

# **Tekoälyn vaikutukset radiologian diagnostiikkaan**

Tietojärjestelmätieteen  
kandidaatintutkielma

Laatija:  
Eemeli Pakarinen  
Ohjaaja:  
FT Kai Kimppa

8.12.2023  
Turku

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

Kandidatutkielma

**Oppiaine:** Tietojärjestelmätiede

**Tekijä:** Eemeli Pakarinen

**Otsikko:** Tekoälyn vaikutukset radiologian diagnostiikkaan

**Ohjaaja:** FT Kai Kimppa

**Sivumäärä:** 39 sivua

**Päivämäärä:** 8.12.2023

Tekoäly nähdään potentiaalisena ratkaisuna moniin lääketieteen alan kohtaamiin ongelmiin, kuten työn kuormittavuuteen ja henkilöstöpulaan. Tekoälyn osa-alueiden, kuten koneoppimisen, syväoppimisen ja keinotekoisien neuroverkkojen käyttö lisääntyy lääketieteessä. Tekoälyä hyödynnetään esimerkiksi tutkimus- ja kehitystyössä, hoitotoimenpiteissä, tiedon hallinnoinnissa ja lääketieteellisessä kuvantamisessa. Tekoälystä lääketieteessä löytyy paljon tieteellistä kirjallisuutta ja sen tuomista hyödyistä on selkeää näyttöä.

Radiologian diagnostiikka on merkittävä tekoälyn integroinnin kohde sen teknologiapainotteisuuden takia. Radiologia ja sen diagnostiikka perustuvat vahvasti kuvantamismenetelmille, jotka hyödyntävät kehittyntä teknologiaa. Tämä tutkielma avaa myös kuvantamismenetelmien, eli röntgenkuvauksen, ultraäänitutkimuksen, tietokonetomografian, magneettikuvauksen ja PET-kuvauksen perusteita. Radiologian diagnostiikkaan kohdistuu useita haasteita, joista voidaan mainita esimerkiksi alan kuormitus, henkilöstöpula, potilasturvallisuus ja uuden teknologian integroinnin haasteet.

Tekoäly todennäköisesti vakiinnuttaa ennen pitkää paikkansa radiologian diagnostiikassa, koska uudet teknologiat hyödyntävät yhä enemmän tekoälyä. Tässä tutkielmassa tutkitaan tekoälyn integrointia yleisimpiin kuvantamismenetelmiin. Tutkielmassa tekoälyn osa-alueista erityinen painoarvo on syväoppimisella ja konvoluutioneuroverkoilla, koska näillä pystytään hyvin tarkkaan kuvantunnistukseen ja analysointiin sekä nopeaan datankäsittelyyn.

Tekoälyn integrointi lisää diagnostiikan tarkkuutta, nopeutta ja tehokkuutta. Tekoälyn integroinnilla on myös laajempia vaikutuksia alaan, ja se näyttäisi tuovan ratkaisuja alan nykyisiin ongelmiin. Toisaalta myös itse tekoäly nähdään haasteena, koska se saattaa esimerkiksi tehdä arvaamattomia virheitä tai päätöksiä ja sitä kautta luotettavuus heikkenee. Siten myös tekoälyn luotettavuus laskee. Lisäksi radiologian diagnostiikassa on niukasti dataa saatavilla, mikä esimerkiksi hankaloittaa syväoppimisalgoritmien toimintaa. Tässä tutkielmassa havaittiin myös muita tekoälyn integrointia vaikeuttavia tekijöitä, kuten tekoälyalgoritmien keskinäiset laadulliset erot, soveltuvuus käyttöympäristöön ja algoritmien puolueellisuus. Lisäksi myös radiologien ja alan opiskelijoiden keskuudessa on havaittu negatiivisia asenteita uutta teknologiaa kohtaan.

Tekoälyllä on positiivisia vaikutuksia radiologian diagnostiikkaan, ja se tuo esimerkiksi ratkaisuja ongelmiin. Se avaa myös uusia mahdollisuuksia, joiden tutkiminen ja kehittäminen on kannattavaa, koska ne voivat tuoda ennen pitkää lisää ratkaisuja. Esimerkkinä voidaan mainita tekoälyn kyky tunnistaa ihmiskehossa tekijöitä ja syitä sairauksille tai niiden riskeille. Kuitenkin tekoälyn mukana tulee myös haasteita, jotka hidastavat sen integrointia ja tuovat diagnostiikkaan epävarmuutta, ja siksi tekoälyä ei voi ainakaan vielä täysin automatisoida, vaan se vaatii valvontaa. Näiden ratkaiseminen lopulta kuitenkin vahvistaisi radiologian diagnostiikan turvallisuutta ja luotettavuutta. Parhaiten tekoäly toimii radiologin tukena siten, että viimeinen päätös on aina radiologilla.

**Avainsanat:** tekoäly, koneoppiminen, neuroverkot, syväoppiminen, konvoluutioneuroverkko, radiologian kuvantamismenetelmät, radiologian diagnostiikka

# SISÄLLYS

<b>1</b>	<b>Johdanto</b>	<b>7</b>
1.1	Johdatus aihealueeseen	7
1.2	Tutkielman tavoite ja rajaukset	8
1.3	Tutkielman rakenne	8
<b>2</b>	<b>Tekoäly ja lääketiede</b>	<b>10</b>
2.1	Tekoälyn määritelmä	10
2.2	Tekoälyn muodot	11
2.2.1	Koneoppiminen	13
2.2.2	Neuroverkot	14
2.2.3	Syväoppiminen ja konvoluutioneuroverkot	15
2.3	Tekoälyn käyttö lääketieteessä	17
<b>3</b>	<b>Radiologian diagnostiikka</b>	<b>20</b>
3.1	Radiologian diagnostiikka yleisesti	20
3.2	Yleisimmät kuvantamismenetelmät	20
3.3	Radiologian haasteet	22
<b>4</b>	<b>Tekoälyn vaikutukset radiologian diagnostiikkaan</b>	<b>24</b>
<b>5</b>	<b>Yhteenveto ja johtopäätökset</b>	<b>30</b>
	<b>Lähteet</b>	<b>35</b>

## **KUVIOT**

Kuva 1	Tekoäly ja sen alakäsitteet (Kreutzer & Sirrenberg, 2020).	13
Kuva 2	Keinotekoinen neuroverkko (Kreutzer & Sirrenberg, 2020).	15
Kuva 3	Konvoluutioneuroverkko (Yamashita ym., 2018).	17
Kuva 4	Tekoälyn vaikutukset radiologian diagnostiikkaan.	31



# 1 Johdanto

## 1.1 Johdatus aihealueeseen

Teknologian nopea kehitys vaikuttaa kaikilla yhteiskunnan osa-alueilla. Yksi teknologian ajankohtaisimmista kehityksistä on tekoäly, jonka merkitys ja rooli kasvaa nopeasti. Myös radiologia ja sen diagnostiikka on yksi merkittävistä teknologian ja tekoällyn vaikutuksen kohteista, sillä ala on vahvasti riippuvainen teknologiasta ja siten on ensimmäisten joukossa, kun uutta teknologiaa sovelletaan. Radiologian diagnostiikka perustuu kuvantamismenetelmille, joiden avulla potilaita diagnosoidaan. Lääketieteellisen kuvantamisen diagnoosit saattoivat ennen kestää vuosia, mutta teknologian kehityksen takia nykyään analyysi voidaan suorittaa viikoissa tai jopa päivissä (Langlotz, 2019).

Tekoälyllä on paljon potentiaalia ratkaista lukuisia ihmiskunnan kohtaamia ongelmia. Sen kyvyt ovat kuitenkin vielä heikkoja ja osa sen toiminnasta ja päätöksistä arvaamatonta. Kun puhutaan tekoällyn päätöksenteosta, kuullaan monesti puhuttavan mustasta laatikosta (engl. black box). Tämä tarkoittaa sitä, että ei tiedetä, miten tekoäly on päässyt saamaansa lopputulokseen tai miksi se on tehnyt tietyn päätöksen. Tekoäly nähdään siis mustana laatikkona, jonka päätöksentekoprosessista ei ole täydellistä tietoa. (Ramirez Zegarra & Ghi, 2023.) Lisäksi moni tekoälymalli vaatii edelleen ihmisen valvontaa ja manuaalista työtä, jotta se toimisi halutulla tavalla. Tekoällyn suuresta potentiaalista huolimatta, se on kuitenkin lopulta sovellus, johon liittyy useita riskejä ja mahdollisuuksia virhetilanteille (Valtioneuvosto, 2023).

Terveydenhuollon sektorin kuormitus lisääntyy kaikkialla maailmassa erinäisten ihmisten terveydentilaan vaikuttavien tekijöiden takia. Tekoälyteknologialla voidaan vastata terveydenhuollon haasteisiin implementoimalla se lukuisiin eri toimintoihin. (Rangareddy & Nagaraj, 2022.) Tekoälyllä on suuri rooli radiologian diagnostiikassa, ja sen uskotaan vaikuttavan positiivisesti lääkäreiden työtaakkaan ja tehtäviin. Lisäksi tekoäly voisi olla ratkaisuna diagnoosien tarkkuuden, laadun ja nopeuden parantamiseen, koska tekoälyalgoritmit loistavat kuvantulkinnassa ja analysoinnissa. Toisaalta tekoällyn uskotaan tuovan haasteita ja olevan jopa uhka alan ammattilaisille. Asiantuntijat ovat uskoneet, että tekoäly korvaisi lopulta radiologit (Langlotz, 2019). Lisäksi radiologit ovat

kokeneet, että he eivät ole saaneet tarpeeksi koulutusta tekoälyn toiminnasta tai sen soveltamisesta radiologiaan (Waymel ym., 2019).

Tekoälyn ja uuden teknologian integrointi on alan suurimpia haasteita ja onnistunut integrointi vaatii syvällistä analyysia tekoälymallin toiminnasta, luotettavuudesta ja soveltuvuudesta tulevaan käyttöympäristöön. Jos tekoälyalgoritmi on esimerkiksi olennainen osa radiologian diagnostiikan työnkulkua, palvelun käyttökato voi vaikuttaa olennaisesti potilaiden hoitoon ja ennusteeseen (Hirvonen & Nyman, 2023).

## **1.2 Tutkielman tavoite ja rajaukset**

Tutkielman aiheeksi valikoitui tekoälyn vaikutukset radiologian diagnostiikkaan, koska tekoälysovellukset ovat tällä alalla vielä alkutekijöissään. Tämä johtuu muun muassa siitä, että ala vaatii erittäin tarkkaa ja luotettavaa tietoa, eikä kriteerit täyttäviä ratkaisuja ole sovellettu radiologian diagnostiikassa, tai lääketieteessä ylipäätään vielä paljon. Tutkielman aihe valikoitui myös siksi, että tutkimukset, jotka lisäävät tietoutta ihmisten terveydestä ja hyvinvoinnista sekä niiden edistämisestä, ovat aina oleellisia ja tärkeitä. Tärkeimpänä tutkielman aiheen motivaattorina toimii kuitenkin oma mielenkiinto tekoälyä, lääketieteen teknologiaa ja niiden kehitystä kohtaan.

Tässä tutkielmassa tutkitaan tekoälyn vaikutuksia radiologian diagnostiikkaan. Tarkastelun kohteena ovat diagnostiikassa käytetyt tekoälymenetelmät, kuten koneoppiminen, neuroverkot ja syväoppiminen. Tutkielma tutkii, mitä haasteita ja mahdollisuuksia tekoälyn integrointi tuo radiologian diagnostiikkaan ja miten se vaikuttaa alaan ja sen toimijoihin. Tutkielman tutkimuskysymykset ovat seuraavat:

1. Miten tekoäly vaikuttaa radiologian diagnostiikkaan?
  - a. Mitä tekoäly on ja miten sitä hyödynnetään lääketieteessä?
  - b. Mitä radiologian diagnostiikka, sen kuvantamismenetelmät ja alan kohtaamat haasteet ovat?

## **1.3 Tutkielman rakenne**

Tutkielma koostuu johdannosta, kolmesta sisältöluvusta sekä yhteenvedosta ja johtopäätöksistä. Johdannossa esitellään tutkimuksen aihe ja käydään läpi tutkielman rakenne sekä tutkimuskysymykset. Ensimmäinen ja toinen sisältöluke käsittelevät



alatutkimuskysymyksiä ja kolmas sisältöluke käsittelee päätutkimuskysymystä. Ensimmäisessä sisältöluvussa määritellään tekoäly ja avataan sen yleisimpiä osa-alueita. Lisäksi luvussa käydään läpi, miten tekoälyä hyödynnetään lääketieteessä yleisesti. Toisessa sisältöluvussa avataan radiologian ja diagnostiikan käsitteitä sekä käydään läpi radiologian yleisempiä kuvantamismenetelmiä. Lisäksi luvussa käsitellään radiologian kohtaamia haasteita. Päätutkimuskysymystä, eli tekoälyn vaikutuksia radiologian diagnostiikkaan tutkitaan kolmannessa sisältöluvussa. Tekoälyn vaikutusten tarkastelu painottuu kuvantamismenetelmiin, eli siihen, miten tekoälyä konkreettisesti hyödynnetään radiologian diagnostiikassa. Konkreettiset vaikutukset kuvantamismenetelmiin heijastuvat myös lopulta koko alaan. Yhteenvedossa kerrataan, mikä oli tutkimuksen tarkoitus, mitä se sisälsi ja mitä tutkimuksesta opittiin. Johtopäätöksissä tehdään tutkielman tiedon perusteella päätelmiä tekoälyn vaikutuksista radiologian diagnostiikkaan, ja käydään läpi mitä haasteita, ratkaisuja ja mahdollisuuksia tekoäly tuo sekä mitä tekoälyratkaisujen integroinnissa tulee ottaa huomioon.

## 2 Tekoäly ja lääketiede

### 2.1 Tekoälyn määritelmä

Tekoälyä hyödynnetään lähes kaikkialla modernissa yhteiskunnassa. Moni ei kuitenkaan tiedä, mitä tekoäly todellisuudessa on tai miten se toimii. Tekoälylle ei ole yhtä selkeää määritelmää, vaikka määritelmät muistuttavatkin paljon toisiaan. Nilsson (1998) määrittelee tekoälyn esineiden älykkäänä toimintana painottaen kuitenkin sitä, että tekoälyn määritelmä on häilyvä ja vahvasti riippuvainen siitä, mistä näkökulmasta tekoälyä määritellään. Nilssonin mukaan pitkän aikavälin tavoitteena olisi kehittää tekoäly suoriutumaan tehtävistä ihmisen kykyjä jäljitellen. Russell ja Norvig (2016) puolestaan esittävät, että tekoäly voidaan sitä määriteltäessä jakaa nelikenttään. Tekoälyllä on ajatteleva ja toiminnallinen puoli, ja tekoäly voi olla inhimillinen tai rationaalinen. Tekoäly ei kuitenkaan kykene toimimaan tai ajattelemaan kuin ihminen, joten tekoälyn ”ajattelu” jäljittelee ihmisen ajattelua ja sen ”inhimillisuus” jäljittelee ihmisen inhimillisyyttä. Nelikenttä koostuu siis ”inhimillisestä ajattelusta” ja ”inhimillisestä” toiminnasta sekä rationaalisesta ”ajattelusta” ja rationaalisesta toiminnasta. Russellin ja Norvigin nelikenttä perustuu useiden tutkijoiden määritelmille tekoälystä ja kuvastaa hyvin tekoälyn monitulkinnallisuutta.

Uudet määritelmät tekoälystä ovat hyvin samankaltaisia verrattuna vanhempiin määritelmiin. Tekoäly määritellään ohjelmiston kykyä tuottaa ihmisen älyn kaltaisia taitoja, joita ovat oppiminen, päättelykyky ja uuden tiedon luominen (Euroopan parlamentti, 2023). Kreutzer ja Sirrenberg (2020) määrittelevät tekoälyn ohjelmiston kykyä toimia ihmisen älyn kaltaisesti, joka tarkoittaa esimerkiksi kykyä havainnoida ja argumentoida sekä kykyä oppia itsenäisesti ja hyödyntää oppimaansa ongelmaratkaisuun. Haenlein ja Kaplan (2019) puolestaan määrittelevät ohjelmiston älykkyyden sen kykyä ymmärtää ulkoista dataa, josta se oppii ja jota se hyödyntää sille määritettyjen tehtävien suorittamiseen. Uusissa määritelmissä huomataan kuitenkin tekoälyn kehitys, koska tekoälylle määritellään konkreettisia taitoja. Vanhemmissa määritelmissä taas viitataan yleisesti ihmisenkaltaiseen älykkyyteen. Tekoälyn käsite ei siis ole pysyvä, vaan se riippuu näkökulmasta ja samalla muovautuu kehityksen mukana.

## 2.2 Tekoälyn muodot

Tekoälyn kenttä on monimuotoinen ja siksi on monia tapoja jakaa se eri osa-alueisiin. Osa-alueisiin jakaminen riippuu paljon näkökulmasta ja käsitteen määrittäjästä. Esimerkiksi Euroopan komission määritelmän mukaan tekoälyn muodot voidaan jakaa ohjelmistoihin ja ”ruumiillistettuun” tekoälyyn. Tekoälyä käyttäviin ohjelmistoihin kuuluvat muun muassa hakukoneet, tunnistusjärjestelmät ja virtuaaliset avustajat. ”Ruumiillistettu” tekoäly, jotka käyttävät tekoälyä koostuu roboteissa, droneissa ja asioiden internetissä (engl. internet of things) tekoälyä käyttävistä sovelluksista. (Euroopan parlamentti, 2023.) Tämä Euroopan komission luokittelutapa on käytännönläheinen, eikä kuvaa tekoälyn kykyjä tai luonnetta. On hyvä huomata, että Euroopan komission määritelmässä tekoälyn muodot eivät itsessään ole tekoälyä, mutta ne kaikki voivat käyttää sitä. Euroopan komission määritelmä tarkastelee tekoälyä sen käyttökohteiden näkökulmasta.

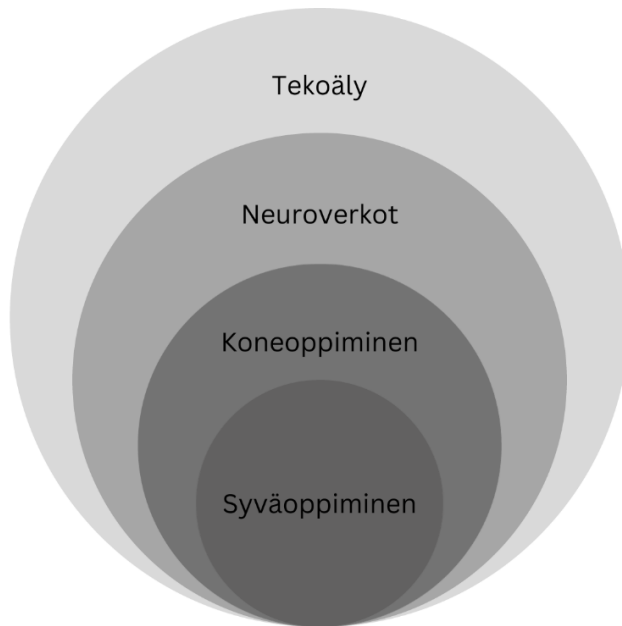
Toinen näkökulma on tarkastella tekoälyä sen kolmella evolutiivisella tasolla: kapea tekoäly, yleinen tekoäly ja super-tekoäly. Kapealla tekoälyllä (engl. artificial narrow intelligence) tarkoitetaan tekoälyn muotoa, joka kykenee vain yksinkertaisiin tehtäviin (Kaplan & Haenlein, 2019), ja se on suunniteltu ennalta määritettyjen tehtävien tekemiseen (Firt, 2020). Valtaosa tämänhetkisestä tekoälystä on kapeaa tekoälyä (Salmon ym., 2023). Yleinen tekoäly (engl. artificial general intelligence) kykenee ratkaisemaan monimutkaisia ongelmia (Kaplan & Haenlein, 2019) ja toimimaan ja oppimaan itsenäisesti (Firt, 2020). Yleinen tekoäly on tekoälyn seuraava kehitysaskel, jonka saavuttamista lähestytään (Salmon ym., 2023). Kaplan ja Haenlein (2019) mainitsevat myös kolmannen tason, super-tekoälyn (engl. artificial super intelligence), jonka saavuttamisesta ei ole varmuutta. Super-tekoäly olisi mahdollisesti tietoinen itsestään ja kykenisi soveltamaan mitä tahansa aihealuetta. Tällainen tekoäly olisi tietyissä asioissa ylivertainen ja kykenisi jossakin määrin siis suoriutumaan tehtävistä ihmistä paremmin. (Kaplan & Haenlein, 2019.)

Hintzen (2016) mukaan tekoäly voidaan jaotella neljään osaan: reaktiiviset koneet, rajattu muisti, mielen teoria ja itsetietoisuus. Reaktiiviset koneet (engl. reactive machines) ovat yksinkertaisin tekoälyn taso, jolla ohjelmisto kykenee vain yksinkertaisiin toimintoihin eikä oppimista tapahdu. Tälle tasolle sijoittuu esimerkiksi yksinkertaisin koneoppimisen muoto. Rajattu muisti (engl. limited memory) on tekoälyn seuraava taso, jossa ohjelmisto

on rakenteeltaan monimutkaisempi ja se kykenee esimerkiksi säilyttämään dataa käyttäen aikaisempaa dataa uusien ennusteiden tekemiseen. Edistyneempi koneoppiminen kuuluu rajatun muistin tasolle. Mielen teoria on kolmas taso (engl. theory of mind), jonka kehitys on vielä alkutekijöissään. Tällainen ohjelmisto kykenee tunnistamaan ihmisten tunteita ja ajatuksia ottaen ne huomioon ollessaan vuorovaikutuksessa ihmisten kanssa. Neljäs taso on itsetietoisuus (engl. self-aware), ja nimensä mukaisesti ohjelmisto tulee tietoiseksi itsestään. Tätä tasoa ei ole saavutettu eikä tiedetä, tullaanko tasoa saavuttamaan. (Hintze, 2016.)

Euroopan komission määritelmä tekoälystä jaottelee tekoälyä sen käyttökohteiden näkökulmasta, kun taas Hintze (2016), Kaplan ja Haenlein (2019), Firt (2020) sekä Salmon ym. (2023) jaottelevat tekoälyä sen toiminnan ja kykyjen perusteella. On siis monta tapaa jaotella tekoälyä eikä yhtä oikeaa tapaa ole. Jaottelu riippuu esimerkiksi siitä, minkä tieteenalan tai sovelluskohteen näkökulmasta tekoälyä tarkastellaan. Jaottelutavat ovat kuitenkin hyvin samankaltaisia, mutta ne painottavat vain eri asioita, kuten toimintaa, käytännön sovelluskohteita tai teknologiaa.

Kuva 1 esittää tekoälyn alakäsitteitä ja niiden välisiä suhteita. Tekoälyn käsitteen alle lukeutuvat koneoppiminen, neuroverkot ja syväoppiminen. Ympyrän sisällä olevan käsitteen toiminta perustuu aina suuremman ympyrän käsitteeseen. Suuremman ympyrän käsite taas mahdollistaa sen sisällä olevan ympyrän käsitteen. Esimerkiksi syväoppiminen perustuu koneoppimiselle ja neuroverkoille, ja koneoppiminen sekä neuroverkot mahdollistavat syväoppimisen. Kuva jäljittelee Kreutzerin ja Sirrenbergin (2020) luomaa kuviota.



Kuva 1 Tekoäly ja sen alakäsitteet (Kreutzer & Sirrenberg, 2020).

### 2.2.1 Koneoppiminen

Koneoppimista (engl. machine learning) hyödyntävät tekoälyohjelmistot ovat nostaneet suosiotaan viimevuosina. Koneoppimisessa tekoälyohjelmisto toimii sille annetun datan avulla tehden itsenäisesti päätöksiä tai ennustuksia. (Kufel ym., 2023.) Haenlein ja Kaplan (2019) esittävät koneoppimisen ohjelmiston kykynä oppia ilman erillistä ohjelmointia. Heidän mukaansa koneoppimisen toiminnan takana voi olla mitä vain yksinkertaisista erittäin monimutkaisiin prosesseihin.

Klassisissa ohjelmistoissa tietoa käsitellään ennalta määrättyjen toimintojen mukaan, kun taas koneoppimisessa ohjelmisto ikään kuin hylkää sille asetetut säännöt. Koneoppimisen avulla tekoäly on tarkoitus saada oppimaan ja kehittymään itsenäisesti päästen entistä parempaan lopputulokseen. Koneoppimiseen perustuvalla ohjelmistolla asetetut lähtöalgoritmit antavat vain perustan uusien algoritmien luomiselle. Jos ohjelmisto huomaa, että uusi algoritmi on parempi kuin aikaisempi, se hylkää vanhan algoritmin ja jatkaa oppimista uuden kanssa. (Kreutzer & Sirrenberg, 2020.) Koneoppiminen on olennainen osa tekoälyä, mutta se ei kykene ymmärtämään tai muokkaamaan dataa kuten tekoäly (Haenlein & Kaplan, 2019).

On olemassa erilaisia tapoja, joilla ohjelmisto oppii. Kreutzerin ja Sirrenbergin (2020) mukaan koneoppiminen voidaan jakaa oppimisen perusteella kolmeen kategoriaan: valvottu oppiminen, valvoton oppiminen ja vahvistava oppiminen. Valvottu

oppiminen (engl. supervised learning) on koneoppimisen muoto, jossa algoritmin tehtävä tiedetään ennalta. Ohjelmistoa opetetaan esimerkeillä, joissa haluttu lopputulos ja alkutiedot on annettu valmiiksi. (Kreutzer & Sirrenberg, 2020.) Ohjelmiston on tarkoitus löytää yhteys syötetyn tiedon ja lopputuloksen välillä. Kun ohjelmisto löytää yhteyksiä syötetiedon ja lopputuloksen väliltä, se oppii etsimään uusia tuntemattomia tietorakenteita ja tekemään niiden perusteella päätöksiä ja ennustuksia. (Kufel ym., 2023.) Esimerkiksi tietyn kuvan tunnistaminen suuresta kuvadatasta on valvottua koneoppimista. Ohjelmiston tehtävänä voisi olla esimerkiksi sääriluun röntgenkuvien tunnistaminen reisiluun röntgenkuvien joukosta. Tällöin ohjelmistolle on opetusvaiheessa annettu tiedot, joiden perusteella se tunnistaa kuvan juuri sääriluuksi.

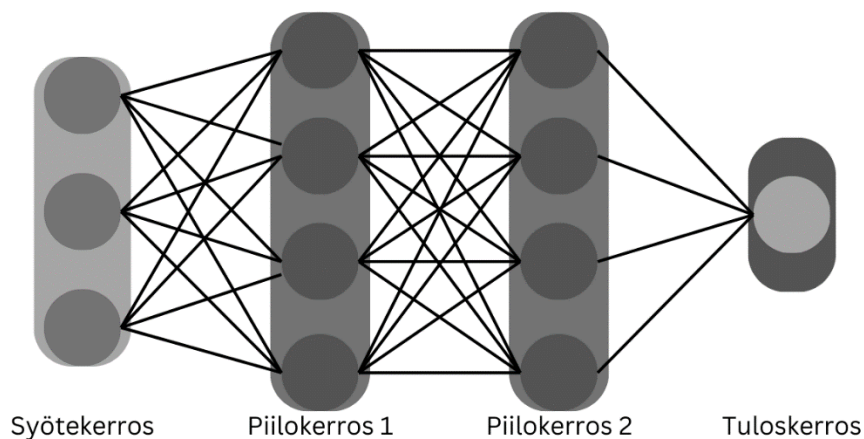
Valvomattomassa oppimisessa (engl. unsupervised learning) ohjelmistolle ei ole ennalta määrätty, mihin lopputulokseen sen tulisi päästä (Kreutzer & Sirrenberg, 2020). Algoritmille syötetään määrittämätöntä dataa (engl. unlabeled data), josta ohjelmiston on tarkoitus itsenäisesti löytää yhteyksiä tietojen välillä (Kufel ym., 2023). Kun ohjelmisto oppii yhdistämään ominaisuuksiltaan samanlaisia kuvia, se tunnistaa itse sääriluun röntgenkuvat muusta kuvadatasta.

Vahvistavassa oppimisessa (engl. reinforcement learning) ei puolestaan ole aluksi mitään optimaalista lopputulosta, vaan algoritmi oppii yrittämisen ja erehtymisen kautta (Kreutzer & Sirrenberg, 2020). Kufelin ym. (2023) mukaan ohjelmistoa “palkitaan” hyvistä ja “rangaistaan” huonoista ratkaisuista. Ohjelmisto kehittyy keräämällä palkitsevia signaaleja ja hylkäämällä huonoja. Vahvistavaa oppimista käytetään tilanteissa, joissa saatavilla olevaa tietoa on vähän eikä haluttua lopputulosta ole tarkkaan määriteltä. (Kreutzer & Sirrenberg, 2020.)

### 2.2.2 Neuroverkot

Neuroverkko on jäljitelmä ihmisen aivoista, ja sen tarkoitus on toimia samalla tavalla kuin ihmisen hermosoluista muodostuvat hermoverkot (Kufel ym., 2023). Keinotekoiset neuroverkot koostuvat monimutkaisista tasoista, joissa on useita solmuja (engl. node) (Kreutzer & Sirrenberg, 2020). Perry (1994) määrittelee nämä solmut keinotekoisiksi neuroneiksi, jotka toimivat kuten ihmisen neuronit. Ihmisen oppimisprosessissa uusi tieto rakentuu jo opitun tiedon päälle, mikä mahdollistaa uusien ongelmien ja tilanteiden ratkomisen. Keinotekoisien neuroverkon on tarkoitus jäljitellä tätä prosessia.

Neuroverkko koostuu useista keinotekoisista neuroneista, jotka toimivat rinnakkain muodostaen useita kerroksia. Jokainen keinotekoinen neuroni prosessoi saamaansa tietoa, ja muodostaa verkoston seuraavan kerroksen neuronien kanssa. (Kufel ym., 2023.) Syötekerros (engl. input layer) ottaa vastaan syötteen ja tuloskerros (engl. output layer) tuottaa lopullisen tuloksen. Näiden kerrosten väliin jäävät piilokerrokset (engl. hidden layer), jotka prosessoivat saamaansa dataa. Uusi kerros ei prosessoi samaa dataa kuin edellinen kerros, vaan se alkaa prosessoimaan edellisen kerroksen aikaansaamaa tulosta. Näin tekoälyohjelmiston on tarkoitus oppia joka kerta, kun tieto siirtyy seuraavalle kerrokselle. (Kreutzer ja Sirrenberg, 2020.)



Kuva 2 Keinotekoinen neuroverkko (Kreutzer & Sirrenberg, 2020).

### 2.2.3 Syväoppiminen ja konvoluutioneuroverkot

Syväoppiminen (engl. deep learning) on koneoppimisen alakäsite ja sen toiminta perustuu neuroverkkoihin. Käytännössä syväoppiminen on hyvin kehittynyt koneoppimisen muoto, joka antaa merkittävästi parempia tuloksia kuin perinteinen koneoppiminen ja vaatii ihmisiltä huomattavasti vähemmän datan esikäsittelyä. (Kreutzer & Sirrenberg, 2020.) Syväoppimisessa neuroverkossa on lukuisia piilokerroksia. Mitä enemmän neuroverkossa on kerroksia, sitä parempiin tuloksiin ohjelmisto pystyy. (Kufel ym., 2023.) Syväoppimiseen perustuva ohjelmisto kykenee käsittelemään erittäin suuren määrän syötettyä dataa, ja ohjelmisto selviytyy vaativimmista tehtävistä oppimalla sen omista toimista ja suhteuttaa opittua tietoa uuteen tietoon. Vähitellen ohjelmisto oppii muodostamaan yksinkertaisista elementeistä monimutkaisia kokonaisuuksia. (Kreutzer & Sirrenberg, 2020.) Syväoppiminen pystyy käymään läpi suuren määrän dataa nopeasti ja tarkasti, jonka takia pystytään datan syvempään analysointiin. Syväoppimisen läpikäynti

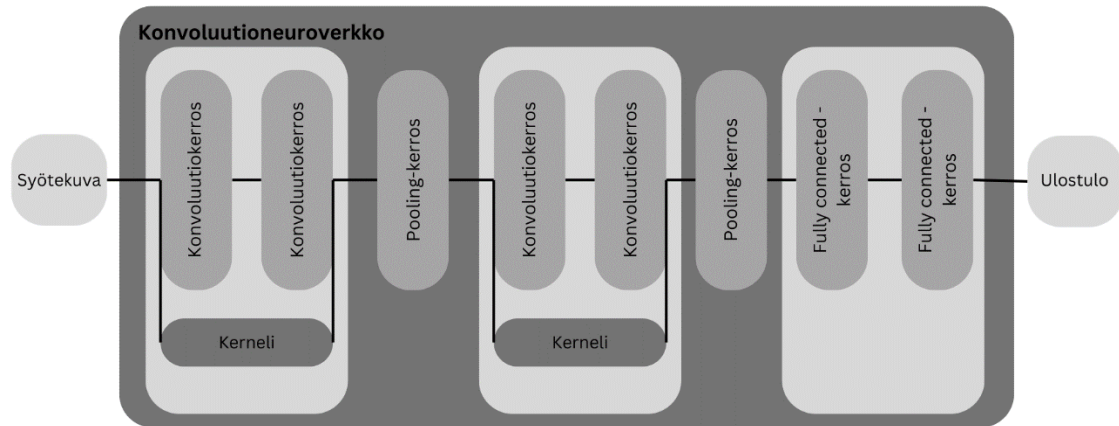
on tutkimuksen kannalta oleellista, koska sen nopeus, tarkkuus ja analysointikyky soveltuvat kuvadatan prosessointiin.

Konvoluutioneuroverkko (engl. convolutional neural network) on syväoppimisen muoto, joka hyödyntää monimutkaisia neuroverkkoja (Yamashita ym., 2018). Juuri näiden neuroverkkojen tarkempi läpikäynti on tutkimuksen kannalta oleellista, koska radiologia ja sen diagnostiikka hyödyntävät syväoppimiseen ja konvoluutioneuroverkkoihin perustuvia algoritmeja kuvantamismenetelmissä. Yamashitan ym. (2018) mukaan konvoluutioneuroverkko rakentuu erilaisista kerroksista, joita ovat konvoluutiokerros (engl. convolutional layer), pooling-kerros ja fully connected -kerros. Konvoluutioneuroverkko on käytännössä neuroverkon osa, joka jää syötekerroksen ja tuloskerroksen väliin.

Konvoluutiokerroksen tehtävänä on ominaisuuksien erottelu, esimerkiksi muotojen tunnistaminen kuvadatasta, mikä onnistuu niin kutsuttujen kernelien (engl. kernel) avulla. Kerneli on useimmiten 3x3 matriisi, jolla on numeeriset arvot. (Moawad ym., 2022.) Kerneli hakee syötetiedosta, esimerkiksi kuvasta, aina matriisin kokoisen alueen. Myös syötetietona toimiva kuva on rikottu numeerisiin alueisiin, jotta kerneli voi liukua kuvassa alueelta toiselle. Jokaisesta alueesta saatu tulos analysoidaan ja summataan piirrekartalle (engl. feature map), johon saadut tulokset piirtyvät. (Yamashita ym., 2018.) Jokainen yksittäinen kerneli tunnistaa niille määrättyjä erilaisia muotoja tai viivoja ja lopulta kernelit ovat käyneet koko syötetiedon läpi.

Pooling-kerrokselle tulee summattu arvo jokaisesta 3x3 matriisista, joten tiedon koko pienenee tällä kerroksella. Pooling-kerros säilyttää näin oleellisimman tiedon, mutta pienentää saadun tiedon kokoa. (Yamashita ym., 2018.) Tämän prosessin avulla myös yksinkertaistetaan laskentaa, jolloin tietoa on helpompi käsitellä. Yamashitan ym. (2018) mukaan nämä kerrokset toistuvat neuroverkossa muodostaakseen lisää tietoa analysoitavasta kuvasta. Mitä syvemmälle neuroverkossa edetään, sitä monimutkaisempia muotoja uudet kerrokset pystyvät analysoimaan. Tämä johtuu siitä, että aikaisemmat kerrokset välittävät jo oppimaansa tietoa eteenpäin. Lopulta piirrekarttojen tulokset pakataan yksiulotteisiksi numerojoukoiksi eli vektoreiksi, jotka siirretään fully connected -kerrokselle (Yamashita ym., 2018), jossa jokainen solmu on kytköksissä toisen kerroksen solmuihin (Moawad ym., 2022). Yksi tai useampi tällainen kerros luokittelee saamansa tiedon ja siirtää tuloksen ulostulokerrokselle.





Kuva 3 Konvoluutioneuroverkko (Yamashita ym., 2018).

### 2.3 Tekoälyn käyttö lääketieteessä

Tekoälyn potentiaali on huomattu lääketieteessä, ja sille onkin lukuisia sovelluskohteita aina potilastietojen käsittelystä kuvantamismenetelmiin ja DNA:n sekvensointiin. Tässä luvussa tarkastellaan tekoälyn hyödyntämistä lääketieteessä aiemmin läpikäytyjen käsitteiden pohjalta, eli tutkitaan miten ja missä koneoppimista, neuroverkkoja ja syväoppimista hyödynnetään lääketieteessä.

Koneoppiminen on tekoälyn käytetyin osa-alue lääketieteessä. Noin 36,9 % lääketieteessä käytetystä koneoppimisesta on kohdennettu ennusteisiin ja 18 % diagnostiikkaan. Koneoppimista on käytetty eniten terveysjärjestelmien hallinnan parantamiseen, tartuntatautien hoitoon ja diagnosointiin sekä ihmisten psykososiaalisen käyttäytymisen ymmärtämiseen. (Otmani ym., 2022.) Koneoppimista hyödyntävää luonnollisen kielen käsittelyä (engl. natural language processing) eli ohjelmiston kykyä ymmärtää esimerkiksi puhuttua kieltä, hyödynnetään jäsenitelemättömän datan käsittelyssä. Käyttökohteita ovat esimerkiksi kliininen tutkimus ja sähköinen potilastieto. (Apell & Eriksson, 2020.)

Tekoälyllä on merkittävä rooli myös lääketieteellisen tiedon hallinnoinnissa ja esimerkiksi potilaan taudin ja siihen liittyvän hoidon hallintaan voidaan käyttää tekoälyä. Tekoäly esimerkiksi suunnittelee, neuvoo ja tarkkailee potilaan tilaa syöpäsairauden hoidossa. Lisäksi yleisimpiä käyttökohteita ovat tiedonhallintajärjestelmät, kuten potilastietojärjestelmät, joissa hyödynnetään esimerkiksi potilaskertomuksia ja puheentunnistusta. (Manickam ym., 2022.)

Koneoppimista käytetään lääketieteellisessä kuvantamisessa diagnosointiin esimerkiksi röntgentutkimuksissa. Kuvantamisessa saatuja tuloksia käytetään syötetietona, joilla ohjelmisto oppii tunnistamaan kuvista poikkeamia. Neuroverkkoja puolestaan käytetään kuvantamisessa, esimerkiksi kuvien analysointiin tietokonetomografiassa ja magneettikuvauksessa, minkä lisäksi nykyisiä syviä neuroverkkoja hyödynnetään toistuvan datan, kuten perimäaineksen (DNA) sekvensoinnissa. (Apell & Eriksson, 2020.) Myös Larentzakis ja Lygeros (2021) mainitsevat, että tietokonetomografian kuvantamistuloksia käytetään syöteenä, jota neuroverkot prosessoivat. Lisäksi syöpädiagnosointi on saanut koneoppimisesta ja neuroverkoista ylivoimaisen työvälineen, koska niillä on onnistuttu erottamaan pahanlaatuisia kasvaimia kuvantamismenetelmillä esimerkiksi patologisessa kuvantamisessa, mammografiassa ja PET-kuvantamisessa (Larentzakis & Lygeros, 2021).

Lääkäri voi hyödyntää tekoälyä myös tehdessään prognoosia eli ennustetta potilaan terveydentilasta. Tekoälyä voidaan hyödyntää ennustettaessa potilaan riskiä sairastua esimerkiksi perinnöllisiin tai ympäristötekijöistä johtuviin sairauksiin. Tällöin tekoälyn avulla voidaan analysoida esimerkiksi potilaan genomia eli perimää. (Poalelungi ym., 2023.) Syväoppimisella kyetään esimerkiksi ennustamaan dementian etenemistä, autismin ja skitsofrenian puhkeamista sekä potilaiden itsemurhariskiä. Koneoppimisella, neuroverkoilla ja syväoppimisella pystytään myös arvioimaan selviytymismahdollisuuksia spesifien sairauksien kohdalla, kuten keuhkoverenpainetaudissa. (Larentzakis & Lygeros, 2021)

Myös potilaille tehdyt konkreettiset hoitotoimenpiteet ovat saaneet apua tekoälystä. Tekoälyä käytetään muun muassa tautien ja sairauksien, kuten kaksisuuntaisen mielialahäiriön ja posttraumaattisen stressin hoitoon. Kehittynyttä tekoälyä voidaan hyödyntää suoraan hoitotoimenpiteissä, kuten kirurgiassa ja operatiivisessa lääketieteessä. (Larentzakis & Lygeros, 2021.)

Kirurgiassa tekoälyä ja sen osa-alueita hyödynnetään tehtävissä, joita tekoäly voi suorittaa itsenäisesti. Yksi mullistavimmista tekoälyn sovelluksista lääketieteessä ovat kirurgiset järjestelmät, jotka toimivat lääkärin apuvälineenä esimerkiksi haastavissa leikkauksissa. Järjestelmä mahdollistaa sen, että leikkausta operoivan lääkärin ei tarvitse olla potilaan välittömässä läheisyydessä, vaan hän voi suorittaa leikkauksen ohjaten järjestelmää esimerkiksi erillisestä työhuoneesta. (Manickam ym., 2022.)

Myös lääketieteellisessä tutkimuksessa ja kehityksessä hyödynnetään tekoälyä. Tekoälyä käytetään esimerkiksi lääkekehityksessä, biomarkkereiden kehityksessä ja käytössä sekä geenimanipuloinnissa. Lisäksi koneoppimista käytetään tartuntatautien tunnistamisessa tutkimalla virusten ja bakteerien perimää. (Larentzakis & Lygeros, 2021.) Lääkekehityksessä tekoälyn avulla esimerkiksi suunnitellaan tehokkaasti kehitettävän lääkkeen rakennetta ja kyetään tunnistamaan kehitettävän lääkkeen komponentteja (Poalelungi ym., 2023).

### 3 Radiologian diagnostiikka

Tässä luvussa käydään läpi, mitä radiologian diagnostiikka on. Lisäksi luvussa tarkastellaan alan haasteita ja yleisimpiä radiologian kuvantamismenetelmiä, jotta lukija ymmärtää, minkälaisissa kohteissa tekoälyä hyödynnetään.

#### 3.1 Radiologian diagnostiikka yleisesti

Radiologialla tarkoitetaan lääketieteen erikoisalaa, joka perustuu kuvantamismenetelmiin. Kuvantamista käytetään myös hoitomuotona, mutta radiologia painottuu vahvasti diagnostiikkaan (SRY, e.p.). Diagnostiikalla tarkoitetaan niitä toimenpiteitä, tutkimuksia, mittauksia ja analyyskejä, jotka auttavat diagnoosin muodostamisessa (Pfizer, 2022). Radiologian diagnostiikalla tarkoitetaan siten kuvantamismenetelmiä ja niiden hyödyntämistä taudinmäärityksessä. Radiologi on puolestaan erikoislääkäri, joka hyödyntää kuvantamismenetelmiä diagnosointiin ja kuvantamisohjattuun hoitoon (Syväranta ym., 2021).

Diagnoosilla tarkoitetaan päätöstä, johon on päästy saatujen esitietojen perusteella. Lääketieteessä diagnoosi on lääketieteelliseen tietoon perustuva käsitys potilaan terveydentilasta (Keinänen-Kiukaanniemi, 2020), mikä tarkoittaa esimerkiksi potilaan oireiden perusteella tehtyä päätöstä taudista, sairaudesta tai jostain muusta terveydellisestä ongelmasta (Pfizer, 2022). Toisin sanoen se on taudinmääritystä. Diagnosoinnilla siis määritetään, onko potilaan oireet yhdistettävissä sairauteen tai tautiin. Tehdyn diagnoosin avulla määritetään potilaan hoitosuunnitelmaa. Potilaan auttaminen on diagnoosin tärkein tarkoitus. (Keinänen-Kiukaanniemi, 2020.)

#### 3.2 Yleisimmät kuvantamismenetelmät

Kuten tutkielmassa on aiemmin todettu, radiologia perustuu vahvasti erilaisten kuvantamismenetelmien hyödyntämiseen. Lääketieteellisen kuvantamisen tarkoituksena on esittää visuaalisesti kehon rakenteita, kuten kudoksia ja elimiä. Kuvantamisella kuvattava kohde tunnistetaan normaaliksi tai poikkeavaksi. Nykyään kuvantamisella voidaan diagnosoida lähes mitä tahansa poikkeavuuksia ihmiskehossa, ja sitä voidaan hyödyntää esimerkiksi sydän- ja verisuonisairauksien, syöpäsairauksien tai fyysisen trauman diagnosoinnissa. (Hussain ym., 2022.) Yleisimpiä radiologisia

kuvantamismenetelmiä ovat röntgenkuvaus, ultraäänitutkimus, tietokonetomografia, magneettikuvaus ja PET-kuvaus.

Yleisin kuvantamismenetelmä on röntgenkuvaus. Syvärannan ym. (2021) mukaan röntgenkuvaus on edullinen kuvantamisvaihtoehto ja sen saatavuus on hyvä. Röntgenkuvauksen säteilyannokset ovat vähäisiä, mutta suorituskyky ei ole tehokkaampien kuvantamismenetelmien luokkaa, mikä tekeekin röntgenkuvauksesta usein ensivaiheen kuvantamismenetelmän. Röntgenkuva muodostuu, kun ihmisen läpi kuljetetaan röntgensäteitä (Syväranta ym., 2021). Hussainin ym. (2022) mukaan röntgenkuvaus soveltuu hyvin luunmurtumien ja rintakehän poikkeavuuksien tunnistamiseen, koska röntgenkuvauksella tunnistetaan eri kudosten rajapinnat niiden tiheyden perusteella. Esimerkiksi luukudos on tiheää ja erottuu selkeästi sitä ympäröivästä pehmytkudoksesta (Syväranta ym., 2021). Mammografia on röntgenkuvauksen erikoismenetelmä, jonka tarkoituksena on rintakudoksen kuvantaminen (Hussain ym., 2022).

Ultraäänitutkimus perustuu ultraääneen eli hyvin korkeataajuisiin ääniaaltoihin. Kuvantamismenetelmä hyödyntää ultraääniaaltojen etenemisnopeutta, joka riippuu kudoksen tiheydestä. Mitä tiheämpi kudos on, sitä nopeammin ääniaalto liikkuu. Ultraäänitutkimuksesta ei aiheudu lainkaan säderasitusta, minkä takia se soveltuu hyvin raskaana oleville ja lapsille. (Syväranta ym., 2021.) Ultraäänitutkimus on tehokas väline raskauden seurannassa, mutta sillä on muita lukuisia käyttökohteita ja sitä käytetään myös muun muassa sydämen ja verisuonten tutkimiseen (Hussain ym., 2022).

Tietokonetomografia perustuu ionisoivaan röntgensäteilyyn, jossa säteilylähde pyörii potilaan ympäri putkenmuotoisessa laitteessa samalla kun potilasta viedään putken läpi. Tietokonetomografiaan kuuluu myös olennaisesti varjoaineen käyttö, jonka avulla saadaan tarkempi kuva, koska kudosten välinen kontrasti kuvassa kasvaa. (Syväranta ym., 2021.) Tietokonetomografialla voidaan tutkia esimerkiksi luunmurtumia, verenkierron ongelmia, aivohalvauksia ja syöpiä (Terveyskylä, 2023). Vaikka menetelmä onkin tehokas ja nopea (Syväranta ym., 2021), siitä aiheutuvat säteilyannokset ovat potilaille kohtalaisen suuria (Hussain ym., 2022).

Kehon kudosten magneettiset ominaisuudet ovat perusta magneettikuvaukselle, jossa kuvantamislaitte käyttää kuvanmuodostukseen magneetti- ja sähkökenttiä sekä radioaaltoja (Syväranta ym., 2021). Kuvaustekniikka sopii erityisen hyvin

pehmytkudoksen tutkimiseen, joten esimerkiksi aivojen kuvantaminen on magneettikuvauksen yleisimpiä kuvantamiskohteita. Magneettikuvauksella tunnistetaan esimerkiksi aivohalvauksia, MS-tautia, verisuonten tukkeumia ja luukudoksen kasvaimia. (Hussain ym., 2022.) Kuvantaminen tehdään hyvin tarkkaan rajatulle alueelle eikä magneettikuvauksessa siis muodostu anatomisesti laajoja kuvia (Syväranta ym., 2021). Magneettikuvauksen vahvuus on tarkka kuvanmuodostus, minkä lisäksi se on ionisoimaton ja kivuton eikä siten aiheuta potilaalle terveyshaittoja (Hussain ym., 2022).

Positroniemissiotomografia (lyh. PET) on kuvantamismenetelmä, joka hyödyntää lyhytikäisten radioisotooppien, eli epävakaiden atomien, hajoamista. Potilaalle annetaan radioaktiivista merkkiainetta, joka hajoaa kehossa. Kuvantamislaitte tunnistaa hajoamisen seurauksena syntyneen gammasäteilyn, jonka pohjalta kuvanmuodostus tapahtuu. PET-kuvantaminen on menetelmänä tarkka, mutta se aiheuttaa säderasitusta, kuten tietokonetomografia. (Hussain ym., 2022.) Syövän diagnosointi on PET-kuvauksen yleisin käyttökohde (Knuuti, 2020).

### 3.3 Radiologian haasteet

Lääketiede ja radiologian diagnostiikka ovat murroksessa ja tämä vaikuttaa lukuisiin asioihin, kuten alan työtehtäviin, henkilökuntaan ja koulutukseen. Diagnostiikkaan suunnitellaan jatkuvasti uusia menetelmiä ja lääkäreiden on välttämätöntä pitää yllä jatkuvaa oppimista myös lääketieteen ulkopuolisista asioista.

Radiologian alalla on kasvava työvoimapula samalla kun kliinisen kuvantamisen kysynnän odotetaan kasvavan. Yksi syistä on nopeasti ikääntyvä väestö, minkä lisäksi radiologeja ei ehditä kouluttaa samaan tahtiin. (Barrera ym., 2023.) Myös Rimmer (2017) mainitsee, että radiologisten menetelmien kysyntään ei kyetä vastaamaan radiologien puutteen takia. Tällä on monia vaikutuksia, ja esimerkiksi radiologeilla Yhdysvalloissa se näkyy työtaakan lisääntymisenä ja jopa työuupumisena (Barrera ym., 2023). Sama trendi on nähtävissä myös Suomessa. Esimerkiksi Knuutin (2020) mukaan PET-kuvantamiseen kohdistuu kasvava lääkäripula, koska tehtävään koulutettuja lääkäreitä ei ole tarpeeksi. Lisäksi kuvantamismenetelmien hyödyntämistä on lisätty muuallakin lääketieteessä, mikä aiheuttaa lisää haasteita jo työvoimapolaiselle ja kuormittuneelle alalle (Barrera ym., 2023). Esimerkiksi kuvantamisohjatut toimenpiteet ovat yleistyneet (SRY, e.p.). Henkilöstöpula ja työmäärän lisääntyminen voivat lopulta heikentää terveyspalveluiden laatua (Rimmer, 2017).

Radiologiassa haasteena on myös potilasturvallisuuden varmistaminen, koska radiologian kuvantamismenetelmillä on todettu olevan negatiivisia vaikutuksia potilaiden terveyteen. Esimerkiksi tietokonetomografian aiheuttamat terveysriskit ovat suhteellisen pieniä, mutta ne ovat kuitenkin olemassa. Kuvantamismenetelmän aiheuttava säteily lisää esimerkiksi syövän riskiä ja erityisesti lapset ovat riskiryhmää, koska he ovat alttiimpia säteilylle kuin aikuiset. (Hussain ym., 2022.) Samaa puoltavat Nikkilä ym. (2018), joiden mukaan lasten tietokonetomografia liittyi lasten leukemiariskin kasvuun ja pienikin säteilyannos lisäsi syövän riskiä. Yhdysvalloissa puolestaan 50 % ionisoivan säteilyn altistuksesta tulee lääketieteellisestä kuvantamisesta (Hussain ym., 2022). Säteilystä aiheuttavaan kuvantamiseen liittyy siis selkeitä terveysriskejä ja haasteisiin etsitään ratkaisuja uudesta teknologiasta, esimerkiksi tekoälystä.

Radiologian kentän murros johtuu muun muassa uudesta teknologiasta ja sen käyttökohteiden jatkuvasta kehittämisestä, jonka tärkeimpänä tavoitteena on saada entistä tarkempia diagnooseja (SRY, e.p.). Radiologia on hyvin teknologiariippuvainen ala ja siksi se joutuu monesti sopeutumaan muutoksiin ensimmäisenä (Pupic ym., 2023). Barreran ym. (2023) mukaan teknologian kehitys ja sen implementointi radiologiaan ovat tapahtuneet nopeasti, jotka aiheuttavat alalla haasteita. Radiologien on esimerkiksi jatkuvasti kehitettävä osaamistaan, kun uusia laitteita ja menetelmiä otetaan käyttöön. Shen (2021) mainitsee, että radiologian vuorovaikutus muiden lääketieteen alojen kanssa kasvaa koko ajan, koska esimerkiksi kuvantamismenetelmien hyödyntäminen yleistyy muilla lääketieteen aloilla. Vuorovaikutuksen kasvaminen vaatii radiologeilta sopeutumista yhteistyöhön.

Uudet kuvantamismenetelmät perustuvat vahvasti tekoälylle, johon liittyy edellä esitetystä paljon epävarmuutta. Yksi haasteista on henkilökunnan ja tekoälyn yhteensovittaminen, sillä moni radiologi ja lääketieteen opiskelija suhtautuu uuteen tekoälyteknologiaan ennakkoluuloisesti. Yksi syy tähän on pelko siitä, että tekoäly korvaisi radiologit. Erityisesti lääketieteen opiskelijoilla tämä on aiheuttanut ahdistusta ja negatiivisia ennakkoluuloja alaa kohtaan (Pupic ym., 2023). Ennakkoluulojen takia opiskelijat voivat valita radiologian sijasta jonkin muun lääketieteen erikoisalnan, jolloin radiologian työvoimapulaankaan ei saada helpotusta. Tekoäly lupaa positiivisia muutoksia radiologialle, mutta ensin tulee selvittää, miten tekoäly saadaan integroitua tehokkaasti, turvallisesti ja luotettavasti osaksi alaa (Shen, 2021). Tekoäly voisi mahdollisesti olla vastaus radiologian diagnostiikan kohtaamiin haasteisiin.

## 4 Tekoälyn vaikutukset radiologian diagnostiikkaan

Tekoäly nähdään voimavarana ja vastauksena lukuisiin ongelmiin ihmiskunnan kohtaamissa haasteissa. Kuten edellä on mainittu, tekoälyllä uskotaan olevan myös olennainen rooli lääketieteen haasteiden ratkomisessa. Radiologia perustuu vahvasti kuvantamisteknologiaan ja sen hyödyntämiseen. Ala on ensimmäisten joukossa, kun lääketieteeseen sovelletaan uutta teknologiaa. Radiologian diagnostiikan ja sen tulevaisuuden kannalta olennaisimpia tekoälyn osa-alueista ovat syviin neuroverkkoihin perustuva konvoluutioneuroverkko ja syväoppiminen. Nämä ovat erityisen tehokkaita kuvien tulkinnassa ja analysoinnissa. Tekoälyn oletetaan tuovan ratkaisuja ja uusia mahdollisuuksia radiologian diagnostiikan haasteisiin ja toimintatapoihin. Haasteena on esimerkiksi tekoälyn onnistunut integrointi osaksi radiologiaa ja sen toimintatapoja. Onnistuneen implementoinnin jälkeenkin tekoäly voi aiheuttaa haasteita tai ongelmatilanteita, jotka tulee ottaa huomioon sujuvan ja turvallisen diagnostiikan takaamiseksi.

Radiologian alalla on käyty kiivasta keskustelua siitä, mikä uuden teknologian, erityisesti tekoälyn, rooli tulee alalla olemaan. On esitetty paljon väitteitä siitä, että tekoäly korvaisi radiologit, vaikka näin ei kyseisen tiedon valossa kuitenkaan näyttäisi olevan. Google Brain -tutkimusryhmän syväoppimisprojekti ennusti, että tekoäly korvaisi radiologit aikaisemmin kuin alan hoitajat. Hinton (2016) puolestaan sanoi, että radiologien kouluttaminen tulisi lopettaa heti, koska syväoppiminen kykenisi pian radiologeja parempaan diagnostiikkaan. Nämä ja monet muut asiantuntijat ovat kuitenkin joutuneet muuttamaan kantaansa. (Langlotz, 2019.) Hirvosen ja Nymanin (2023) mukaan tekoäly ei voi korvata radiologia, mutta sen avulla voidaan lisätä työn mielekkyyttä, tehokkuutta ja laatua. Langlotzin (2019) mukaan puhe radiologien korvaamisesta tekoälyllä on liioiteltua, mutta tekoäly tulee kuitenkin muokkaamaan radiologien työtä perustavanlaatuisesti. Hänen mukaansa muutos on radiologien kannalta positiivinen. Tekoäly ei siis korvaa radiologeja. Radiologit, jotka hyödyntävät tekoälyä korvaavat ne radiologit, jotka eivät hyödynnä tekoälyä. (Langlotz, 2019.)

Suurin osa tekoälymalleista radiologian kuvantamisessa painottuu tietokonetomografiaan, magneettikuvaukseen ja röntgenkuvaukseen, mutta muutamia sovellutuksia on tehty myös mammografiaan ja ultraäänitutkimukseen. Tekoälyn kyvyt painottuvat pitkälti havainnointiin ja päättelyyn, ja vain muutama sovellutus on tehty



hallinto tai raportointitehtäviin. Tekoölyn integrointi painottuu siten kuvantamismenetelmiin ja sillä uskotaankin olevan suuri rooli radiologian kuvantamismenetelmissä tulevaisuudessa. Tekoölyn hyödyntämisen voidaan siis olettaa paranevan ja lisääntyvän radiologian diagnostiikassa. (Hosein ym., 2021.)

Ultraäänitutkimuksessa hyödynnetään syväoppimista. Ramirez Zegarra ja Ghi (2023) kertovat ultraääneen liittyvässä tutkimuksessaan, että syväoppimisen tehtävät voidaan jakaa neljään ryhmään: tunnistus, lokalisointi, kohteentunnistus ja segmentointi. Kuvadatan avulla syväoppimisteknologia pystyy jakamaan kuvat normaaleihin ja poikkeaviin. Löytäessään poikkeavuuden tekoöly merkitsee sen rajaamalla poikkeaman, minkä jälkeen tekoöly pyrkii määrittämään poikkeaman laadun ja sijainnin. Lopulta algoritmi rajaa kohteen muista rakenteista, jotta sitä on helpompi arvioida. Algoritmi voi myös antaa arvion löydöksen rajoista ja muodosta. Tällaista syväoppimiseen perustuvaa tekoölyalgoritmia käytetään esimerkiksi poikkeavuuksien tunnistamiseen sikiön ultraäänikuvantamisessa. (Ramirez Zegarra & Ghi, 2023.)

Keinotekoisia neuroverkkoja hyödyntävät syväoppimismallit pystyvät jaottelemaan radiologisia kuvia automaattisesti (Hirvonen & Nyman, 2023). Automaatiosta on merkittävää hyötyä radiologeille esimerkiksi työtehtävien allokoinnissa. Toisaalta syväoppimisalgoritmit tulkitsevat tunnistettavan kuvan helposti väärin. Ihmiskeho ei noudata minkäänlaista täydellistä kaavaa, vaan täysin normaaleja kehon poikkeamia esiintyy jokaisella ja kaikkialla kehossa. Tekoöly saattaa tunnistaa nämä harmittomat poikkeamat esimerkiksi syöväksi. Toinen haaste syväoppimisen hyödyntämisessä on jo johdannossa mainittu musta laatikko (engl. black box), eli ei siis välttämättä täysin tiedetä, miksi tekoöly pääsi lopputulokseensa. Syväoppimista hyödyntävä algoritmi käsittelee kuvia neuroverkkojen piilossa olevilla kerroksilla, eikä ihminen kykene vaikuttamaan asiaan ennen kuin algoritmi pääsee lopputulokseensa. (Ramirez Zegarra & Ghi, 2023.)

Ramirez Zegarra ja Ghi (2023) myös mainitsevat, että syväoppimismalleissa käytetään usein valvottua oppimista. Radiologit siis analysoivat kuvia manuaalisesti. Tähän liittyy heidän mukaansa mahdollisuus puolueellisuuteen. Radiologien osaamattomuus ja epävarmuus voivat jo itsessään vaikuttaa tekoölyn oikeanlaiseen hyödyntämiseen. Langlotzin (2019) mukaan radiologeja koulutetaan tunnistamaan tekoölyn puutteita ja hyödyntämään sen vahvuuksia. Koulutuksen saralla on kuitenkin vielä kehitettävää, sillä

esimerkiksi Waymelin ym. (2019) ranskalaisille radiologeille teettämän kyselytutkimuksen mukaan 73,3 % kyselyyn vastanneista radiologeista ovat mielestään saaneet liian vähän tietoa tekoälystä ja sen toiminnasta. 13,7 % vastaajista kertoi, että ei ollut saanut minkäänlaista aikaisempaa tietoa tai koulutusta aiheesta. 94,4 % vastaajista olisi puolestaan kiinnostuneita saamaan koulutusta tekoälyyn liittyen. Tarvetta ja halua koulutukselle siis löytyy, ja siksi olisi aiheellista järjestää radiologeille suunnattuja koulutuksia tekoälyyn ja radiologiaan liittyen.

Mammografia on käytetyin kuvantamismenetelmä rintasyövän tunnistuksessa, mutta menetelmän käyttö on kuitenkin vaikeaa ja sen tarkkuuden tiedetään vaihtelevan. Esimerkiksi niiden potilaiden kohdalla, joiden rinnat ovat koostumukseltaan tiheät, poikkeamien tunnistustarkkuus laskee merkittävästi. (Yoon ym., 2023.) Yoon ym. (2023) toteuttivat tutkimuksen, jonka tuloksena oli, että tekoälyyn pohjautuva diagnosointi tunnisti tapauksia syöviksi, vaikka radiologit olivat arvioineet ne alun perin normaaleiksi. Tekoälyn avulla kyettiin siis lisäämään kuvantamistulosten tarkkuutta ja tunnistamaan muutoin pimentoon jääneitä syöpiä. Tekoälyn avulla voidaan siis lisätä mammografisen kuvantamisen tarkkuutta.

Toisaalta tekoäly tunnisti mammografisessa kuvantamisessa myös negatiivisia tuloksia positiivisiksi (Yoon ym., 2023). Jos tekoäly tekee virheellisen päätöksen, on mahdollista, että radiologi tekee tämän seurauksena myös itse virheellisen päätöksen (Bernstein ym., 2023). Tekoälyn virheen seurauksena sekä radiologin tekemän virheellisen negatiivisen että virheellisen positiivisen diagnoosin mahdollisuus kasvaa. Tekoälyn tekemän virheen takia myös radiologit tekivät jatkopäätöksissään virheitä, vaikka he olisivat tehneet oikean päätöksen ilman tekoälyä. (Bernstein ym., 2023.) Virheelliset negatiiviset ja virheelliset positiiviset diagnoosit aiheuttavat radiologeille ylimääräistä työtä ja työn tehokkuuden laskua. Ne voivat viedä aikaa myös oikeanlaisen hoidon aloittamisesta tai johtaa jopa virheellisen hoidon antamiseen. Lisäksi virheelliset diagnoosit voivat aiheuttaa potilaille turhaa huolta.

Kuten alaluvussa 3.3 todettiin, kuvantamismenetelmät kuten röntgen- ja PET-kuvaus sekä tietokonetomografia altistavat potilaita haitalliselle säteilylle. Tekoälyn avulla tätä ongelmaa voitaisiin mahdollisesti pienentää. Syväoppimisalgoritmeilla on saatu aikaan tuloksia, joissa säteilyannos on pienentynyt. Mittaukset ja kuvanlaatu ovat kuitenkin pysyneet kuvantamisessa samalla tasolla. Tulosten perusteella kuvantamista on siis

mahdollista kehittää siten, että säteilyannokset pienenevät vaikuttamatta kuvantamisen laatuun. (Seah ym., 2021.) Esimerkiksi tietokonetomografiassa säteilyannoksia on onnistuttu vähentämään potilaan optimaalisella asemoinnilla kuvantamislaitteeseen. Laite hyödyntää syväoppimista asemoidakseen potilaan siten, että säteilyn lähde kohdistuu tehokkaasti kuvattavaan kohteeseen. Tämän takia säteilyannoksen ei tarvitse olla enää yhtä suuri. Aihealueesta on kuitenkin Seahin ym. (2021) mukaan hyvin vähän tieteellistä kirjallisuutta, eikä mallin laajempaa toimivuutta voida sanoa varmaksi. Tekoäly on kuitenkin varteenotettava ratkaisu potilaiden turvallisuuden edistämiseksi. Tulevaisuudessa tekoälyn avulla pystytään todennäköisesti auttamaan kuvantamismenetelmien aiheuttamien säteilyaltistusten vähentämisessä.

Nikapanah ym. (2021) tutkivat, miten konvoluutioneuroverkkoon perustuva syväoppimismalli kykeni tunnistamaan magneettikuvauksessa kirkassoluisen munuaiskarsinooman (aggressiivinen munuaissyöpä) onkosytoomasta (hyvänlaatuinen munuaiskasvain). Tutkimuksen käyttämä tekoälymalli oli ennalta koulutettu. Tutkimuksen mukaan tekoälymalli kykeni 91 % tarkkuudella tunnistamaan syövän ja hyvälaatuisen kasvaimen toisistaan. Kun todennäköisyys kasvoi, tekoäly teki parempia ja tarkempia päätöksiä. Kun todennäköisyys laski, myös päätösten laatu heikkeni. Huomionarvoista on se, että diagnoosin tarkkuus oli parempi kirkassoluisen munuaiskarsinooman diagnosoinnissa. (Nikapanah ym., 2021.) Tekoäly siis ikään kuin ottaa vaarallisemman vaihtoehdon vakavammin ja tulkitsee sen mieluummin herkemmin positiiviseksi kuin negatiiviseksi. Täytyy myös huomioda, että vaikka syövän todennäköisyys olisi pieni, se ei silti sulje pois sen olemassaolon mahdollisuutta. Tässä tilanteessa tekoälyn huonompi diagnosointitarkkuus epätodennäköisissä tilanteissa voi olla petollista ja sen kehittämiseen tulee kiinnittää huomiota.

Tekoälyn hyödyntäminen PET-kuvantamisessa on kehittynyt merkittävästi. Tekoäly on erittäin hyödyllinen, jälleen kerran, kuvien analysoinnissa. Syväoppimista hyödyntäen voidaan erotella huonolaatuiset kuvat hyvälaatuisista. Potilaille annettavat merkkiaineannokset tulee pitää minimissä, mutta aineen vähentäminen nostaa kohinan määrää ja näin huonontaa kuvan laatua. Tekoälyalgoritmien avulla on onnistuttu vähentämään annoksia huonontamatta PET-kuvantamisen laatua. (Matsubara ym., 2022.) Tekoälyalgoritmien avulla kuvantunnistus on entistä tarkempaa ja tehokkaampaa. Kuvien laatu paranee huomattavasti, kun tekoälyalgoritmi tunnistaa laadukkaimmat kuvat.

Tekoälyn implementoinnin haasteita PET-kuvantamisessa on esimerkiksi syväoppimisen sovittaminen kuvantamismenetelmään. Syväoppiminen tarvitsee lähtökohtaisesti suuren määrän dataa, mutta PET-kuvantamisessa dataa ei synny tarpeeksi eikä sitä ole ennestään saatavilla. Tätä varten voisi mahdollisesti kehittää tietokannan, josta tekoälyalgoritmit pystyisivät ottamaan dataa analysoitavakseen. (Matsubara ym., 2022.) Kuvadatan rajallisuus on aito ongelma radiologiassa. Tietokannat on vartenotettava mahdollisuus tekoälyalgoritmien kouluttamiselle. Hirvonen ja Nyman (2023) mainitsevat, että tekoälyyn pohjautuva automaattinen kuvantulkintaohjelma on kehitetty osaksi kuvantamisprosessia. Kuvaslaitteella kuvattu kuva siirtyy automaattisesti tekoälypalvelimelle, jossa tekoäly jakaa kuvan komponentteihin. Näiden avulla se pystyy luokittelemaan löydöksen normaaliksi tai poikkeavaksi. Kuva siirretään takaisin radiologin tulkittavaksi. (Hirvonen & Nyman, 2023.) Tämäntapainen ratkaisu voisi sopia PET-kuvantamiselle. Radiologeille olisi yhteinen palvelin, josta tekoäly voisi analysoida ja hakea tietoa diagnosointia varten.

Röntgenkuvantaminen on yleisimpiä tekoälyn integroinnin kohteita lääketieteellisessä kuvantamisessa. Matsudan ym. (2022) tekemässä tutkimuksessa huomattiin, että kieliluun pystysuuntainen asento suhteessa alaleuan reunaan vaikutti dysfagian (nielemisvaikeus) riskiin. Jos kieliluu sijaitsee alaleuan reunaa alempana, on potilaalla 1.5 kertainen todennäköisyys dysfagiaan. Tämä toteutettiin ja löydettiin tekoälyalgoritmin avulla. Matsuda ym. (2022) mainitsevat tutkimuksessaan, että he aikovat rakentaa tekoälymallin, joka diagnosoi dysfagiaa perustuen tähän löydökseen. Tekoälymallin avulla siis etsittäisiin poikkeamaa, jonka tekoälyalgoritmi löysi ja tämän perusteella diagnosoidaan dysfagian todennäköisyyttä. Tämä mukaillee neuroverkkoja, jossa seuraava kerros oppii uutta aikaisemmin opitun tiedon avulla. Tekoälyalgoritmeja voitaisiin siis rakentaa toimimaan aikaisempien tekoälyalgoritmien toiminnan ja tulosten pohjalta.

Lakhani ja Sundaram (2017) puolestaan perehtyivät tutkimuksessaan kahteen syvään konvoluutioneuroverkkoon, ennalta koulutettuun ja kouluttamattomaan. Tutkimuksessa tutkittiin, miten nämä neuroverkot kykenevät tunnistamaan tuberkuloosin rintakehän röntgenkuvauksessa. Paras algoritmi kykeni 99 prosentin tarkkuuteen. Ennalta koulutettu malli tunnistoi tuberkuloosin kouluttamatonta paremmin. Ennalta koulutetulle mallille on syötetty ennalta suuri määrä kuvadataa, jota se on analysoinut ennen lääketieteellistä kuvadataa, jonka takia se onnistui diagnosoinnissa paremmin. Konvoluutioneuroverkko

pienensi kuvadatan 256x256 matriisiksi, jotta prosessiin kuluva aika lyhenisi. Kuvadata muutettiin lähetettävään muotoon tietokoneelle. (Lakhani & Sundaram, 2017.) Onnistuneesti integroidut tekoälymallit itsessään nopeuttavat lääkäreiden työtehtäviä, mutta tehokkuus saadaan vieläkin optimaalisemmaksi, jos tekoälyalgoritminkin toimintaa nopeutetaan. Tässä tapauksessa se tarkoittaa kuvadatan muokkaamista pienempään muotoon. Konvoluutioneuroverkot kykenevät kuvien erittäin tarkkaan analysointiin. Neuroverkon monimutkainen toiminta takaa perusteellisen kuvantulkinnan ja sen tulosten oikeellisuus on korkea.

Radiologit suhtautuvat pääosin myönteisesti uusiin tekoälymenetelmiin, mutta ne herättävät myös huolta. Hirvosen ja Nymanin (2023) mukaan huolta kannetaan siitä, että tekoälyä yleistettäessä se nostaa esille eettisiä ja juridisia kysymyksiä. Kaupallisten tekoälyohjelmien tieteellinen näyttö on vaihtelevaa, ja lääkärit ovat aidosti huolissaan siitä, että tekoälyä yleistetään toimintatapoihin ilman perusteellista soveltuvuusanalyysia. Tekoäly ei välttämättä toimi toivotulla tavalla riippuen tietojärjestelmien rakenteesta tai saatavilla olevasta kuvadatasta. Esimerkiksi Ruotsissa tehdyssä arvioinnissa vain yksi kolmesta kaupallisesta tekoälyalgoritmista ylsi radiologin syöpädiagnostiikan tasolle. (Hirvonen & Nyman, 2023.) Kaupallisilla tekoälyalgoritmeilla on siis laadullisia eroja. Laadulliset erot vaikuttavat kuvantamisen laatuun ja tärkeimpänä potilaan hoitoon ja terveyteen. Voidaan myös pohtia eritasoista hoitoa tarjoavien kuvantamismenetelmien ja terveydenhuollon palvelujen oikeudenmukaisuutta, jos yksi sairaala kykenee muita parempaan diagnosointiin. Kaupallisten järjestelmien ostossa tulee aina kilpailuttaa yritykset ja perehtyä syvällisesti käyttöönotettavan järjestelmän luotettavuuteen, laatuun ja integroinnin mahdollisuuteen.

## 5 Yhteenveto ja johtopäätökset

Tässä tutkielmassa on tutkittu tekoälyn vaikutuksia radiologian diagnostiikkaan. Aihetta käsiteltiin perehtymällä ensin tekoölyyn ja sen jälkeen radiologian diagnostiikkaan. Tämän pohjalta tutkimus eteni tutkimaan päätutkimuskysymystä siitä, minkälaisia vaikutuksia tekoölyllä on radiologian diagnostiikkaan. Tutkielmassa on tutkittu tekoälyn vaikutuksia alaan kokonaisvaltaisesti ja konkreettisesti tekoälyn integroinnin pohjalta.

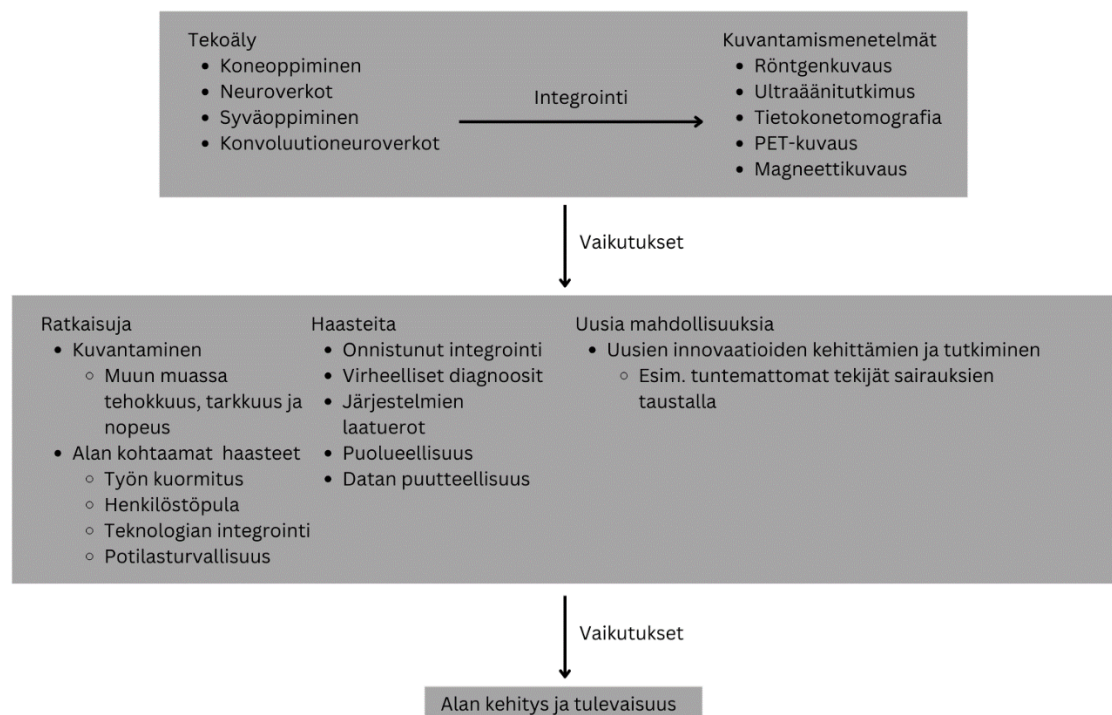
Ensimmäinen sisältöluke vastasi ensimmäiseen alatutkimuskysymykseen siitä, mitä tekoöly on ja miten sitä hyödynnetään lääketieteessä yleisesti. Tutkimuksessa määriteltiin tekoöly ja käytiin läpi sen osa-alueet. Tutkimuksen kannalta eniten painoarvoa aihealueesta saivat syväoppiminen ja konvoluutioneuroverkot, joita hyödynnetään radiologian diagnostiikan kuvantamismenetelmissä. Tutkimuksessa havaittiin, että tekoölyä hyödynnetään lääketieteessä laaja-alaisesti ja että tekoälyn rooli kasvaa jatkuvasti. Erityisesti toimenpiteissä ja käytännönläheisissä työtehtävissä, kuten hoitotoimenpiteissä, leikkauksissa ja erilaisissa analyysitehtävissä tekoälyn hyödyntäminen lisääntyy merkittävästi.

Toisessa sisältöluvussa vastattiin toiseen alatutkimuskysymykseen siitä, mitä radiologian diagnostiikka ja sen kuvantamismenetelmät ovat, sekä mitä haasteita ala kohtaa. Radiologian diagnostiikan tärkeimpänä tehtävänä on taudintunnistus ja -määritys. Alan työtehtävät perustuvat kuvantamismenetelmille, joista yleisimmät käytiin tutkielmassa läpi. Radiologian ala kohtaa useita haasteita, mutta tutkielman kannalta olennaisia haasteita ovat alan kuormitus, henkilöstöpula, teknologian integrointi ja potilasturvallisuus.

Kolmannessa sisältöluvussa vastattiin päätutkimuskysymykseen siitä, miten tekoöly vaikuttaa radiologian diagnostiikkaan. Tutkielmassa todettiin, että tekoöly vaikuttaa alaan monin tavoin. Tiivistettynä voidaan sanoa, että tekoöly tuo radiologian diagnostiikkaan ratkaisuja, uusia mahdollisuuksia ja haasteita. Tekoälyn vaikutukset näkyvät konkreettisesti kuvantamismenetelmissä, joita se nopeuttaa, tarkentaa ja tehostaa. Tekoälyn integrointi vaikuttaa ennen pitkää myös laajemmin koko alaan ja sen kohtaamiin haasteisiin. Tekoöly vaikuttaa todennäköisesti positiivisesti työtaakkaan, työtehtäviin, henkilöstöpulaan ja potilasturvallisuuteen. Tekoöly ja erityisesti sen

onnistunut integrointi tuo myös haasteita, joista tärkeimpinä voidaan mainita virheelliset diagnoosit, järjestelmien laatuerot, puolueellisuus ja datan puutteellisuus.

Tekoälyn ja radiologian diagnostiikan aihealueilla on selkeä keskinäinen yhteys, jonka takia myös tutkielma oli aiheellista toteuttaa. Kuva 4 esittää tekoälyn ja radiologian diagnostiikan välistä suhdetta tämän tutkielman näkökulmasta. Tekoäly ja sen osa-alueet ovat integroitavia ja radiologian kuvantamismenetelmät ovat puolestaan integroinnin kohteita. Tekoälyn integrointi kuvantamismenetelmiin vaikuttaa radiologian diagnostiikkaan tuoden ratkaisuja, haasteita ja uusia mahdollisuuksia. Nämä kaikki vaikuttavat alan kehitykseen ja tulevaisuuteen.



Kuva 4 Tekoälyn vaikutukset radiologian diagnostiikkaan.

Tekoälyllä on merkittäviä vaikutuksia radiologiaan ja sen diagnostiikkaan. Se aiheuttaa haasteita, mutta tuo myös mahdollisuuksia ja ratkaisuja alan ongelmiin. Tutkielman sisältöluvuissa on vastattu tutkimuskysymyksiin ja tehty perusteltuja johtopäätöksiä tutkielman aiheesta.

On todettu, että tekoälyn integroinnin avulla kuvantamismenetelmillä saadaan entistä tarkempia tuloksia. Merkittävimpiä syitä tähän ovat konvoluutioneuroverkot, joilla kyetään erittäin tarkkoihin kuva-analyyseihin. Tekoälyalgoritmit kykenevät myös löytämään erityisen vaikeasti havaittavia yksityiskohtia, joiden löytämiseen lääkärit eivät

välttämättä kykene. Pienempien yksityiskohtien havaitseminen johtaa aikaisempiin diagnooseihin, joka nopeuttaa esimerkiksi potilaan hoidon aloittamista ja parantaa ennustetta. Voidaan siis todeta, että diagnostiikan nopeus ja tehokkuus lisääntyy muun muassa tekoälyn integroinnin takia.

Tuntemattomien syiden tai tekijöiden löytäminen ja kehittäminen voi tuoda myös ennen pitkää lisää ratkaisuja. Esimerkiksi Matsudan ym. (2022) tutkimus, jossa tekoälyalgoritmi löysi kielen ja leukaluun keskinäisillä suhteilla riskin nielemisvaikeuteen, tuo alalle mahdollisesti uusia tapoja ratkaista ongelmia. Tekoälyalgoritmin avulla voidaan siten löytää tuntemattomia ongelmia, joita voidaan lähteä ratkomaan edelleen tekoälyn avulla.

Tutkimuksessa myös havaittiin, että tekoälyn avulla kuvantamislaitteilla kyetään optimoimaan kuvantamisalue ja vähentämään säteilyannoksia huonontamatta diagnosoinnin laatua. Potilaiden turvallisuus paranee ja kuvantamisen haitallisuus vähenee, sillä tekoälyn tuoman tarkkuuden takia laadukkaita kuvia saadaan pienemmilläkin säteilyannoksilla. Lisäksi tekoälyn ansiosta lääkärin ei välttämättä tarvitse olla samassa paikassa potilaan kanssa diagnoosin tekemiseksi. Tämä auttaisi mahdollisesti ihmisiä, jotka asuvat alueilla, joissa terveydenhuolto on vaikeasti saavutettavissa esimerkiksi pitkien välimatkojen tai ruuhkautuneiden palveluiden takia. Lääkäri voi tehdä diagnoosin eri kaupungista tai vaikka omasta kodistaan. Näin säästyy aikaa, mikä osaltaan mahdollisesti osaltaan purkaisi terveydenhuollon pitkiä jonoja.

Radiologian teknologiapainotteisuuden takia tekoäly tulee todennäköisesti ennen pitkää ottamaan vakituisen paikkansa alalla. Tämä toisi kuvantamiseen konkreettisesti uusia mahdollisuuksia, joiden seurauksena voitaisiin havaita suuremman skaalan vaikutuksia, kuten työtaakan ja metatyön väheneminen sekä työtehtävien mielekkyyden lisääntyminen. Näillä voisi olla ennen pitkää merkittävä vaikutus alan työvoimapulaan tai muihin henkilöstöhaasteisiin. Tekoälyn onnistuneella integroinnilla olisi lopulta vaikutusta alan työprosesseihin kokonaisvaltaisesti, kun esimerkiksi resurssit pystytään allokoimaan entistä paremmin ja pullonkaulat vähenevät. Lisäksi työn mielekkyys lisääntyy, koska tekoäly tuo arvokasta lisätietoa päätöksentekoon ja radiologeille jää enemmän aikaa esimerkiksi potilaiden kanssa käytävälle vuorovaikutukselle. Lisäksi varhaisemmat diagnoosit vaikuttavat positiivisesti potilaiden elämään. Radiologit voivat siten kokea työnsä entistä merkityksellisempänä.



Tutkielmassa tekoälyn ja sen integroinnin todettiin myös aiheuttavan haasteita. Esimerkiksi radiologit ovat kantaneet huolta tekoälyn vaikutuksista alan työtehtäviin. Erityisesti alaa opiskelevat tulevat lääkärit ovat kokeneet ahdistusta, ja moni on saattanut jättää jopa hakematta alalle tämän takia. Radiologeille tulisi mahdollisesti kehittää kattavia koulutuksia tekoälyyn liittyen, ja kaikkein parasta olisi aloittaa kouluttaminen mahdollisimman varhain, jotta alan opiskelijat ymmärtävät tekoälyn todellisen luonteen ja roolin radiologin työssä. Kouluttautuminen jatkuisi myös läpi työuran.

Tekoälyalgoritmit, kuten syväoppimismallit, tarvitsevat valtavia määriä dataa, eikä tämä ole kaikissa kuvantamismenetelmissä tai tilanteissa mahdollista. Esimerkiksi PET-kuvantamisessa kuvadataa on usein niukasti saatavilla. Lisäksi harvinaisista sairauksista voi olla hyvin vähän aikaisempaa tutkimustietoa. Varteenotettava ratkaisu olisikin luoda ja ottaa käyttöön palvelimia, josta tekoäly voisi haalia sekä analysoida kuvadataa paremman diagnoosin aikaansaamiseksi. Esimerkiksi suurien kaupunkien keskussairaaloilla voisi olla yhteinen tietokanta. Tässä voisi olla markkinarako yrityksille, jotka kehittävät tekoälyratkaisuja lääketieteen alalle.

Tekoälyn hankinnassa ja integroinnissa tulee kuitenkin ottaa huomioon monia tekijöitä, kuten ohjelmistojen laatuerot ja tietoturva. Lisäksi tekoälyn kehittäjien tulee pyrkiä puolueettomuuteen. Tekoälyohjelmistot ovat ihmisten luomia, joten mahdollisuus inhimillisiin virheisiin on aina olemassa. Tulee kuitenkin huomata, että myös algoritmin tarkoituksenmukainen ihmisryhmän tai muun vastaavan suosiminen diagnosoinnissa on mahdollista. Esimerkiksi mieskehon ominaisuuksien perusteella voidaan virheellisesti diagnosoida naispotilaita, ja siksi sekä palveluntarjoajien että niiden ostajien tulee kiinnittää puolueellisuuteen erityistä huomiota tekemällä palvelun käyttöönotosta ja soveltuvuudesta perustavanlaatuisen taustaselvityksen. Hirvonen ja Nyman (2023) mainitsevat Yhdysvaltojen radiologiyhdistyksen kehittäneen riippumattoman testialustan tekoälyalgoritmien testaamiseen. He mainitsevat myös, että kaupallisia testialustoja on olemassa. Heidän tietonsa mukaan suomalaisissa korkeakouluissa tai sairaaloissa ei ole toimivaa riippumatonta testialustaa, mutta kysyntää tällaiselle ratkaisulle voisi kuitenkin löytyä.

Lisäksi tekoälyä hyödynnettäessä tulee myös noudattaa turvallisuutta ja oikeudellista sääntelyä. Eettisyys ja vastuukysymykset on tärkeää ottaa huomioon tekoälyn paikan vakiintuessa. Onko tekoälyllä esimerkiksi oikeus hoitaa potilasta vai tarvitaanko siihen

erillinen lupa? Entä saako potilas kieltäytyä tekoölyn antamasta hoidosta ja vaatia lääkärin antamaa hoitoa tai miten taataan hoidon läpinäkyvyys ja oikeudenmukainen käyttö. Jos tekoäly tekee suuren hoitovirheen, kuka ottaa vastuun. Kenen vastuulla tekoäly ja sen toiminta lopulta on?

Tutkielman pohjalta voidaan todeta, että tekoäly osoittaa merkittäviä kykyjä kuvantunnistuksessa ja analyyseissa ollen siten erittäin tehokas tulevaisuuden työväline. Tekoölymallit eivät kuitenkaan ole valmiita itsenäiseen työskentelyyn, vaan ne vaativat valvontaa. Vaikka tekoäly kykenee hämmästyttäviin suorituksiin, radiologit kykenevät ottamaan huomioon sellaisia asioita, joihin tekoäly ei kykene, kuten esimerkiksi potilaan taustat, aikaisemmat potilastiedot ja elämäntilanteen. Nämä tekijät voivat joissain tilanteissa vaikuttaa olennaisesti diagnoosiin, joita tekoäly ei ainakaan vielä osaa ottaa huomioon. Lisäksi tekoäly tekee virheitä siinä missä ihminenkin. Päätökset ja tulkinnat voivat osoittautua virheellisiksi, minkä takia on hyvä, että tekoölyn toiminta on valvottua ja se toimii diagnostiikassa radiologin tukena.

## Lähteet

- Apell, P., & Eriksson, H. (2020). *Artificial intelligence (AI) healthcare technology innovations: The current state and challenges from a life science industry perspective*. <https://doi.org/10.1080/09537325.2021.1971188>
- Barrera, C. A., Solomon, N., Nikpanah, M., & Calle, F. (2023). *International Medical Graduates in Diagnostic Radiology: Overcoming Challenges and Making an Impact*. <https://doi.org/10.1148/rg.230038>
- Bernstein, M. H., Atalay, M. K., Dibble, E. H., Maxwell, A. W. P., Karam, A. R., Agarwal, S., Ward, R. C., Healey, T. T., & Baird, G. L. (2023). Can incorrect artificial intelligence (AI) results impact radiologists, and if so, what can we do about it? A multi-reader pilot study of lung cancer detection with chest radiography. *European radiology*. <https://doi.org/10.1007/s00330-023-09747-1>
- Creative Destruction Lab. (2016, marraskuuta 24). *Geoff Hinton: On Radiology*. <https://www.youtube.com/watch?v=2HMpRXstSvQ>
- Euroopan parlamentti. (2023). *Mitä tekoäly on ja mihin sitä käytetään? | Ajankohtaista | Euroopan parlamentti*. <https://www.europarl.europa.eu/news/fi/headlines/society/20200827STO85804/mita-tekoaly-on-ja-mihin-sita-kaytetaan>
- Firt, E. (2020). The missing G. *AI & SOCIETY*, 35(4), 995–1007. <https://doi.org/10.1007/s00146-020-00942-y>
- Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Hintze, A. (2016, marraskuuta 18). Understanding the 4 Types of A.I. *R & D*. <https://www.proquest.com/docview/1844751172/abstract/1F42A9C340EB4E31PQ/1>
- Hirvonen, J., & Nyman, M. (2023). *Ostaisinko radiologista tekoälyä sairaalaan—Mitä asiasta pitää tietää?* <https://www.duodecimlehti.fi/duo17593>
- Hosein, R. M. M., Link to external site, this link will open in a new tab, Peter, van O., & Milou, H. (2021). Applications of artificial intelligence (AI) in diagnostic radiology: A technography study. *European Radiology*, 31(4), 1805–1811. <https://doi.org/10.1007/s00330-020-07230-9>

- Hussain, S., Mubeen, I., Ullah, N., Shah, S. S. U. D., Khan, B. A., Zahoor, M., Ullah, R., Khan, F. A., & Sultan, M. A. (2022). Modern Diagnostic Imaging Technique Applications and Risk Factors in the Medical Field: A Review. *BioMed research international*, 2022, 5164970. <https://doi.org/10.1155/2022/5164970>
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15–25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Keinänen-Kiukaanniemi, S. (2020). *Potilas, lääkäri, diagnoosi ja totuus*. <https://www.duodecimlehti.fi/duo15961>
- Knuuti, J. (2020). *PET-kuvantaminen tänään ja tulevaisuudessa*. <https://www.duodecimlehti.fi/duo15569>
- Kreutzer, R. T., & Sirrenberg, M. (2020). What Is Artificial Intelligence and How to Exploit It? Teoksessa R. T. Kreutzer & M. Sirrenberg (Toim.), *Understanding Artificial Intelligence: Fundamentals, Use Cases and Methods for a Corporate AI Journey* (ss. 1–57). Springer International Publishing. [https://doi.org/10.1007/978-3-030-25271-7\\_1](https://doi.org/10.1007/978-3-030-25271-7_1)
- Kufel, J., Bargieł-Łączek, K., Kocot, S., Koźlik, M., Bartnikowska, W., Janik, M., Czogalik, L., 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), Article 15. <https://doi.org/10.3390/diagnostics13152582>
- Lakhani, P., & Sundaram, B. (2017). Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural Networks. *Radiology*, 284(2), 574–582. <https://doi.org/10.1148/radiol.2017162326>
- Langlotz, C. P. (2019). Will Artificial Intelligence Replace Radiologists? *Radiology: Artificial Intelligence*, 1(3), e190058. <https://doi.org/10.1148/ryai.2019190058>
- Larentzakis, A., & Lygeros, N. (2021). Artificial Intelligence (AI) in medicine as a strategic valuable tool. *The Pan African Medical Journal*, 38(184), Article 184. <https://doi.org/10.11604/pamj.2021.38.184.28197>
- Manickam, P., Mariappan, S. A., Murugesan, S. M., Hansda, S., Kaushik, A., Shinde, R., & Thipperudraswamy, S. P. (2022). Artificial Intelligence (AI) and Internet

- of Medical Things (IoMT) Assisted Biomedical Systems for Intelligent Healthcare. *Biosensors*, 12(8), Article 8. <https://doi.org/10.3390/bios12080562>
- Matsubara, K., Ibaraki, M., Nemoto, M., Watabe, H., & Kimura, Y. (2022). A review on AI in PET imaging. *Annals of Nuclear Medicine*, 36(2), 133–143. <https://doi.org/10.1007/s12149-021-01710-8>
- Matsuda, Y., Link to external site, this link will open in a new tab, Ito, E., Kuroda, M., & Araki, K. (2022). A Basic Study for Predicting Dysphagia in Panoramic X-ray Images Using Artificial Intelligence (AI)—Part 1: Determining Evaluation Factors and Cutoff Levels. *International Journal of Environmental Research and Public Health*, 19(8), 4529. <https://doi.org/10.3390/ijerph19084529>
- Moawad, A. W., Fuentes, D. T., ElBanan, M. G., Shalaby, A. S., Guccione, J., Kamel, S., Jensen, C. T., & Elsayes, K. M. (2022). Artificial Intelligence in Diagnostic Radiology: Where Do We Stand, Challenges, and Opportunities. *Journal of Computer Assisted Tomography*, 46(1), 78–90. <https://doi.org/10.1097/RCT.0000000000001247>
- Nikkilä, A., Raitanen, J., Lohi, O., & Auvinen, A. (2018). *Tietokonetomografia aiheuttaa lapsille pienen leukemiariskin*. <https://www.duodecimlehti.fi/duo14519>
- Nikpanah, M., Xu, Z., Jin, D., Farhadi, F., Saboury, B., Ball, M. W., Gautam, R., Merino, M. J., Wood, B. J., Turkbey, B., Jones, E. C., Linehan, W. M., & Malayeri, A. A. (2021). A deep-learning based artificial intelligence (AI) approach for differentiation of clear cell renal cell carcinoma from oncocytoma on multi-phasic MRI. *Clinical Imaging*, 77, 291–298. <https://doi.org/10.1016/j.clinimag.2021.06.016>
- Nilsson, N. J. (1998). *Artificial Intelligence: A New Synthesis*. Morgan Kaufmann Publishers.
- Otmani, N., Qarmiche, N., Omari, M., Bourkhime, H., Tachfouti, N., & El Fakir, S. (2022). Artificial Intelligence And Machine Learning In Healthcare: Application And Challenges. *Journal of Positive School Psychology*, 6(8), 1847–1853.
- Perry, W. G. (1994). What is neural network software? *Journal of Systems Management*, 45(9), 12.
- Pfizer. (2022). *Diagnostiikka ennen ja nyt – täsmällisen taudinmäärityksen jäljillä | Pfizer | Finland*. <https://www.pfizer.fi/tutkimus/terveytesi-tahdet/diagnostiikka-ennen-ja-nyt-tasmallisen-taudinmaarityksen-jaljilla>

- Poalelungi, D. G., Musat, C. L., Fulga, A., Neagu, M., Neagu, A. I., Piraianu, A. I., & Fulga, I. (2023). Advancing Patient Care: How Artificial Intelligence Is Transforming Healthcare. *Journal of Personalized Medicine*, *13*(8), Article 8. <https://doi.org/10.3390/jpm13081214>
- Pupic, N., Ghaffarizadeh, S. A., Forster, B. B., & Darras, K. E. (2023). Artificial Intelligence: The Medium and The Message. *Canadian Association of Radiologists Journal*, *74*(1), 14–15. <https://doi.org/10.1177/08465371221114590>
- Ramirez Zegarra, R., & Ghi, T. (2023). Use of artificial intelligence and deep learning in fetal ultrasound imaging. *Ultrasound in Obstetrics & Gynecology*, *62*(2), 185–194. <https://doi.org/10.1002/uog.26130>
- Rangareddy, H., & Nagaraj, S. K. (2022). Artificial Intelligence and Healthcare. *Journal of Clinical and Diagnostic Research*. <https://doi.org/10.7860/JCDR/2022/56148.17020>
- Rimmer, A. (2017). Radiologist shortage leaves patient care at risk, warns royal college. *BMJ: British Medical Journal (Online)*, *359*. <https://doi.org/10.1136/bmj.j4683>
- Russell, S., & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach* (Third Edition). Pearson.
- Salmon, P. M., Baber, C., Burns, C., Carden, T., Cooke, N., Cummings, M., Hancock, P., McLean, S., Read, G. J. M., & Stanton, N. A. (2023). Managing the risks of artificial general intelligence: A human factors and ergonomics perspective. *Human Factors and Ergonomics in Manufacturing & Service Industries*, *33*(5), 366–378. <https://doi.org/10.1002/hfm.20996>
- Seah, J., Brady, Z., Ewert, K., & Law, M. (2021). Artificial intelligence in medical imaging: Implications for patient radiation safety. *The British Journal of Radiology*, *94*(1126), 20210406. <https://doi.org/10.1259/bjr.20210406>
- Shen, D. (2021). Grand Challenges in Radiology. *Frontiers in Radiology*, *1*. <https://www.frontiersin.org/articles/10.3389/fradi.2021.615138>
- SRY. (e.p.). Radiologia. *SRY*. Noudettu 29. syyskuuta 2023, osoitteesta <https://sry.fi/radiologia/>
- Syväranta, S., Vuorinen, A.-M., & Tokola, A. (2021). *Radiologisen kuvantamisen perusteet*. <https://www.duodecimlehti.fi/duo16215>
- Terveyskylä. (2023). *Tietokonetomografia- eli TT-tutkimus | Tutkimukseen tulijan talo | Terveyskylä.fi*.

<https://www.terveyskyla.fi:443/tutkimukseen/kuvantamistutkimuksia/tietokonetoimografia-eli-tt-tutkimus>

Valtioneuvosto. (2023). *Tekoäly mullistaa terveydenhuoltoa – riskit voidaan torjua suunnittelulla ja yhteistyöllä*. Valtioneuvosto. <https://valtioneuvosto.fi/-/1271139/tekoaly-mullistaa-terveydenhuoltoa-riskit-voidaan-torjua-suunnittelulla-ja-yhteistyolla>

Waymel, Q., Badr, S., Demondion, X., Cotten, A., & Jacques, T. (2019). Impact of the rise of artificial intelligence in radiology: What do radiologists think? *Diagnostic and Interventional Imaging*, 100(6), 327–336.  
<https://doi.org/10.1016/j.diii.2019.03.015>

Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: An overview and application in radiology. *Insights into Imaging*, 9(4), Article 4. <https://doi.org/10.1007/s13244-018-0639-9>

Yoon, J. H., Han, K., Suh, H. J., Youk, J. H., Lee, S. E., & Kim, E.-K. (2023). Artificial intelligence-based computer-assisted detection/diagnosis (AI-CAD) for screening mammography: Outcomes of AI-CAD in the mammographic interpretation workflow. *European Journal of Radiology Open*, 11.  
<https://doi.org/10.1016/j.ejro.2023.100509>