

Opinnäytetyö (AMK)

Tieto- ja viestintäteknikka

2024

Ville Lindfors

# Tekoälyn tulevaisuus ihosyöpien seulonnan tukena



Opinnäytetyö (AMK) | Tiivistelmä

Turun ammattikorkeakoulu

Tieto- ja viestintäteknikka

2024 | 38 sivua

Ville Lindfors

## Tekoälyn tulevaisuus ihosyöpien seulonnan tukena

Opinnäytetyön tavoitteena on luoda ymmärrys tekoälyn ja erityisesti syväoppimisen neuroverkkojen mahdollisuuksista terveydenhuollon sovelluksissa. Opinnäytetyössä perehdytään tekoälyyn ja sen mahdollistamiin konvoluutionaalisiin neuroverkkoihin, joiden avulla kuvantunnistus mahdollistetaan. Esimerkkinä konenäön mahdollisuuksista terveydenhuollossa on ihosyöpiä tarkastavat sovellukset.

Selvityksenä tuotettiin arvio konvoluutionaalisten neuroverkkojen mahdollisuuksista ihomuutosten tarkastamisessa perehtymällä arkkitehtuureihin, joiden avulla tämä operaatio on mahdollista suorittaa parhaimmalla tavalla. Tämän saavuttamiseksi perehdyttiin tutkimuksiin, joissa konvoluutionaaliset neuroverkot ovat suorittaneet ihosyöpien tarkastamista.

Neuroverkkojen arkkitehtuureihin ja toimintaan tutustumalla, luotiin selvitys siitä voidaanko konenäköä käyttää ihosyöpien tarkastamisessa. Selvityksen aikana selville tulleille ongelmille esitettiin ratkaisuja, jotka mahdollistaisivat laajemman konenäön käyttöönoton ihosyöpien seulonnassa. Opinnäytetyössä konenäön käytön uskotaan olevan mahdollista, jos tämänhetkisiin ongelmiin löydetään toimivat ratkaisut.

Asiasanat:

Tekoäly, Koneoppiminen, Syväoppiminen, Neuroverkko, Koneäkö,  
Terveysthuolto

Bachelor's Thesis | Abstract

Turku University of Applied Sciences

Information and Communication Technology

2024 | 38

Ville Lindfors

## The future of artificial intelligence in support of skin cancer detections

The objective of the thesis is to create an understanding of artificial intelligence, particularly deep learning neural networks, and their possibilities in healthcare applications. The thesis explores artificial intelligence and convolutional neural networks, which enable image recognition. As an example of the applications in healthcare, the focus is on applications that examine skin cancers using computer vision.

The investigation produced an assessment of the potential of convolutional neural networks in inspecting skin changes by delving into architectures that facilitate this operation in the most effective manner. To achieve this, research was conducted on studies where convolutional neural networks have examined skin cancers.

By familiarizing oneself with the architectures and functioning of neural networks, an assessment was made regarding whether computer vision can be used in examining skin cancers. Solutions were proposed for the problems identified during the assessment, which would enable broader implementation of computer vision in skin cancer screening. In the thesis, it is believed that the use of computer vision is possible if effective solutions are found for the current problems.

Keywords:

Artificial Intelligence, machine learning, deep learning, computer vision,  
healthcare

# Sisältö

<b>Käytetyt sanastot</b>	<b>8</b>
<b>1 Johdanto</b>	<b>9</b>
<b>2 Tekoäly</b>	<b>11</b>
2.1 Tyypit	12
2.2 Koneoppiminen	13
2.3 Syväoppiminen ja neuroverkot	14
2.4 Yhteenveto	14
<b>3 Konvoluutioneuroverkko konenäön apuna</b>	<b>16</b>
3.1 Mitä on konenäkö?	16
3.2 Toimintaperiaate	16
3.3 Konvoluutio kerrokset	18
<b>4 Konenäkö ihomuutosten tarkastuksissa</b>	<b>23</b>
4.1 Ihomuutosten tarkastus CNN verkkoja käyttäen	24
4.2 Tutkimuksista	25
4.3 Haasteet	28
CNN-verkkojen haasteet ihonmuutosten tarkistuksessa	29
4.3.1 Haasteiden ratkominen	30
4.4 Tulevaisuus	31
<b>5 Johtopäätös</b>	<b>34</b>
<b>Lähteet</b>	<b>36</b>

## Kuvat

Kuva 1. Tekoälyn ryhmä. Perustuu lähteeseen (Choi, et al., 2020)	15
------------------------------------------------------------------	----

Kuva 2. Konvoluution laskeminen (Pietikäinen & Silven)	18
Kuva 3. CNN arkkitehtuuri	19
Kuva 4. Max-pooling operaattori (Pietikäinen & Silven, 2021, p. 89)	20
Kuva 5 Dropout kerroksen toiminta	21
Kuva 6 Ihosyövän tarkastamissysteemi CNN-verkkoa käyttäen (Fu'adah, et al., 2020)	26
Kuva 7 Morfologiset operaatiot, eroosio ja dilaatio (Arneesh & Akhilesh, 2019)	27
Kuva 8 Ihomuutosten seurannan tulevaisuuden näkymät tekoälyn kanssa. Perustuu lähteeseen (N, et al., 2023)	32

## **Taulukot**

Taulukko 1 Tekoälynmääritelmä (Stuart & Norvig, 2023)	11
-------------------------------------------------------	----

## Käytetyt sanastot

CNN	konvoluutioneuroverkko (eng. Convolutional neural network)
FC-kerros	täysin yhdistetty kerros (eng. Fully connected layer)
ReLU	tasasuuntainen lineariinen yksikkö (eng. Rectified linear unit)
RGP	värinmuodostusjärjestelmä, lyhenne sanoista red,green ja blue
Softmax	funktio, jota käytetään usein syväoppimisessa ja erityisesti moniluokkaisten luokitteluongelmien yhteydessä.
TensorFlow	avoimen lähdekoodin ohjelmistokirjasto, joka on kehitetty erityisesti koneoppimisen ja syväoppimisen sovelluksiin.



# 1 Johdanto

Viime vuosina teknologian saralla on tapahtunut huomattavaa edistystä erityisesti tekoälyn ja koneoppimisen kehityksissä. Tekoälyn odotetaan vaikuttavan voimakkaasti yhteiskuntaamme mahdollistaen uudenlaisia ratkaisuja ongelmiin. Sen potentiaali näyttää lupaavalta niin liiketoiminnallisesti kuin tieteellisestikin. (Kolari & Kallio, 2023) Tietotekniikan suuret kehitysloikat viime aikoina ovatkin selvästi vaikuttaneet siihen. Internetin kehitys on avannut mahdollisuuden erittäin suurelle määrälle dataa ja tukenut näin myös tekoälyn tutkimuksia. Tämä on tapahtunut samanaikaisesti, kun tekniikkaa käyttävien laitteistojen kehitys on jatkunut merkittävästi. (Pietikäinen & Silven, 2021)

Teknologian kehityksen takia konenäkö on noussut sovelluksissa tärkeään osaan. Kuvantamisen sovellukset hyödyntävät tekoälyä ja koneoppimista mahdollistaen entistä tarkemman ja tehokkaamman kuvien analysoinnin. Tämä avaa uusia mahdollisuuksia esimerkiksi terveydenhuollon alalla, erityisesti konenäön tarjoamat mahdollisuudet parantaa diagnostiikkaa, nopeuttaa hoitoprosesseja ja optimoida resurssien käyttöä kiinnostavat. Tutkimukset ovatkin osoittaneet tekoälyn mahdollisuudet terveydenhuollossa oikeiksi. Tutkimukset ovat osoittaneet, että yli 80 % terveydenhuollossa tehdyistä virheistä voitaisiin mahdollisesti välttää, jos nämä tehtävät ja toiminnot siirrettäisiin tekoälylle. (Kolari & Kallio, 2023)

Tässä opinnäytetyössä tutkitaan tekoälyä mutta erityisesti konvoluutionaalisten neuroverkkojen mahdollistamaa konenäköä. Opinnäytetyön aihe on kuitenkin rajattu keskittymään konenäön kannalta olennaisiin näkökulmiin, erityisesti konvoluutioneuroverkkojen arkkitehtuuriin. Tutkimuskysymykset liittyvät kuva-analyysisovellusten mahdollisuuksiin, haasteisiin ja rajoituksiin ihosyöpien tarkastussovelluksissa. Lopullisena tavoitteena on selvittää, miten konvoluutioneuroverkkoja (CNN-verkko), joita käytetään konenäön apuna, voidaan hyödyntää tehokkaasti ihosyövän seulonnassa, hyödyntäen olemassa olevia tutkimuksia aiheesta. Tekoälyn aiheuttamiin haasteisiin konenäön

kontekstissa pyritään etsimään ratkaisuja. Opinnäytetyön lopputuloksena syntyy selvitys aiheesta, joka toivottavasti antaa panoksensa terveydenhuollon ja tekoälyn kehitykseen.

## 2 Tekoäly

Tekoäly voidaan määritellä monella eri tapaa. Yhden määritelmien mukaan se on tutkimusta tietokoneiden älykkääksi saamiseksi. Toisen määritelmän mukaan tekoälyssä tutkitaan sellaisia asioita, joiden toteutusta ei vielä tunneta, eli älykkään ja tavallisen koneen välinen raja on näin muuttuva. (Pietikäinen & Silven, 2021)

Yksinkertaisimmillaan tekoäly on ala, joka yhdistää tietojenkäsittelytieteen ja vahvat tietoaaineistot mahdollistaakseen ongelmanratkaisun. Se kattaa myös koneoppimisen ja syväoppimisen alaotsakkeet, jotka mainitaan usein yhdessä tekoälyn kanssa. Nämä tieteenalat koostuvat tekoälyalgoritmeista, jotka pyrkivät luomaan asiantuntijajärjestelmiä, jotka tekevät ennusteita tai luokituksia syöteaineiston perusteella. (IBM, 2023c)

Kirjassa *Artificial Intelligence: A Modern Approach* (Stuart & Norvig, 2023) jaetaan tekoälyn määritelmän neljään erilaiseen luokkaan. (Taulukko 1) Nämä luokat ovat on vielä jaettuna kahtia. Toinen puoli kuvaa ihmisen päättelyä ja ajattelua, kun taas toinen osa kuvastaa henkilöiden toimintaa.

Taulukko 1 Tekoälynmääritelmä (Stuart & Norvig, 2023)

Ajatella ihmisen lailla	Ajatella rationaalisesti
Toimia ihmisen lailla	Toimia rationaalisesti

Tekoäly voidaan siis määritellä monella tavalla eikä selvää jakoa sen määritelmälle ole vielä tähän päiväänkään mennessä keksitty. Osa syynä tähän voi olla tekoälyn laajuus, koska se sisältää paljon ala kategorioita, kuten esimerkiksi koneoppimisen ja syväoppimisen.

## 2.1 Tyypit

Yleisesti ajatellaan, että tekoäly voidaan jakaa sen vahvuuden mukaan kahteen tyyppiin: vahvaan ja heikkoon tekoölyyn. Heikko tekoäly kuvaa tilannetta, jossa ei vielä pystytä luomaan koneita, jotka voivat todella suorittaa päättely- ja ongelmanratkaisutehtäviä. Nämä koneet voivat vaikuttaa älykkäiltä, mutta ne eivät todellisuudessa omaa älykkyyttä eivätkä itsetietoisuutta. Olemme tällä hetkellä heikon tekoälyn aikakaudella. Heikon tekoälyn käyttöönotto vähentää älyllisen työn taakkaa toimimalla eri aloilla asiantuntijoiden apuna. (Huawei Technologies Co., 2023) Esimerkiksi terveydenhuollon alalla tämän tyylinen tekoäly mahdollistaisi taakan vähentämistä sekä lääkäreiltä että muilta terveydenhuollon asiantuntijoilta.

Vahvalla tekoälyllä, joka on tulevaisuudessa mahdollinen, voidaan taas suorittaa haastaviakin päättely- ja ongelman ratkaisutehtäviä. Olettamus on, että nämä koneet ovat tietoisia ja kykenisivät itsenäiseen ajatteluun ja toimivien ratkaisujen löytämiseen. Vahvalla tekoälyllä on myös omat arvot ja maailmankatsomus, ja se on varustettu vaistoin, kuten selviytymisen ja turvallisuuden tarpeilla, aivan kuten kaikilla elävillä olennoilla. (Huawei Technologies Co., 2023)

Supertekoälyn on käsite, joka liittyy siihen vaiheeseen, jossa koneäly ylittää merkittävästi ihmisen älykkyyden. Tämä käännekohta voi toteutua älykkyyden räjähdysten tai teknologisen singulariteetin seurauksena. Supertekoälyn saavuttaminen on lähellä, kun vahva tekoäly, saavuttaa ihmisen älykkyyden tason. Tämän jälkeen se kykenee aktiivisesti keräämään tietoa ja kokemuksia. Singulariteetti muodostuu hetkellä, jolloin tämä edistyksellinen tekoäly alkaa itsenäisesti kehittää entistä monimutkaisempia ja kehittyneempiä ratkaisuja. Tämä käännekohta voi käynnistää nopean kehityksen, jossa tekoäly parantaa itseään eksponentiaalisesti, mahdollisesti ylittäen ihmisen ymmärryksen ja älykkyyden monilla eri aloilla. (Pietikäinen & Silven, 2021, p. 24)

## 2.2 Koneoppiminen

Koneoppiminen on yksi keskeisimmistä tutkimusaloista tekoälyn alueella. Koneoppimisessa tietokoneohjelman suorituskyky tietyllä tehtävällä parantuu kokemuksen myötä. Ohjelma siis oppii kokemuksesta. Ohjelmisto ei kuitenkaan itse pysty hakemaan tärkeitä yksityiskohtia ja kokemuksia halutusta datasta vaan se täytyy kouluttaa koneoppimisalgoritmeja hyväksi käyttäen. Tätä koulutettua tietokoneohjelmaa kutsutaan malliksi. (Huawei Technologies Co., 2023)

Koneoppimisalgoritmit luodaan yleensä kehysratkaisujen avulla, jotka nopeuttavat ratkaisun kehittämistä, kuten TensorFlow, joka tarjoaa avoimen lähdekoodin työkaluja koneoppimisen ja neuroverkkojen toteuttamiseen ja kouluttamiseen. (TensorFlow, 2024)

Yleisesti ottaen koneoppimisalgoritmeja käytetään ennusteen tai luokittelun tekemiseen. Erilaisten syöteaineistojen perusteella, jotka voivat olla merkittäviä tai merkitsemättömiä, algoritmi tuottaa arvion datassa olevasta kaavasta. Päätöksenteossa kone arvioi mitä kaavaa algoritmi on hakemassa. Virhefunktion avulla seurataan, kuinka oikeassa malli oli ja jos malli voi sovitua paremmin koulutusjoukon datapisteisiin. Tämän jälkeen painoja säädellään vähentääkseen eroa tunnetun esimerkin ja mallin arvion välillä. Tätä metodia kutsutaan optimoinniksi. (IBM, 2023)

Tiettyjä tehtäviä olisi erittäin vaikea saavuttaa perinteisellä ohjelmoinnilla. Ohjelmoinnissa vastaan tulisivat säännöt, joiden tulisi vastata haluamamme datajoukon ominaisuuksia. Koneoppimisen tilastollisen lähestymistavan avulla voidaan antaa koneen oppia nämä säännöt automaattisesti näytteiden avulla. Koneoppiminen voi siis oppia monimutkaisia ja vaikeasti kuvailtavissa olevia sääntöjä. (Huawei Technologies Co., 2023)

### 2.3 Syväoppiminen ja neuroverkot

Syväoppiminen on koneoppimisen osajoukko. Se perustuu neuroverkkoihin, jotka jäljittelevät huomattavasti ihmisten omia aivoja. Nämä neuroverkot ovat siis syviä ja monimutkaisia. Sen myötä neuroverkko kerroksia voi olla monia, jopa sata, kun taas ennen näitä kerroksia saattoi olla vain muutama. Tämä rakenne parantaa kerroksien toimintaa mahdollistamalla ensimmäisten kerroksien keskittymisen datan piirteistämiseen ja loppujen kerrosten tehtäväksi jää tuloksen tuottaminen. (Kolari & Kallio, 2023)

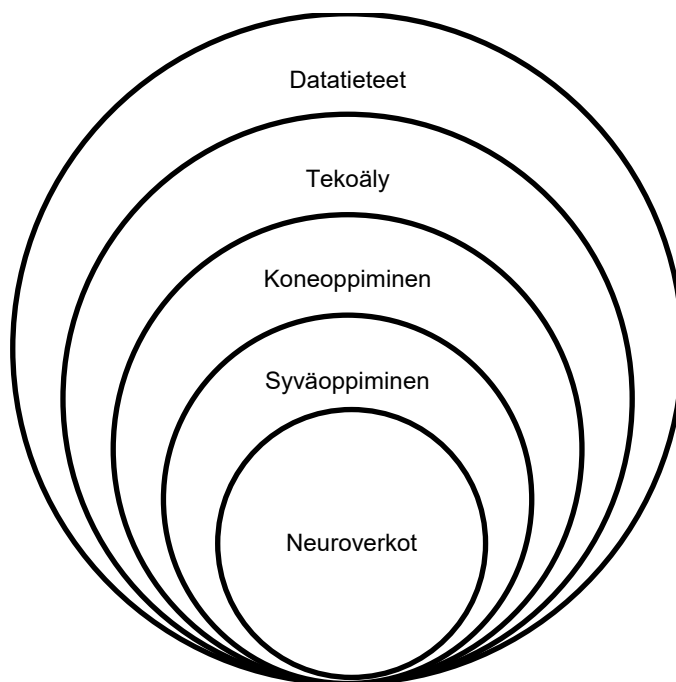
Toiminta vaatii paljon dataa. Tämä data puretaan numeroarvoiksi syötoneuroneihin, josta ne välittyvät porrastetusti toisiin kerroksiin. Yhdistelyjen jälkeen tulosneuronit välittävät oikean lopputuloksen. (Kolari & Kallio, 2023)

Syväoppiminen poistaa datan esikäsittelyn, koska se mahdollistaa epästrukturoidun datan prosessoinnin ja automatisoi piirteiden erottelun taaksepäin suuntautuvan (backpropagation) ja gradientti laskennan kautta. Tämä taas vähentää riippuvuutta ihmisistä, koska syväoppimisalgoritmi säätää näin itse tarkkuuttaan saadakseen oikean lopputuloksen (IBM, 2023b).

Tässä opinnäytetyössä keskitytään erityisesti konvoluutioneuroverkkoihin, koska niiden käyttötarkoitus on juuri konenäössä ja kuvantunnistamisessa. Konvoluutioverkko (CNN) on tekoälyverkkojen luokka, joka on noussut hallitsevaksi erilaisissa tietokoneen näkemisen tehtävissä. CNN on syvän oppimisen malli datan käsittelyyn, joka käyttää hyväkseen ruudukkomaista rakennetta, kuten kuvia.

### 2.4 Yhteenveto

Tekoäly sisältää paljon eri alueita. (Kuva 1). Se lukeutuu siis datatieteisiin mutta pitää sisällään paljon alakategorioita, kuten koneoppimisen, syväoppimisen sekä neuroverkot.



Kuva 1. Tekoälyn ryhmä. Perustuu lähteeseen (Choi, et al., 2020)

Lisäksi koneoppiminen (mukaan lukien syväoppiminen) voitaisiin jakaa edelleen alakategorioihin, kuten ohjattu, ohjaamaton, puolittain ohjattu, ihmistoiminnan kanssa yhteistyössä tapahtuva, riippuen siitä, kuinka paljon käyttäjän vuorovaikutusta on mukana. (Jones & Strange, 2023) Tämän takia tekoälyn selittäminen onkin niin hankalaa.

Tekoälyn määrittelyistä riippumatta sen viimeaikainen kehitys perustuu kuitenkin syväoppiviin neuroverkkoihin, jotka pystyvät luokittelemaan automaattisesti kuvassa olevia kohteita, tunnistamaan puhetta. Syvät neuroverkot pystyvät tekemään ennustuksia opettamiseen kerättyjen esimerkinäytteiden avulla. (Pietikäinen & Silven, 2021)

## 3 Konvoluutioneuroverkko konenäön apuna

### 3.1 Mitä on konenäkö?

Konenäkö on tietojenkäsittelytieteen ala, joka keskittyy ihmisen näköjärjestelmän monimutkaisuuden osittaiseen jäljentämiseen ja tietokoneiden kyvyn parantamiseen tunnistaa ja käsitellä kohteita kuvissa ja videoissa samalla tavalla kuin ihmiset tekevät. Muutamia vuosia sitten konenäkö toimi vain rajoitetusti. (Mihajlovic, 2019)

Se toimii hyvin samalla tavalla kuin ihmisen näkökyky käyttäen kuitenkin apunaan dataa ja algoritmeja apunaan, ihmisen näköhermostojen sijasta. (IBM, 2023) Tekoälyn edistysaskeleen, syvänoppimisen sekä neuroverkkojen innovaatioiden vuoksi ala on viime vuosina ottanut suuria harppauksia ja kyennyt jopa ylittämään ihmisen suorituskyvyn joissain kohteiden tunnistamiseen ja merkitsemiseen liittyvissä tehtävissä. Yksi konenäön kasvun ajureista on se suuri datan määrä, joka tuotetaan nykyään ja jota käytetään hyväksi konenäön kouluttamisessa ja parantamisessa. (Mihajlovic, 2019)

Konenäön tehtäviä ovat muun muassa kuvienluokittelu, jonka tarkoituksena on selvittää, mihin luokkaan kuva kuuluu. Lisäksi konenäöllä voidaan suorittaa kohteen havaitsemista, jonka avulla voidaan huomata vaurioita tai muita haluttuja yksityiskohtia. Myös kohteen seuranta kuuluu normaaleihin konenäön tehtäviin. (IBM, 2023d)

### 3.2 Toimintaperiaate

Konenäkö vaatii paljon dataa. Se suorittaa analyysia datalla yhä uudelleen ja uudelleen, kunnes se erottaa eroavaisuudet ja tunnistaa lopulta kuvia. (IBM, 2023d) Konenäkö on tietyllä tasolla kaiken kaikkiaan kuviohahmontunnistusta. Joten yksi tapa kouluttaa tietokonetta ymmärtämään visuaalista dataa on syöttää sille kuvia, jos mahdollista tuhansia, jotka on merkitty. Altistamalla ne erilaisille algoritmeille, mahdollistetaan tietokoneen tunnistaa kuvioita kaikissa




niissä elementeissä, jotka liittyvät näihin merkintöihin. (Mihajlovic, 2019). Tämän saavuttamiseksi käytetään CNN-neuroverkkoja

CNN-verkko auttaa koneoppimis- tai syvää oppimismallia "näkemään" jakamalla kuvat pikseleiksi, joille annetaan tunnisteita tai merkintöjä. Termi "Convolution" CNN:ssä viittaa konvoluution matemaattiseen funktioon, joka on erityinen lineaarinen operaatio, jossa kaksi funktiota kerrotaan tuottaen kolmannen funktion. Tämä kolmas funktio kuvaa, miten toisen funktion muoto muuttuu toisen vaikutuksesta. Kaksi kuvaa, jotka voidaan esittää matriiseina, kerrotaan keskenään, ja tuloksena olevaa arvoa käytetään piirteiden erottamiseen kuvasta. (Gurucharan, 2022) Neuroverkko suorittaa konvoluutioita ja tarkistaa ennusteidensa tarkkuuden iteraatioiden sarjassa, kunnes ennusteet alkavat toteutua.

Lähekkäiset pikselit ovat vahvasti korreloivia kuvissa. Niihin liittyvät tiedot saadaan hyödynnettyä CNN-verkoilla. Verkot pyrkivät oppimaan konvoluutiot, jotka karakterisoivat parhaiten syötteitä. Ne voivat myös erotella eri kategorioita toisistaan. Tämä koulutus tapahtuu näytteillä, jotka edustavat haluttua kohdetta parhaiten. (Pietikäinen & Silven, 2021, p. 59)

Kuvassa 2 konvoluutio on laskenut ensimmäiseksi arvoksi konvoluutiotuloksen vasempaan ylänurkkaan piirre-arvon -10, joka tässä tapauksessa jotenkin karakterisoi kuvassa olevaa paikallista gradienttia. Konvoluutiot pyrkivät oppimisen tuloksena tuottamaan erityisesti reunoihin, harjanteisiin ja nurkkiin liittyvää piirretietoa. Kun kyseessä ovat monitasoiset neuroverkot, seuraavilla tasoilla näitä havaintoja koostetaan. Lopulta, opetettaessa millä tahansa kuvilla, saadaan siihen dataan erikoistuneita tunnistimia. (Pietikäinen & Silven, 2021)

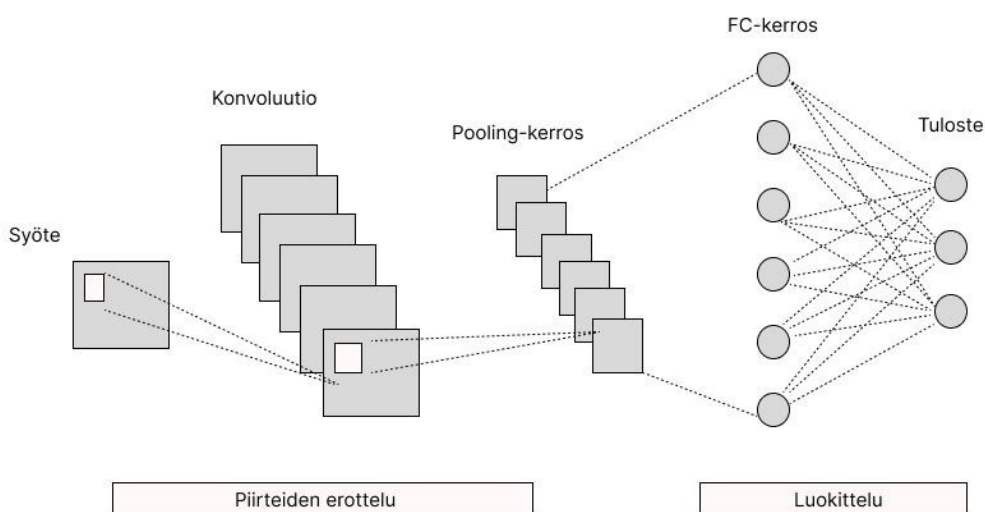


Kuva 2. Konvoluution laskeminen (Pietikäinen & Silven)

Aivan kuten ihminen hahmottaa kuvaa etäisyydeltä, CNN ensin erottaa kovat reunat ja yksinkertaiset muodot, täydentää sitten tietoa suorittaessaan ennusteidensa iteraatioita. Näitä neuroverkkoja käytetään ymmärtämään vain yksittäisiä kuvia. (IBM, 2023b)

### 3.3 Konvoluutio kerrokset

CNN:ssä on kolme kerrostyyppiä: konvoluutiokerrokset, pooling-kerrokset ja Fully connected (FC) kerrokset. Kun nämä kerrokset pinotaan päällekkäin, muodostuu CNN-arkkitehtuuri (Kuva 3). Näiden kolmen kerroksen lisäksi arkkitehtuuri sisältää myös kaksi muuta tärkeää parametria, jotka ovat dropout-kerros ja aktivointifunktio. (Gurucharan, 2022)




Kuva 3. CNN arkkitehtuuri

Konvoluutio-operaation tavoitteena on erottaa korkean tason piirteitä, kuten reunat, syötekuvasta. Konvoluutioverkkoja ei myöskään tarvitse rajoittaa vain yhteen konvoluutiokerrokseen vaan perinteisesti ensimmäinen konvoluutiokerros vastaa matalan tason piirteistä, kuten reunojen, värin havaitsemisesta. Lisäkerroksien myötä arkkitehtuuri sopeutuu myös korkeamman tason ja yksityiskohtaisempien piirteiden huomiointiin. Tämän kaltainen monikerroksinen verkko antaa mahdollisuuden ymmärtää kuvia kokonaisvaltaisesti, samalla tavalla kuin ihmiset. (Saha, 2018)

Konvoluutiokerros on konvoluutioneuroverkkojen ydinrakennusosa, ja se on paikka, jossa suurin osa laskennasta tapahtuu konvoluution avulla. Siihen tarvittavia komponentteja ovat: syötedata, konvoluutio-operaattori ja piirrekartta. Kun kuva on värillinen, luodaan kolmiulotteinen pikselimatriisi. Tämä tarkoittaa, että syötteellä on kolme ulottuvuutta korkeus, leveys ja syvyys, jotka vastaavat kuvan RGB-kanavia, eli tunnettua värimuodostusjärjestelmää, jossa punaista, vihreää ja sinistä valoa käyttämällä voidaan luoda valikoima eri värejä. Konvoluutio-operaattoria voidaan pitää eräänlaisena suodattimena, ja se liikkuu kuvan kentällä tarkistaen, onko piirre läsnä kuvan 2 tapaisesti. Tätä prosessia kutsutaan konvoluutioksi. (IBM, 2023d)

Konvoluutio-operaattori on kaksiulotteinen matriisi, jolla on opitut kertoimet, jotka edustavat osaa kuvasta. Vaikka niiden koko voi vaihdella, operaattorin kokona pidetään yleensä  $3 \times 3$  matriisia. Operaattori levitetään sitten kuvan alueelle, ja pistetulo lasketaan syötepikseleiden ja operaattorin välillä. Tämä pistetulo syötetään sitten tulosteeseen. Sen jälkeen operaattori siirtyy askeleen verran, ja prosessi toistetaan, kunnes operaattori on kulkenut koko kuvan läpi. Sarjasta pistetuloja, jotka syntyvät syötteestä ja operaattorista, saatu lopullinen tulos tunnetaan myös piirrekarttana. (IBM, 2023d)

Pooling-kerrokset, suorittavat dimensionaalisen pienenennyksen, vähentäen parametrien määrää syötteessä (Kuva 4). Myös pooling-operaattori liikkuu yli koko syötteen, mutta ilman painoja, joita konvoluutiossa on. Sen sijaan sovelletaan kokonaislukufunktiota kentän arvoihin ja täytetään tulostematriisi. Esimerkiksi voidaan korvata neljä vierekkäistä pikseliä  $2 \times 2$  ikkunassa olevien pikselien maksimiarvolla. Tätä kutsutaan Max-pooling operaattoriksi. Tuloksena saadaan pikseli, joka edustaa neljää edeltävää pikseliä. Tämän operaattorin tarkoituksena on pienentää konvoluutiosta syntyvää piirrekarttaa. (Pietikäinen & Silven, 2021, p. 89)

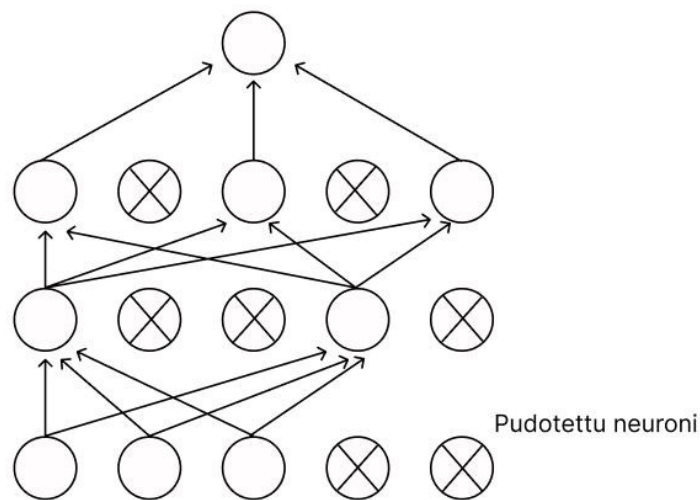


Kuva 4. Max-pooling operaattori (Pietikäinen & Silven, 2021, p. 89)

Osittain liitettyjen kerrosten pikseliarvot eivät ole suoraan yhteydessä tulostekerrokseen. Sen sijaan FC-kerroksessa jokainen solmu tulostekerroksessa liittyy suoraan solmuun edellisessä kerroksessa. Tämä kerros suorittaa luokittelutehtävän perustuen aiempien kerrosten ja niiden eri suotimien kautta uutettuihin piirteisiin. Vaikka konvoluutio- ja Pooling-kerrokset käyttävät usein ReLu-funktiota, täysin liitetyt kerrokset hyödyntävät yleensä

softmax-aktivaatiofunktiota luokitellakseen syötteet asianmukaisesti ja tuottaakseen todennäköisyyden välillä 0 ja 1. (IBM, 2023d)

Joskus kuitenkin syvät neuroverkot saattavat harjoittellessaan oppia niin sanottua turhaa informaatiota, mikä saattaa juuri harjoitteludatassa mahdollistaa todella hyvän oppimisen mutta aiheuttaa ongelmia uusissa datapisteissä. Tätä kutsutaan ylisovittamiseksi. Ylisovittaminen on kuitenkin ongelma, mitä varten on kehitetty erityinen Dropout-kerros (Kuva 5), jonka avulla yksittäisiä neuroneja pudotetaan väliaikaisesti pois. (Yadav, 2022)



Kuva 5 Dropout kerroksen toiminta

Tämän tarkoituksena on poistaa kohinaa, jota neuroverkko oppii, jos ylisovittamista ilmenee. Satunnaisesti pudottamalla muutamia neuroneja pakotetaan samalla muut neuronit ottamaan enemmän vastuuta. Tällä taas varmistetaan kyseisen mallin yleistymisen, joka vähentää ylisovittamista. (Yadav, 2022)

ReLU ja Softmax ovat aktivointifunktioita. Aktivointifunktion tarkoituksena on lisätä ei-lineaarisia ominaisuuksia neuroverkkoon. Jos aktivointifunktiota ei ole, voi neuroverkko kaikista kerroksistaan huolimatta edustaa vain yhtä lineaarista funktiota. Tämä vaikeuttaisi neuroverkon oppimista koska yksinkertaisella

lineaarisella funktiolla se ei voisi löytää oikeita kuvauksia tietoaineistosta. (Huawei Technologies Co., 2023)

ReLU, jota käytetään konvoluutio- ja poolingkerroksissa, on tällä hetkellä laajiten käytetty aktivointi funktio. ReLU on yksinkertainen funktio, ja se palauttaa syötteen, jos se on positiivinen, ja nollan, jos se on negatiivinen. Lisäksi sen laskennassa ja tietojenkäsittelyssä säästetään paljon aikaa ja vaivaa.

Softmax-aktivaatiofunktio, jota käytetään FC-kerroksissa, on matemaattinen funktio, joka muuntaa reaaliarvoiset luvut todennäköisyyksiksi siten, että ne summautuvat yhteen. Tämä funktio on usein käytössä koneoppimisen ja tekoälyn algoritmeissa, erityisesti luokitteluongelmissa, joissa tavoitteena on arvioida todennäköisyyksiä eri luokille. Softmax-funktio ottaa vektorin reaaliarvoja ja normalisoi ne siten, että ne muuttuvat positiivisiksi ja summautuvat yhteen. Tämä tekee siitä hyödyllisen luokitteluongelmissa, joissa halutaan arvioida, mikä luokka on todennäköisin syötteen perusteella. (Huawei Technologies Co., 2023, p. 100)

## 4 Konenäkö ihomuutosten tarkastuksissa

Tekoälyn voidaan olettaa tulevan lääkäreiden avuksi datan tulkintaan. Tulevaisuuden näkymissä on myös sairauksien automaattisen diagnosoinnin ja lääkesuosituksien aiheuttaman taakan osittainen siirto tekoälyn kannettavaksi. Tämän kaiken voisi mahdollistaa lääketieteellisen kuvantamisen valtava kasvu, joka on jo nyt lisännyt datan määrää terveydenhuollossa huomattavasti. (Pietikäinen & Silven, 2021, p. 123)

Nämä toiveet tekoälyn edistyksestä terveydenhuollossa voivat diagnosoitien ja suositusten lisäksi pitää sisällään lääkekehitystä ja yksilöllisemmän kokemuksen luomista potilaalle. Tärkeimpänä voidaan kuitenkin pitää ennusteiden parantumista. Toiveita on lisänneet ja ruokkineet onnistuneet kokeet ja sovellukset tekoälyn parissa tällä sektorilla. Toisaalta samalla myös epärealistisia odotuksia on noussut pintaan, kun tekoälyn suosio on kasvanut entisestään. Tärkeää onkin saada selvä kuva siitä, millainen toimialan tulevaisuus on ja mitä on mahdollista saavuttaa oikealla aikajänteellä. (Basu, et al., 2020)

Tämän hetken yleisimmät tekoälyn roolit terveydenhuollon sektorilla liittyvät juuri kliiniseen päätöksentukeen sekä kuvantamiseen. Päätöksen tuki mahdollistaa jo tällä hetkellä hyviä työkaluja asiantuntijoiden tueksi muun muassa hoitojen, lääkkeiden ja muiden potilaille tärkeiden asioiden hoidossa. Tekoäly mahdollistaa nopean pääsyn juuri potilaalle relevantin datan äärelle. Kuvantaminen taas antaa tekoälylle mahdollisuuden analysoida lääketieteellisiä kuvia. Tekoälyä käytetään erityisesti löytämään vaurioita ja muita relevantteja löydöksiä kuten kasvaimia, joita ihminen saattaisi mahdollisesti jättää huomioimatta. (IBM, 2023a)

Epäilemättä tekoäly on tällä hetkellä lääketieteellisen kuvantamisen tutkimuksen keskustelluin aihe sekä diagnostiikassa että hoidossa. Suuren kiinnostuksen takana on juuri valtavat datamäärät, joita nykyajan terveydenhuolto tuottaa. Tekoäly on olennainen voimanlähde lääketieteellisten kuvien käsittelyssä ja

paljastaa taudin ominaisuuksia, joita paljaalla silmällä ei joko ole mahdollista havaita tai on vaikeasti havaittavissa. (Xiaoli, 2019)

#### 4.1 Ihomuutosten tarkastus CNN verkkoja käyttäen

Hyvänä ja tärkeänä esimerkkinä tietokonenäön sovelluksesta terveydenhuollossa voidaan pitää ihomuutosten tarkasteluun soveltuvia sovelluksia, jotka mahdollistavat luomien sekä muiden epäilyttävien ihomuutosten tarkastamisen huomattavalla tarkkuudella. Nämä sairaudet luovat hyvän pohjan tekoäly tutkimuksille ja sovelluksille niiden yleisyyden sekä selkeän diagnosointi tavan vuoksi.

Nämä syövät kuuluvat yleisimpiin maailmassa ja samalla muodostavat syöpätyypin, joka on kasvanut yleisyydessä maailmanlaajuisesti viimeisimpien vuosien aikana. Ihosyöpiä on monia, mutta yleisimmät ovat melanooma, tyvisolusyöpä sekä okasolusyöpä. Ihosyöpä voi ilmaantua minne tahansa, mutta yleisimmin ilmaantumisaikana on kehon osassa, joka on vuosien saatossa altistunut paljon auringolle. Luomien muutokset kuten ulkonäkö, muoto ja väri liittyvät vaarallisimpaan ihosyövän muotoon eli melanoomaan. Varsinkin nopeat muutokset sekä luomen epätarkkuus reunoilla viittaavat melanoomaan. (Saara, 2022)

Vaikka nykyään melanooma on jo hyvin hoidettavissa, on ennusteiden kannalta tärkeää huomata sekä tarkistaa ihomuutokset hyvissä ajoin. Voidaankin olettaa, että CNN neuroverkot mahdollistavat hyvin laajoja mahdollisuuksia erityisesti ihosyöpien tunnistamisessa juuri tämän takia. Melanoomaa tarkastaessa tärkeää on erityisesti muoto, koko, tummuus ja kaikkia näitä CNN-neuroverkot pystyvät havainnoimaan melko yksinkertaisesti, kunhan se on opetettu laadukkaalla datalla. Vaikeammaksi neuroverkon opettaminen meneekin, kun sen tulisi osata havainnoida monia eri ihosyöpä tyyppisiä ja erottaa ne muista ihosairauksista kuten esimerkiksi erilaisista ihottumista.



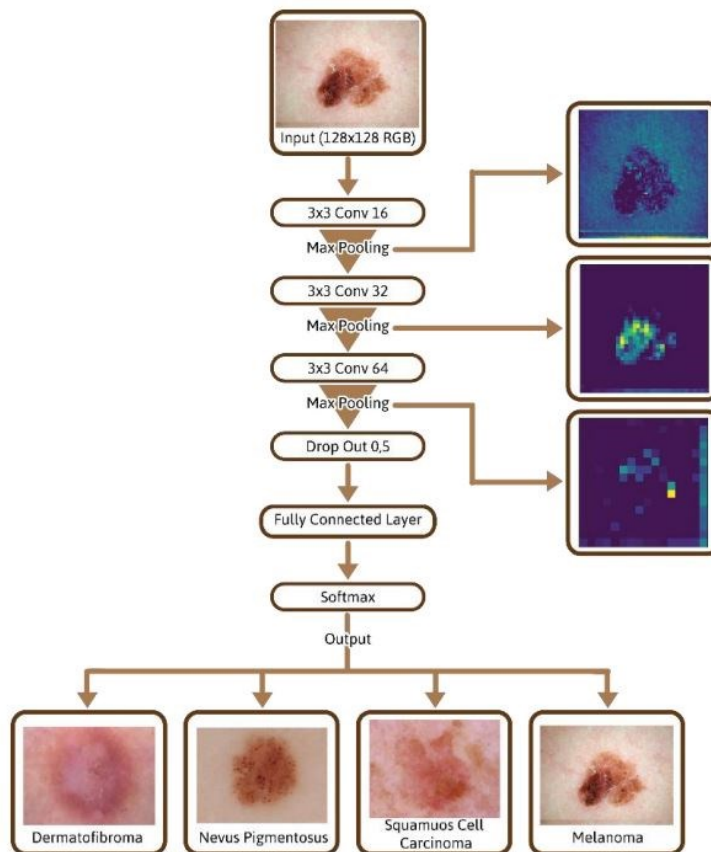
## 4.2 Tutkimuksista

Tutkimuksia ja sovelluksia on tehty paljon konenäön käytöstä ihosyöpien seulonnassa. Tässä selvityksessä on pyritty löytämään aiheeseen liittyviä tutkimuksia, joiden avulla voidaan tehdä johtopäätöksiä ihosyövän tunnistamisen tulevaisuuden näkymistä samalla selvittäen, miten CNN-verkkoja pystytään käyttämään haluamallamme tavalla. Tutkimuksessa Convolutional Neural Network (CNN) for Automatic Skin Cancer Classification System kehitettiin järjestelmä, jolla pystyi tunnistamaan ihosyövän ja hyvälaatuiset kasvaimet käyttäen konvoluutioneuroverkkoa. Malli koostui myös kolmesta kerroksesta, joissa on 16, 32 ja 64 lähtökanavaa kullekin kerrokselle. (Fu'adah, et al., 2020)

Kuvassa 6 näkyy, miten tutkijat suorittivat toiminnan sovelluksessaan ja miltä heidän ehdottamansa CNN-arkkitehtuuri näytti. Tarkoituksena oli siis erottaa neljä luomi tyyppiä toisistaan, vaarallisimpana tietysti melanooma, johtuen sen leviämismahdollisuuksista.

Neuroverkon opettamisen jälkeen sitä voitiin testata viemällä esimerkiksi kuva melanoomasta neuroverkkoon. Konvoluutiokerros koostui kolmesta kerroksesta, joista ensimmäinen kerros konvoluutio-operaattorin avulla etsi yksinkertaiset piirteet kuvasta. Syvemmälle kerrokseen mentäessä verkko pystyy havaitsemaan vaikeammin havaittavissa olevia yksityiskohtia, mikä onkin juuri tärkeää luomen tilaa tutkittaessa.

Konvoluutioiden välissä käytettiin Max-pooling operaattoria, joka pienentää konvoluutioista syntyneen piirrekartan. Näiden operaatioiden jälkeen ylisovittamista on pyritty estämään Dropout-operaattorilla, jonka arvoksi on asetettu 0.5, mikä tarkoittaa, että puolet neuroneista pudotetaan pois ylimääräisen kohinan poistamiseksi. FC-kerrokseen siirtyessä optimointi suoritettiin ehdotetulle mallille käyttäen Softmax-aktiivointifunktiota, mikä muuttaa vektorin todennäköisyysjakaumaksi.



Kuva 6 Ihosyövän tarkastamissysteemi CNN-verkkoa käyttäen (Fu'adah, et al., 2020)


Tässä kyseisessä tutkimuksessa datana oli 3 000 harjoituskuva.

Suorituskykytulosten perusteella järjestelmä osoitti, että ehdotettu malli on lupaava työkalu lääketieteelliselle henkilökunnalle ihosyövän tai hyvänlaatuisten kasvainten diagnoosin määrittämisessä. Sen avulla pystyttiin tunnistamaan ihomuutosten tila 90 % tarkkuudella. (Fu'adah, et al., 2020) CNN-arkkitehtuuri tässä muodossa toimi siis yllättävän hyvin neljällä eri ihosyöpä tyypillä.

Voidaan siis olettaa CNN-verkkojen olevan oiva työkalu ihomuutosten havaitsemiseen mutta pelkällä arkkitehtuurin laadullakaan ei pelasteta tilannetta, jossa kuvat ovat heikkoja. Saman alan toisessa tutkimuksessa Predictive approach for Melanoma Skin Cancer Detection using CNN perehdyttiin juuri siihen, miten kuvia tulee muokata ennen, kun niillä opetetaan CNN-verkkoja. Esimerkiksi kuvien tulee olla heidän mukaansa 100×100 pikseliä

jotta ongelmia kokosuhteiden kanssa ei tule. (Arneesh & Akhilesh, 2019). Tämä tietysti riippuu aineiston laadusta.

Kuvan valmistelu ja muokkaaminen on kuitenkin tärkeä prosessi. Sen avulla voidaan esimerkiksi poistaa kiinnostavan alueen reunat, kuten kuvassa 7 on tehty. Tämän kanssa tulee kuitenkin olla tarkkana, koska juuri melanoomalle tärkeät reunojen muodot eivät saa vaurioitua muokkauksen yhteydessä tai sen havaitseminen CNN-verkkojen avulla vaikeutuu. Sen takia tutkimuksessa suoritettiin myös käänteistä muokkausta, jotta reunat eivät vaurioituisi ja turhat mustat pikselit eivät haittaisi ja vaikuttaisi mallin toimintaan. (Arneesh & Akhilesh, 2019)



Kuva 7 Morfologiset operaatiot, eroosio ja dilaatio (Arneesh & Akhilesh, 2019)

Kuvien muokkaamisen jälkeen valmiit kuvat syötettiin CNN-verkkoon. Tietoaineisto perustui 514 kuvaan, joista osa ei ollut tutkijoiden mukaan ollut laadullisesti parhaassa kunnossa. Mallin tarkkuudeksi tuli silti noin 75 %, joka on heidän mukaansa hieman parempi kuin asiantuntijoiden kyky arvioida luomen tila. (Arneesh & Akhilesh, 2019)

Tutkimuksessa Convolutional Neural Network for Diagnosing Skin Cancer Mohammad Ashraf Ottom tutki CNN toimintaa ISIC (International Skin Imaging Collaboration) vapaasti saatavia kuvia käyttäen. Menetelmä sisältää kuvien esikäsittelyn kiinnostavan alueen erottamiseksi itse kuvasta. Siten myös aineisto, joka sisältää 3 000 kuvaa luokkaa kohti, suurenee. (Mohammad, 2019)

Mallin testaaminen tuotti lupaavia tuloksia tarkkuudella 0,74. Tulevaisuuden tutkimustyö tässä tutkimuksessa on tutkia ja uudelleenrakentaa CNN-arkkitehtuuria tarkkuuden lisäämiseksi. Myös aineiston suurentaminen on vaatimus paremman koulutuksen saamiseksi. Lopullinen tulevaisuudensuunnitelma on tehdä tästä mallista käytettävä älypuhelinsovellusten avulla. (Mohammad, 2019)

Konvoluutio neuroverkot tarjoavat siis vahvoja ratkaisuja ihosyövän havaitsemiseen. Nämä neuroverkot voivat tarkasti ennustaa ihosyövän esiintymistä melko korkealla tarkkuudella, mutta niiden ongelma on, että ne ovat tehokkaita vain suurilla tietoaineistoilla. Uudet tekniikat syväoppimisen alalla tulevat hyödyntämään vielä parempia sekä tehokkaampia malleja. Nämä mallit suoriutuvat paremmin kuin nykyajan tekniikat ja niiden oletetaan haastavissakin tilanteissa pääsemään yli 90 % tarkkuuksiin. (N, et al., 2023)

### 4.3 Haasteet

Tekoäly ei ole kuitenkaan ongelmaton ratkaisu. Sen avulla voidaan toki suorittaa vaikeitakin tehtäviä hyvin lyhyessä ajassa, mutta ongelmia syntyy erityisesti syväoppimisen osa-alueella. Varsinkin sen toiminta ja luotettavuus ovat tarkkailun kohteena. Esimerkiksi syväoppiminen ei ole riittävän läpinäkyvää. Neuroverkkoihin perustuvat menetelmät toimivat pitkälti niin sanottuina ”mustina laatikkoina”. Järjestelmät sisältävät paljon parametreja, jopa miljardeja. Kehittäjätkään eivät välttämättä ymmärrä tai pysty analysoimaan näitä parametreja tarpeeksi hyvin. Oppimisjärjestelmien toimiessa itsenäisesti ja ongelmattomasti, asia ei aiheuta haasteita. Lääketieteellisessä järjestelmässä asiantuntijat ja potilaat haluavat kuitenkin olla

varmoja siitä miksi järjestelmä päätyi juuri tiettyyn ratkaisuun. (Pietikäinen & Silven, 2021)

Nykyiset tekoälyalgoritmit ovat kaikki dataohjautuvia, koska mallien kouluttaminen vaatii valtavia määriä dataa. Vaikka ihmiset hyötyvät tekoälyn tuomasta kätevyydestä, yksityisyyden vuotamisen riski on samalla olemassa. Esimerkiksi joidenkin teknologiayritysten keräämät valtavat tietomäärät voivat altistaa henkilöille tärkeitä tietoja paljastumisen uhan alaisuuteen. (Huawei Technologies Co., 2023)

Tämän lisäksi tekoälyä voidaan käyttää muiden teknologioiden tavoin myös tarkoituksellisesti väärin, jos sen soveltajat pyrkivät siihen. Koneoppiminen toimii sen mukaisesti, millaista dataa sille syötetään. Jos oppiminen perustuu väärään ja valheelliseen dataan, tuloksia voidaan käyttää väärin. (Pietikäinen & Silven, 2021) Datan tulee siis olla oikea laatuista varsinkin sovelluksissa, joissa toimitaan arkaluontoisten tietojen parissa.

Lisäksi, jos sovelluksia käytetään verkossa, on teknisesti mahdollista tallentaa käyttäjän toimintaa sekä sijaintitietoja. Yritykset voivat siis halutessaan käyttää näitäkin henkilökohtaisia tietoja väärin. (Huawei Technologies Co., 2023)

### CNN-verkkojen haasteet ihonmuutosten tarkistuksessa

Haasteita ilmaantuu myös spesifimmin syväoppimisessa ja sitä kautta konenäössä. Esimerkiksi eri ihotyypit eivät ole samalla tavalla edustettuina saatavilla olevissa aineistoissa, mikä johtaa siihen, että mallit eivät opi tunnistamaan melanoomaa tietyiltä henkilöiltä. Samalla täytyy myös muistaa kuvien olevan sensitiivistä informaatiota, joten mahdollisia yksityisyyttä loukkaavia tilanteita voi huonoimmassa tilanteessa syntyä. (Brancaccio, et al., 2023)

Terveystieteiden säädösten kehittyvä maisema, erityisesti tekoälyn ja tietojenkäsittelyn osalta, luo epävarmuutta, joka voi hidastaa hyväksymistä ja käyttöönottoa. Huomion arvoista konvoluutioneuroverkkojen kanssa on myös

se, että tekoälymallit saattavat olla ongelmassa, kun kuvat eivät vastaakaan koulutusaineistossa vastaan tulleita kuvia. Jo pienet muutokset kuten kuvan koko tai kirkkaus vaikeuttavat melanooman tunnistamista tekoälyn avulla. (Brancaccio, et al., 2023)

#### 4.3.1 Haasteiden ratkominen

Pietikäinen ja Silven ehdottavat kolmea keinoa tekoälyn ongelmien ratkaisemiseksi: 1) koneoppimisen ja lääketieteen eksperttien yhteistiimien muodostaminen, 2) korkealaatuisen datan käyttö ja sen alkuperän tunteminen, 3) tieteellisiä konferensseja järjestävien yhteisöjen omaksuttava standardeja, jotka edellyttävät laadukkaan datan käyttöä ja tulosten riittävän kattavaa raportointia julkaisuissa. (Pietikäinen & Silven, 2021, p. 124) Varsinkin 2. kohta on tärkeä asia. Voidaan kehittää kaikki lupaavat teknologiat ja koneoppimisalgoritmit, mutta ilman riittävää ja hyvin edustettua dataa ei voida saavuttaa tekoälyn täyttä potentiaalia terveydenhuollossa. (Basu, et al., 2020)

Terveydenhuollon on lisäksi päästävä yhteisymmärrykseen tietoaaineistojen standardoinnista. Samalla sen on luotava järjestelmä suojellakseen potilaiden tietojen luottamuksellisuutta. Ilman näitä tärkeitä muutoksia ja yhteistyötä, terveydenhuollon alalla, olisi haastavaa saavuttaa tekoälyn todellista potentiaalia ihmisten terveyden parantamiseksi. (Basu, et al., 2020)

Huomioitavaa on kuitenkin, että tarvitaan asiantuntija lopulta ratkaisemaan, onko kyseessä vaaraton luomi vai esimerkiksi melanooma. Järjestelmä voi tehdä alustavan arvion mutta lopullisen päätöksen tekee asiantuntija. Tekoälyn, mikä pystyisi yksin olemaan vastuussa diagnosoinneista, kehittäminen olisi pitkäjänteistä työtä, koska järjestelmän vaatimusten mukaisuuden todentaminen sekä lääketieteelliset validaatiot vievät paljon aikaa. On oltava varmuus, että järjestelmä tuottaa tuloksia sillä tasolla mitä on luvattu. Myös siitä saatava hyöty potilaille ja asiantuntijoille on todennettava. (Pietikäinen & Silven, 2021, p. 124)

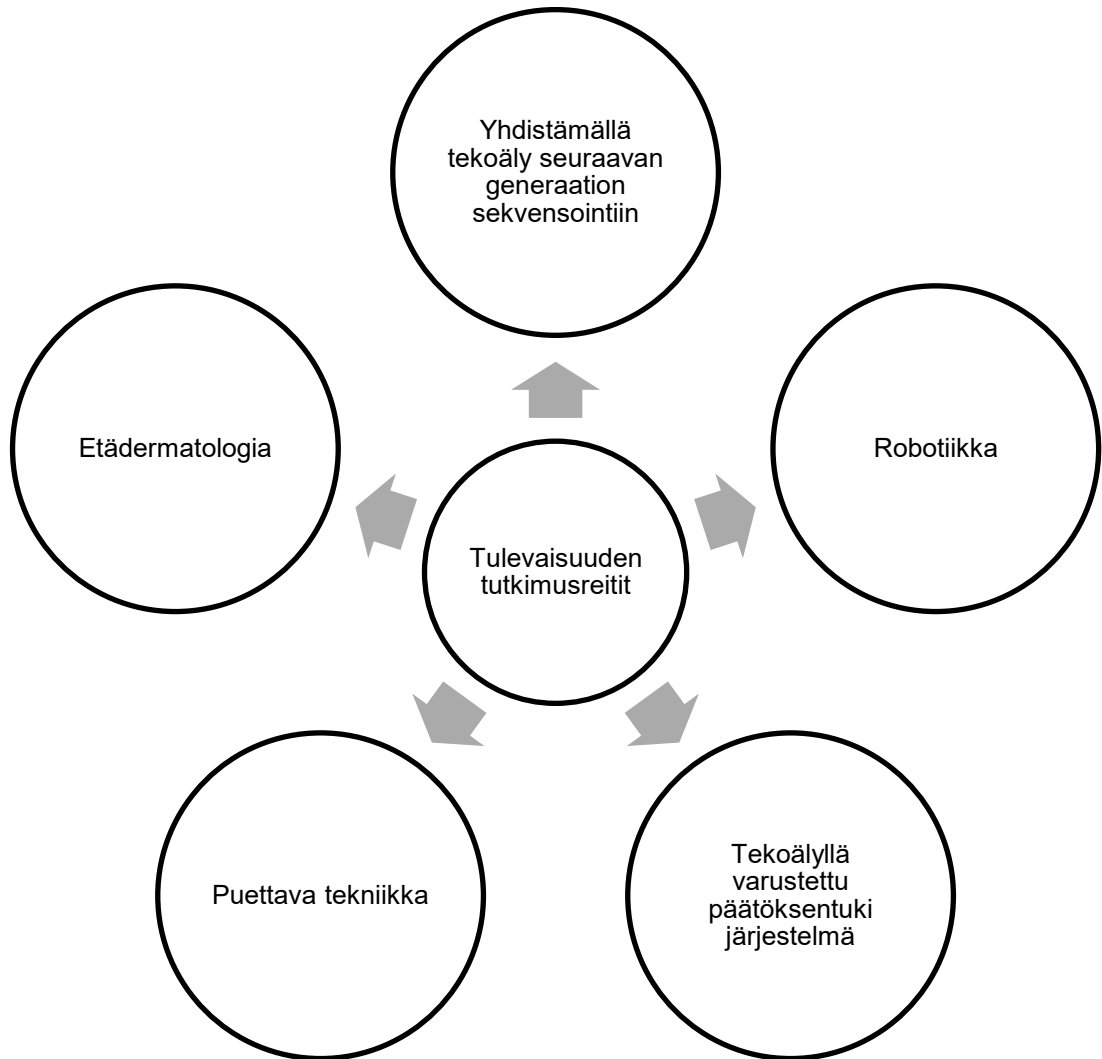
Aktiivinen monipuolisten koulutusaineistojen käyttö voi mahdollistaa, että tekoälymallit ovat suunniteltu ja tuotettu tarkasti erilaisille ihoille ja tiloille.

Tekoäly voisi myös mahdollisesti automatisoida informaation anonymisoinnin ja turvallisen säilytyksen, mikä parantaisi sen tietosuojaa, joka on yleisenä pelon kohteena erityisesti terveydenhuollon sovelluksissa. Lisäksi eettisesti sekä avoimesti tuotetut algoritmit luovat luottamusta sekä potilaille että lääkäreille samalla ratkaisten ”black box” ongelmaa. (Brancaccio, et al., 2023)

#### 4.4 Tulevaisuus

Miltä siis CNN verkkojen tulevaisuus näyttää ihomuutosten seurannan tasalla? Kuten kuvasta 8 voidaan huomata, ainakin etädermatologia, jonka avulla voidaan tarjota palveluita ja seurata potilaan terveyttä etäyhteyden päästä, on yksi tärkeimpiä tulevaisuuden kehittämiskohteita. Tälläkin hetkellä potilaat ja lääkärit vaihtavat kuvia, jotta diagnosointi nopeutuisi. Tulevaisuudessa voimme odottaa kameroiden ja videosovellusten kehittyvän mikä johtaa diagnosointien paranemiseen. CNN arkkitehtuuria voidaan käyttää tulevaisuudessa esimerkiksi siirtomallinnuksessa. (N, et al., 2023)

Myös robotteja ja puettavaa tekniikkaa voidaan käyttää tulevaisuudessa diagnosoinnin apuna. Haasteita näissä järjestelmissä ovat kuitenkin hyväksynnän saanti sekä kustannukset. Tulevaisuudessa näidenkin järjestelmien odotetaan kehittyvän tavalla, joka mahdollistaa tekoälyn ja teknologian liittämisen yhteen. (N, et al., 2023)



Kuva 8 Ihomuutosten seurannan tulevaisuuden näkymät tekoälyn kanssa. Perustuu lähteeseen (N, et al., 2023)

Päätöksentukijärjestelmät ovat ohjelmia, joiden avulla oikean toimintatavan valinta helpottuu. Kun tekoäly lisätään ohjelmaan mukaan, pystytään muun muassa antamaan vihjeitä toistuvista kaavoista ja vähentämään vanhanaikaisten tekniikoiden kuten leikkausten käyttöä ihosyövän diagnosoinnissa. Uudensukupolven sekvensointi, jolla määritetään DNA:n sekvenssi, yhdistettynä tekoälyyn mahdollistaa taas kohdennettujen hoitovaihtoehtojen kehittämisen. (N, et al., 2023)

Tekoäly kehittyy tulevaisuudessakin vahvasti, mutta ihmisen älyn tasolla se ei tule vielä pääsemään. Täytyy muistaa, että nykyinenkin tekoäly on jo



suhteellisen kehittynyt, jos vertaa muutaman vuoden takaisin järjestelmiin. Jotta uudet järjestelmät kehittyvät halutusti tarvitaan myös uusia ideoita. Prosessien yhdisteleminen on tulevaisuudessa kehityskohteiden kärjessä. Esimerkiksi hahmontunnistuksen ja tiedonkäsittelyn menetelmien yhdistäminen saattaa olla yksi kohteista. (Pietikäinen & Silven, 2021) Voimme siis vain mielenkiinnolla jäädä odottamaan mitä tulevaisuus tuo tullessaan.

## 5 Johtopäätös

Opinnäytetyön tavoitteena oli selvittää aiheeseen liittyviä tutkimuksia, joiden avulla voitiin tehdä johtopäätöksiä ihosyövän tunnistamisen tulevaisuuden näkymistä samalla selvittäen, miten CNN-verkkoja pystytään käyttämään haluamallamme tavalla. Lisäksi kyseessä olevan tekniikan tuomien ongelmien esiintuonti ja niille ratkaisuvaihtoehtojen etsiminen kuului tavoitteisiin.

Tuloksena syntyi selvitys siitä, miten CNN-verkkoja voidaan käyttää terveydenhuollon apuna ihosyöpien seulonnassa nyt ja tulevaisuudessa. Selvityksessä perehdyttiin erityisesti arkkitehtuuriin, mikä mahdollistaisi toiminnan. Lisäksi ratkaisuja haasteisiin löydettiin muun muassa tutkimuksista, jotka olivat käsitelleet samaa aihealuetta.

Selvityksestä pystytään myös toteamaan neuroverkon pääsevän ainakin asiantuntijan tasolle ihosyöpien seulonnassa. Lisäarvoa selvitykselle olisi kuitenkin tuonut itse tehty ja koulutettu neuroverkko. Tämä olisi mahdollistanut paremman arvioinnin oman tutkimuksen ja muiden tutkimuksien välillä. Lopulta datan saatavuus olisi saattanut aiheuttaa tässä tehtävässä ongelmia. Myös tietoturvan parantaminen on yksi kysymyksistä, johon kunnollista vastausta ei tässä opinnäytetyössä annettu.

Ihosyöpien seulonnan saralla jatkotutkimuksia voidaan tehdä esimerkiksi kuluttajasovellusten parissa. Tekoälyn suosion kasvaessa, tulee ensin ajankohtaiseksi kuitenkin tutkimukset siitä, miten se vaikuttaa terveydenhuoltoon yleisesti. Näin spesifin alueen tarkasteleminen, kuten ihosyöpien seulonta, ei ole vielä ajankohtaista vaan pohjatyön rakentaminen tekoälyn käytölle alkaa datan saatavuuden parantamisesta sekä asiantuntija tiimien rakentamisesta. Nämä tutkimukset mahdollistavat myös luottamuksen rakentamisen.

Konvoluutionaalisten neuroverkkojen tutkimusten kehittyessä sekä tekoälyn kasvattaessa edelleen suosiotaan, voidaan kuitenkin olettaa ihmisten mielipiteiden ja suhtautumisen keventyvän tekoälyä kohtaan samalla tavalla

kuin muillekin teknologioille on käynyt. Tekoäly tulee mahdollistamaan apua terveydenhuollon asiantuntijoille varsinkin kuvantamisessa, kunhan vain tutkimuksille annetaan oikeat työvälineet ja vastaanottavat osapuolet haluavat ottaa uuden teknologian vastaan.

## Lähteet

Arneesh, A. & Akhilesh, K. S. 2019. Predictive approach for Melanoma Skin Cancer Detection using CNN, Viitattu 10.02.2024

<https://deliverypdf.ssrn.com/delivery.php?ID=164026089095086065071097066069122106103071022042063039098083018018007028098097081104027098125022121046105081108012102102104031010025046089088011007015120091083002127077010044119007085099025126126030086005005113>

Basu, K., Sinha, R., Ong, A. & Basu, T. 2020. Artificial Intelligence: How is It Changing Medical Sciences and Its Future? Viitattu 29.01.2024

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7640807/#ref12>

Brancaccio, G., Balato, A., Malveyh, J., Puig, S., Argenziano, G., & Kittler, H 2023. Artificial Intelligence in Skin Cancer Diagnosis: A RealityCheck, Viitattu 10.02.2024

<https://www.sciencedirect.com/science/article/pii/S0022202X23029640>

Fu'adah, Y. N., Pratiwi, N. C., Pramudito, M. A. & Ibrahim, N. 2020. Convolutional Neural Network (CNN) for Automatic, Viitattu 16.01.2024

<https://iopscience.iop.org/article/10.1088/1757-899X/982/1/012005/pdf>

Gurucharan, M. 2022. Basic CNN Architecture: Explaining 5 Layers of Convolutional Neural Network, Viitattu 16.01.2024

<https://www.upgrad.com/blog/basic-cnn-architecture/>

Huawei Technologies Co., L. 2023. Artificial intelligence technology Viitattu 23.01.2024, ISBN 978-981-19-2879-6

IBM 2023a. How is artificial intelligence used in medicine? Viitattu 01.02.2024

<https://www.ibm.com/topics/artificial-intelligence-medicine>

IBM 2023b. What are neural networks?. Viitattu 22.01.2024

<https://www.ibm.com/topics/neural-networks>

IBM 2023c. What is artificial intelligence (AI)? Viitattu 22.01.2024

<https://www.ibm.com/topics/artificial-intelligence>

IBM 2023d. What is computer vision? Viitattu 02.02.2024

<https://www.ibm.com/topics/computer-vision>

Jones, M. L. & Strange, A. 2023. Artificial intelligence for image analysis in microscopy, s.l.: Wiley Analytical Science.

<https://analyticalscience.wiley.com/content/article-do/artificial-intelligence-image-analysis-microscopy>

Kolari, J. & Kallio, A. 2023. Tekoäly 123: matkaopas tulevaisuuteen. Viitattu 15.01.2024

Mihajlovic, I. 2019. Everything You Ever Wanted To Know About Computer Vision. Viitattu 05.02.2024 <https://towardsdatascience.com/everything-you-ever-wanted-to-know-about-computer-vision-heres-a-look-why-it-s-so-awesome-e8a58dfb641e>

N, M., K, S., SM, Q. & P, P. 2023. AI-Powered Diagnosis of Skin Cancer: A Contemporary Review, Open Challenges and Future Research Directions Viitattu 10.02.2024 <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9953963/>

Pietikäinen, M. & Silven, O. 2021. TEKOÄLYN HAASTEET – Koneoppimisesta ja konenäöstä tunnetekoälyyn Viitattu 15.01.2024 ISBN: 978-952-62-3202-7

Saara, H. 2022. Terveystalo Luomet ja niiden ulkonäön muuttuminen liittyy ihosyövistä nimenomaan melanoomaan Viitattu 19.02.2024

Saha, S. 2018. A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way Viitattu 02.02.2024 <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

Stuart, R. & Norvig, P. 2023. Artificial Intelligence: A Modern Approach, Global Edition Viitattu 16.01.2024

Yadav, H. 2022. Dropout in Neural Networks Viitattu 18.02.2024

Xiaoli, T. 2019. The role of artificial intelligence in medical imaging research  
Viitattu 02.02.2024 <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7594889/>

Mohammad Ashraf Ottom 2019. Convolutional Neural Network for Diagnosing  
Skin Cancer, Viitattu 24.02.2024,  
[https://www.researchgate.net/profile/Mohammad-Ashraf-Ottom/publication/334943887\\_Convolutional\\_Neural\\_Network\\_for\\_Diagnosing\\_Skin\\_Cancer/links/5d7f7113458515fca16bef7c/Convolutional-Neural-Network-for-Diagnosing-Skin-Cancer.pdf](https://www.researchgate.net/profile/Mohammad-Ashraf-Ottom/publication/334943887_Convolutional_Neural_Network_for_Diagnosing_Skin_Cancer/links/5d7f7113458515fca16bef7c/Convolutional-Neural-Network-for-Diagnosing-Skin-Cancer.pdf)

TensorFlow 2024. Viitattu 02.04.2024 <https://www.tensorflow.org/>