



Osaamista  
ja oivallusta  
tulevaisuuden  
tekemiseen

Jani Korkea-aho, Miika Virtala

## Tekoälyn käytön edellytykset kuvantamisen diagnostiikassa

Kuvaileva kirjallisuuskatsaus

Metropolia Ammattikorkeakoulu

Röntgenhoitaja (AMK)

Radiografia ja sädehoito

Opinnäytetyö

19.04.2019

Tekijä(t) Otsikko	Jani Korkea-aho, Miika Virtala Tekoälyn edellytykset kuvantamisen diagnostiikassa
Sivumäärä Aika	19 sivua + 3 liitettä 19.04.2019
Tutkinto	Röntgenhoitaja (AMK)
Tutkinto-ohjelma	Radiografia ja sädehoito
Suuntautumisvaihtoehto	Radiografia ja sädehoito
Ohjaaja(t)	Lehtori Sanna Törnroos Lehtori Heidi Varonen
<p>Tekoälyssä on tapahtunut paljon kehitystä varsinkin radiografiassa. Tekoälyllä on iso rooli tänä päivänä sekä tulevaisuudessa kuvantamisen diagnostiikassa. Jatkuvan kehityksen avulla on tekoäly pystytty opettamaan käsittelemään radiologisissa tutkimuksista saavutettua massiivista määrää dataa ja on datan käsittelyn myötä saavuttanut asemansa spesifisenä työkaluna radiologiassa. Opinnäytetyön tarkoitus on etsiä tietoa, kuvailla ja pohtia tekoälyn käyttöä, mahdollisuuksia, ongelmia ja edellytyksiä diagnostisessa kuvantamisessa. Opinnäytetyön tavoitteena on käsitellä tekoälyn käyttöä ja käytön edellytyksiä kuvantamisen diagnostiikassa ja tuottaa tästä tietopohja.</p> <p>Opinnäytetyön toteutus tapahtui kuvailevalla kirjallisuuskatsauksella. Kirjallisuuskatsauksen tiedonhaku ja aineistohaku suoritettiin PubMed ja Cinahl tietokannoista. Opinnäytetyössä käytettiin myös muuta kirjallisuutta aiheeseen liittyen. Haut suoritettiin poissulkukriteereillä sekä aiheen liittyen aseteltuihin tutkimuskysymyksiin, tarkemmin on tästä mainittuna opinnäytetyössä. Yhteensä aineistonkeruussa löysimme poissulku- ja sisäänottokriteerien jälkeen 21 tutkimusta. Aineisto analysoitiin laadullisen sisällönanalyysin avulla.</p> <p>Keskisimpinä tuloksina tekoälyn käytön edellytyksessä nousi esiin datan määrä ja laatu, laskentateho sekä lainsäädäntö, eettisyys ja tietoturva. Maslow'n hierarkian pohjalta oli helppo käsitellä tekoälyn käytön edellytyksiä. Tiedon keruu, laadukkaan datan kasaaminen ja sen opettaminen tekoälylle vei huomattavan määrän aikaa. Tekoälystä on saatu pohjustettua monia sovelluksia, mutta niiden käyttöönotto on rajallista, johtuen tekoälyä koskevien laillisten ja teknillisten ratkaisemattomien ongelmien vuoksi.</p> <p>Tuloksia pystyy hyödyntämään esimerkiksi tietopohjana tekoälyn tämänhetkisestä tilanteesta. Tulokset mahdollistavat myös jatkokehityksen tekoälyn käytöstä muissa modaliteeteissa, sillä opinnäytetyö rajautui ainoastaan natiivi- ja mammografiakuvauksiin. Jatkotutkimusehdotuksena pohdimme ja toimme esille myös tekoälyn käytön hyödyntämistä röntgenhoitajien työssä, josta saataisiin hyötyä röntgenhoitajien ammattitaidon kehittymistä ja samalla opetusmateriaalia tekoälylle.</p>	
Avainsanat	Röntgenhoitaja, tekoäly kuvantamisen diagnostiikassa, AI

Author(s) Title	Jani Korkea-aho Miika Virtala The requirements of artificial intelligence in diagnostic imaging
Number of Pages Date	19 pages + 3 appendices 19 April 2019
Degree	Bachelor of Health Care
Degree Programme	Radiography and Radiotherapy
Specialisation option	Radiography and Radiotherapy
Instructor(s)	Sanna Törnroos, Senior Lecturer Heidi Varonen, Senior Lecturer
<p>Lots of development has happened with artificial intelligence especially in the field of radiography. Artificial intelligence plays big role at this day and in the future days of diagnostic imaging. Consistent development has given the possibility to teach the artificial intelligence to process the massive amount of data acquired from exams performed in radiology. Due from the possibility to process the massive data amount has artificial intelligence achieved position as a specific tool used in radiology. Purpose of this thesis is to find knowledge, describe and ponder the use of artificial intelligence, the possibilities, it's problems and requirements for it. Aim for this thesis is to process the use of artificial intelligence and the requirements in diagnostic imaging and to produce information about these two.</p> <p>Thesis was conducted as a literature review. Information retrieval we performed in PubMed and Cinahl databases. In this thesis literature outside of these databases was also used. Exclusion was used in information retrieval and it is explained more specific in the thesis. After all the exclusions we were left with 21 researches. All researches were analysed with qualitative methods.</p> <p>Key results in requirements for the use of artificial intelligence were the amount of data and its quality, computing capacity, legislation, ethicalness and information security. The requirements of artificial intelligence were easier to process with Maslow's hierarchy. Collecting the data with good quality and teaching it for the artificial intelligence took remarkable amount of time. Lots of applications based with artificial intelligence have been created but the commission of these applications is limited due to legal and technical issues that hasn't been solved.</p> <p>Results provided in this thesis can be used for example as an information of the status of artificial intelligence in diagnostic imaging. Results also gives the possibility to further investigation of the use of artificial intelligence in other modalities because this thesis was limited to traditional x-ray and mammography. We also bring up the aspect of using artificial intelligence with radiographers because the current usage is only for physicians.</p>	
Keywords	Radiographer, AI, Artificial intelligence in diagnostic imaging

## Sisällys

1. Johdanto	1
2. Tekoälyn lyhyt oppimäärä	2
2.1. Tekoälyn toiminta	2
2.2. Tekoälyn lyhyt historia	4
3. Tekoäly terveydenhuollon kuvantamisessa	5
3.1. Tekoälyn käytön mahdollisuuksia kuvantamisessa	5
3.2. Tekoälyn käytön haasteet kuvantamisessa	7
4. Terveydenhuollossa käytettävän tekoälyn taloudellisuus	8
5. Opinnäytetyön tarkoitus ja tavoite	10
6. Opinnäytetyön toteutus	10
6.1. Kuvaileva kirjallisuuskatsaus opinnäytetyön menetelmänä	10
6.2. Aineiston valinta ja tiedonhaku	11
6.3. Aineiston analysointi	13
7. Tuloksia	13
7.1. Tekoälyn hyödyntäminen kuvantamisessa	13
7.2. Tekoälyn käytön edellytykset kuvantamisen diagnostiikassa	15
8. Pohdinta	16
8.1. Tuloksien tarkastelu	16
8.2. Luotettavuus	17
8.3. Eettisyys	17
8.4. Oma ammatillinen kehittyminen	18
8.5. Jatkotutkimus- ja kehittämis ehdotukset	18
Lähteet	20
Liitteet	
Liite 1. Aineiston haku tietokannoista	
Liite 2. Tutkimusaineiston analyysitaulukko	
Liite 3. Opinnäytetyössä käytettyä sanastoa	

## 1. Johdanto

Terveystieteiden ja etenkin lääketieteellisessä kuvantamisessa yksi lupaavimmista innovaatioalueista on tekoäly. Tekoäly on kehittynyt huomattavasti eteenpäin viimeisen 60 vuoden aikana. Kuvantamisessa tuotettu datamäärä on lisääntynyt vuosien varrella ja siitä iso osa jää hyödyntämättä. Mahdollisuus hyödyntää tekoälyä tunnistamaan löydöksiä oli ne sitten nähtävissä tai ei ihmissilmillä, muuttaa radiologian subjektiivisesta visuaalisuudesta enemmän objektiiviseen tieteseen. Asiantuntijat, jotka olivat eturintamassa viemässä radiologiaa digitalisaation pariin ovat nyt saaneet mahdollisuuden ohjata tekoälyä radiologian pariin. Tekoäly voi löytää lääketieteellisestä kuvantamisesta monta soveltamisen kohtaa, kuten kuvien prosessointi, avustettu diagnosointi, jatko suunnitelman luominen, datan taltiointi, tiedonlouhinta ja monta muuta. Laajan soveltamisalan vuoksi tekoälyn oletetaan vaikuttavan esimerkiksi radiologin päivittäiseen työskentelyyn. (Pesapane – Codari – Sardanelli. 2018.)

Viimeisten vuosien aikana on kehityksessä menty eteenpäin ja tämän vuoksi tekoäly kykenee kuvailemaan ja tulkitsemaan monimutkaista dataa. Tekoälyn avulla konetta pystyttiin käyttämään apuna tehtävien suorittamisessa, mutta kehitys, etenkin syväoppimisessa käytettävät algoritmit ovat kehittäneet tekoälyä ihmisen tasolle ja tästä myös ohi yksityiskohtaisissa tehtävissä. Tehokkaampien laitteistojen sekä massiivisen digitaalisen datamäärän syöttäminen tekoälylle on parantanut syväoppimisessa käytettäviä algoritmeja. Kuvantamisessa tuotettu datamäärä jatkaa kasvamistaan verrattuna saatavilla olevien asiantuntijoiden määrään, kuten esimerkiksi radiologit. Sen lisäksi, että datasta osa jää käyttämättä lisää tämä myös radiologien työmäärää. Tutkimuksissa on todettu, että saavuttaakseen työmäärän vaatimukset tulisi radiologin tulkita 1 kuva suhteessa 3-4 sekuntiin. Liittämällä tekoäly tähän työmäärään saadaan lisättyä tehokkuutta, vähennettyä virheitä ja saavutettua tavoitteet mahdollisimman vähäisellä manuaalisella syötteellä. (Hosny – Parmar – Quackenbush – Schwartz – Aerts. 2018.)

Tässä opinnäytetyössä toteutettiin kuvaileva kirjallisuuskatsaus tekoälyn käytön hyödyntämisestä kuvantamisessa sekä käytön edellytyksistä kuvantamisen diagnostiikassa. Tekoäly on keskeinen aihe kuvantamisessa sekä yleisesti terveydenhuollossa varsinkin sen jatkuvan kehityksen kannalta sekä aihe herättää myös keskustelua ja mielipiteitä eri alan ammattilaisissa. Valitsimme aiheen, kun olimme itse

kiinnostuneista jo entuudestaan tekoälystä ja asioista sen ympärillä. Opinnäytetyön rajaus päädyttiin tekemään kuvantamismodaliteettien pohjalta mammografioihin ja natiivikuvantamiseen. Tekoälyllä on potentiaalisuutta nykyisissä ja tulevaisuudessa kehiteltävissä kuvantamisessa tehtävissä tutkimuksissa. Oikeilla menetelmillä ja soveltamisella voidaan tekoälystä saada paljon hyötyä irti.

Liitteessä 3 on lyhyesti esitelty tässä työssä käytettyä sanastoa helpottamaan lukemista.

## **2. Tekoälyn lyhyt oppimäärä**


### **2.1. Tekoälyn toiminta**

Tekoälyllä (Artificial intelligence, AI) tarkoitetaan koneen tai tietokoneohjelman kykyä suorittaa älykkäinä pidettäviä toimintoja, toisin sanoen koneen kykyä imitoida ihmisen älykkyyttä tai käyttäytymistä. Tekoälyn taustalla on siis jokin tietty ajatusprosessia muistuttava algoritmi, looginen päättely ja lopulta toiminta päättelyn mukaan. Tekoälyä voidaan tältä pohjalta lähestyä neljältä eri kantilta: "Ajattelee ihmismäisesti", "Toimii ihmismäisesti", "Ajattelee rationaalisesti" ja "Toimii rationaalisesti" (Russel – Norvig 2016: 2.)

Monet nykyajan tekoälysovellukset pohjautuvat neuroverkkoihin ja koneoppimiseen. Neuroverkot koostuvat joukosta yksittäisiä keinotekoisia neuroneita, jotka reagoivat saamaansa dataan ja kommunikoivat keskenään. Yksinkertainen neuroverkko on yksitasoinen eteenpäin kytketty neuroverkko, jossa tieto liikkuu vain yhteen suuntaan. Neuroverkoista voidaan myös tehdä monitasoisia ja niistä voidaan tehdä takaisinkytkentöjä aikaisempiin neuroneihin, jolloin kone kykenee ratkaisemaan vaikeampiakin ongelmia (Russell – Norvig. 2016: 727–732.)

Yksinkertaiset neuroverkot ratkaisevat tehokkaasti monia yksinkertaisia tai hyvin määriteltyjä ongelmia. Ongelmien monimutkaistuessa yksinkertaisten neuroverkkojen rajallisuus tulee hyvin esiin. Esimerkiksi ihmisen puheen tai kuvien tunnistaminen vaatii monimuotoisempia ja monitasoisia neuroverkkoja. Syväoppimisella siis viitataankin neuroverkkoihin, joissa on useampi eri kerros yksinkertaisempia neuroverkkoja (Deng – Dong. 2014: 205–206.)

Kuviossa 1 on esitetty yksinkertainen neuroverkko, data syötetään tekoälylle sisääntuloista (kuvassa merkitty siniseksi), datan manipulointi ja laskenta tapahtuu tekoälyyn piilotetuissa tasoissa (kuvassa merkitty keltaiseksi) ja tekoälyn tuottama data saadaan ulos ulostuloista (kuvassa merkitty vihreäksi). Tekoälyä opetetaan muuttamalla piilossa olevan tason neuroneiden (kuvassa merkitty palloina) aktivointi arvoja. Tekoälyn monimutkaisuutta voidaan lisätä skaalaamalla keinotekoisien neuronien ja piilossa olevien tasojen avulla. (Goldberg. 2017: 37–45.)



Kuvio 1. Yksinkertainen neuroverkko (mukautettu Goldberg. 2017)

Pääosin tekoälyä voidaan opettaa kahdella eri tavalla: valvotulla ja valvomattomalla oppimisella. Oppimistyylin valinta pohjautuu siihen, minkälaista dataa yritetään analysoida. Valvotussa oppimisessä tekoälylle annetaan luokiteltu koulutusaineisto, jonka pohjalta tekoäly rakentaa mallin. Valvomattomassa oppimisessä tekoäly saa luokittelematonta koulutusaineistoa, jonka pohjalta se pyrkii löytämään yhteyksiä.

Käytännössä tekoälyä voidaan opettaa myös monilla muilla monimutkaisemmilla tavoilla (Mohri – Rostamizadeh – Talwalkar. 2012: 7-8.)

## 2.2. Tekoälyn lyhyt historia

Idea tekoälystä ja itsenäisesti toimivista koneista on mahdollisesti lähtöisin jo antiikin kreikan ajoilta. Homeruksen kirjoittamassa eepoksessa Ilias kuvaillaan rampautuneen Hefaistoksen rakentamia kultaisia auttajia (”attendants”), jotka auttavat Hefaistosta liikkumaan ja työskentelmään pajassaan (Homerus – Lattimore (käänt.) 1951: 386).

Nykymuotoisen tekoälyn käsityksen voidaan katsoa lähteneeksi Alan Turingin kehittämästä teoreettisesta mallista tietokoneelle (Turing 1936.) Monissa artikkeleissa Turing esittää ihmistä ”tietokoneena”, ”toimijana”, joka manipuloi äärellisen määrän symboleita tiettyjen sääntöjen mukaan. Monet 1930-luvun ihmiset toimivat Turingin kuvailemina ”tietokoneina”, kuten kirjureina, sihteereinä tai kassamyijinä (Berlinski 2000: 184–194.) Toisin sanoen Turingin ja Alonzo Churchin mukaan tietokone teoriassa pystyisi simuloimaan mitä tahansa ihmisen järjellistä päättelykykyä (Berlinski 2000: 205–208.)

Vuonna 1950 Turing kehitti testin, jonka avulla voitiin mitata koneen esittämää älykkyyttä. Testin mukaan kone on älykäs, jos se kykeni imitoimaan ihmistä niin, ettei sitä kyetty erittelemään koneeksi (Turing 1950.)

Amerikkalainen tietojenkäsittelytieteilijä John McCarthy loi termin tekoäly (”Artificial intelligence”) vuoden 1956 Dartmouth-konferenssin ehdotuksessaan vuonna 1955. Ehdotuksen tavoitteena oli tutkia mahdollisuuksia ja tapoja tehdä koneita simuloimaan ihmistä ongelmien ratkaisusta abstraktiin ajatteluun ja oppimiseen ja itsensä kehittämiseen (McCarthy – Minsky – Rochester – Shannon 1955.)

60-luvun alussa Margaret Masterman ja hänen kollegansa suunnittelivat semanttisia verkkoja, jotka mahdollistivat tietokonekäännökset ja 60-luvun loppupuolella Doug Engelbart kehitti tietokonehiiren (Tekoäly.info.)

Vuonna 1970 suomalainen matemaatikko Seppo Linnainmaa esitti käänteisen tavan automaattiselle differentiaatiolle ("backpropagation"). Kyseistä menetelmää käytetään opettamaan neuroverkkoja (Griewank 2012.)

1970-luvun loppupuolella Jack Myers ja Harry Pope kehittivät ohjelman (INTERNIST-I), joka antoi lääketieteellisiä diagnooseja saadun tiedon perusteella ja 1980-luvun puolivälistä lähtien neuroverkot saatiin laajempaan käyttöön (Tekoäly.info.)

2000-luvulla tekoälyn kehitys on jatkunut ja älykkäitä tuotteita on jo jokaisen kuluttajan saatavilla. Laitteistojen kehittyessä ja laskentatehon kasvaessa on tekoäly myös kehittynyt mukana. Tekoälyn laskentateho on arviolta kasvanut vuodesta 2012 (AlexNet) lähtien 300000 kertaiseksi (AlphaGo Zero) (Amodei – Hernandez 2018.)

### **3. Tekoäly terveydenhuollon kuvantamisessa**

#### **3.1. Tekoälyn käytön mahdollisuuksia kuvantamisessa**

CAD (computer-aided diagnosis/detection) on jatkuvasti kehittymässä ja on enemmänkin mukana radiologian valtavirrassa. Lääketieteessä käytettyä CAD termiä ei kuitenkaan pidä sekoittaa insinöörien tai arkkitehtien käyttämään tietokoneavusteiseen suunnitteluun (CAD, Computer aided design). Tekoäly on jo osa kliinistä työtä esimerkiksi rintasyövän ja keuhkokuvien diagnosoimisessa. Tekoälyn tarjoamaa dataa käytetään usein radiologien apuna tai "toisena mielipiteenä" kuvien diagnosoimisessa. Koneen tuottamalla algoritmillla on useita eri prosesseja, jotka voivat olla kuvien käsittelyä, kuvien ominaisuuksien analysointia, kuvista saatavan datan luokittelua sekä ROI (region of interest) alueen määrittämistä. CAD:in lisäksi on tekoälyyn liitetty elementtejä, kuten ANN (artificial neural network) ja CNN (convolutional neural network). Ensimmäisiä yrityksiä tuoda CAD systeemi radiologian alueelle tapahtui jo 1960-luvulla ja laitteistojen nopea kehitys on mahdollistanut myös CAD systeemien kehittymisen. Tutkimuksissa todetaan, että CAD systeemi keuhkokuvien diagnosoinnin apuna parantaa diagnoosien tarkkuutta keuhkoissa sijaitsevien sairauksien ja poikkeavuuksien löytämiseen. Vaikka keuhkokuvat ovatkin yleisiä maailmanlaajuisesti niiden hyvän saatavuuden vuoksi, ovat ne silti liian monimutkaisia CAD systeemille automaattiseen diagnosointiin. Tämä on edelleen jatkuvassa kehityksessä ja suurin osa CAD systeemeistä on muunneltu vuosien varrella keuhkoissa sijaitsevan syövän aikaiseen

havainnointiin. Automaattisen diagnosoimisen haastavuuden vuoksi on pieni osa tutkimuksista osoitettu systeemin automatisoimiseen erilaisten patologisten muutosten löytämiseen. CAD systeemin kehityksessä on hyödynnetty tekoälyn kehittymistä ja liitetty tekoälyä yhä enemmän systeemiin mahdollistaen uusia ominaisuuksia systeemin rakentamista lääketieteellisiä sovelluksia varten. (Chunli – Demin – Yonghong – Zhijian. 2018.)

CAD systeemin käytöllä on kuvien käsittelyssä erilaisia menetelmiä. DES (dual energy subtraction) menetelmän käyttö edellyttää digitaalista kuvantamista sekä hieman erilaisempaa laitteistoa ja on tästä syystä harvinaisempi. DES menetelmää voidaan käyttää, kun keuhkoista otetaan kaksi PA kuvaa; toinen korkealla ja toinen matalalla energialla. Ensimmäinen kuva otetaan korkealla energialla 120kVp, jonka jälkeen 150ms viiveellä otetaan toinen kuva matalalla energialla 60kVp. Algoritmi käsittelee sekä yhdistää kuvat ja antaa käsitellystä datasta kaksi 120kVp kuvaa, joista tekoälyn avulla on toisesta vaimennettu kylkiluut sekä solisluut ja toisesta vaimennettu pehmytkudoksia. MTANN (multiresolution large-scale training artificial network) menetelmä soveltaa ConvNets (convolutional neural network) tekoälyä. Tarkennettuna ICA (independent component analysis) parantaa pehmytkudosten näkyvyyttä vaimentamalla luisia rakenteita tai vaihtoehtoisesti vaimentamalla pehmytkudoksia taustalta. ICA on todennettu näistä kahdesta parempana menetelmänä sen korkealaatuisten kuvien ja hyvän saatavuuden ansiosta. Molemmilla tekoälyä hyödyntävillä CAD menetelmillä on saatu paranneltua keuhkoissa sijaitsevien syöpien diagnosointia. (Chunli ym. 2018.)

CAD tuotiin mammografian kuvantamiseen 1998. Samalla tavalla, kuten keuhkojen kuvantamisessa on CAD "toisena mielipiteenä" kuvan tulkitsemisessa mukana. CAD käyttö mammografiassa on tuonut 19"-23% parannuksen löydöksiä löytämiseen kuvista. Eteenpäin kehitelty CAD käyttää mammografiassa DCNN (deep convolutional neural network) lähestymistapaa kuvan kannalta ja soveltaen vielä tarkemmin DDCNN (dual deep convolutional neural network). DDCNN tarkoituksena on, että tekoäly lähestyy kuvaa samalla tavalla kuin radiologit eli ensiksi arvioimalla koko kuvaa ja tämän jälkeen ROI alueen. DDCNN pystyy käymän kuvan datasta läpi samanaikaisesti koko kuvan sekä ROI alueen. (Teare – Fishman – Benzaquen – Toledan – Elnekave. 2017.)

### 3.2. Tekoälyn käytön haasteet kuvantamisessa

Tekoälyn käytölle on myös paljon haasteellisuutta. CAD käyttö kliinisissä tutkimuksissa vaatisi CAD systeemiltä yleisesti neljä asiaa: 1) Tarkoituksena on parantaa radiologien suoritusta. 2) Systeemin tulisi säästää aikaa. 3) Saumaton integrointi työntekoon. 4) vastuuvollisuuksia ei tulisi lisätä ja lisäkustannusten olisi oltava vähäisiä. Suurin osa CAD systeemeistä eivät vastaa asetettuja vaatimuksia ja tästä syystä ne eivät ole kliinisessä käytössä, vaikka kehitystä tekoälyn parissa on tehty paljon. (van Ginneken – Schaefer-Prokop – Prokop 2011.)

Tämänhetkisten CAD systeemien käyttö painottuu työkaluun, jonka tarkoituksena olisi kiinnittää radiologin kiinnostuksen kohde tietylle alueelle kuvasta. CAD ei kykene huomaamaan itsenäisesti kaikkea, joten radiologin on edelleen itse arvioitava koko kuva. Kuitenkin on mahdollista, että CAD huomaa esimerkiksi ylimääräisen poikkeaman tai vaurion, mikä olisi mahdollisesti jäänyt radiologilta huomaamatta. (van Ginneken ym. 2011.)

Tekoälyn käytössä on tärkeää diagnoosin ja prognoosin erottaminen toiminnasta ja suosituksista. Radiologin korvaaminen koneiden avulla ei ole mahdollista, koska radiologiaan kuuluu paljon enemmän, kuin yksinkertainen kuvien tulkitseminen. Radiologin vastuualueeseen kuuluu paljon tehtäviä, joita ei pystytä ohjelmilla ja algoritmeilla suorittamaan. (Pesapane ym. 2018.)

Radiologin työhön kuuluu muun muassa henkilön kliinisten, yksilöllisten ja yhteiskunnallisten kontekstien huomioiminen, joita tekoäly ei vielä kykene suorittamaan. Tekoäly ei kykene empaattiseen tai neuvokkaaseen toimintatapaan. Lääketiede vaatii uniikkia ihmislunnetta, eikä ihmisen tarvetta voida poistaa yhtälöstä. On kuitenkin mahdollista, jos kuvien tulkitsemiseen kulutettua aikaa saataisiin lyhennettyä tekoälyn avulla, voisi esimerkiksi radiologi keskittyä enemmän diagnoosin tekemiseen. Mikäli aikaa saadaan vähennettyä huomattavasti ja tekoälyn käytön tehokkuutta lisättyä, olisi mahdollista esimerkiksi tarve vähemmälle määrälle radiologeja, mutta siltikään radiologin korvaaminen ei tulisi kyseen. Tekoälyn käyttöön ottamisessa tulee vastaan mahdollinen lisätarve radiologeille, mitä ei tulisi jättää huomioimatta. (Pesapane ym. 2018.)

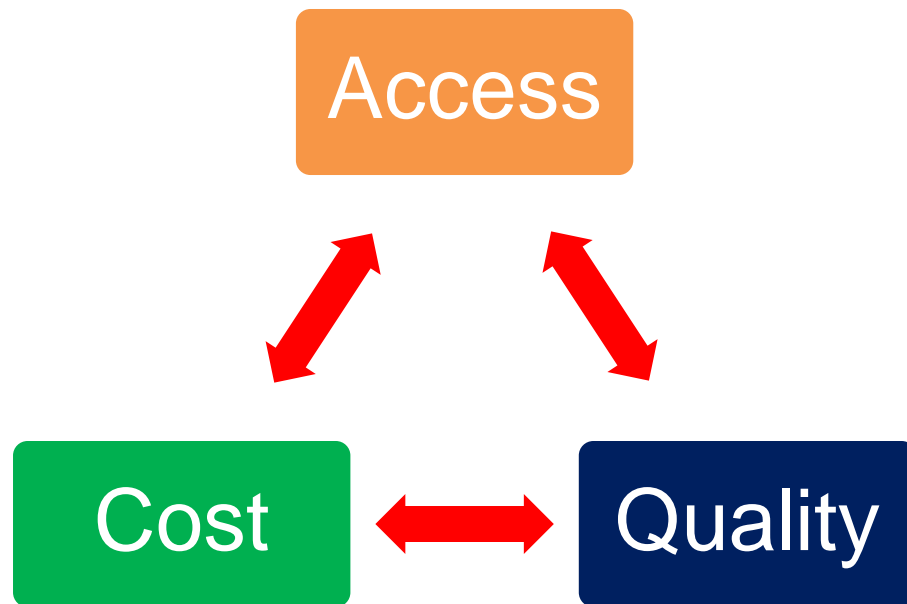
Tekoäly jäljittelee ihmisen älyä, tämä tulisi aina muistaa tekoälyä käsitellessä. Radiologien rooli tekoälyä koskevissa haasteissa on esimerkiksi laadukkaiden koulutusaineistojen luominen, käsiteltävän kliinisen tehtävän määrittely ja saatujen tulosten tulkinta. Tekoälyä ei ilman edellä mainittuja asioita pystytä opettamaan sen lisäksi, että kyseisen dataan käsiksi pääseminen on sekä aikaa vievää, että korkea kustanteista. (Pesapane ym. 2018.)

Myös laillinen näkökulma tulee huomioida terveydenhuollossa ja kuvantamisessa käytettävässä tekoälyssä. Tekoälyn muuttuessa työkalusta autonomiseen päätöksen tekoon diagnoosiin ja prognoosiin liittyen, tulee vastaan laillisia haasteita. Tehdessään väärän päätöksen tai valinnan joudutaan miettimään, kuka on vastuussa. Kenelle tässä tilanteessa kuuluu eettisten ja laillisten alueiden vastuu, tekoälyn tehdessä päätöksen. Kuuluuko vastuu radiologille, tekoälyn suunnittelijalle tai tekijälle vai tekoälylle? Se on yksi suurimmista syistä, miksi tekoälyä ei voida hyödyntää autonomisena vaan enemmänkin työkaluna. (Pesapane ym. 2018.)

#### **4. Terveydenhuollossa käytettävän tekoälyn taloudellisuus**

Tekoäly on sellaisessa asemassa, että se muuttaa terveydenhuoltoa kokonaisvaltaisesti. Tehtyjen analyysien ja tutkimusten perusteella terveydenhuollon tekoälyn markkina-alue kasvaa 40% vuoteen 2021 mennessä. Accenture yhtiön tekemän analyysin mukaan tekoälyn hyödyntäminen terveydenhuollossa mahdollistaisi 150Bn dollarin säästön Yhdysvaltojen terveydenhuollossa vuoteen 2026 mennessä. Tekoälyllä on mahdollisuus muuttaa terveydenhuollon prosessin tulosta 30-40% ja puolittaa hoitokustannuksia. (Menon. 2018.)

Tekoälyllä olisi myös mahdollista ratkaista terveydenhuollossa muodostuva ”iron triangle”. ”Iron triangle” muodostuu kolmesta osasta, jotka ovat saatavuus, laatu ja kustannusten hallinta. Parantamalla yhtä osaa kolmesta usein aiheutetaan vahinkoa johonkin toiseen. Tekoälyllä katsotaan olevan mahdollisuutta poiketa tavallisista menetelmistä ja parantaa kolmion kaikkia osia ilman toisen osan vahingoittamista. Eli tekoälyllä saataisiin paranneltua hoidon saatavuutta, hoitomenetelmien kustannusten vähentämistä sekä nostettua hoidon laatua samanaikaisesti. (AI And Healthcare: A Giant Opportunity. 2019.)



Kuvio 2. The iron triangle of healthcare

Suurituloisissa maissa hyödynnetään jo integroitua tekoälyä arkipäiväisessä käytössä terveydenhuollossa. Pienituloisissa maissa tilanne on toinen ja siellä tekoälystä saataisiin enemmän hyötyä. Maailmanlaajuisesti älypuhelimien käyttö on tullut yleisemmäksi ja sen käyttö yhdistettynä tukevien teknologisten sovellusten ja palveluiden kanssa voitaisiin pienituloisemmissa maissa parantaa julkisen terveydenhuollon prosessin lopputulosta tekoälyn avulla. Palveluiden rajallisuuksien vuoksi tekoälyä pystyttäisiin hyödyntämään kokonaisuudessaan työkaluna sekä joissain tilanteissa korvaamaan hoitoon liittyvän asiantuntijan, mikäli sellaista ei siinä hetkessä ole saatavilla. Suurituloisissa maissa jo käytössä olevat tekoälyä hyödyntävät työkalut auttavat lääkäreitä potilaan diagnosoimisessa ja hoitosuunnitelmaa laatiessa, pienituloisemmissa maissa olisi tämänlaisesta työkalusta suuri hyöty ja pystyisi se tarvittaessa toimimaan itsenäisesti, mikäli asiantuntijaa ei olisi saatavilla. (Wahl – Cossy-Gantner – Germann – Schwalbe. 2018.)

## 5. Opinnäytetyön tarkoitus ja tavoite

Opinnäytetyön tarkoituksena on etsiä tietoa, kuvailla ja pohtia tekoälyn käytön mahdollisuuksia, ongelmia ja edellytyksiä diagnostisessa kuvantamisessa sekä tuottaa tietoa aiheesta kirjallisuuskatsauksena. Opinnäytetyön tavoitteena on tuottaa tietopohjaa tekoälyn käytön hyödyistä, edellytyksistä ja ongelmista diagnostisessa kuvantamisessa. Aihe on rajattu natiivikuvantamiseen sekä mammografiaan.

Opinnäytetyötä ohjaavat tutkimuskysymykset:

1. Kuinka tekoälyä hyödynnetään kuvantamisessa?
2. Mitä edellytyksiä tekoälyn käytölle olisi kuvantamisen diagnostiikassa?

## 6. Opinnäytetyön toteutus

Opinnäytetyötä työstettiin kuvailevalla kirjallisuuskatsauksella ja tämän menetelmän periaatteita sekä ohjeistuksia noudattaen. Kirjallisuuskatsaus on kattava tutkielma ja tulkinta kirjallisuudesta, joka liittyy tiettyyn rajattuun aiheeseen. Kirjallisuuskatsausta tehdessä on hyvä tehdä tutkimuskysymys tai kysymykset ja niiden kautta analysoida aiheeseen liittyvää kirjallisuutta vastaten kehitettyihin tutkimuskysymyksiin. Kirjallisuuskatsaukset ovat hyviä ja tärkeitä menetelmiä, sillä niillä saadaan tehtyä yhteenveto aiheeseen liittyvästä kirjallisuudesta. Kirjallisuuskatsaus on saavuttanut yleisen aseman tutkimusmenetelmänä sosiaali- ja terveydenhuoltoon liittyvissä tutkimuksissa, koska alan kirjallisuus on jatkuvasti lisääntyvää ja kirjallisuuskatsaus on tällöin paras menetelmä aineistojen käsittelemiseen. (Aveyard. 2014.)

### 6.1. Kuvaileva kirjallisuuskatsaus opinnäytetyön menetelmänä

Kuvailevan kirjallisuuskatsauksen tarkoituksena on tunnistaa olennaiset tutkimukset, kriittisesti arvostella ja analysoida löydöksiä ja esittää tietoja rajatusta aiheesta. Menetelmässä tutkimustyö perustuu huolellisesti aiheesta löydetyn tiedon läpi

käymiseen. Julkaistujen tutkimusten analyysien ja yhteenvedojen läpi käyminen antaa syvemmän ymmärryksen rajatusta aiheesta. Erityisesti tällä saavutetaan kattava kokonaisuus terveydenhuollon ammattilaisille aiheeseen liittyvästä kirjallisuudesta sekä tutkimuksista. (Coughlan – Cronin. 2016.)

Kuvaileva kirjallisuus mahdollistaa laajan menetelmän kirjallisuuden valintaan sekä mahdollistaa sisällön valitsemisen, mikä voi sisältää esimerkiksi kvalitatiivisia tai kvantitatiivisia tutkimuksia. Kuvaileva kirjallisuuskatsaus ei menetelmänä suoranaisesti noudata tarkkaa ja määriteltyä prosessia, mutta sillä voidaan silti soveltaa strukturoidusta systemaattisesta kirjallisuuskatsauksesta osatekijöitä ilman sen rajoituksia. Vaikka opinnäytetyössä on käytetty kuvailevaa kirjallisuuskatsausta, voidaan lähestymistapana myös käyttää systemaattista. Tähän sisältyy haussa käytettyjen termien, tietokantoihin syötettyjen termien ja valitun kirjallisuuden analyysin kehittämisen selittämistä. Lisäksi menetelmän kuvaus havainnollistaa, että valitsemisprosessi on hyvin perusteltu ja aiheellinen. (Coughlan ym. 2016.)

## 6.2. Aineiston valinta ja tiedonhaku

Aineiston keräystä ja valintaa ohjasi tutkimuskysymykset. Kuvailevan kirjallisuuskatsauksen perusta on aineistolähtöinen, minkä tarkoituksena olisi ymmärtää käsiteltyä aineistoa. Aineistovalinta tapahtui aluksi artikkelien otsikoiden perusteella. Otsikoiden mukaan valitusta aineistoista luettiin johdanto ja aineistoa karsittiin tutkimuskysymysten perusteella. Lopullinen valinta aineiston sopivuudesta tehtiin koko tekstin pohjalta. Aineiston käytettävyyden edellytys oli, että aineisto käsitteli tutkimuskysymyksissä esiteltyjä aiheita. Aineiston valintaprosessia avataan ja käsitellään lukijalle tässä kappaleessa. Kyseisen aineistonkeruun menetelmän seurauksena löysimme yhteensä 21 sopivaa tutkimusta.

Aineistonkeruussa käytettiin internetistä löytyviä tietokantoja PubMed ja Cinahl. Hakuja suoritettiin myös muihin tietokantoihin, kuten Ovid Medline ja Google Scholar, mutta alustavantiedonhaun seurauksena huomasimme löytävämme vain samoja tutkimuksia tai muuten aineiston valinnan ulkopuolelle jääviä tutkimuksia. Alustavien hakujen hakusanoja olivat: “ai”, “artificial intelligence”, “radiology”, “radiography”, “diagnostic\*”, “mammography” ja “neural network\*”. Hauissa saaduista tuloksista poissuljettiin yli 10

vuotta vanhat, maksulliset sekä muulla kuin englannin kielellä kirjoitetut tutkimukset. Aineiston valinnan ja tiedonhaun tulokset on esitetty Liitteessä 1.

PubMedin tietokannasta suoritettussa haussa parhaimmat hakutulokset saimme hakusanoilla “artificial intelligence [Title/Abstract]” OR “neural network\* [Title/Abstract]” AND “radiography [Title/Abstract]” ja “artificial intelligence [Title/Abstract]” OR “neural network\* [Title/Abstract]” AND “mammography [Title/Abstract]”.

Hakusanoilla “artificial intelligence [Title/Abstract]” OR “neural network\* [Title/Abstract]” AND “radiography [Title/Abstract]” PubMedin tietokantaan löysimme yhteensä 17 tutkimusta, joista otsikoiden perusteella valittiin yhdeksän. Aineistoa pyrittiin rajaamaan myös abstraktin sekä koko tekstin pohjalta, mutta lopulliseen analyysiin valittiin kuitenkin otsikoiden pohjalta löytyneet yhdeksän tutkimusta.

Hakusanoilla “artificial intelligence [Title/Abstract]” OR “neural network\* [Title/Abstract]” AND “mammography [Title/Abstract]” PubMedin tietokantaan löysimme yhteensä 49 tutkimusta, joista otsikoiden perusteella valittiin 21. Abstraktin ja koko tekstin pohjalta lopulliseen analyysiin valittiin yhteensä 10 tutkimusta.

Cinahlin tietokantaan suoritettiin PubMediä vastaavat haut hakusanoilla “TI artificial intelligence OR TI neural network\* AND radiography” ja “TI artificial intelligence OR TI neural network\* AND mammography”. Haulla “TI artificial intelligence OR TI neural network\* AND radiography” löytyi yhteensä 110 tulosta, joista otsikoiden perusteella valittiin 13. Abstraktin ja tekstin pohjalta tarkasteluun valittiin kuusi tutkimusta, joista neljä löytyi myös PubMedin haussa. Kyseisellä haulla lopulliseen analyysiin valittiin kaksi, joista toinen suljettiin pois tutkimuksen saatavuuden perusteella.

Haulla “TI artificial intelligence OR TI neural network\* AND mammography” Cinahlin tietokantaan löysimme yhteensä 105 tutkimusta, joista otsikoiden perusteella valittiin kolme. Abstraktin ja tekstin pohjalta valittiin kaksi, joista toinen löytyi jo aikaisemmalla haulla ja suljettiin pois saatavuuden perusteella. Lopulliseen analyysiin päätyi yksi tutkimus.

### 6.3. Aineiston analysointi

Aineistoa lähdettiin analysoimaan laadullisen sisällönanalyysin avulla. Valitusta aineistosta pyrittiin etsimään tutkimuskysymysten kannalta oleellisia asioita ja aineisto pyrittiin luokittelemaan sisällöllisiin kokonaisuuksiin. Sisällönanalyysin avulla aineistoa pelkistettiin ja luokiteltiin kuvantamiskohteen ja mukaan. Alkuperäistutkimukset on esitelty kokonaisuudessaan liitteessä 2 olevassa analyysikehyksessä.

## 7. Tuloksia

Kirjallisuuskatsauksen aineistoksi valikoitui kvantitatiivisia tutkimuksia. Aineistonkeruun pohjalta tutkimuksia kirjallisuuskatsaukseen valittiin yhteensä 21. Tutkimuksista neljä oli yhdysvaltalaisia, kolme kiinalaisia, kolme korealaisia, yksi intialaisia, kaksi japanilaisia, kaksi brasilialaisia, yksi ruotsalainen, yksi iranilainen, yksi unkarilainen, yksi israelilainen, yksi alankomaalainen. Näiden tutkimusten lisäksi yksi tutkimus oli toteutettu yhteistyössä Egyptin ja yhdistyneiden kansakuntien kanssa. Tutkimuskysymyksiin löydettiin osittaiset vastaukset katsaukseen valituista tutkimuksista. Tutkimukset eivät ottaneet kantaa eettisiin tai laillisiin kysymyksiin tekoälyn soveltamisesta kuvantamisen diagnostiikassa. Aineistonhaun analyysin perusteella tutkimukset jaoteltiin kategorioihin kuvantamiskohteen hyödyn mukaan. Kategorioita muodostui yhteensä viisi: mammografiat, thorax alueen kuvantaminen, muu kuvantaminen, kuvien luokittelu ja kuvanlaatu. Kategoriat päättyivät vain helpottamaan sisällönanalyysiä eikä niitä käytetty lopullisissa tuloksissa hyödyksi.

### 7.1. Tekoälyn hyödyntäminen kuvantamisessa

Tutkimuksista kuusi käsitteli thorax alueen kuvantamista ja 11 oli mammografioihin tarkoitettuja sovelluksia. Kaksi tutkimusta käsitteli tekoälyn soveltumista muuhun natiivikuvantamiseen, yksi tekoälyn hyödyntämistä kuvien luokittelussa ja yksi kuvanlaadun parantamista.

Monia tekoälypohjaisia sovelluksia on kehitetty terveydenhuollon ja kuvantamisen avuksi, mutta niiden käyttöönotto on hyvin rajallista ennen, kuin tekoälyä koskevat lailliset ja teknilliset ongelmat on ratkaistu (Pesapane ym. 2018; Jung ym. 2018.)

Tekoälyä kuitenkin voitaisiin hyödyntää monella eri tapaa kuvantamisen diagnostiikassa. Esimerkiksi tekoälyn avulla voitaisiin luokitella vaikeasti diagnosoitavaa ja luokiteltavaa pölykeuhkoa (Okumura – Kawashita – Ishida. 2011) tai diagnosoida rintasyöpää (Teare – Fishman – Benzaquen – Toledano – Elnekave. 2017). Röntgenkuvista voitiin myös tekoälyn avulla vähentää luista aiheuttamia varjoja virtuaalisen monienergia röntgenkuvauksen avulla (Chen – Suzuki. 2012.)

Kaikissa löytämissämme tutkimuksissa (liite 2) tekoäly kykeni diagnosoimaan ja löytämään thorax- ja mammografiakuvista poikkeuksia vähintäänkin yhtä tarkasti, kuin kokenut radiologi.

Yhdessä tutkimuksessa tekoäly opetettiin normaalista tavasta eroten puhtaasti kuvadatan pohjalta, ilman kuvien manuaalista annotaatiota (Kim – Kim – Han – Kang – Sohn – Woo – Lee. 2018.)

Tekoälyä hyödynnettiin myös ortopedisissä kuvauksissa löytämään kuvista murtumia, luokittelemaan kuvattavia kohteita ja kuvien puolisuuutta (oikea tai vasen). Puolisuuuden luokitteluun tekoäly kykeni yllättävästi ilman puolenmerkkejä, vaikka kuvia peilattiinkin data määrän kasvattamiseksi ja datan ylisovittamisen vähentämiseksi (Olczak – Fahlberg – Maki – Razavian – Jilert – Stark – Sköldenberg – Gordon. 2017.)

Tekoälyn avulla myös pystyttiin diagnosoimaan harvinaisia sairauksia, kuten moyamoyan-tauti normaaleista kallon kuvista, vaikka taudin diagnosoimiseen yleensä vaaditaan angiografia (Kim – Heo – Jang – Sunwoo – Kim – Lee – Kang – Park – Kwon – Oh. 2018.)


Tekoälyn käyttö ei kuitenkaan rajaudu ainoastaan kuvien luokitteluun tai diagnosoinnin aputyökaluksi. Tekoälyn avulla kyettäisiin myös kohentamaan huonolaatuisempien röntgenkuvien laatua (Sun – Li – Cong – Wang – Guo. 2017).

## 7.2. Tekoälyn käytön edellytykset kuvantamisen diagnostiikassa

Aineiston analyysiä tehdessä mietimme, mitä edellytyksiä tekoälyn käytölle tulisi olla. Lähdimme tarkastelemaan kysymystä Maslow'n tarvehierarkian pohjalta (Maslow. 1954: 35–46.) Kaikissa analyysiin päätyneissä tutkimuksissa tekoälyn kehittäminen lähti liikkeelle tiedon keruusta. Laadukkaan datan kerääminen vaikuttaa suurelta osin tekoälyn toimintaan. Hyvänä esimerkkinä tekoälylle syötettävän datan vaikutuksesta tekoälyn toimintaan toimii Massachusettsin teknillisessä korkeakoulussa kehitetty psykopaattinen tekoäly (Yanardag – Cebrian – Rahwan. 2018.)

Hyvän datan pohjalta tekoälyä voidaan alkaa suunnittelemaan ja opettamaan. Data jaetaan opetus-, validaatio- ja testidataksi. Opetusdatalla tekoäly opetetaan, validaatiodatalla tekoälyn toimintaa tarkennetaan ja testidatalla lopulta tekoälyn toimintaa testataan (Sarle. 2002.) Suurien datamäärien vuoksi tekoälyn opettaminen järkevässä ajassa vaatii paljon laskentatehoa ja usein opetus tapahtuu näytönohjainten avulla (Ribli – Horváth – Unger – Pollner – Czabai. 2018).

Kuviossa 3 on esitetty yksinkertaistettu Maslow'n tarvehierarkia askeleista, mitä käytännössä tekoälyn kehityksessä käydään läpi. Tekoälyn toiminnan kannalta vaaditaan paljon laadukasta dataa, jonka pohjalta tekoäly voidaan opettaa, validoida ja lopulta testata. Vasta testin pohjalta voidaan arvioida tekoälyn suoritumista tehtävästään.



Kuvio 3. Maslow'n hierarkia tekoälylle.

Löytämämme tutkimukset eivät ottaneet kantaa siihen, kuinka lailliset ja eettiset ongelmat tai kysymykset tulisi ratkaista. Ennen tekoälyn laajamittaista käyttöönottoa näihin ongelmiin ja kysymyksiin kuitenkin täytyy löytyä vastaus, joten suurin edellytys tekoälyn käytölle on tekoälyn käyttöön liittyvä lainsäädäntö, eettisyys ja tietoturva.

## 8. Pohdinta

Kappaleessa vertailemme ja pohdimme tuloksia kappaleissa kaksi, kolme, neljä ja seitsemän oleviin teorianäytöihin. Myös kappaleessa tarkastellaan tulosten validiutta, oppinäytetyön prosessia, työhön käytetyn menetelmän luotettavuutta, työn eettisyyttä sekä ammatillista kehitystä työn aikana.

### 8.1. Tuloksien tarkastelu

Löytämämme aineiston perusteella on selvää, että hyvin toteutetusta tekoälystä olisi apua kuvantamisen diagnostiikassa. Tekoäly voidaan opettaa nyky menetelmin tunnistamaan monia eri poikkeavuuksia röntgenkuvista jopa kokeneen radiologin tarkkuudella (Pesapane ym. 2018.)

Tekoälyn opettaminen, validaatio ja testaus vaatii usein suuria kuvamääriä ja laskentatehoa. Löytämässämme tutkimuksissa käytettiin satoja tai jopa tuhansia kuvia opettamaan tekoälylle spesifinen tarkoitus, esimerkiksi tuberkuloosin diagnosointi (Lopes – Valiati. 2017). Lähdekuvia myös usein muokattiin eri kuvankäsittely menetelmillä kasvattamaan saatavilla olevan datan määrää (Rajkomar – Lingam – Taylor – Blum – Mongan. 2017).

Löytämistämme tutkimuksista lähes kaikki tekoälysovellukset opetettiin tunnistamaan jokin spesifinen poikkeavuus jo etukäteen sanelluilla kuvilla. Suurien saneltujen ja tarkastettujen kuvamäärien hankkiminen on kuitenkin usein vaikeaa yksityisyyteen ja tietosuojaan liittyvien ongelmien taika (Jung ym. 2018).

Tekoälyä on myös mahdollista opettaa ilman radiologin sanelemia kuvia, pelkällä raa'alla kuvadatala. Tällainen tekoäly ei kuitenkaan yhdistä poikkeamaa itse diagnoosiin, vaikka tekoäly kuvista osaakin korostaa poikkeaman näkyville (Kim ym. 2018.)

Tekoälyn avulla oli myös mahdollista havaita harvinaisia poikkeamia, kuten moyamoya-tauti normaaleista röntgenkuvista, vaikka normaaleja kuvia ei perinteisesti käytetä moyamoya-taudin diagnosointiin (Kim – Heo – Jang – Sunwoo – Kim – Lee – Kang – Park – Kwon – Oh. 2018.)

Kaikista löytämistämme tutkimuksista kävi myös ilmi nykyisten tekoälysovellusten spesifisyys. Tekoäly opetettiin yhtä ja ainoaa tehtävää varten, sillä laajempaa vahvaa tekoälyä ei lukuisista hankkeista huolimatta ole vielä onnistuttu kehittämään (Baum. 2017.)

## 8.2. Luotettavuus

Opinnäytetyön prosessi toteutettiin hyvän tieteellisen tutkimuksen käytännön edellyttämällä tavalla, tutkimuseettisen neuvottelukunnan ohjeiden mukaisesti. Prosessin eri työvaiheet kuvailtiin tarkasti ja järjestelmällisesti, jotta lukija pystyy itse katsomaan ja arvioimaan toteutukseen käytettyä menetelmää sekä luotettavuutta. Kirjallisuuskatsauksella pystyttiin valitsemaan tiedonhausta saatava aineisto vastaamaan ja käsittelemään tutkimuskysymyksessä esiteltyjä aiheita. Kirjallisuuskatsaus suoritettiin kriittisesti arvioimalla ja analysoimalla löydettyjä tutkimuksia rajatusta aiheesta. Kuvaileva kirjallisuuskatsaus oli hyvä valinta tutkimusmenetelmäksi, koska se mahdollisti laajan sisällön valitsemisen ja näin ollen saavutettiin kattava kokonaisuus aiheeseen liittyvästä kirjallisuudesta ja tutkimuksista. Osa tiedonhauilla saaduista tutkimuksista arvioitiin ja analysoitiin kahdestaan ja osa itsenäisesti. Lähdekriittisyys on kuvailevassa kirjallisuuskatsauksessa esillä ja sen kautta valitsimme aineiston aineistokeruussa. Aineistokeruusta aineistoksi päätyneiden valintaprosessi on kuvailtu liitteessä 1. Kuvaileva kirjallisuuskatsaus on hyvin perusteltu ja aiheellinen, kun siinä käsitellyt aineistot analysoidaan.

## 8.3. Eettisyys

Tutkimuksen suorittaminen hyvän tieteellisen käytännön mukaisesti saadaan tutkimukselle eettisesti luotettava ja hyväksyttävä status sekä uskottavat tulokset. Tiedeyhteisön tunnustamia toimintatapoja ovat rehellisyys, huolellisuus, tarkkuus tutkimustyössä sekä tulosten tallentamisessa, esittämisessä ja arvioinnissa. Tutkimusta tehdessä tulee tiedeyhteisön noudattamia toimintatapoja noudattaa. Tiedonhankinta-, tutkimus-, ja arviointimenetelmiä sovelletaan tieteellisen tutkimuksen eettisesti

kestävällä ja kriteerien mukaisella tavalla. Muiden tutkijoiden työ ja saavutukset otetaan huomioon ja kunnioitetaan heidän tekemää työtä. Tutkimuksen suunnittelu, toteutus ja raportoidaan tieteelliselle tiedolle asetettujen vaatimusten mukaisesti. Työ toteutettiin kirjallisuuskatsauksena, eikä tutkimuslupia näin ollen tarvinnut hakea. (TENK 2012.)

#### 8.4. Oma ammatillinen kehittyminen

Opinnäytetyön prosessi meidän kohdallamme alkoi 2018 keväällä aiheen valinnalla ja jatkui suunnitelman työstämisellä saman vuoden syksyllä. Kirjallisuuskatsaus valikoitui menetelmäksi ottaen huomioon aiheen, mitä opinnäytetyössä käsittelemme. Koko prosessin aikana kävimme työpajoissa, jotka liittyivät opinnäytetyön tekoon jollakin osa-alueella. Lisäksi kävimme keskeneräisen opinnäytetyön kanssa sovituissa ohjausajoissa, joissa saimme ohjausta opinnäytetyötä ohjaavilta opettajilta. Teoriaa aiheesta löytyi enemmän, kuin tarpeeksi ja aiheen rajaaminen oli välttämätöntä. Aiheen rajauksesta huolimatta löytyi suoritetusta tiedonhausta runsaasti tutkimuksia, jotka käsitelivät taikka sivuuttivat opinnäytetyössä käsiteltävää aihetta. Opimme paljon uutta varsinkin, kun kyseinen aihe ei kenellekään ole täysin selkeä. Molempien yleinen kiinnostus aihetta kohti helpotti opinnäytetyön tekemistä kokonaisvaltaisesti ja olimme molemmat tyytyväisiä työn lopputulokseen.

Tutkimusmenetelmänä kuvaileva kirjallisuuskatsaus oli molemmille kohtalaisen uutta, vaikka olimme aikaisemmissa opinnoissa työskennellyt projektien parissa. Tiedonhaku sekä löydettyjen tutkimusten käsittely ja analysointi veivät eniten aikaa opinnäytetyön prosessista. Kuvailevan kirjallisuuskatsauksen kautta käsitelimme aineistoa kriittisesti ja poimimalla tutkimuskysymyksiin olennaiset tutkimukset mukaan. Opimme syvällisemmin lähdekriittisyyttä tutkimusmenetelmän kautta, tiedonhaku oli molemmilla jo entuudestaan hallussa. Kaikki löydetty tutkimukset olivat englannin kielellä kirjoitettuja, mutta tästäkään ei meille koitunut ongelmaa. Opinnäytetyötä tehdessä olemme oppineet ja pohtineet paljon tekoälystä ja aiheista sen ympärillä. Työskennellessämme olemme aina lukeneet toistemme tekstejä ja vielä tarvittaessa näyttäneet työtä ulkopuoliselle henkilölle, mikäli koimme sokaistumista omalle työllemme.

#### 8.5. Jatkotutkimus- ja kehittämis ehdotukset

Opinnäytetyön aihe rajattiin natiivikuvantamiseen ja mammografiaan, mutta tekoälylle löytyi käyttöä myös muista modaliteeteista. Esimerkiksi 50% tekoälyyn ja kuvantamiseen

koskevista julkaisuista keskittyä magneetti- ja tietokonetomografiakuvauksiin liittyviin tekoälysovelluksiin (Pesapane ym. 2018). Tekoälyä voitaisiin hyödyntää myös älykkäissä potilastietojärjestelmissä (Tenhunen ym. 2018.)

Opinnäytetyömme ei myöskään keskittynyt laajoihin laillisiin tai eettisiin ongelmiin koskien tekoälyn käyttöä, näitä kysymyksiä tulisi myös pohtia ennen, kuin tekoälyä voidaan hyödyntää laajemmin terveydenhuollossa tai kuvantamisessa.

Tekoälyn käytön yhteydessä myös olisi hyvä pohtia tekoälyn pimeämpää puolta tarkemmin, sillä tekoälyn avulla on myös mahdollista muokata röntgen- ja tietokonetomografiakuva lisäämällä keinotekoisia poikkeamia. Tekoälyn ja laitteiden kehittyessä myös laitteiden fyysistä ja digitaalista turvaamista tulisi pitää silmällä mahdollisten murtojen vuoksi (Mirsky – Mahler – Shelef – Elovici. 2019.)

Löytämämme tutkimukset keskittyivät lähinnä radiologeille tarkoitetuista aputyökaluista. Tekoälyn käyttöä voisi myös pohtia röntgenhoitajan työhön tarkistamaan esimerkiksi hyvän kuvan kriteereitä, kuvan laatua ja puolenmerkkien varmistusta. Tällaisilla röntgenhoitajille suunnatuilla työkaluilla kuvien laatu ja röntgenhoitajien ammattitaito voisi kasvaa ja kehittyä. Hyvien kuvien määrän kasvaessa myös tekoälylle voisi tulevaisuudessa olla enemmän laadukasta opetusdataa.

Suomessa otetaan vuosittain vuoden 2015 tilastojen mukaan keuhkokuvia 1 040 000 ja mammografiakuvia 356 000 (Röntgentutkimukset. 2015. STUK.) Näiden tutkimusten hinnat HUS kuvantamisen hinnaston mukaan ovat 37€ ja 75€ (Hinnasto. 2019.) Erilaisten tekoälyyn pohjautuvien sovellusten implementointi voisi mahdollisesti laskea näitä kustannuksia (Pesapane ym. 2018; Tenhunen – Hirvonen – Linna – Halminen – Hörhammer. 2018.)

## Lähteet

AI And Healthcare: A Giant Opportunity. 2019. Forbes Media LLC. Verkkodokumentti. <<https://www.forbes.com/sites/insights-intelai/2019/02/11/ai-and-healthcare-a-giant-opportunity/#2dd617d64c68>>. Luettu 25.3.2019.

Amodei, Dario – Hernandez, Danny 2018. AI and Compute. OpenAI. Verkkodokumentti <<https://blog.openai.com/ai-and-compute/>>. Luettu 25.01.2019.

Aveyard, Helen. 2014. Doing a Literature Review in Health and Social Care: A Practical Guide. London: Open University Press.

Bandeira, Diniz João Otávio – Bandeira, Diniz Pedro Henrique – Azevedo, Valente Thales Levi – Corrêa, Silva Aristófanés – de Paiva, Anselmo Cardoso – Gattass, Marcelo. 2018. Detection of mass regions in mammograms by bilateral analysis adapted to breast density using similarity indexes and convolutional neural networks. Verkkodokumentti. Luettu 20.03.2019.

Baum, Seth. 2017. A Survey of Artificial General Intelligence Projects for Ethics, Risk, and Policy. Global Catastrophic Risk Institute Working Paper 17-1.

Berlinski, David. 2000. The Advent of the Algorithm. Harcourt Books.

Chen, Sheng – Suzuki, Kenji. 2012. Computerized detection of lung nodules by means of "virtual dual-energy" radiography. Verkkodokumentti. Luettu 15.03.2019.

Chunli, Qin. – Demin, Yao. – Yonghong, Shi. – Zhijian, Song. 2018. Computer-aided detection in chest radiography based on artificial intelligence: a survey. BioMed Central Ltd. Verkkodokumentti. <<https://biomedical-engineering-online.biomedcentral.com/articles/10.1186/s12938-018-0544-y>>. Luettu 23.2.2019.

Coughlan, Michael – Cronin, Patricia. 2016. Doing a Literature Review in Nursing, Health and Social care. London: SAGE Publications Ltd.

Deng, Li – Dong, Yu. 2014. Deep Learning: Methods and Applications.

Goldberg, Yoav. 2017. Neural Network Methods in Natural Language Processing. Morgan & Claypool.

Griewank, Andreas 2012. Who invented the reverse mode of differentiation? Optimization Stories, Documenta Mathematica, Extra Volume ISMP.

Hinnasto. 2019. HUS Kuvantamisen hinnasto 2019 sairaanhoitoalueet ja kunnat. Verkkodokumentti. <<http://www.hus.fi/ammattilaiselle/hus->

kuvantaminen/Hinnastot/HUS%20-alueen%20hinnasto%202019.pdf>. Luettu 30.03.2019.

Homerus – Lattimore, Richmond (käänt.) 1951. The Iliad. The university of Chicago press.

Hosny, Ahmed – Parmar, Chintan – Quackenbush, John – Schwartz, Lawrence H. – Aerts, Hugo J. W. L. 2018. Artificial intelligence in radiology. National Center for Biotechnology information, U.S. National Library of Medicine. Verkkodokumentti. < <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6268174/>>. Luettu 25.3.2019.

Jung, Hwejin – Kim, Bumsoo – Lee, Inyeop – Yoo, Minhwan – Lee, Junhyun – Ham, Sooyoun – Woo, Okhee – Kang, Jaewoo. 2018. Detection of masses in mammograms using a one-stage object detector based on a deep convolutional neural network. Verkkodokumentti. Luettu 20.03.2019.

Kim, Eun-Kyung – Kim, Hyo-Eun – Han, Kyunghwa – Kang, Bong Joo – Sohn, Yu-Mee – Woo, Ok Hee – Lee, Chan Wha. 2018. Applying Data-driven Imaging Biomarker in Mammography for Breast Cancer Screening: Preliminary Study. Verkkodokumentti. Luettu 20.03.2019.

Kim, Tackeun – Heo, Jaehyuk. –Jang, Dong-Kyu – Sunwoo, Leonard. – Kim, Joonghee. – Lee, Kyong Jon – Kang, Si-Hyuck – Park, Sang Jun – Kwon, O-Ki – Oh, Chang Wan. 2018. Machine learning for detecting moyamoya disease in plain skull radiography using a convolutional neural network. Verkkodokumentti. Luettu 15.03.2019.

Kooi, Thijs – Karssemeijer, Nico. 2017. Classifying symmetrical differences and temporal change for the detection of malignant masses in mammography using deep neural networks. Verkkodokumentti. Luettu 20.03.2019.

Lakhani, Paras. 2017. Deep Convolutional Neural Networks for Endotracheal Tube Position and X-ray Image Classification: Challenges and Opportunities. Verkkodokumentti. Luettu 15.03.2019.

Lopes, U.K. – Valiati, J.F. 2017. Pre-trained convolutional neural networks as feature extractors for tuberculosis detection. Verkkodokumentti. Luettu 15.03.2019.

Maslow, Abraham Harold. 1954. Motivation and Personality. New York, NY: Harper.

McCarthy, J. – Minsky, M. L. – Rochester, N. – Shannon, C.E. 1955. A proposal for the Dartmouth summer research project on artificial intelligence.

Mirsky, Yisroel – Mahler, Tom – Shelef, Ilan – Elovici, Yuval. 2019. CT-GAN: Malicious Tampering of 3D Medical Imagery using Deep Learning.

Mohammed, Aly A. – Berg, Wendie A. – Peng, Hong – Luo, Yahong – Jankowitz, Rachel C. – Wu, Shandong. 2018. A deep learning method for classifying mammographic breast density categories. Verkkodokumentti. Luettu 20.03.2019.

Menon, Sumi. 2018. How Artificial Intelligence is Changing the Healthcare Industry. Cabot Technology Solutions Inc. Verkkodokumentti. <<https://www.cabotsolutions.com/how-artificial-intelligence-is-changing-the-healthcare-industry>>. Luettu 25.3.2019.

Mohri, Mehryar – Rostamizadeh, Afshin – Talwalkar, Ameet. 2012. Foundations of Machine Learning. The MIT Press.

Olczak, Jakub – Fahlberg, Niklas – Maki, Atsuto – Razavian, Ali – Jilert, Anthony – Stark, André – Sköldenberg, Olof – Gordon, Max. 2017. Artificial intelligence for analyzing orthopedic trauma radiographs Deep learning algorithms—are they on par with humans for diagnosing fractures? Verkkodokumentti. Luettu 15.03.2019.

Okumura, Eiichiro – Kawashita, Ikuo – Ishida, Takayuki. 2011. Computerized analysis of pneumoconiosis in digital chest radiography: effect of artificial neural network trained with power spectra. Verkkodokumentti. Luettu 15.03.2019.

Okumura, Eiichiro – Kawashita, Ikuo – Ishida, Takayuki. 2017. Computerized Classification of Pneumoconiosis on Digital Chest Radiography Artificial Neural Network with Three Stages. Verkkodokumentti. Luettu 15.03.2019.

Pesapane, Filippo – Codari, Marina – Sardanelli, Francesco. 2018. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. National Center for Biotechnology information, U.S. National Library of Medicine. Verkkodokumentti. <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6199205/>>. Luettu 20.3.2018.

Ragab, Dina A. – Sharkas, Maha – Marshall, Stephen – Ren, Jinchang. 2019. Breast cancer detection using deep convolutional neural networks and support vector machines. Verkkodokumentti. Luettu 20.03.2019.

Rajkomar, Alvin. – Lingam, Sneha. – Taylor, Andrew G. – Blum, Michael – Mongan, John. 2017. High-Throughput Classification of Radiographs Using Deep Convolutional Neural Networks. Verkkodokumentti. Luettu 15.03.2019.

Ribli, Dezső – Horváth, Anna – Unger, Zsuzsa – Pollner, P Péter – Czabai, István. 2018. Detecting and classifying lesions in mammograms with Deep Learning. Verkkodokumentti. Luettu 20.03.2019.

Russel, Stuart J. – Norvig, Peter. 2016. Artificial Intelligence. A Modern Approach. 3rd ed.

Röntgentutkimukset. 2015. STUK. Verkkodokumentti. <<https://www.stuk.fi/aiheet/sateily-terveydenhuollossa/rontgentutkimukset>>. Luettu 30.03.2019.

Sarle, Warren. 2002. Neural Network FAQ. Verkkodokumentti. <<ftp://ftp.sas.com/pub/neural/FAQ.html>>. Luettu 04.04.2019.

Sepandi, Mojtaba – Taghdir, Maryam – Rezaianzadeh, Abbas – Rahimikazerooni, Salar. 2018. Assessing Breast Cancer Risk with an Artificial Neural Network. Verkkodokumentti. Luettu 20.03.2019.

Sun, Yuewen – Li, Litao – Cong, Peng – Wang, Zhentao – Guo, Xiaojing. 2017. Enhancement of digital radiography image quality using a convolutional neural network. Verkkodokumentti. Luettu 15.03.2019.

Tan, Maxine – Pu, Jiantao – Zheng, Bin. 2014. Reduction of false-positive recalls using a computerized mammographic image feature analysis scheme. Verkkodokumentti. Luettu 20.03.2019.

Teare, Philip – Fishman, Michael – Benzaquen, Oshra – Toledano, Eyal – Elnekave, Eldad. 2017. Malignancy Detection on Mammography Using Dual Deep Convolutional Neural Networks and Genetically Discovered False Color Input Enhancement. National Center for Biotechnology information, U.S. National Library of Medicine. Verkkodokumentti. <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5537100/>>. Luettu 19.03.2019.

Tekoäly.info. N.d. Verkkodokumentti <[https://tekoäly.info/tekoaly\\_historia/](https://tekoäly.info/tekoaly_historia/)>. Luettu 24.01.2019.

Tenhunen, Henni – Hirvonen, Petteri – Linna, Miika – Halminen, Olli – Hörhammer, Iiris. 2018. Intelligent Patient Flow Management System at a Primary Healthcare Center – The Effect on Service Use and Costs.

TENK 2012. Hyvä tieteellinen käytäntö ja sen loukkauksien käsitteleminen Suomessa. Tutkimuseettinen neuvottelukunta. Verkkodokumentti. . Luettu 28.3.2018.

Turing, A. M. 1936. On Computable Numbers, with an Application to the Entscheidungsproblem.

Turing, A. M. 1950. Computing machinery and intelligence. Mind 49: 433-460.

Yanardag, Pinar – Cebrian, Manuel – Rahwan, Iyad. 2018. Norman AI-Powered Psychopath. Verkkodokumentti. <<http://norman-ai.mit.edu/>>. Luettu 04.04.2019.

van Ginneken, Bram – Schaefer-Prokop, Cornelia – Prokop, Mathias. 2011. Computer-aided Diagnosis: How to Move from the Laboratory to the Clinic. Verkkodokumentti. <<https://pubs.rsna.org/doi/full/10.1148/radiol.11091710>>. Luettu 20.03.2019.

Wahl, Brian – Cossy-Gantner, Aline – Germann, Stefan – Schwalbe, Nina R. 2018. Artificial intelligence (AI) and global health: how can AI contribute to health in resource-poor settings? National Center for Biotechnology information, U.S. National Library of Medicine. Verkkodokumentti. <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6135465/>>. Luettu 23.3.2019.

### Liite 1. Aineiston haku tietokannoista

Tehdyt haut ja hakusanat, vuodet rajasimme 2010-2019.

#### Cinahl #1

artificial intelligence TI" OR "neural network\* TI" AND "mammography

#### Cinahl #2

Artificial intelligence TI" OR "neural network\* TI" AND "radiography

#### Pubmed #1

"artificial intelligence [Title/Abstract]" OR "neural network\* [Title/Abstract]" AND "radiography [Title/Abstract]"

#### Pubmed #2

"artificial intelligence [Title/Abstract]" OR "neural network\* [Title/Abstract]" AND "mammography [Title/Abstract]"

Tulokset 277  
Cinahl #1 – 110  
Cinahl #2 – 105  
PubMed #1 - 17  
PubMed #2 - 49

otsikoiden perusteella valitsimme  
Cinahl #1 – 13  
Cinahl #2 – 2  
PubMed #1 - 9  
PubMed #2 - 20

Abstraktin ja tekstin perusteella  
valitsimme  
Cinahl #1 - 6  
Cinahl #2 - 2  
PubMed #1 – 9  
PubMed #2 - 10

Päällekkäislöydöksiä vuoksi karsimme  
cinahl tietokannasta löydetyistä hauista 4  
tutkimusta vielä pois, koska olimme  
löytäneet ne jo PubMedistä. Cinahl  
hakutulokset olivat siis  
Cinahl #1 – 2  
Cinahl #2 - 1

Lopulliseen analyysiin kaikkien  
sisäänottokriteerin jälkeen olivat yhteensä 22  
tutkimusta.  
Cinahl #1 – 1 PubMed #1 - 9  
Cinahl #2 – 1 PubMed #2 - 11

## Liite 2. Tutkimusaineiston analyysitaulukko

Tekijä(t), vuosi, maa	Tarkoi- tus / Hyöty k uvantamiseen	Kohderyhmä/Otos	Aineis- ton keruu ja anal ysointi	Tulokset
Chunli ym. 2018. Kiina.	THX- alue. Luusuppr essio. Tautien t unnistaminen/lu okittelu.	Yhteensä 19365 THX-kuvaa (PA/AP ja LAT).	Aineisto kerättiin 6 eri julkisesta tietok annasta (India (India na, KIT, MC, JSRT, Shezhen). Ku via esikäsiteltiin ja segmentoitiiin.	Tekoäly kykenee tunnistamaan yksittäisi ä sekä useampia poikkeavuuksia kuvist a. Luusupressio paransi tuloksia.
Lopes, Valiati. 2017. Brasilia.	Tuberku- loosin tunnistam inen.	Yhteensä 1106 PA/AP kuvaa.	Aineisto kerättiin 4 eri tietokannasta ( Mont gomery, Shenzhen, DA ja DB). Kuvia esikäsite ltiin ja segmentoitiiin.	Tekoäly kykenee tunnistamaan TB:n. Es iopetetut tekoälyt mahdollisesti hyödyllin en vaihtoehto laskentaintensiiviselle ja aikaa kuluttavalle spesifiselle tekoälyll e.
Lakhani. 2017. USA.	Endotrakeaalise n putken olema ssaolon ja paikan tarkas telu. Eri tekoälyi mplementaatioi den vertailu.	Yhteensä 720 kuvaa. THX-kuvia 600, joissa 150/150 ET/ET puuttui. 150/1 50 jossa ET paikka hyvä/liian alhainen. 120, joista 60/60 THX/vatsa- alue	Aineisto kerättiin Thomas Jeffersonin yliopistollisen sairaal an PACS- järjestelmästä. Kuva t luokiteltiin opetusd ataksi, validaatio ja t estidataksi. Matalan/ normaalin ET- putken paikan kuvia rajattiin manuaalies ti.	Eri implementaatiot tunnistivat helposti e rot THX-kuvat ja vatsa- alueen kuvat erilleen. ET- putken olemassaolo todettiin parhaiten e siopetetuilla tekoälyillä (0.989, 0.856). Matalan tai normaalin putken paikan erottelu oli t ekoälylle vaikein.
Oku- mura ym. 2011 . Japani.	Pneumo- konioosin tun- nistam inen THX- kuvasta.	11 normaalia ja 12 e pänormaalaa PA- kuvaa, joista valittiin molem mista yhteensä 112 k iinnostavaa aluetta.	Normaalit kuvat valit tiin satunnaisesti JS RT:n tietokannasta. Poikkeavat valittiin s atunnaisesti Ministry of Laborin ylläpitämäst ä tietokannasta. Nor maalit kuvat varmist ettiin TT- tutkimuksella.	Sääntöihin ja hahmon tunnistukseen perustuva ANN hyödylline n työkalu PS tunnistamiseen. Luokittelun tehokku uteen vaikutti suuresti väärät negatiivise t tulokset sääntöpohjaisessa menetelmä ssä. Vaaditaan lisää CAD- systemien kehitystä.
Okumura ym. 2017. Japani.	Pneumo- konioosin tun- nistam inen THX- kuvasta.	Yhteensä 55 PA- kuvaa, joista 9 normaaleja, 20 luo kka 1, 15 luokka 2 ja 11 luokka 3	Kuvat hankittiin Mini stry of Labor ja ILO- tietokannoista. Kuvi sta valittiin manuaali sesti 100- 1200 kiinnostavaa al uetta poikkeavista ja normaaleista alueis ta.	Tekoäly onnistui suhteellisen hyvin luoki ttelemaan pneumokonioosin vaikeuaste en luokkiin 0-3.
Chen, Su- zuki. 2012. Ki- ina.	Noduulien havai tseminen THX- kuvista tekoälyn ja VDE (Virtual dual energy) avulla.	Yhteensä 300 kuvaa, joissa keuhkoalueen löydöksiä. 100 norm aalaa kuvaa.	Kuvat kerättiin 6 eri lähteestä. Poikkeavuudet varm istettiin CT- tutkimuksella. Tekoälyä testattiin	Tekoälyn avulla toteutettu monienergiak uva auttoi havaitsemaan noduuleja pare mmin, mutta joissain tapauksissa tasoitti vaikeasti havaittavia noduuleja. Norma alin ja VDE- kuvan yhdistäminen tekoälyyn paranti t

			JSRT-tietokannan kuvilla.	unnistettavuutta. Yhden tapauksen käsittely vei 115s systeemiltä.
Kim ym. 2018. Korea.	Moyamoya taudin diagnosointi normaalia päänröntgenkuvasta.	Yhteensä 436 sopivaa potilasta moyamoya diagnoosilla. Tutkimuksen kontrollissa käytettiin sopivia pääntraumakuvia.	Tutkimukseen etsittiin 18-50 molemminpuoleisesti diagnosoituja moyamoya potilaita. Yksipuoleinen MMD. Kontrolliryhmään valittiin samasta ikäluokasta pääntraumakuvia.	Normaaleja kallokuvia ei käytetä MMD diagnosointiin normaalisti, koska uskotaan ettei niistä näe taudille ominaisia merkkejä. Tekoäly kuitenkin löysi onnistuneesti MMD ominaisia merkkejä normaaleista kallokuvista.
Rajko-mar ym. 2017. USA.	Tutkimuksella pyrittiin selvittämään voiko tekoälyn avulla suorittaa kliinisesti merkityksellisiä kuvialuokituksia vähäisellä määrällä (THX)rtg-kuvia. Tekoäly luokitteli kuvia PA/AP ja LAT.	Yhteensä 1885 kuvaa 909 potilaasta. Opetus: 1129, validaatio: 376 ja testi: 377. Opetus/validaatio kuvia augmentoituihin, josta saatiin opetus: 119674 ja validaatio: 39856.	Kuvat kerättiin UCSF PACS-järjestelmästä. Tekoäly esiovetettiin ImageNetin kuvilla (Ei radiologisia). RTG-opetuskuvilla paranneltiin tekoälyn toimintaa.	Tekoäly pystyttiin opettamaan kuvien luokitus PA/AP ja LAT suuntiin, ilman suurta määrää radiologisia kuvia. Kuvien luokittelu oli nopeaa. Luokittelu oli nopeaa (38 kuvaa/s). Tekoälyn opettaminen muilla, kuin radiologisilla kuvilla mahdollista.
Olczak ym. 2017. Ruotsi.	Tutkimuksella pyrittiin selvittämään tekoälyn käyttöä ortopedisissä kuvauksissa tunnistamaan murtumia, kehon osia sekä lateraalisuutta.	Yhteensä 256000 kuvaa käsistä, ranteista ja nilkoista. 4 luokkaa: murtuma, lateraalisuus, projektiio ja kehon osa.	Kuvat kerättiin Danderydin sairaalan PACS-järjestelmästä. Kuvia rajattiin ja skaalattiin.	Tekoäly kykeni tunnistamaan murtumia ja luokittamaan kuvia kuvanlaadusta huolimatta (rajaus/skaalaus). Tekoälyn luokitteli kohteen puolen (vasen/oikea) yllättävän hyvin vaikka kuvia peilattiin satunnaisesti, kuvissa mahdollisesti pieniä merkkejä puolesta perustuen luuston rakenteisiin, jota ihminen ei havaitse.
Sun ym. 2017. Kiina.	Kuvanlaadun parantaminen tekoälyn avulla.	Yhteensä 80 kuvaa kolmesta luokasta.	Korkealaatuisia kuvia käsiteltiin huonontamalla niiden laatua. Datan ylisovittamista kuvilla augmentoituihin pyrittämällä ja peilaamalla.	Tekoälyn avulla kyettiin parantamaan kuvanlaatua ja vähentämään kohinaa huonolaatuisissa kuvissa.
Teare ym. 2017. USA.	Automaattinen itseenäinen työkalu positiivisiin ja negatiivisiin löydöksiin tekoälyn avulla. (false color, CLAHE)	Yli 7500 kuvaa tasaisesti positiivisten ja negatiivisten löydösten kanssa.	Kuvat DDSM ja ZMDS tietokannoista, positiiviset löydökset vahvistettiin biopsioilla ja negatiiviset vahvistettiin 2 vuoden tarkistus kuvilla.	Tekoäly kykeni samoihin tai parempiin tuloksiin, kuin radiologi.
Ragab ym. 2019. Egypti/UK.	Rinta-syövän havaitseminen tekoälyn avulla.	Yhteensä 2620 kuvaa (normaali, benigni, maligni)	Kuvat saatiin DDSM CBIS-DDMS tietokannoista. Pienen kuvamäärän takia kuvia augmentoituihin lisäämään kuvien määrää.	Tutkimuksessa esitetty tekoäly kykeni huomaamaan kuvista poikkeavuuksia ja mikrokalsifikaatioita.

Shenbaga-valli, Thangarajan. 2018. Intia.	Rintasyövän havaitseminen tekoölyn ja shearlet muunnoksen avulla.	300 kuvaa, joista 100 normaaleja, 100 beningejä ja 100 maligneja.	Kuvat DDSM tietokannasta. Kuville shearlet muunnos ja manuaalinen rajaus.	Tekoöly onnistui luokittelemaan malignit ja beningit löydökset. Shearlet muunnos kuville tehosti tekoölyn toimintaa.
Jung ym. 2018. Korea.	Abnormaalien massojen löytäminen rinnoista tekoölyn avulla.	632 kuvaa, joista 227 sisälsi massoja.	INbreast 410 kuvaa Porton S. João sairaalasta. 222 kuvaa Korean yliopistollisesta Guro sairaalasta.	Massan tunnistaminen tekoölyllä onnistui korkealla onnistumisprosentilla ja alhaisilla väärillä tuloksilla.
Se-pandi ym. 2018. Iran.	Tekoölyn käyttö rinta-syövän riskiarvioinnissa.	665 naista, joista 196 malignia ja 459 beningiä.	Maligniteetti varmistettiin patologisesti	Rintasyövän riskiä pystyttiin arvioimaan tarkasti tekoölyn avulla käyttäen potilastietoja/kertomusta ja mammografisia ominaisuuksia.
Ribli ym. 2018. Unkari.	Leesioiden tunnistaminen ja luokittelu mammografioista.	Yhteensä 3582 kuvaa 3 eri lähteestä.	2620 kuvaa DDSM kannasta pelkästään opetuksen, 847 kuvaa Semmelweisin yliopistosta ja 115 INbreast kannasta.	Tutkimuksen tekoöly onnistui luokittelemaan malignit leesiot INbreast kannasta 90%, 0.3 väärää positiivista per kuva.
Bandeira Diniz ym. 2018. Brasilia.	Massa-alueiden tunnistaminen automaattisesti mammografia kuvista.	1241 kuvaa, joista 502 non-dense ja 739 dense	2500 tutkimusta ostettu Massachusetts general hospital, Wake Forest university ja St. Louis medical school. Yksi tutkimus sisälsi 1-4 kuvaa. Kuvan piti sisältää massaleesio, muut leesiot ei otettu tutkimukseen mukaan.	Tutkimuksessa esitely menetelmä luokitteli tiheet rinnat 97.72% ja epätiheet rinnat 95.6% tarkkuudella. Tiheästä rinnasta massan tunnistus 94.8% ja epätiheästä rinnasta 91% tarkkuudella.
Kim ym. 2018. Korea.	Datapohjaisen biomarkkerin käyttö mammografioissa tekoölyn avulla.	Yhteensä 29107, joista 4339 syöpätapausta ja 24768 normaaleja. 1238 tapausta validointiin ja 1238 tapausta testattiin.	Kuvat saatiin 5 eri instituutiosta. Potilaiden iät, rintatiheydet ja laitteisto yhteensovitettiin, joista saatiin 1238 validointi ja 1238 testi dataksi. Loput kuvista opetus dataksi.	Tekoöly onnistui tunnistamaan hyvällä tarkkuudella tunnistamaan leesioita mammografioista. Tekoölyn opetuksessa ei käytetty apuna leesioiden annotaatioita vaan tekoöly opetettiin puhtaasti kuvien perusteella ilman ihmisen lisäämää annotaatioita.
Mohammed ym. 2018. USA.	Tekoölyn käyttö rinnan tiheyden luokittelussa mammografian avulla.	22000 kuvaa, joista 7925 kuvassa homogeeninen tiheys ja 14075 kuvaa, joissa heterogeeninen parrenkyymi.	Retrospektiivinen tutkimus. Kuvat peräisin mammografia seulonnoista ja tutkimuksen kirjoitushetkellä potilaille ei ollut diagnosoitu rintasyöpää.	Tekoöly kykeni luokittelemaan seulontakuvista hetero- ja homogeeniset tiheydet.
Kooi, Karssemeijer. 2017. Alankomaat.	Pahalaatuisen leesioinnin tunnistaminen pehmytkudoksesta mammografiassa tekoölyn avulla,	18366 tapausta, joista jokainen sisältää yhden tai useamman tutkimuksen 2 vuoden	Kuvat kerätty Hollannissa suoritetuista mammografia seulonnoista. Kuvista 65% meni opettamiseen,	Tekoölyn kykyä diagnosoida massoja mammografioista parani, jos tekoölylle syötettiin symmetristä ja temporaalista informaatiota mammografioista.

		ajalta, yksi tutkimus sisältää 4 kuvaa.	15% validointiin ja 25% testaamiseen.	
Tan ym. 2018. USA.	Väärän positiivisen diagnoosin vähentäminen tekoälyn avulla.	1052 potilasta, joista 669 positiivisesti todettua syöpää ja 383 benigniä.	Kuvat otettu aikasemmista samojen tekijöiden tutkimuksista. Jokaiselta potilaalta 2 MLO ja 2 CC kuvaa eli 4x1052.	71.2% tarkkuudella saatiin luokiteltua (755/1052) oikein ja 28.2% (297/1052) luokiteltiin väärin. Syöpä tapauksissa tarkkuus oli 73.4% (491/669) ja benignin tapauksissa tarkkuus oli 68.9% (264/383).

### **Liite 3. Opinnäytetyössä käytettyä sanastoa**

#### **Tekoäly, artificial intelligence, AI**

Koneen tai tietokoneohjelman suorittama toiminto, jota voidaan pitää älykkäänä

#### **Keinotekoinen neuroni, artificial neuron**

Yksittäinen keinotekoinen neuroni, osa suurempaa neuroverkkoa, yksinkertainen prosessori

#### **Neuroverkko, neural network**

Neuroverkko on joukko neuroneita, jotka on kytketty toisiinsa ja jotka kommunikoivat keskenään.

#### **Koneoppiminen, machine learning**

Koneelle tai ohjelmalle ei ole ennalta määritetty ohjeistusta tilanteita varten, vaan kone oppii itsenäisesti saamansa tiedon pohjalta

#### **Valvottu oppiminen, supervised learning**

Kone opetetaan ohjatusti opetusdatalla, eli koneelle annetaan oikea vastaus

#### **Valvomaton oppiminen, unsupervised learning**

Kone tai ohjelma pääättelee itsenäisesti datassa esiintyviä suhteita ja säännönmukaisuuksia

#### **Syväoppiminen, deep learning**

Syväoppiminen on useiden neuroniverkkokerrosten hyödyntämistä ratkaisemaan monimutkaisia ongelmia

#### **Semanttinen verkko, semantic network**

Tiedon esittämisen tapa. Yhdistää käsitteitä ja niiden välisiä semanttisia suhteita

#### **Tietokoneavusteinen tulkinta, Computer aided detection/diagnosis, CAD**

Tietokonepohjainen systeemi auttamaan lääkäreitä kuvien tulkinnassa

#### **Opetus-, validaatio- ja testidata**

Opetusdatalla tekoäly opetetaan, validaatiodatalla tekoälymallin toimintaa tarkennetaan haluttuun suuntaan ja testidatalla tekoälyn toimintaa testataan.