin sääntöihin ja intensiteettiin pohjautuviin operaatioihin. Vaikka nämä menetelmät ovat tehokkaita ja helposti tulkittavia, niiden suorituskyky heikkenee monimutkaisten lääketieteellisten kuvien kohdalla, erityisesti tilanteissa, joissa esiintyy kohinaa, intensiteettivaihteluita tai monitulkintaisia rajoja. (Xu ym. 2024, 1–2.) CNN-verkot voivat oppia oleellisia ominaisuuksia suoraan raakadatasta ilman manuaalista piirteidenpoimintaa, ja ne soveltuvat hyvin laajojen ja monimutkaisten tietoaaineistojen käsittelyyn (Li ym. 2023, 17; Xu ym. 2024, 10).

CNN- ja GAN-verkot ovat osoittautuneet erityisen tehokkaiksi monimutkaisten anatomisten rakenteiden, kuten aivo-, maksa-, keuhko- ja eturauhaskasvainten segmentoinnissa. Ne pystyvät hallitsemaan sekä korkean että matalan tason ominaisuuksia, mikä tekee niistä hyvin soveltuvia lääketieteellisiin kuviin, joissa esiintyy usein epäsäännöllisiä muotoja, heikkoja rajoja ja vaihtelevia intensiteettitasoja. (Xu ym. 2024, 31.) Alnaggarin ja kumppanien (2024, 49–51) katsauksen mukaan GAN-verkkoja on käytetty tunnistamaan ja rajaamaan tarkasti erilaisia rakenteita ja poikkeavuuksia kuvista, kuten selkärangan osia, aivokudoksia ja kasvaimia. Joissakin tapauksissa GAN-verkkoja on yhdistetty konvoluutioneuroverkkoihin, jotta segmentoinnista on saatu tarkempaa (Alnaggar ym. 2024, 49–51). Katsauksessa (Xu ym. 2024, 21–23) esiteltiin kehittyneitä syväoppimismalleja

keuhkosyövän kuvantamiseen, erityisesti keuhkojen automaattiseen segmentointiin röntgenkuvista ja tietokonetomografiasta. Useat arkkitehtuurit hyödynsivät esikoulutettuja CNN-verkkoja, GAN-verkkoja tai laajennettuja CNN-verkkoja parantaakseen suorituskykyä ja pienentääkseen virhemarginaaleja. (Xu ym. 2024, 21–23.)

CNN-verkkojen on havaittu parantavan myös kuvien luokittelua, mikä tekee niistä hyödyllisiä lääketieteellisessä diagnostiikassa ja ennustamisessa (Li ym. 2023, 17). Murphy ja kumppanit (2020, E170) osoittivat, että tekoälyjärjestelmän suorituskyky oli verrattavissa kuuden asiantuntijalukijan tarkkuuteen COVID-19-taudin tunnistamisessa rintakehän röntgenkuvista. Tutkimuksessa käytettiin U-net-arkkitehtuuriin pohjautuvaa ohjelmistoa, joka hyödynsi CNN-verkkoa kuvien luokittelussa (Murphy ym. 2020, E167). Dorr kumppaneineen (2020, 6) havaitsi vastaavasti, että DenseNet121-arkkitehtuuria hyödyntävä syväoppimismalli paransi lääkärin suorituskykyä COVID-19-keuhkuumeen tunnistamisessa röntgenkuvista.

5.1.2 Synteettinen data ja kuvanlaadun parantaminen

Ohjaamattoman oppimisen menetelmät, kuten GAN-verkot, ovat osoittautuneet lupaaviksi, koska ne pystyvät oppimaan valikoivia ominaisuuksia ilman tarkkaa datan merkitsemistä (Hosny ym. 2018, 11). GAN-verkot kykenevät matkimaan datan jakaumia, tuottamaan realistisia kuvia ja oppimaan hyödyllisiä yhtäläisyysmittareita, jotka tukevat tarkkaa tunnistamista ja luokittelua (Kazemina ym. 2020, 28). Niitä on hyödynnetty esimerkiksi magneettikuvien tuottamiseen tietokonetomografiakuvista sekä realististen ihomuutosten mallintamiseen (Galić ym. 2023, 10).

Lääketieteellisessä kuvantamisessa joudutaan usein tasapainoilemaan kuvan kontrastin ja säteilyaltistuksen välillä. Parempi kontrasti voi parantaa diagnostiikkaa, mutta johtaa suurempaan säteilyannokseen, kun taas matala säteilyaltistus heikentää kuvanlaatua lisäämällä kohinaa (Kazemina ym. 2020, 24.). Syväoppimismalleja on käytetty onnistuneesti kuvan resoluution parantamiseen ja kohinan poistamiseen, mutta niillä on taipumus tuottaa epäselviä kuvia. GAN-verkot tarjoavat mahdollisuuden ratkaista tämä ongelma, tuottamalla terävämpiä ja realistisempia kuvia (Kazemina ym. 2020, 24.).

CNN-verkot vaativat laajoja opetusaineistoja, mutta lääketieteellisen kuvadatan saatavuus on usein rajoitettua (Kazemina ym. 2020, 26; Xu ym. 2024, 14). GAN-verkot voivat kuitenkin auttaa laajentamaan opetusdataa ja tuottamaan aluekohtaisia piirteitä, mikä tukee CNN-verkkojen opettamista (Kazemina ym. 2020, 26; Xu ym. 2024, 14). Lisäksi ne kykenevät tunnistamaan merkityksellisiä kuvapiirteitä, joita pikselipohjaiset, perinteiset menetelmät eivät pysty havaitsemaan. Tätä ominaisuutta on hyödynnetty menestyksekkäästi kuvien segmentoinnissa, rekisteröinnissä ja kohinan poistossa (Kazemina ym. 2020, 29).

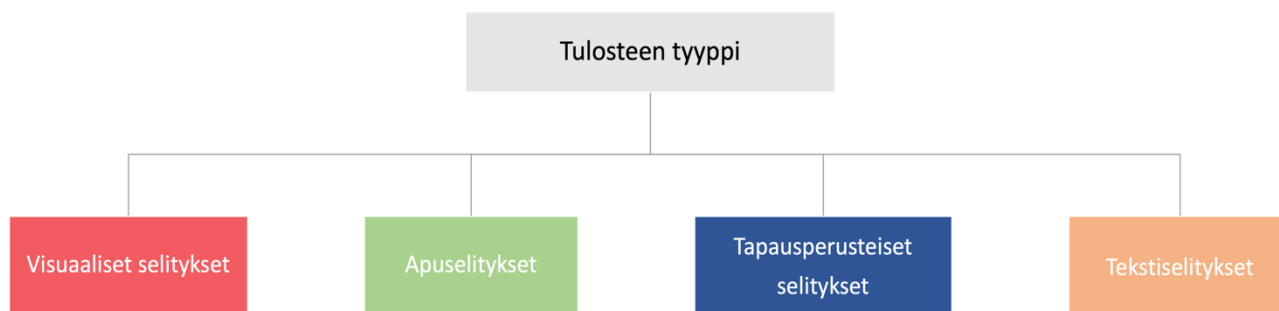
5.2 Syväoppimismallien haasteet

Syväoppimismallit ovat tehokkaita, mutta koska ne ovat verrattain uusi tutkimusala, niiden hyödyntämiseen liittyy edelleen haasteita. Seuraaviin lukuihin on koottu yleisimmät haasteet.

5.2.1 Mallien läpinäkyvyys ja selitettävyys

Vaikka syväoppimismallit ovat osoittautuneet tehokkaiksi, niiden läpinäkyvyyden puute muodostaa merkittävän haasteen. Näiden mallien toimintaa on vaikea selittää, mikä johtuu neuroverkkojen neuronien yhteyksien monimutkaisuudesta ja matemaattisista käsitteistä, joita nämä yhteydet luovat, esimerkiksi merkitsemällä pikseleiden yhdistelmiä kuvassa. (Quinn, Jacobs, Senadeera, Le & Coghlan 2022, 3.) Tämän vuoksi syväoppimismalleista käytetään termiä ”musta laatikko” (*eng. black box*), jonka sisäiset toiminnot jäävät epäselviksi (Quinn ym. 2022, 3, Litjens ym. 2017, 80; Xu ym. 2024, 14–15). Tämä vaikeuttaa niiden kliinistä hyödyntämistä (Quinn ym. 2022, 3, Adadi & Berrada 2018, 52–138). Läpinäkyvyyden puute heikentää myös virheiden tunnistettavuutta. Jos malli perustuu virheelliseen tai puutteelliseen opetusdataan, sen ennusteiden arviointi on vaikeaa. Tällöin mahdolliset virheet voivat jäädä huomaamatta ja johtaa vääriin johtopäätöksiin (Quinn ym. 2022, 3.)

Algoritmien läpinäkyvyysongelman ratkaisemiseksi on kehitetty selittävä tekoäly (XAI, Explainable Artificial Intelligence), jonka tavoitteena on luoda tekniikoita, jotka tuottavat selitettävissä olevia malleja ilman suoritustason heikkenemistä (Adadi & Berrada 2018, 52–138). Teknisesti selittävälle tekoälylle ei ole olemassa standardia ja yleisesti hyväksyttyä määritelmää. (Adadi & Berrada 2018, 52–140.) Yksi XAI:n sovellusalue on visuaaliset esitykset, kuten huomiokartat ja lämpökartat, jotka osoittavat, mitkä kuvan alueet vaikuttavat eniten mallin tekemisiin ennusteisiin. Esimerkiksi GAN- tai CNN-pohjaisissa malleissa olevat piirrekartat (*eng. saliency maps*) voivat auttaa havaitsemaan kasvainsegmentoinnissa tärkeimmät kuvapiirteet, lisäten luottamusta mallin päätöksiin. (Xu ym. 2024, 32.) Näiden lisäksi XAI-tekniikat voidaan jakaa kolmeen alaryhmään: apuselityksiin, tapauskohtaisiin selityksiin ja tekstimuotoisiin selityksiin, kuten kuvassa 6 (Borys ym. 2023, 2–3).



Kuva 6. Selittävän tekoälyn lähestymistapojen erottelua tuloksena saatavan esitysmuodon avulla (mukaillen Borys ym. 2023, 2).

Syväoppimismallien ennusteiden pohjalta voidaan myös kouluttaa tulkitsevia malleja, kuten päätöspuita tai lineaarisia malleja, jotta päätöksentekoprosessista saadaan yksinkertaisempi ja ymmärrettävämpi (Xu ym. 2024, 15).

5.2.2 Datan laatu ja saatavuus

Yksi keskeisimmistä haasteista syväoppimismenetelmissä on laadukkaan, merkityn kuvadatan saatavuus. (Li ym. 2023, 19). Mallien tehokas oppiminen edellyttää suuria määriä huolellisesti merkittyä dataa (Xu ym. 2024, 14; Li ym. 2023, 19). Tällaisten laadukkaiden lääketieteellisten kuvien saaminen on kuitenkin vaikeaa, sillä niiden tuottaminen ja annotointi on kallista ja aikaa vievää. (Li ym. 2023, 19; Xu ym. 2024, 14). Lisäksi pätevien asiantuntijoiden saatavuus voi olla rajoitettua. (Li ym. 2023, 19.) Erityistä haastetta aiheuttavat harvinaiset sairaudet, joita varten saatavilla oleva data on vähäistä tai puutteellisesti merkittyä (Hosny ym. 2018, 11). Harvinaisten tapausten kohdalla esimerkiksi GAN-verkot eivät välttämättä kykene tuottamaan realistisia esimerkkejä, mikä heikentää mallien kykyä yleistää (Li ym. 2023, 17).

Lääketieteelliset kuvat ovat luonteeltaan monimutkaisia ja vaihtelevia. Tämän vuoksi kuvien merkitseminen vaatii tarkkuutta ja johdonmukaisuutta, mikä voi osoittautua haasteelliseksi monimutkaisten ja heterogeenisten sairauksien kohdalla. (Li ym. 2023, 19.) Litjens ym. (2017, 78) toteavatkin, että ongelmana ei ole pelkästään kuvien saatavuus, vaan relevanttien merkintöjen tuottaminen. Laadukkaan datan puute voi johtaa vinoumiin ja virheisiin mallien toiminnassa. Esimerkiksi sukupuoleen tai etnisiin ryhmiin liittyvät epätasapainot saattavat heijastua mallin ennusteisiin. Tämä vaarantaa eettisyyden ja luotettavuuden. (Barragán-Montero ym. 2021, 13.) Lisäksi tiedonkeruun hitaus on merkittävä haaste: tekoälymallien koulutus vie vain tunteja, mutta hyvin kuratoitujen tietokantojen kokoaminen voi kestää kuukausia (Barragán-Montero ym. 2021, 13).

Litjens ym. (2017, 79) tuovat esiin, että kuvien luokittelu tai segmentointi esitetään usein binäärisenä: normaali vastaan epänormaali, objekti vastaan tausta. Tämä on usein liian karkea yksinkertaistus (Litjens ym. 2017, 79). Etenkin harvinaisten löydösten kohdalla mallien suorituskyky voi heikentyä merkittävästi. Litjens ym. (2017, 79) ehdottavat ratkaisuksi moniluokkaisia järjestelmiä, mutta toteavat, että asiantuntijoiden rajallinen käytettävyyys rajoittaa tämän lähestymistavan käytännön toteutusta. Toinen haaste liittyy luokkien epätasapainoon (Litjens ym. 2017, 79; Sarvamangala & Kulkarni 2022, 16–17). Esimerkiksi mammografiassa suurin osa kuvista on normaaleja, jolloin poikkeamien havaitseminen vaikeutuu ja mallien opetus painottuu väärin kohteisiin (Litjens ym. 2017, 79). Kun positiivista luokkaa (esim. sairaus) esiintyy usein huomattavasti vähemmän kuin normaalia dataa, CNN-verkkomallien suunnittelu epätasapainoiselle aineistolle on vaikeaa (Sarvamangala & Kulkarni 2022, 16–17).

5.2.3 Eettisyys ja yksityisyys

Li ja kumppanit (2023, 19) nostavat esiin, että potilaan yksityisyyden säilyttäminen datan hyödyntämisen kanssa samanaikaisesti on haastavaa, erityisesti visuaalisen datan osalta. Lääketieteellisen kuvadatan merkitseminen voikin altistaa arkaluontoisia potilastietoja väärinkäytöksille tai luvattomalle käytölle (Li ym. 2023, 19). Saw ja Ng (2022, 13) nostavat esiin, että sairaaloiden kyberturvallisuus on heikointa muihin toimialoihin verrattuna, sillä ne investoivat verkkojärjestelmien turvallisuuteen yleisesti hyvin vähän. Vuonna 2020 terveydenhuollon kyberhyökkäysten määrä Euroopassa nousi 67 prosenttia ja Yhdysvalloissa 55 prosenttia edelliseen vuoteen verrattuna (Saw & Ng 2022, 13).

Saw ja Ng (2022, 13) nostavat myös esiin, että jo vuonna 2014 ehdotettiin yhteisen lääkinnällisen tietokannan perustamista tekoälyteknologioiden kehityksen helpottamiseksi, mutta se sai eurooppalaisissa aikaaan vastustusta juuri yksityisyyden suojaan liittyvien huolien vuoksi (Saw & Ng 2022, 13). Jotta tekoälyn kehitystä voitaisiin tukea terveydenhuollossa, ovat monet organisaatiot jo julkaisseet yhtenäisiä linjauksia. Esimerkiksi Maailman terveysjärjestö (WHO) julkaisi ensimmäiset ohjeensa tekoälyn käytöstä otsikolla "Tekoälyn etiikka ja hallintotapa terveydenhuollossa". Lisäksi Yhdysvaltain elintarvike- ja lääkevirasto (FDA) on julkaissut omat ohjeensa, jotka tukevat tekoälyalgoritmien kehittämistä lääkinnällisenä laitteena. Myös Euroopan Unioni on lähtenyt mukaan suosituksella, joka sekin käsittelee tekoälyn eettistä kehitystä. (Saw & Ng 2022, 15.)

6 Pohdinta

Kuten luvussa 5.1.1 todettiin syväoppimismalleilla, erityisesti konvoluutioneuroverkoilla, lääketieteellisiä kuvia voitaisiin segmentoida perinteisiä menetelmiä nopeammin ja jopa tarkemmin. Konvoluutioneuroverkkojen kyky oppia laajoista ja monimutkaisista kuva-aineistoista on valttia, sillä kuvien laatu voi vaihdella merkittävästi kohinan ja muiden häiriötekijöiden vuoksi. Lisäksi potilaiden anatomiset rakenteet voivat poiketa huomattavasti normaalista. Konvoluutioneuroverkot voisivat ratkoa näitä haasteita, vapauttaen samalla aikaa ammattilaisten päätöksentekoon, aikaa vievän tulkinnan sijasta. Ne voisivat olla myös tulevaisuuden työkalu syrjäisille seuduille, jossa ammattilaisista voi olla pulaa.

GAN-verkkojen rooli synteettisen datan luomisessa ja kuvanlaadun parantamisessa tarjoaa lupavia ratkaisuja rajallisen opetusdatan saatavuuteen, erityisesti harvinaisten sairauksien kohdalla. GAN-verkkojen kyky generoida realistista dataa ja parantaa olemassa olevien kuvien laatua voi auttaa laajentamaan syväoppimismallien opetusaineistoja ja parantamaan niiden yleistämiskykyä.

Vaikka syväoppimismalleilla on saatu huomattavia etuja, luku 5.2 tuo esiin kriittisiä haasteita, jotka on ratkaistava, jotta nämä menetelmät voitaisiin ottaa laajemmin käyttöön kliinisessä ympäristössä. Mallien läpinäkyvyyden ja selitettävyyden puute voi olla merkittävä este asiantuntijoiden luottamuksen rakentamiselle. Radiologien ja lääkäreiden on voitava ymmärtää, mihin mallien päätökset perustuvat, jotta he voivat luottaa niihin kliinisessä päätöksenteossa. Selittävän tekoälyn (XAI) kehitys voisi tarjota ratkaisuja, kuten päätöksentekoa tukevat huomiokartat.

Toinen merkittävä haaste liittyy datan laatuun ja saatavuuteen. Vaikka GAN-verkot voisivat auttaa synteettisen datan luomisessa, laadukkaan ja huolellisesti merkityn aidon datan tarve on edelleen kriittinen. Kuva-aineistojen merkitsemisen kalleus, ajankäyttö ja asiantuntijoiden rajallinen saatavuus voivat muodostaa merkittäviä haasteita. Lisäksi mahdolliset vinoumat tietoaaineistoissa voivat heikentää mallien suorituskykyä ja eettistä luotettavuutta. Eettiset ja yksityisyyteen liittyvät näkökohdat korostuvat arkaluonteisen potilastiedon käsittelyssä.

Kuten kappaleessa 5.2.3 todetaan, terveydenhuoltoon tehdään runsaasti kyberhyökkäyksiä, mutta muihin toimialoihin verrattuna esimerkiksi sairaaloiden tietoturva on heikompaa. Myös tekoälyjärjestelmät ovat varmasti kyberrikollisten mielenkiinnonkohteena, joten niiden suojaaminen vaatii erityistä huomiota. Datan anonymisoinnin ja potilaiden yksityisyyden suojaamisen on oltava ensisijaista samalla, kun kuva-aineistoja pyritään hyödyntämään kehityksessä.

6.1 Jatkotutkimus

Syväoppimismallien mahdollistaminen lääketieteellisen kuva-analyysin tukena on jatkuvasti kasvava tutkimusten kohde. Mielestäni tutkimuksissa on tullut esiin runsaasti aihioita, mutta niiden siirtäminen käytäntöön on haastavaa. Uskon, että tulevaisuuden isoin haaste onkin saada malleja kliiniseen käyttöön. Tutkimukset tekoälyn ja ammattilaisen yhteistyöstä ovat olleet lupaavia, osoittaen että syväoppimismallit voisivat parantaa ja tehostaa diagnostiikkaa, vähentäen samalla työtaakkaa. On kuitenkin ensiarvoisen tärkeää varmistaa järjestelmien luotettavuus. Erityisesti algoritmien keskeisyys, eli esimerkiksi, miten mahdollisten virheiden vaikutus mallin ennusteeseen voidaan estää, vaatii lisää tutkimusta. Jatkossa tarvitaan ehdottomasti keinoja, joilla parantaa algoritmien läpinäkyvyyttä.

Lisäksi yksi isoimmista näkökulmista liittyy tekoälyn eettisyyteen. Tekoälyn hyödyntäminen vaatii yhteisiä käytäntöjä, sekä eettisiä linjauksia niin maailmanlaajuisesti kuin alueellisestikin. Tämän eteen on jo tehty runsaasti työtä, ja olisi mielenkiintoista tarkastella, missä mennään tällä hetkellä. Kiinnostava näkökulma on myös pohtia tekoälyä lain näkökulmasta. Tällöin kysymys kuuluu: kenenellä on lopullinen vastuu järjestelmän tuottamasta virheestä, mikäli se aiheuttaa potilaalle hengenvaaran?

6.2 Oman projektin ja oppimisen arviointi

Opinnäytetyöprojekti oli monella tapaa haastava mutta samalla erittäin opettavainen prosessi. Tekoäly on mullistanut nykypäivän kuvankäsittelyä, joten kiinnostuin, millainen potentiaali sillä voisi olla terveydenhuollossa. Minulla oli hieman aiempaa osaamista, mutta lähinnä koneoppimisesta. Opinnäytetyön myötä opin huomattavasti syvemmin tekoälyn eri osa-alueista, sekä kone- että syväoppimisen algoritmeista.

Tutkimuksen alkuvaiheessa suunnittelin eri algoritmien keskinäistä vertailua, mutta huomasin nopeasti, että aihe saattaisi muuttua teknisesti liian haastavaksi ja laajaksi. Erityisesti CNN-verkkojen monimutkainen rakenne, sekä niiden pohjalta kehitetyt sovellukset ja hybridiratkaisut olisivat tehneet vertailusta haastavaa. Koin hyödyllisemmäksi tarkastella aihetta yleisemmällä tasolla – keskittyen siihen, missä kuvantamisen vaiheissa näitä menetelmiä voidaan käyttää ja millaisia etuja niillä on esimerkiksi tarkkuuteen, tehokkuuteen tai diagnosoimiseen.

Yksi tutkimuksen työläimmistä vaiheista oli luotettavan aineiston keruu ja analysointi. Alussa tarvitsin paljon aikaa pelkkään aiheeseen tutustumiseen, jotta sitä voisi rajata onnistuneesti. Lisäksi aineistojen kääntäminen vei enemmän aikaa, kuin osasin odottaa. Tekoälyyn liittyy paljon teknistä sanastoa, jonka suomentaminen ei ollut aina niin suoraviivaista. Osa termeistä oli myös verrattain uusia, joten niille oli vaikea löytää suomenkielistä vastinetta. Työn myötä onnistuin kehittämään

omia työskentelytapoja, sekä hyödyntämään uusia työkaluja tutkimuksen tukena. Hienoa oli myös huomata, että aiheen tutkiminen herätti lisää kysymyksiä sekä näkökulmia, joiden parissa voin jatkaa esimerkiksi jatko-opintojen tai muun kehityksen muodossa.

Lähteet

- Adadi, A. & Berrada, M. 2018. Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). *IEEE Access*, 6, s. 52138–52160.
- Alnaggar, O.A.M.F., Jagadale, B.N., Saif, M.A.N., Ghaleb, O.A.M., Ahmed, A.A.Q., Aqlan, H.A.A. & Al-Ariki, H.D.E. 2024. Efficient artificial intelligence approaches for medical image processing in healthcare: comprehensive review, taxonomy, and analysis. *Artificial Intelligence Review*, 57, 8, s. 1–139.
- Alom, M.Z., Taha, T.M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M.S., Esesn, B.C.V., Awwal, A.A.S. & Asari, V.K. 2018. The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches. s. 1–39.
- Barragán-Montero, A., Javaid, U., Valdés, G., Nguyen, D., Desbordes, P., Macq, B., Willems, S., Vandewinckele, L., Holmström, M., Löfman, F., Michiels, S., Souris, K., Sterpin, E. & Lee, J.A. 2021. Artificial intelligence and machine learning for medical imaging: a technology review. *Physica medica: PM: an international journal devoted to the applications of physics to medicine and biology: official journal of the Italian Association of Biomedical Physics (AIFB)*, 83, 221, s. 242–256.
- Bohr A. & Memarzadeh K. 2020. *Artificial Intelligence in Healthcare*. Academic Press. E-kirja. Luettu: 10.11.2024.
- Dorr F., Chaves H., Mercedes Serra M., Ramirez A., Elías Costa M., Seia J., Cejas C., Castro M., Eyheremendy E., Fernández Slezak D. & Farez M. F. 2020. COVID-19 pneumonia accurately detected on chest radiographs with artificial intelligence. *Intelligence-Based Med*, 3-4, s. 1-7.
- Galić, I., Habijan, M., Leventić, H. & Romić, K. 2023. Machine Learning Empowering Personalized Medicine: A Comprehensive Review of Medical Image Analysis Methods. *Electronics*, 12, 21, s. 4411, s. 1-29.
- Huhtanen H., Nyman M., Karlsson A. & Hirvonen J. 2020. Tekoäly radiologiassa. *Duodecim*, 136, s.1957-1964.
- Kananen H. & Puolitaival H. 2019. *Tekoäly – bisneksen uudet työkalut*. Alma Talent. E-kirja. Luettu: 26.11.2024.
- Kangasniemi, M., Pietilä, A-M., Utriainen, K., Jääskeläinen, P., Ahonen, S-M & Liikanen, E. 2013. Kuvaileva kirjallisuuskatsaus: eteneminen tutkimuskysymyksestä jäsennettyyn tietoon. *Hoitotiede* 2013, 25 (4), s. 291-301.

Kazemina, S., Baur, C., Kuijper, A., van Ginneken, B., Navab, N., Albarqouni, S. & Mukhopadhyay, A. 2020. GANs for medical image analysis. *Artificial Intelligence in Medicine*, 109, s. 1–40.

Kolari J. & Kallio A. 2023. *Tekoäly 123*. Docendo. E-kirja. Luettu: 1.4.2024.

Kufel, J., Bargiel-Łączek, K., Kocot, S., Koźlik, M., Bartnikowska, W., Janik, M., Czogalik, Ł., Dudek, P., Magiera, M., Lis, A., Paszkiewicz, I., Nawrat, Z., Cebula, M. & Gruszczyńska, K. 2023. What Is Machine Learning, Artificial Neural Networks and Deep Learning?—Examples of Practical Applications in Medicine. *Diagnostics*, 13, 15, 2582 s. 1–22.

Li, M., Jiang, Y., Zhang, Y. & Zhu, H. 2023. Medical image analysis using deep learning algorithms. *Frontiers in Public Health*, 11, s.1–28.

Li, J., Jiang, P., An, Q., Wang, G.-G. & Kong, H.-F. 2024. Medical image identification methods: A review. *Computers in Biology and Medicine*, 169, s.1–26.

Lloyd, M.C., Monaco, J.P. & Bui, M.M. 2016. Image Analysis in Surgical Pathology. *Surgical pathology clinics*, 9, 2, s.1–13.

Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M., van der Laak, J.A.W.M., van Ginneken, B. & Sánchez, C.I. 2017. A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, s. 60–88.

Merilehto, A. 2018. *Tekoäly: matkaopas johtajalle*. Alma Talent. Helsinki. E-kirja. Luettu: 22.11.2024.

Murphy K., Smits H., Knoop A. J. G., Korst M. B. J. M., Samson T., Scholten E. T., Schalekamp S., Schaefer-Prokop C. M., Philipsen R. H. H. M., A., Melendez J., van Ginneken B., Rutten M. 2020. COVID-19 on Chest Radiographs: A Multireader Evaluation of an Artificial Intelligence System. *Radiology* 296, 3, s. E166-E172.

Quanyang, W., Yao, H., Sicong, W., Linlin, Q., Zewei, Z., Donghui, H., Hongjia, L. & Shijun, Z. 2024. Artificial intelligence in lung cancer screening: Detection, classification, prediction, and prognosis. *Cancer Medicine*, 13, 7, s. 1–19.

Quinn, T.P., Jacobs, S., Senadeera, M., Le, V. & Coghlan, S. 2022. The three ghosts of medical AI: Can the black-box present deliver? *Artificial Intelligence in Medicine*, 124, s. 102158, s.1–12.

Salminen, A. 2011. Mikä kirjallisuuskatsaus? – Johdatus kirjallisuuskatsauksen tyyppeihin ja hallintotieteellisiin sovelluksiin. *Vaasan yliopiston opetusjulkaisuja* 62. Vaasan yliopisto.

Sarvamangala, D.R. & Kulkarni, R.V. 2022. Convolutional neural networks in medical image understanding: a survey. *Evolutionary Intelligence*, 15, s. 1–22.

Saw, S.N. & Ng, K.H. 2022. Current challenges of implementing artificial intelligence in medical imaging. *Physica Medica*, 100, s. 12–17.

Soimakallio S., Kivisaari L., Manninen H., Svedström E., Tervonen O., Söderström W. 2005. *Radiologia WSOY*. 1. painos. Porvoo/Helsinki.

Wang, S. & Summers, R.M. 2012. Machine learning and radiology. *Medical Image Analysis*, 16, 5, s. 1–44.

Xu, Y., Quan, R., Xu, W., Huang, Y., Chen, X. & Liu, F. 2024. Advances in Medical Image Segmentation: A Comprehensive Review of Traditional, Deep Learning and Hybrid Approaches. *Bioengineering*, 11, 1034, s. 1–42.

Yamashita, R., Nishio, M., Do, R.K.G. & Togashi, K. 2018. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9, s. 611–629.

Zhang, Z. & Sejdić, E. 2019. Radiological images and machine learning: Trends, perspectives, and prospects. *Computers in Biology and Medicine*, 108, s. 1–50.

What is a decision tree? IBM. Luettavissa: <https://www.ibm.com/think/topics/decision-trees>. Luettu 19.4.2024

What are support vector machines (SVMs)? IBM. Luettavissa: <https://www.ibm.com/topics/support-vector-machine>. Luettu 19.4.2024

What is random forest? IBM. Luettavissa: <https://www.ibm.com/topics/random-forest>. Luettu 19.4.2024.

7 Liitteet

7.1 Liite 1. Opinnäytetyössä hyödynnetyt tieteelliset julkaisut

Julkaisun nimi	Tekijät (vuosi)	Tutkimus-tyyppi	Keskeinen sisältö	Tutkimuskysymys	Kappale
Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI)	Adadi A. & Berrada M. (2018)	Kirjallisuuskatsaus	Selittävän tekoälyn ratkaisuja tekoälymallien ennusteiden ymmärtämiseen	TK3	5.2.1
Artificial intelligence and machine learning for medical imaging: a technology review	Barragán-Montero ym. (2021)	Kirjallisuuskatsaus	Esittelee tekoälyn menetelmiä ja niiden soveltamista kuvantamisen osalualueisiin	TK1, TK2	2.1, 2.2, 2.3.1, 2.3.2, 5.2
Explainable AI in medical imaging: An overview for clinical practitioners – Beyond saliency-based XAI approaches	Borys ym. (2023)	Kirjallisuuskatsaus	Tarkastelee selittävän tekoälyn käytännön ratkaisuja tekoälymallien ennusteiden ymmärtämiseen	TK3	5.2.1
COVID-19 pneumonia accurately detected on chest radiographs	Dorr ym. (2020)	Empiirinen tutkimus	Tutkii COVID-19 taudin tunnistamista keuhkojen röntgenkuvista pelkän	TK1	5.1.1

Julkaisun nimi	Tekijät (vuosi)	Tutkimus-tyyppi	Keskeinen sisältö	Tutkimuskysymys	Kappale
with artificial intelligence			asiantuntijan tulkinnan avulla, sekä asiantuntijan ja tekoälyn yhteistyönä		
Machine Learning Empowering Personalized Medicine: A Comprehensive Review of Medical Image Analysis Methods	Galić ym. (2023)	Kirjallisuuskatsaus	Tutkii syväoppimismallien (CNN, GANN) rakennetta ja hyödyntämistä kuvantamisen osalualueilla	TK1, TK3	3.3, 3.4, 5.1.2
Artificial intelligence in radiology	Hosny ym. (2018)	Kirjallisuuskatsaus	Tutkii valmiiksi koulutetun AlexNet sovelluksen hyödyntämistä ihovaurioiden luokittelussa	TK3	5.1.2
GANs for medical image analysis	Kazemina ym. (2020)	Kirjallisuuskatsaus	Tutkii GAN-verkkojen rakennetta sekä hyödyntämistä kuvantamisen osalualueilla	TK1	2.3.2, 5.1.2

Julkaisun nimi	Tekijät (vuosi)	Tutkimus-tyyppi	Keskeinen sisältö	Tutkimuskysymys	Kappale
Medical image analysis using deep learning algorithms	Li ym. (2023)	Kirjallisuuskatsaus	Tutkii syväoppimismallien rakenteita sekä hyödyntämistä eri kuvantamisen osa-alueilla	TK1, TK2, TK3	2.3.1, 3, 3.1, 3.2, 5.1.1, 5.2.2, 5.2.3
A survey on deep learning in medical image analysis	Litjens ym. (2017)	Kirjallisuuskatsaus	Tutkii syväoppimismallien hyödyntämistä eri kuvantamisen osa-alueilla	TK1, TK3	3.3, 3.4, 5.2.1, 5.2.2
COVID-19 on Chest Radiographs: A Multi-reader Evaluation of an Artificial Intelligence System	Murphy ym. (2020)	Empiirinen tutkimus	Tutkii COVID-19 taudin aiheuttaman keuhkokuumeen tunnistamista keuhkojen röntgenkuvista CNN-menetelmällä	TK1	5.1.1
The three ghosts of medical AI: Can the black-box present deliver?	Quinn ym. (2022)	Kirjallisuuskatsaus	Tutkii tekoälymallien selittävyyttä	TK3	5.2.1

Julkaisun nimi	Tekijät (vuosi)	Tutkimus-tyyppi	Keskeinen sisältö	Tutkimuskysymys	Kappale
Convolutional neural networks in medical image understanding: a survey	Sarvamangala & Kulkarni (2022)	Kirjallisuuskatsaus	Tutkii CNN-mallien rakennetta ja hyödyntämistä eri kuvantamisen osa-alueilla	TK2,TK3	2.3.1, 5.2.2
Advances in Medical Image Segmentation: A Comprehensive Review of Traditional, Deep Learning and Hybrid Approaches	Xu ym. (2024)	Kirjallisuuskatsaus	Tutkii segmentoinnin perinteisiä menetelmiä, syväoppimis- menetelmiä, sekä hybridi-muotoisia menetelmiä	TK1, TK2, TK3	2.3.1, 3.2, 5.1.1, 5.1.2, 5.2.1, 5.2.2