

Syväoppiminen glaukooman
diagnostiikassa: konvoluutioneuroverkot
OCT-kuvien analysoinnissa

TURUN YLIOPISTO
Tietotekniikan laitos
TkK-tutkielma
Lääketieteellinen tekniikka ja terveysteknologia
Joulukuu 2025
Eeva Pehkonen

TURUN YLIOPISTO
Tietotekniikan laitos

EEVA PEHKONEN: Syväoppiminen glaukooman diagnostiikassa: konvoluutioneuroverkot OCT-kuvien analysoinnissa

TkK-tutkielma, 29 s.

Lääketieteellinen tekniikka ja terveysteknologia

Joulukuu 2025

Tässä tutkielmassa tarkastellaan, miten konvoluutioneuroverkkomalleja voidaan hyödyntää OCT-kuvien analysointiin glaukooman diagnostiikassa. Kirjallisuuskatsauksen avulla selvitetään, millaisia tuloksia konvoluutioneuroverkkomalleilla on saavutettu. Tutkielmassa pohditaan tuloksiin vaikuttavia tekijöitä sekä mallien käyttöön liittyviä haasteita. Glaukooma vaurioittaa näköhermoa ja silmän verkkokalvon hermosäikekerrosta. Hoitamattomana sairaus johtaa merkittäviin hermovaurioihin, jotka voivat aiheuttaa näkökyvyn heikentymistä tai menetyksen. Varhaisella diagnoosilla hermovaurioita voidaan havaita ajoissa ja sairauden etenemistä hidastaa. Silmän OCT-kuvaus on tarkka noninvasiivinen menetelmä verkkokalvon hermosäikekerroksen ja näköhermon kuvantamiseen. OCT-kuvista glaukoomaa voidaan diagnosoida hermosäikekerroksen ja näköhermon muutosten perusteella. Konvoluutioneuroverkkomalleja on kehitetty ja koulutettu tunnistamaan näitä piirteitä OCT-kuvista. Konvoluutioneuroverkkomallien avulla OCT-kuvia voitaisiin luokitella automaattisesti terveisiin tai glaukoomaa sairastaviin. Syväoppimisen hyödyntäminen tehostaisi ja tarkentaisi diagnoosia.

Kirjallisuuskatsauksen perusteella voidaan todeta, että glaukooman diagnosointiin voidaan hyödyntää hienosäädettyjä konvoluutioneuroverkkomalleja sekä täysin uusia malleja. Kuvantunnistukseen kehitettyjä konvoluutioneuroverkkomalleja hienosäädetään ja uudelleenkoulutetaan tunnistamaan glaukooman piirteet OCT-kuvista. Uusien mallien arkkitehtuurit suunnitellaan alusta alkaen, ja ne koulutetaan kokonaan OCT-kuvilla. Hienosäädetyillä malleilla on saavutettu erittäin hyviä luokittelun tarkkuuksia. VGG16-malli saavutti parhaimmat tulokset, ja se soveltuu tulosten perusteella glaukooman diagnosointiin. Myös uudet konvoluutioneuroverkkomallit suoriutuivat luokittelusta hyvin, mutta niiden tuloksien välillä on suuria eroja. Glaukooman diagnostiikkaan vaaditaan hyviä tarkkuuksia, ja tuloksiin täytyy pystyä luottamaan. Luotettavuutta voidaan parantaa, ja konvoluutioneuroverkkomalleihin liittyviä haasteita ratkaista luokka-aktivaatiokarttoihin perustuvilla lämpökartoilla. Niiden avulla pystytään varmistumaan siitä, että malli tekee luokittelun oikeiden piirteiden perusteella. Konvoluutioneuroverkkomallien soveltamista glaukooman diagnostiikkaan tulee tutkia lisää, jotta ne voitaisiin saada osaksi OCT-kuvien analysointia kliinisissä ympäristöissä.

Asiasanat: glaukooma, OCT, syväoppiminen, konvoluutioneuroverkot

Sisällys

1	Johdanto	1
2	Tausta	5
2.1	Silmän anatomia ja glaukooma	5
2.2	Optinen koherenssitomografia	7
2.3	Syväoppiminen ja konvoluutioneuroverkot	10
3	OCT-kuvien analysointi konvoluutioneuroverkkomalleilla	14
3.1	Hienosäädetyt mallit glaukooman diagnostiikassa	15
3.2	Uudet mallit glaukooman diagnostiikassa	18
4	Pohdinta	21
5	Yhteenveto	28
	Lähdeluettelo	30

Kuvat

1.1	Aineiston hakuprosessi	3
2.1	Silmän anatomia. Glaukoomassa verkkokalvon hermosäiekerros ohenee ja näköhermon nysty surkastuu [9].	7
2.2	OCT:n toimintaperiaate. Muokattu lähteestä [13].	9
2.3	OCT-kuva. Kuvassa näkyy näköhermon pää ja hermosäiekerros, joita glaukooma vaurioittaa. Muokattu lähteestä [17].	10
2.4	Konvoluutioneuroverkkomallin rakenne. Muokattu lähteestä [25]. . . .	13

Taulukot

3.1 Hienosäädettyjen ja uusien konvoluutioneuroverkkomallien tulokset glaukooman diagnosoinnissa.	19
--	----

1 Johdanto

Glaukooma eli silmänpainetauti on silmän hermorakenteita vaurioittava sairaus, joka voi hoitamattomana johtaa näkökyvyn menetykseen. Glaukooma on maailmalla toiseksi yleisin näkövammaisuuden aiheuttaja [1]. Glaukoomaa sairastaa maailmanlaajuisesti noin 80 miljoonaa ihmistä [2]. Suomessa glaukoomaa sairastaa yli 90 000 potilasta, joista suurin osa on yli 65-vuotiaita [3]. Tauti on alkuvaiheessa täysin oireeton, ja usein se todetaan vasta kun näkökyky on selvästi heikentynyt. Glaukooman tarkkaa syytä ei edelleenkään tiedetä, mutta kohonnut silmänpaine on sen suurin riskitekijä. Korkean silmänpaineen aiheuttama glaukooma vaurioittaa silmänpohjassa sijaitsevan näköhermon pään aineenvaihduntaa ja verenkiertoa. Glaukoomassa silmän verkkokalvon hermosäiekerros ohenee. [3]

Glaukooma diagnosoidaan yhdistämällä useita silmätutkimuksia. Yleisesti käytössä on silmänpaineen mittaus ja verkkokalvon hermosäiekerroksen kuvantaminen. Hermosäiekerrosta kuvannetaan silmänpohjan valokerroskuvauksella eli optisella koherenssitomografialla (engl. Optical Coherence Tomography, OCT).[3] OCT-kuvaus on noninvasiivinen menetelmä silmänpohjan kuvantamiseen. OCT-kuvauksessa tutkitaan, miten silmään lähetetty valo heijastuu silmänpohjan kudoksista [4]. Glaukoomassa silmän rakenteelliset muutokset eli näköhermon vaurioituminen ja hermosäiekerroksen oheneminen tapahtuvat ennen kuin silmän toimintahäiriöitä havaitaan [5]. Rakenteellisten muutosten havaitsemisessa OCT-kuvaus on tarkka menetelmä, ja glaukooma voidaan diagnosoida kuvista usealla perusteella. [6]

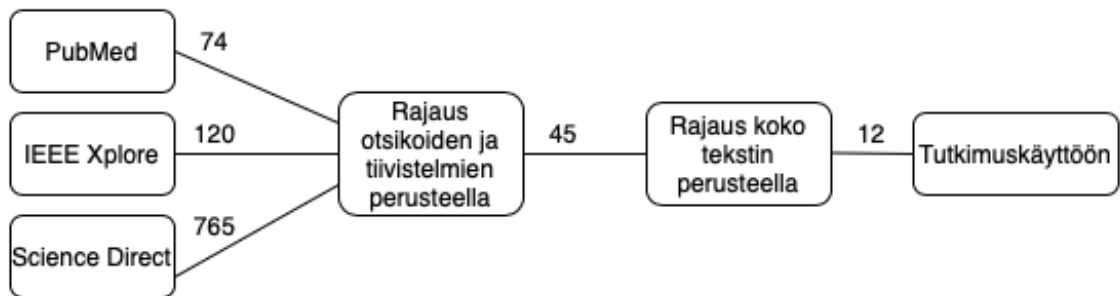
Glaukooman varhainen diagnosointi on näkökyvyn säilymisen kannalta erittäin tärkeää. Varhaisen diagnoosin avulla sairauden eteneminen eli vakavampien hermo-
vaurioiden syntyminen saadaan pysäytettyä. [7] OCT-kuvien analysointi on merkit-
tävässä asemassa diagnoosia muodostettaessa. Silmälääkärit ja optometristit tulkit-
sevat kuvia havainnoimalla muutoksia silmämääräisesti. Tekoälyn edistys lääketie-
teessä ja siten oftalmologiassa (silmätautioppi) on mahdollistanut OCT-kuvia ana-
lysoivien koneoppimismenetelmien (engl. Machine Learning, ML) kehittämisen [5].
Syväoppiminen (engl. Deep Learning, DL) on koneoppimisen alalaji, jossa syväoppi-
mismallit analysoivat kuvapohjaista glaukoomadataa monikerroksisten neuroverkkö-
jen avulla [7]. Konvoluutioneuroverkot (engl. Convolutional Neural Networks, CNNs)
ovat neuroverkkoja, joissa erilaiset kerrokset tunnistavat haluttuja piirteitä ja suo-
rittavat niiden perusteella luokittelun. OCT-kuvien analysointiin kehitetyt ja kou-
lutetut konvoluutioneuroverkot segmentoivat kuvasta alueita, joissa havaitaan glau-
kooman aiheuttamia muutoksia. Mallit luokittelevat alueiden piirteiden perusteella
OCT-kuvan terveeksi tai glaukoomaa sairastavaksi. [5] Konvoluutioneuroverkot voi-
sivat tehostaa glaukooman diagnosointia tarjoamalla luokittelun tuloksen heti ku-
vantamisen jälkeen. Konvoluutioneuroverkkomallien hyödyntäminen mahdollistaisi
varhaisemman diagnostiikan, jos tekoäly pystyy tunnistamaan glaukooman piirteitä
OCT-kuvista ihmistä herkemmin.

Tämän kandidaatintutkielman tavoitteena on selvittää, miten konvoluutioneu-
roverkkoja voidaan hyödyntää glaukooman diagnosointiin OCT-kuvista. Tarkoituk-
sena on selvittää glaukooman diagnosointiin kehitettyjen ja koulutettujen konvolu-
utioneuroverkkomallien rakenteet sekä toimintaperiaatteet. Toisena tavoitteena on
selvittää, millaisia tuloksia malleilla on saatu aikaan, ja mitkä tekijät vaikuttavat
tuloksiin. Tutkielmassa pyritään vastaamaan seuraaviin tutkimuskysymyksiin:

- TK 1: Miten konvoluutioneuroverkkomalleja voidaan soveltaa OCT-kuvien
analysointiin glaukooman diagnostiikassa?

- TK 2: Millaisia tuloksia konvoluutioneuroverkkomalleilla on saavutettu glaukooman diagnosoinnissa?

Tutkielma on toteutettu kirjallisuuskatsauksena, johon on haettu tietoa PubMedistä, IEEE Xploresta sekä Science Directistä. Hakulauseeseen liitettiin kaikki aiheeseen liittyvät termit ja niiden mahdolliset lyhenteet. Haut suoritettiin englanniksi käyttäen hakulauseita: glaucoma AND ("optical coherence tomography" OR OCT) AND ("convolutional neural network" OR CNN). Haut rajattiin vuosina 2019–2025 julkaistuihin englanninkielisiin teoksiin. Rajaus ei vaikuttanut hakutulosten määrään merkittävästi, koska aiheesta ei juurikaan ole tutkimustietoa varhaisemmilta vuosilta. Haku tuotti näistä tietokannoista, näillä kriteereillä, yhteensä 959 tulosta. Hakutulokset rajattiin otsikoiden ja tiivistelmien perusteella, jonka jälkeen tuloksia jäi 45. Nämä artikkelit luettiin läpi ja niistä suoritettiin rajaus sisällön sopivuuden mukaan. Tutkimuskäyttöön valittiin 12 artikkelia. Kuvassa 1.1 on esitetty aineiston hakuprosessi.



Kuva 1.1: Aineiston hakuprosessi

Tutkielman toisessa luvussa tarkastellaan silmän anatomiaa, glaukooman taustaa, OCT-kuvauksen ja syväoppimisen teoriaa, jotta voidaan ymmärtää, miten syväoppimista voidaan soveltaa glaukooman diagnosointiin. Kolmannessa luvussa selvitetään, miten konvoluutioneuroverkkomalleja hyödynnetään OCT-kuvien analysoinnissa ja glaukooman diagnostiikassa, sekä miten ne suoriutuvat luokittelussa. Neljännessä luvussa arvioidaan saatuja tuloksia ja niihin vaikuttavia tekijöitä. Luvussa

pohditaan myös millaisia haasteita konvoluutioneuroverkkomallien hyödyntämiseen liittyy. Viidennessä luvussa tehdään yhteenveto ja vastataan tutkimuskysymyksiin kirjallisuuskatsauksen pohjalta.

2 Tausta

Silmän perusanatomian avulla voidaan selittää tarkemmin glaukooman syntyä ja sen aiheuttamia vaurioita. OCT-kuvauksen teoria perustelee, miksi se on sopiva kuvantamismenetelmä juuri silmänpohjan kuvantamiseen, ja miten sen avulla glaukoomaa voidaan diagnosoida. Syväoppimisen teoria auttaa ymmärtämään, miten konvoluutioneuroverkkomalleja voidaan soveltaa glaukooman diagnosointiin OCT-kuvista. Tässä luvussa käsitellään silmän anatomiaa, glaukooman taustaa ja OCT-kuvauksen toimintaperiaate. Luvussa käsitellään konvoluutioneuroverkkomallien rakennetta ja toimintaa.


2.1 Silmän anatomia ja glaukooma

Silmä havaitsee ja analysoi valoa. Valo on sähkömagneettista säteilyä, jota ihmisen silmä pystyy näkemään. Pupilli on silmän keskellä oleva aukko, josta valo pääsee silmään. Pupillin ympärillä on iiris (värikalvo), joka vastaa pupillin koon muuttamisesta. Iiriksessä on kaksi lihasta, joista toinen suurentaa ja toinen pienentää pupillia. Suuremmasta pupillista valoa pääsee enemmän ja pienemmästä vähemmän. Sarveiskalvo on silmän uloin, läpinäkyvä kalvo, joka peittää iiriksen ja pupillin. [8] Sarveiskalvo läpäisee valoa ja suojaa silmää. Silmän valkoinen osa, kovakalvo, muodostaa silmän kovan seinämän. Kovakalvossa sijaitsee kammiokulman rakenteet, joiden kautta pääosa silmän sisäisestä nesteestä poistuu silmästä. Silmän linssi eli mykiö sijaitsee iiriksen takana. Sädelihas säätelee mykiön muotoa ja mahdollistaa lähi-

tarkentumisen eli akkommodaation. Silmän sisäosan täyttää hyytelömäinen neste, jota kutsutaan lasiaiseksi. Lasiaiskalvo pitää lasiaisen koossa, ja kiinnittyy verkkokalvoon sekä näköhermon päähän. Verkkokalvo (retina) sijaitsee silmän takaosassa ja koostuu useista kerroksista. Gangliosolujen aksonit eli viejähaarakkeet muodostavat verkkokalvon hermosäiekerroksen, joka välittää hermoimpulsseja aivoihin. Valoa aistivat fotoreseptorit ja näköhermon nysty eli pää sijaitsevat verkkokalvolla. Makula on verkkokalvon keskiosa, joka on vastuussa tarkasta näkemisestä ja värinäöstä. [9] Kuvassa 2.1 on esitetty silmän rakenne pääpiirteittäin.

Glaukoomassa näköhermon pää surkastuu ja verkkokalvon hermosäiekerros vaurioituu [10]. Taudin kehittymisen yksityiskohtia ei tunneta, mutta korkea silmänpaine liittyy kammiokulman rakenteiden muutoksiin. Muutokset estävät silmän sisäisen nesteen poistumista, vaikka kammiokulma pysyy avoimena, jolloin silmänpaine kohoaa edelleen. [10] Glaukooma saattaa kehittyä, vaikka silmänpaine on normaali. Tällöin potilaan silmän paineherkkyys on suurempi. Normaali silmänpaine on 10–21 elohopeamillimetriä (mmHg) [3]. Jos silmänpaine kohoaa yli 30 mmHg:iin, riski sairastua glaukoomaan kasvaa 40-kertaiseksi [3]. Glaukooman riskitekijöitä ovat suvussa esiintyvä glaukooma, diabetes sekä kohonnut verenpaine. Myös likinäköisillä (myopia) on suurempi riski sairastua glaukoomaan. [3]

Glaukooma aiheuttaa verkkokalvon hermosäiekerroksen (engl. Retinal Nerve Fiber Layer, RNFL) ohenemista. Hermosäiekerroksen paksuusmittaus on keskeisin glaukooman diagnosointiin käytettävä OCT-tutkimus [11]. Verkkokalvon hermosäiekerroksen paksuuden mittauksella on korkea spesifisyys ja diagnostinen herkkyys erottaa glaukooma terveestä verkkokalvosta [6]. Verkkokalvon hermosäiekerroksen paksuuden mittauksella voidaan myös seurata diagnosoidun glaukooman etenemistä. Glaukooman varhainen toteaminen on tärkeää, koska jo syntyneitä vaurioita ei pystytä korjaamaan [10].



Kuva 2.1: Silmän anatomia. Glaukoomassa verkkokalvon hermosäiekerros ohenee ja näköhermon nysty surkastuu [9].

2.2 Optinen koherenssitomografia

Optisen koherenssitomografian toiminta perustuu valon interferenssiin. Perustana on Michelsonin interferometri. Matalakoherenssisestä lähteestä tuleva valo jaetaan kahdelle kuidulle haaroittimen avulla. Valo kulkeutuu interferometrillä kahteen eri haaraan. Toinen haaroista on vertailuhaara ja toinen toimii näytehaarana. Valon poistuessa kummankin haaran kuidusta kohti interferometriä, sen muotoa sääde- tään optisilla komponenteilla, kuten peileillä ja linseillä. Optisten komponenttien avulla ohjataan valonsäteen ominaisuuksia, kuten intensiteettijakaumaa ja tarken- nussyvyyttä. [12]

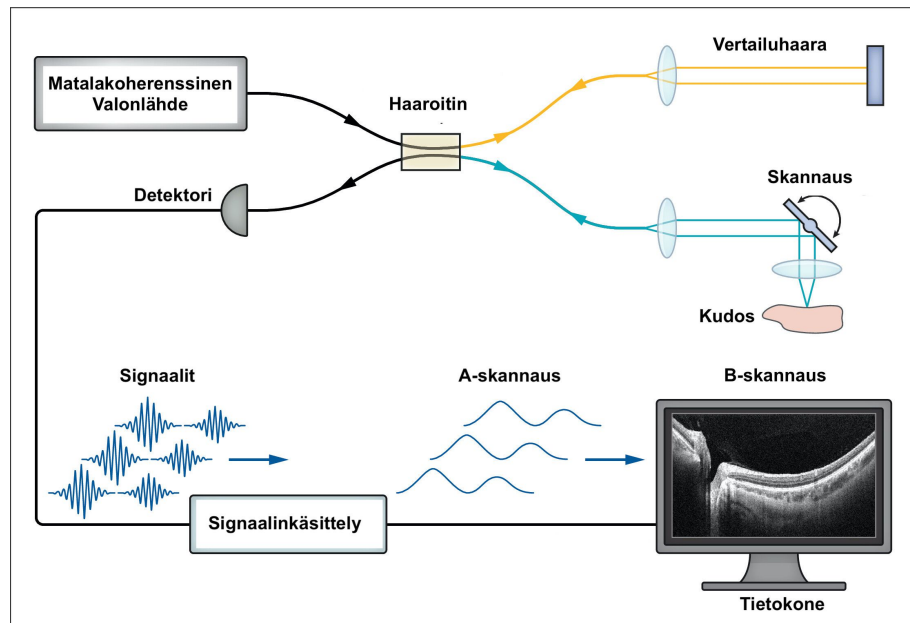
Vertailuhaarassa valo heijastuu takaisin vertailupeilistä ja palaa interferenssijär- jestelmään samaa reittiä, mutta vastakkaiseen suuntaan. Näytehaarassa tapahtuu samoin, mutta valonsäde siroutuu takaisin näytteestä eikä peilistä. Heterogeenisessä näytteessä eri rakenteilla on erilaiset taitekerroin-arvot. Valo heijastuu takaisin koh- datessaan kahden materiaalin rajapinnan, joilla on eri taitekertoimet. Näytteestä takaisin heijastuva valo ohjataan takaisin näytehaaran kuituun. Kuidussa se sekoit-

tuu vertailuhaarasta palaavan valon kanssa haaroittimessa. Yhdistetyt valonsäteet interferoivat detektorin pinnalla. Interferenssiä tapahtuu vain niiden valonsäteiden kesken, jotka ovat kulkeneet saman optisen matkan. Vertailupeiliä siirretään valon etenemissuunnassa ja peilin eri asennoista palaava valo interferoi näytteen vastavista syvyyksistä takaisin heijastuneen valon kanssa. Näin interferenssi saadaan tapahtumaan myös näytteen pinnan alta takaisin heijastuvalle valolle. [12] Detektorin havaitsemat signaalit muokataan yksiulotteiseksi amplitudiskannaukseksi eli A-skannaukseksi. Mekanismi skannaa koko näytteen ja tallentaa useita A-skannauksia, jotka prosessoidaan tietokoneella kaksiulotteiseksi kuvaksi. Tätä poikkileikkauskuvaa kutsutaan B-skannaukseksi. [13] Kokonaisuudessaan OCT-kuvauksen periaate on esitetty kuvassa 2.2. OCT:stä on useita sovelluksia, joista ensimmäinen eli aikataso-OCT kehitettiin 1990-luvun alussa [14] ja uusi menetelmä eli pyyhkäisy-OCT 1997 [15].

Aikataso-OCT (engl. Time-Domain OCT, TD-OCT) toimii kuten edellä on kerrottu. Valonlähteenä käytetään matalan koherenssin superluminoivaa diodia (SLD) tai infrapunavaloa, ja detektori on pistemäinen. [12]

Taajuustaso-OCT (engl. Fourier-Domain OCT, FD-OCT) eroaa TD-OCT:stä siten, että siinä valon viiveen mittaus tapahtuu samanaikaisesti kaikista aksiaalisista syvyyksistä. Viive mitataan valonlähteen spektrin moduloitumisena, jolloin kaikki spektrikomponentit tallennetaan yhtä aikaa. FD-OCT-järjestelmän vertailuhaarassa on paikallaan pysyvä peili, kun taas TD-OCT-järjestelmässä peili liikkuu. FD-OCT:ssä detektori tuottaa hetkellisen sähkövirran, kun siihen saapuu valonsäde. Data muunnetaan A-skannaukseksi tekemällä käänteinen Fourier-muunnos. Taajuustaso-OCT on jakautunut kahteen menetelmään: spektrialueen-OCT ja pyyhkäisy-OCT perustuen ilmaisintekniikoihin ja valonlähteisiin. [12]

Spektrialueen-OCT (engl. Spectral-Domain OCT, SD-OCT) laitteessa on paikallaan oleva vertailupeili ja matalakoherenssinen valonlähde. Laitteen detektori




Kuva 2.2: OCT:n toimintaperiaate. Muokattu lähteestä [13].

ei kuitenkaan ole pistemäinen, vaan sen tilalla on diffraktioristikko. Interferometrin haaroista palaavien valonsäteiden interferenssikuvion spektri hajotetaan diffraktioristikon avulla spektrikomponenteiksi ja tallennetaan CCD-viivakameralla. Kameran tallentamasta spektrisesti erotellusta interferenssikuvioista tehdään Fourier-muunnos, joka tuottaa A-skannauksen. [12]

Pyyhkäisy-OCT (engl. Swept-Source OCT, SS-OCT) käyttää laseria, joka pyyhkäisee näytteen yli. Vertailuhaaran valonsäde heijastuu paikallaan olevasta peilistä ja muodostaa interferenssikuvion näytteestä takaisin heijastuneen valon kanssa. Signaali havaitaan pistemäisellä detektorilla. Yhden pyyhkäisyn aikana havaitun signaalin Fourier-muunnoksella saadaan A-skannaus. [12]

Silmän OCT-kuvauksessa yleisin menetelmä on spektrialueen-OCT. Laitteet ovat kehittyneimpiä OCT-laitteita, joihin on yhdistetty kolmiulotteinen OCT sekä kaksiulotteinen kuva verkkokalvosta. [16] Silmänpohjan kerrokset eroavat optiselta heijastuskyvyltään [4]. OCT-kuvassa silmänpohjan kerrokset näkyvät valon viiveen perusteella erilaisina ja ne on esitetty Kuvassa 2.3. Glaukooman aiheuttama näköhermon pään surkastuminen näkyisi OCT-kuvassa kuopan syventymisenä. Hermosäie-



Kuva 2.3: OCT-kuva. Kuvassa näkyy näköhermon pää ja hermosäiekerros, joita glaukooma vaurioittaa. Muokattu lähteestä [17].

kerros on verkkokalvon sisin kerros, joka näkyy näköhermon lähettyvillä vaaleana. Hermosäiekerroksen oheneminen näkyisi mustavalkoisessa OCT-kuvassa selkeästi.

Kuvauksessa potilas asettaa leukansa leukatuolelle ja tukee otsansa otsatukeen. Silmän etäisyys kamerasta pyritään pitämään vakiona [4]. Infrapunakamera kohdistetaan silmän eteen, potilas kohdistaa katseensa kameras kohdevaloon ja laite ottaa kuvan yhdestä silmästä kerrallaan. Ensimmäisen kuvan jälkeen kamera kohdistetaan toisen silmän eteen ja kuvaus toistetaan uudelleen samalla tavalla. Kuvauksen kesto on kokonaisuudessaan alle viisi minuuttia.

2.3 Syväoppiminen ja konvoluutioneuroverkot

Tekoäly määritellään pyrkimykseksi automatisoida normaalisti ihmisten suorittamia älyllisiä tehtäviä. [18] Tekoäly on yleinen termi, joka kattaa koneoppimisen ja syväoppimisen. Koneoppiminen tulkitsee sille annettua dataa ja datasta luettuja tuloksia. Koneoppimismalli määrittelee, millä tavalla tulokseen on päädytty. Koneoppiminen on hyödyllisten representaatioiden ja sääntöjen etsimistä sille annetusta datasta. Representaatio tarkoittaa mallin sisäistä tiedon esitysmuotoa. Koneoppimismalli koulutetaan suurella määrällä dataa. [18]

Syväoppiminen on koneoppimisen alalaji, joka painottaa peräkkäisten kerrosten representaatioiden oppimista. Kerrostetut representaatiot opitaan neuroverkkojen avulla. [18] Neuroverkot koostuvat neuroneista, jotka ovat yhteydessä muiden kerrosten neuroneihin. Neuronien yhteyksiä kuvataan painoilla (engl. Weights), jotka kertovat kahden neuronin välisestä voimakkuudesta ja suunnasta. Painot asetetaan aluksi satunnaisesti ja mallin kouluttamisen edetessä painoja säädellään, jotta syötteen ja ulostulon suhde saadaan halutunlaiseksi [19]. Jokainen neuroni muuntaa sille tulevaa dataa. Neuronin laskee painotetun summan edellisen kerroksen neuronin tuottamasta arvosta. Summa kuljetetaan epälineaarisen aktivointifunktion läpi, joka muodostaa neuronin ulostulon. [20] Neuroverkon ensimmäiset kerrokset oppivat pieniä ominaisuuksia, toiset kerrokset havaitsevat ominaisuuksien motiiveja. Kolmannet kokoavat motiiveja suuremmiksi yhdistelmiksi, jotka vastaavat opittujen objektien osia. Seuraavat kerrokset havaitsevat objektit yhdistelemällä niiden osia. [21] Konvoluutioneuroverkot ovat yksi neuroverkkojen muodoista.

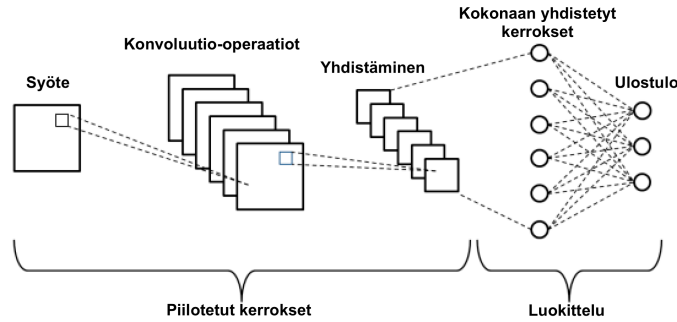
Konvoluutioneuroverkot eristävät piirteitä konvoluutio-operaatioiden avulla. Konvoluutioneuroverkot käsittelevät moniulotteista dataa. Signaalit, järjestykset ja kielet ovat yksiulotteisia (1D), kuvat ja äänispektrit kaksiulotteisia (2D), videot sekä tilavuuskuvat kolmiulotteisia (3D). [20] Konvoluutioneuroverkon rakenne voidaan jakaa syötteeseen sekä piilotettuihin- ja ulostulokerrokseen. Piilotettuja kerroksia (engl. Hidden Layers) kutsutaan myös ominaisuuksien erotuskerroksiksi. Piilotetut kerrokset koostuvat konvoluutiokerroksista, yhdistävistä kerroksista, kokonaan yhdistetyistä ja normalisointikerroksista. Piilotettujen kerrosten määrä vaihtelee mallin mukaan. [22] Konvoluutiolohkoksi kutsutaan konvoluutiokerrosten ja yhdistävien kerrosten yhdistelmää. Lohkossa voi esimerkiksi olla yksi yhdistävä kerros ja kolme konvoluutiokerrosta.

Konvoluutiokerrokset koostuvat suodattimista (engl. Filters tai Kernels), jotka suorittavat konvoluutio-operaatioita syötteen ja suodattimien välillä. Suodattimet

tuottavat ominaisuuskarttoja. Ominaisuuskartta on konvoluutio-operaation tulos, joka näyttää, missä ja kuinka voimakkaasti tietty piirre esiintyy syötteessä. Suodattimet on kytketty edellisen kerroksen ominaisuuskarttojen paikallisiin alueisiin painojen avulla. Suodattimien lukumäärä määrittää, kuinka monta erilaista piirretä kerros kykenee havaitsemaan. Suodattimia on yleensä 32–512. [20] Useammalla suodattimella saadaan tehokkaampi neuroverkko, mutta ylisovituksen riski kasvaa. Ylisovitus tarkoittaa sitä, että malli oppii liikaa koulutusdatan yksityiskohtia ja kohinaa, jolloin sen kyky yleistää heikentyy. [23] Suodattimen koko eli leveys ja korkeus, määrittelevät sen spatiaalisen laajuuden. Kuvantunnistuksessa käytetään usein pieniä 3 x 3 suodattimia. [20]

Yhdistävien kerrosten (engl. Pooling Layers) tarkoituksena on pienentää ominaisuuskarttojen kokoa, tehdä niistä tilallisesti muuttumattomia ja säilyttää tärkeimmät tiedot. Yhdistäminen voidaan jakaa tyypeihin: maksimi, keskiarvo ja minimi. Maksimaalisessa yhdistämisessä otetaan korjatun ominaisuuskartan suurin elementti. [20] Normalisointikerrokset varmistavat, että tieto pysyy sopivassa muodossa kerrokselta toiselle siirryttäessä [24]. Konvoluutioneuroverkoissa käytetään epälineaarista aktivointifunktiota konvoluutiokerroksen suodattimien operaatioiden jälkeen. Yleensä aktivointifunktio määritellään konvoluutiokerroksen sisälle, mutta se voidaan toteuttaa myös itsenäisenä kerroksena. ReLU-funktio (engl. Rectified Linear Unit) on yleisesti käytetyin funktio, joka mahdollistaa syvien konvoluutioneuroverkkomallien kouluttamisen nopeasti. [20]

Yhdistävien kerrosten ja konvoluutiokerrosten ulostulo esittää syötteen korkean tason ominaisuuksia. Täysin yhdistetyt kerrokset käyttävät näitä korkean tason ominaisuuksia luokittelemaan syötteen johonkin luokkaan. [22] Kuvassa 2.4 on esitetty yksinkertainen esimerkki konvoluutioneuroverkkomallin rakenteesta. Kerroksia voidaan yhdistellä eri tavoin sopivan arkkitehtuurin saavuttamiseksi.



Kuva 2.4: Konvoluutioneuroverkkomallin rakenne. Muokattu lähteestä [25].

Konvoluutioneuroverkot koulutetaan suurella määrällä kuvia, jotka sisältävät piirteitä, joita mallin on tarkoitus oppia. Aina kuvadataa ei ole saatavilla riittävästi, jotta malli voitaisiin kouluttaa tunnistamaan piirteitä hyvällä tarkkuudella. Konvoluutioneuroverkkomallien datan augmentoinnin avulla koulutusdatan monimuotoisuutta voidaan lisätä. Kuvadataa augmentoidaan kuvia kääntämällä, peilamalla, siirtämällä sekä värejä säätämällä. Augmentoinnin avulla konvoluutioneuroverkkomalli oppii tunnistamaan haluttuja kohteita eri asennoissa, sijainneissa sekä valaistuksissa. [26]

Konvoluutioneuroverkkomallien suorituskykyä arvioidaan useilla suureilla. Tarkkuus (engl. Precision) kuvaa kuinka suuri osuus mallin positiiviseksi ennustetuista on todellinen positiivinen eli oikeasti glaukoomaa sairastava. Herkkyys (engl. Sensitivity tai Recall) kertoo, kuinka monta todellisista positiivisista malli on luokitellut positiiviseksi. F1-pisteet (engl. F1-score) arvioi mallin suorituskykyä laskemalla tarkkuuden ja herkkyyden keskiarvon. F1-pisteet voivat olla väliltä 0–1, joista 1 tarkoittaa täydellistä tarkkuutta ja herkkyyttä. Spesifisyys (engl. Specificity) kuvaa todellisten negatiivisten tapausten osuutta, jotka ennustetaan oikein negatiivisiksi. ROC-käyrä (engl. Receiver Operating Characteristic) kuvaa todellisten positiivisten osuuden suhdetta virheellisten positiivisten osuuteen. AUC-arvo (engl. Area Under the Receiver Operator Characteristics Curve) kuvaa mallin kykyä erottaa positiiviset ja negatiiviset toisistaan. [27] Tekoälymallille hyvä AUC-arvo on yli 0,90 [22].

3 OCT-kuvien analysointi

konvoluutioneuroverkkomalleilla

OCT-kuvien analysointiin koulutetut konvoluutioneuroverkkoihin pohjautuvat syväoppimismallit ovat antaneet lupaavia tuloksia glaukooman diagnostiikassa. [28] Mallit automatisoivat ja tarkentavat diagnosointiprosessia. Konvoluutioneuroverkkomallit pystyvät erottamaan kuvista paikallisia yksityiskohtia, tekstuureja sekä rakenteita, jotka kertovat glaukooman aiheuttamista vaurioista. Malleilla voi tulevaisuudessa olla tärkeä rooli oikea-aikaisessa ja tarkassa glaukooman diagnosoinnissa. [28] Kuvantunnistusta varten on kehitetty konvoluutioneuroverkkomalleja, joita voidaan hienosäätää toimimaan useassa tarkoituksessa. Kun mallia halutaan soveltaa glaukooman diagnosointiin OCT-kuvista, malli uudelleenkoulutetaan OCT-kuvilla. Malleihin lisätään tarvittaessa kerroksia, joilla suoritetaan luokittelu glaukooman ja terveen välillä. Glaukooman diagnosointiin on kehitetty myös täysin uusia konvoluutioneuroverkkomalleja. Tutkijat ovat suunnitelleet niiden arkkitehtuurit alusta alkaen ja kouluttavat mallit pelkästään OCT-kuvilla. Hienosäädettyjen ja täysin uusien mallien arkkitehtuureissa ja käyttöönotossa on yhtäläisyyksiä, jotka käsitellään seuraavissa luvuissa. Luvussa tarkastellaan, miten konvoluutioneuroverkkomalleja on sovellettu OCT-kuvien analysointiin ja glaukooman diagnosointiin. Tässä luvussa esitellään kaikkien mallien saavuttamat tulokset glaukooman diagnosoinnissa.

3.1 Hienosäädetyt mallit glaukooman diagnostiikassa

Glaukooman diagnosoinnissa voidaan hyödyntää hienosäädettyjä valmiiksi koulutettuja konvoluutioneuroverkkomalleja, jotka on kehitetty siirto-oppimisen (engl. Transfer learning) avulla. Siirto-oppiminen on toiseen tarkoitukseen kehitetyn mallin uudelleenkäyttöä ja painojen muuttamista eri kohdealueelle [22]. Alkuperäisen neuroverkon painoja käytetään lähtöarvoina ja niitä hienosäädetään (engl. Fine-tuning) eli ne optimoidaan ratkaisemaan toinen tehtävä [22].

Yleisesti käytössä olevia, valmiiksi koulutettuja (engl. Pre-trained) hienosäädettäviä malleja ovat VGG, ResNet ja Inception. Mallit on koulutettu suurella 14 miljoonan kuvan ImageNet-datasarjalla [29]. VGG (Visual Geometry Group) on kuvantunnistukseen käytettävä malli, joissa kerrosten lukumäärä on 16 tai 19, ja nimi määräytyy kerrosten perusteella (VGG16 tai VGG19) [20]. VGG-malleissa on yksinkertaisia konvoluutiolohkoja ja suodattimien määrä kasvaa, kun ominaisuuskarttojen koko pienenee. Molemmissa VGG-versioissa on viisi konvoluutiolohkoa, joissa on kaksi tai kolme konvoluutiokerrosta ja yhdistävä kerros. [20] ResNet (Residual Network) malleissa kerroksia voi olla 18–1202 [22]. ResNet-malleissa käytetään jäänöslohkoihin perustuvia ohituskytkentöjä, joiden avulla tieto voi ohittaa kerroksia. Ohituskytkennät mahdollistavat syvät ja tehokkaat neuroverkot. [30] Glaukooman diagnosointiin on sovellettu ResNet50-mallia, jossa on nimensä mukaan 50 kerrosta. Inception-malleja on V1-V4 ja ne perustuvat tehokkaisiin Inception-lohkoihin, jotka toimivat kuten konvoluutiolohkot eli eristävät ominaisuuksia [31]. Inception V3 on suunniteltu kuvantunnistukseen ja luokitteluun, joten sitä voidaan soveltaa glaukooman diagnosointiin. Alkuperäisessä mallissa on 42 kerrosta. [32]

Mallien syötteenä on OCT-kuva. Konvoluutioneuroverkkomallit on suunniteltu toimimaan RGB-väriskaalan (Red, Green, Blue) kuvien kanssa, joten ne tarvitsevat

kolmekanavaisen syötteen eli jokaiselle värille oman kanavan. OCT-kuvat ovat mustavalkoisia, joten kuvat kopioidaan syötössä kolmesti, jotta jokaiseen kanavaan saadaan kuva. [33] Glaukooman diagnosointiin käytetyissä konvoluutioneuroverkkomalleissa konvoluutiokerrokset eristävät paikallisia piirteitä seuraaville kerroksille [34]. Paikallisia piirteitä ovat näköhermon pään muutokset ja verkkokalvon hermosäiekerroksen oheneminen. Kokonaan yhdistetyt kerrokset ennustavat luokittelun terveisiin ja glaukoomaa sairastaviin [34]. Luokittelutehtävissä konvoluutioneuroverkkomallin neuronien lukumäärä ulostulokerroksessa vastaa luokkien lukumäärää. Glaukooman diagnosointiin sovelletuissa malleissa luokkia on kaksi eli viimeisessä kerroksessa neuroneita on kaksi. Luokittelussa käytetään erityistä epälineaarista funktiota, jota kutsutaan softmax-funktioksi. Funktio laskee todennäköisyyden potilaan kuulumiseksi kuhunkin luokkaan. [19]

Konvoluutioneuroverkkomallit täytyy kouluttaa, validoida ja testata ennen käyttöä. Tähän käytetään datasarjoja, jotka jaetaan lohkoihin koulutusta, validointia ja testausta varten. Koulutus tehdään yleensä erissä (engl. Batch), jotka valitaan satunnaisesti koulutusdatasta. Koulutusdatan avulla neuroverkon painot optimoidaan. [22] Epookki (engl. Epoch) on koko koulutusdatan täydellinen läpikäynti konvoluutioneuroverkolla eli opetuskierron [18]. Mallit oppivat yleensä paremmin, kun opetuskierrosten määrä kasvaa [33]. Validoinnin avulla mallille valitaan sopivat parametrit ja hienosäädöt. Mallin suorituskyky testataan testausdatalla. Testaus tulisi suorittaa monipuolisella ja riippumattomalla aineistolla, jotta mallin yleistettävyyden varmistuisi kliinisissä olosuhteissa. [22]

Nishanth ja muut [33] tutkivat hienosäädettävien mallien, VGG16 ja VGG19, ResNet50 sekä Inception V3 käyttöä glaukooman diagnosoinnissa OCT-kuvista. Malleja hienosäädettiin ja uudelleenkoulutettiin tunnistamaan glaukooma OCT-kuvista. Täysin yhdistetyt kerrokset suorittavat malleissa lopullisen luokittelun. Luokittelua varten malleihin lisättiin neljä kerrosta, joista viimeisessä kaksi neuro-

nia vastaamaan haluttuja luokkia. Mallit koulutettiin 1000 opetuskerroksella, eräkoolla (engl. Batch size) 32. Malli testattiin 246 OCT-kuvalla, joista 162 terveiden potilaiden ja 84 glaukoomaa sairastavien. [33]

Hienosäädetyistä malleista parhaiten suoriutui VGG16. Mallin tarkkuus, herkkyys ja F1-pisteet olivat 0,92 ja keskimääräinen AUC-arvo 0,96. Inception V3 suoriutui malleista heikoiten ja sillä saavutettiin 0,85 tarkkuus, herkkyys sekä F1-pisteet. Inception V3 keskimääräinen AUC-arvo oli 0,92. Toiseksi parhaat tulokset saatiin mallilla VGG19. Tarkkuus, herkkyys ja F1-pisteet olivat 0,92 sekä AUC-arvo 0,95. ResNet50 saavutti vain hieman paremmat tulokset kuin Inception V3. Tarkkuus oli 0,88, herkkyys ja F1-pisteet 0,87 ja AUC-arvo 0,92. Nishanth ja muut [33] totesivat, että näistä malleista VGG16 soveltuu parhaiten havaitsemaan glaukoomaa OCT-kuvista. [33]

Anandhi ja muut [29] hienosäätivät samoja konvoluutioneuroverkkomalleja kuin Nishanth ja muut [33] eli VGG:t, Inception V3 ja ResNet50. Mallien yleistä tietoa sisältävien kerrosten ennakkoon opetetut painot säilytettiin. Mallien viimeiset konvoluutiokerrokset uudelleen koulutettiin OCT-kuvien avulla. Koulutukseen käytettiin 125 opetuskerrosta ja eräkokoa 16. Malli testattiin 250 OCT-kuvalla, joista 95 oli glaukoomaa sairastavien ja 155 terveiden potilaiden OCT-kuvia. [29]

Hienosäädetyistä malleista VGG16 suoriutui parhaiten 0,91 herkkyydellä, 0,93 spesifisyydellä, 0,91 F1-pisteillä ja AUC-arvolla 0,95. ResNet50 saavutti hienosäädetyistä malleista heikoimman herkkyyden 0,85, spesifisyyden 0,88, F1-pisteet 0,86 ja AUC-arvon 0,90. Toiseksi parhaiten suoriutui VGG19 herkkyydellä 0,90, spesifisyydellä 0,92, F1-pisteillä 0,90 ja AUC-arvolla 0,94. Inception V3 herkkyys oli 0,86, spesifisyys 0,89, F1-pisteet 0,87 ja AUC-arvo 0,91. Anandhi ja muut [29] totesivat myös, että VGG16 suoriutuu selkeästi parhaiten muihin malleihin verrattuna. Anandhi ja muut [29] sekä Nishanth ja muut [33] tulokset hienosäädettyjen konvoluutioneuroverkkomallien testeistä on koottu Taulukkoon 3.1.

3.2 Uudet mallit glaukooman diagnostiikassa

Nishanth ja muut [33] suunnittelivat oman konvoluutioneuroverkkomallin, joka luokittelee potilaat terveisiin ja glaukoomaa sairastaviin OCT-kuvien perusteella. Tutkimuksen aikana terveiden potilaiden ja glaukoomaa sairastavien OCT-kuvia eli tutkimuksessa käytettävää dataa kerättiin reaaliajassa. Dataa prosessoitiin ja segmentointiin Heidelbergin ohjelmistolla. Heidelbergin ohjelmisto on OCT-kuvien analysointialusta, jossa kuville voidaan suorittaa erilaisia segmentointeja ja mittauksia [35]. Segmentointi tehtiin näköhermon pään muutosten ja verkkokalvon hermosäiekerroksen ohenemisen perusteella. Potilaille luotiin käyrä, joka kuvaa verkkokalvon kerrosten keskimääräistä paksuutta. Näin saatiin kaavio, joka kertoo onko potilaan arvot terveiden viitearvojen sisällä vai niiden ulkopuolella, jolloin glaukooma on mahdollinen. Kaavion perusteella OCT-kuvat jaettiin terveisiin ja glaukoomaa sairastaviin. [33]

Tutkimuskäyttöön saatiin 246 kuvaa, joista 162 terveiden potilaiden ja 84 glaukoomaa sairastavien. Kuvien määrien välillä on epätasapaino, joka pitää ottaa huomioon mallia koulutettaessa siten, että malli kiinnittää enemmän huomiota glaukoomaa sairastavien kuviin. Kerätty data jaettiin kolmeen lohkokoon, joita käytetään kouluttamiseen, validointiin ja testaukseen. [33]

Konvoluutioneuroverkkomallissa on kaksi konvoluutiolohkoa. Lohkot koostuvat kahdesta konvoluutiokerroksesta, joissa on 3 x 3 kokoiset suodattimet sekä ReLU-funktio. Lohkojen välissä on drop-out, joka pyrkii estämään ylisovitusta katkaisemalla satunnaisesti neuronien yhteyksiä. [33] Konvoluutiokerrosten jälkeen on kaksi yhdistävää kerrosta. Toisen yhdistävän kerroksen jälkeen on kokonaan yhdistetyt kerrokset, joissa luokittelu tehdään. Viimeisenä on softmax-funktio, joka määrittää luokituksen todennäköisyyden. Yhteensä mallissa on kahdeksan kerrosta. Malli koulutettiin 1000 opetuskierröksellä, eräkoolla 32. [33]

Taulukko 3.1: Hienosäädettyjen ja uusien konvoluutioneuroverkkomallien tulokset glaukooman diagnosoinnissa.

Tutkimus	Malli	Herkkyys	Spesifisyys	Tarkkuus	AUC	F1
Nishanth et al.	uusi	0,76	-	0,81	-	0,76
Anandhi et al.	uusi	0,87	0,90	-	0,92	0,88
Nishanth et al.	VGG16	0,92	-	0,92	0,96	0,92
Anandhi et al.	VGG16	0,91	0,93	-	0,95	0,91
Nishanth et al.	VGG19	0,92	-	0,92	0,95	0,92
Anandhi et al.	VGG19	0,90	0,92	-	0,94	0,90
Nishanth et al.	ResNet50	0,87	-	0,88	0,92	0,87
Anandhi et al.	ResNet50	0,85	0,88	-	0,90	0,86
Nishanth et al.	Inception V3	0,85	-	0,85	0,92	0,85
Anandhi et al.	Inception V3	0,86	0,89	-	0,91	0,87

Koulutuksen jälkeen malli testattiin testausdatalla ja sillä saavutettiin seuraavia tuloksia. Nishanth ja muut [33] suunnitteleman mallin tarkkuus oli 0,78, herkkyys ja F1-pisteet 0,74. Suunniteltua mallia uudelleenkoulutettiin datan augmentoinnin avulla. Luokittelun tarkkuus parantui hieman, kun mallin tarkkuus oli datan augmentoinnin jälkeen 0,81, herkkyys 0,76 ja F1-pisteet 0,76. [33] Tutkimuksessa saatiin suunniteltua uusi konvoluutioneuroverkkomalli, joka kykenee erottamaan terveet ja glaukoomaa sairastavat potilaat melko hyvällä tarkkuudella.

Anandhi ja muut [29] suunnittelivat myös oman uuden konvoluutioneuroverkkomallin glaukooman havaitsemiseen verkkokalvon hermosäiekerroksen paksuuden perusteella. Tutkimuksessa käytetty yksityinen data jaettiin koulutus- ja testausdataan. Koulutukseen käytettiin 80 % kuvista, joista 76 oli glaukoomaa sairastavien kuvia ja 125 terveiden OCT-kuvia. Loput 20 % OCT-kuvista toimi testinäytteenä, joka koostui 19 glaukoomaa sairastavan potilaan kuvista ja 30 terveestä kuvasta.

Kaksi asiantuntijaa kävi läpi kaikki kuvat, jotta diagnoosien oikeellisuus voitiin tarkistaa. Koulutuksen aikana käytettiin sisäistä ristiinvalidointia (engl. Internal Cross-Validation, ICV), joka jakaa koulutusdatan osiin toistuvaa validointia varten. [29]

Anandhi ja muut [29] suunnittelemassa konvoluutioneuroverkkomallissa on neljä lohkoa. Konvoluutiokerroksissa käytettiin 3 x 3 suodattimia. Konvoluutiokerrosten jälkeen mallissa on yhdistävät kerrokset. Toisin kuin Nishanth ja muut [33] mallissa drop-out kerrokset jätettiin pois, koska ne eivät parantaneet mallin suorituskykyä validointivaiheessa [29]. Viimeisenä kerroksena oli softmax-funktio ja kaksi neuronua luokittelemaan glaukoomaa sairastava ja terve potilas. Mallissa on yhteensä 11 kerrosta. Malli koulutettiin 150 opetuskierröksellä, eräkoolla 16, ja testattiin testausdatalla. Tähän tutkimukseen suunniteltu uusi malli saavutti 0,90 spesifisyyden, 0,87 herkkyden, F1-pisteet 0,88 sekä AUC-arvon 0,92. [29] Glaukooman diagnosointiin kehitettyjen uusien konvoluutioneuroverkkomallien tulokset on koottu Taulukkoon 3.1.

4 Pohdinta

Nishanth ja muut [33] sekä Anandhi ja muut [29] suorittivat samankaltaisen tutkimuksen konvoluutioneuroverkkojen hyödyntämisestä glaukooman diagnosointiin OCT-kuvista. Molemmat tutkimusryhmät hienosäätivät kuvantunnistukseen suunniteltuja konvoluutioneuroverkkomalleja sekä kehittivät oman arkkitehtuurin, ja kouluttivat sen alusta alkaen. Tuloksissa oli myös yhtäläisyyksiä. Hienosäädetyt VGG16 ja VGG19-mallit suoriutuivat molemmissa tutkimuksissa parhaiten. ResNet50 ja Inception V3 pärjäsivät molemmissa tutkimuksissa heikommin, melko samanlaisilla tuloksilla. Nishanth ja muut [33] uusi malli suoriutui selkeästi heikoiten kaikista malleista. Anandhi ja muut [29] malli saavutti samankaltaiset tulokset kuin ResNet50 ja Inception V3. Tulosten vaihteluväli on pieni. Glaukooman diagnosoinnissa pienetkin erot ovat merkittäviä, koska diagnoosin oikeellisuuden kannalta on tärkeää, että luokittelu on mahdollisimman tarkkaa.

Hienosäädettyjen ja uusien konvoluutioneuroverkkomallien tulosten vertailuun voidaan käyttää mallien AUC-arvoja, herkkyyttä ja F1-pisteitä. Nishanth ja muut [33] käyttivät lisäksi tarkkuutta kuvaamaan tuloksia ja Anandhi ja muut [29] spesifisyyttä. Suureet eivät ole vertailukelpoisia keskenään, joten johtopäätökset tuloksista tulee tehdä AUC-arvon, herkkyuden ja F1-pisteiden perusteella.

Luvussa 2 todettiin, että tekoälymallille hyvä AUC-arvo on yli 0,90 [22]. Kaikki hienosäädetyt mallit sekä Anandhi ja muut [29] uusi konvoluutioneuroverkkomalli saavuttivat vähintään 0,90 AUC-arvon. Parhaimman AUC-arvon, jopa 0,96, saavut-

ti VGG16 Nishanth ja muut [33] tutkimuksessa. VGG -mallien AUC-arvot olivat tutkimusten parhaita, kaikkien ollessa väliltä 0,94–0,96. Anandhi ja muut [29] uuden mallin, ResNet50 ja Inception V3 AUC-arvot sijoittuivat välille 0,90–0,92. Heikoin AUC-arvon 0,90 saavutti ResNet50 Anandhi ja muut [29] tutkimuksessa. Nishanth ja muut [33] esittivät tutkimuksessaan ROC-käyrän omasta mallistaan graafisesti, mutta numeerista AUC-arvoa ei esitetty, joten mallia ei pystytä vertaamaan muihin malleihin AUC-arvon kannalta. AUC-arvo kuvaa glaukooman diagnostiikan tapauksessa sitä, kuinka tarkasti malli on erottanut glaukoomaa sairastavat ja terveet potilaat toisistaan. Hienosäädetyjä ja uusia konvoluutioneuroverkkomalleja voidaan pitää ainakin luokkien erotuskyvyn tarkkuuden kannalta glaukooman diagnosointiin soveltuvina hyvän AUC-arvon takia.

Glaukooman diagnosoinnissa mallin herkkyys kuvaa sitä, kuinka monta glaukoomaa sairastavan potilaan OCT-kuvaa konvoluutioneuroverkkomalli on luokitellut glaukoomaa sairastavaksi. Parhaimmat herkkyydet 0,90–0,92 saavuttivat VGG-mallit. ResNet50 ja Inception V3 saavuttivat 0,85–0,87 herkkyyksiä eli hieman heikompia kuin VGG-mallit. Anandhi ja muut [29] uusi malli saavutti 0,87 herkkyyden eli se luokitteli kuvia oikein melko samalla herkkyydellä kuin ResNet50 ja Inception V3 mallit. Nishanth ja muut [33] uusi malli saavutti selkeästi huonoimman, 0,76 herkkyyden. Malli ei siis pystynyt luokittelemaan läheskään kaikkia glaukoomaa sairastavien OCT-kuvia glaukoomaa sairastavaksi. VGG-mallien suuret herkkyydet kertovat, että ne pystyvät luokittelemaan oikein glaukoomaa sairastavien OCT-kuvia glaukoomaa sairastaviksi.

Konvoluutioneuroverkkojen tulosten arviointiin käytettävät F1-pisteet kertovat tarkkuuden ja herkkyyden keskiarvon. Suurimmat F1-pisteet 0,90–0,92 saavuttivat jälleen VGG-mallit. Kuten herkkyyden kohdalla, ResNet50 ja Inception V3 saavuttivat hieman heikommät pisteet 0,85–0,87. Anandhi ja muut [29] uusi malli saavutti paremmat F1-pisteet, 0,88 kuin ResNet50 ja Inception V3. Nishanth ja muut [33]

uusi malli saavutti heikoimmat F1-pisteet 0,76. Myös F1-pisteiden kannalta VGG-mallit soveltuvat parhaiten glaukooman diagnosointiin.

Konvoluutioneuroverkkomallien saavuttamat tulokset ovat johdonmukaisia. Kaikien suorituskkyparametrien kannalta VGG-mallit onnistuivat luokittelussa parhaiten. ResNet50 ja Inception V3 sekä Anandhi ja muut [29] uusi malli saavuttivat hieman heikompia tuloksia kuin VGG:t. Kaikista huonoiten suoriutui Nishanth ja muut [33] uusi malli. Tuloksista voidaan päätellä, että syvempien mallien hyödyntäminen parantaa tuloksia. VGG16 ja VGG19 suoriutuivat paremmin, kuin matalimmat Nishanth ja muut [33] suunnittelema kahdeksan kerroksen arkkitehtuuri, tai Anandhi ja muut [29] suunnittelema 11-kerroksen malli. Syvimmät mallit Inception V3 ja ResNet50 suoriutuivat huonommin kuin VGG-mallit, joten kerrosten määrän lisääminen on hyödyllistä vain tiettyyn määrään asti. Matalimpien mallien eli Nishanth ja muut [33] kahdeksan kerroksen sekä Anandhi ja muut [29] 11-kerroksen mallien tuloksissa havaitaan suurimmat erot tuloksissa. Mallit saavuttivat parhaimmillaan herkkyudet 0,76 ja 0,87 sekä F1-pisteet 0,76 ja 0,88. Nishanth ja muut [33] mallissa oli kaksi konvoluutiolohkoa ja Anandhi ja muut [29] mallissa neljä. Molemmissa käytettiin samankokoisia suodattimia, eikä käytettävissä olevan datan määrässä ollut suurta eroa. Voidaan todeta, että muiden erojen ollessa pienet, konvoluutiolohkojen määrä näyttäisi parantavan tuloksia. Päätelmää tukee se, että molemmissa tutkimuksissa parhaiten suoriutuneissa VGG16 ja VGG19 malleissa on viisi konvoluutiolohkoa [20].

Uusien mallien koulutukseen käytettyjen opetuskerrosten määrässä oli huomattava ero. Nishanth ja muut [33] malli koulutettiin 1000 opetuskerroksella, eräkoolla 32 ja Anandhi ja muut [29] vain 150 opetuskerroksella, 16 eräkoolla. Anandhi ja muut [29] malli suoriutui paremmin erosta huolimatta. Nishanth ja muut [33] mukaan mallit oppivat paremmin kuin opetuskerrosten lukumäärä kasvaa. Näissä tutkimuksissa opetuskerrosten lukumäärässä on suuri ero, mutta silti vähemmällä

opetuskierröksillä koulutettu Anandhi ja muut [29] malli suoriutui paremmin. Joten Nishanth ja muut [33] väite ei pidä paikkaansa näiden matalampien, uusien konvoluutioneuroverkkomallien kohdalla. Nishanth ja muut [33] tutkimuksessa hienosäädetyt konvoluutioneuroverkkomallit koulutettiin myös 1000 opetuskierröksellä ja 32 eräkoolla. Anandhi ja muut [29] kouluttivat mallit 125 opetuskierröksellä ja eräkoolla 16. Hienosäädettyjen mallien kohdalla useammalla opetuskierröksellä tulokset olivat paremmat kuin vähemmällä opetuskierröksillä. Kaikki muut mallit, Inception V3 lukuun ottamatta suoriutuivat Nishanth ja muut [33] tutkimuksessa paremmin. Uusien mallien kohdalla opetuskierrösten lisääminen ei parantanut tuloksia, mutta hienosäädettyjen mallien tuloksia se paransi yleisesti. Epäjohdonmukaisuus voi liittyä eroihin mallien arkkitehtuureissa. Hienosäädetyt, syvemmät mallit tarvitsevat useampia opetuskierröksiä, oppiakseen tunnistamaan haluttuja piirteitä tarkasti. Matalammissa malleissa tuloksiin näyttäisi vaikuttavan enemmän konvoluutiolohkojen määrä kuin opetuskierrökset. Uusien mallien kohdalla useampi opetuskierrös on saattanut aiheuttaa Nishanth ja muut [33] malliin ylisovitusta, joka on heikentänyt tuloksia. Anandhi ja muut [29] malli ei välttämättä ylisovittunut yhtä paljoa, jolloin tulokset olivat parempia.

Koulutukseen käytetyn datan määrällä voisi myös olla merkitystä tuloksissa. Näiden tutkimusten kohdalla siinä ei kuitenkaan ole johdonmukaisuutta. Nishanth ja muut [33] sekä Anandhi ja muut [29] tutkimuksilla oli käytössään suunnilleen saman verran kuvadataa. Uusien mallien tuloksissa oli kuitenkin suuria eroja. Hienosäädetyt mallit oli koulutettu valmiiksi miljoonien kuvien datasarjalla. Uudet mallit koulutettiin pienillä alle 300 OCT-kuvan datasarjoilla. Hienosäädetyistä malleista ResNet50 ja Inception V3 saavuttivat samankaltaisia tuloksia kuin Anandhi ja muut [29] malli, vaikka koulutukseen käytetyn datan määrässä on huomattava ero. Nishanth ja muut [33] keräsivät tutkimusaineiston itse ja Anandhi ja muut [29] hyödynsivät yksityistä dataa. Mallien luotettavuuden vertailun kannalta datan pieni

määrä ja erilaisuus tuo haasteita. Tulevaisuudessa tulisi kerätä suuri avoin, ImageNetin kaltainen, OCT-kuvien datasarja. Suurta, samankaltaista dataa käyttämällä konvoluutioneuroverkkomalleja voitaisiin vertailla luotettavammin.

Edellä esitetyn perusteella konvoluutioneuroverkon arkkitehtuurilla on selkeästi vaikutusta mallin saavuttamiin tuloksiin. VGG-malleissa on viisi konvoluutiolohkoa, jotka eristävät glaukoomalle tyypillisiä piirteitä OCT-kuvista. ResNet50-mallissa käytetään jäännöslohkoja ja Inception V3-mallissa Inception-lohkoja, joten niitä ei voida suoraan verrata konvoluutiolohkoihin. Tulosten perusteella konvoluutiolohkot toimivat kuitenkin paremmin kuin muut lohkot, koska niitä hyödyntävät VGG-mallit suoriutuivat selkeästi parhaiten. Molempien tutkimusten välillä kokonaisuutta tarkastellen VGG16 ja VGG19-mallien tulosten väliset erot ovat hyvin pieniä. VGG16 saavutti kuitenkin molemmissa tutkimuksissa parhaimmat tulokset. Sitä voidaan pitää tulosten perusteella glaukooman diagnosointiin soveltuvana konvoluutioneuroverkkomallina. Nishanth ja muut [33] mukaan VGG16 vaatii kuitenkin suuren laskennallisen tehon, paljon muistia ja pidemmän koulutusajan. Teho ja muistinkulutus ovat asioita, jotka täytyy ottaa huomioon kun mallia ollaan ottamassa kliiniseen jokapäiväiseen käyttöön. Tulevaisuuden tutkimuksissa nämä asiat tulee ottaa huomioon, jotta mallin soveltuvuutta voidaan arvioida kokonaisvaltaisesti. Tässä tutkielmassa kuitenkin tarkastellaan vain mallin soveltamista glaukooman diagnosointiin ja tuloksia, joita mallilla on saavutettu.

Ylisovitus on yksi konvoluutioneuroverkkojen hyödyntämisen haasteista. OCT-kuvissa esiintyy artefakteja, kuten verisuonien varjostumia ja liikeartefakteja. Artefaktit heikentävät kuvanlaatua ja johtavat syväoppimismalleja harhaan. Mallit ylisovittuvat artefakteihin koulutusdatassa, jonka takia ne suoriutuvat huonommin OCT-kuvien analysoinnissa. [36] OCT-kuvien analysointiin koulutetut konvoluutioneuroverkkomallit saattavat oppia tunnistamaan piirteitä, jotka eivät ole glaukoomalle tyypillisiä ja näin suorittaa virheellisiä luokitteluja. Datatunnetun augmentoinnin avulla yli-

sovitusta voidaan yrittää vähentää. Augmentoinnilla konvoluutioneuroverkkomallin kykyä yleistää yritetään parantaa, kun malli oppii tunnistamaan glaukooman piirteitä eri kuvan asennoissa ja valaistuksissa. Nishanth ja muut [33] yrittivät estää ylisovitusta drop-out kerroksella sekä datan augmentoinnilla. Anandhi ja muut [29] totesivat omassa tutkimuksessaan, että drop-out ei parantanut tuloksia. Tutkimusten tuloksista nähdään, että Anandhi ja muut [29] malli suoriutui paremmin kuin Nishanth ja muut [33] malli, joten ylisovituksen kannalta ainakaan drop-out kerroksella ei ollut mallissa luokittelua parantavaa merkitystä.

Nishanth ja muut [33] tutkimuksessa uusi konvoluutioneuroverkkomalli koulutettiin uudelleen datan augmentoinnin avulla. Luokittelun tarkkuus parantui, ja ylisovitus vähentyi, mutta ei kadonnut kokonaan. Anandhi ja muut [29] totesivat, että ilman datan augmentointia koulutetussa konvoluutioneuroverkkomallissa tapahtui validaatiovaiheessa ylisovitusta. Ylisovitus näkyi tuloksissa herkkyyden korkeana keskihajontana [29]. Anandhi ja muut [29] hyödynsivät myös datan augmentointia ja se vähensi ylisovitusta eli paransi mallin kykyä yleistää. Datan augmentointi voisi siis olla ratkaisu ylisovituksen vähentämiseen. Augmentoinnin vaikutusta tuloksiin tulisi tutkia lisää, jotta sen tehokkuudesta voitaisiin varmistua.

Toinen syväoppimismallien haasteista on niiden tulkittavuus (engl. Interpretability). Mallit toimivat mustina laatikoina, jotka tekevät luokittelua ilman selkeitä perusteluja. OCT-kuvissa on yksityiskohtaisia piirteitä ja useita verkkokalvon kerroksia, joten tulkittavuuden puute on ongelma. Diagnooseja tekevät lääkärit tarvitsevat tietoa siitä, millä perusteella malli on tehnyt luokittelun, jotta he voivat luottaa diagnoosin tarkkuuteen. [36] Jotta syväoppimismalleja voitaisiin ottaa kliinisesti käyttöön glaukooman diagnosointiin, täytyisi mallien tulkittavuutta parantaa. Ammattilaisten täytyy tietää, onko syväoppimismalli käyttänyt luokittelun perustana oikeita glaukooman piirteitä.

Luokka-aktivaatiokartat (engl. Class Activation Maps, CAM) ja niiden avulla luodut lämpökartat ovat yksi ratkaisu mallien tulkittavuuden parantamiseen. Lämpökartat näyttävät alueet, joihin malli keskittyy kunkin OCT-kuvan luokan määrittämisessä. Anandhi ja muut [29] sovelsivat tutkimukseensa luokka-aktivaatiokarttoja. Kartoista nähtiin, että syväoppimismalli keskittyi diagnosoinnissa samoihin kohtiin, joita asiantuntijat käyttävät diagnoosin perustana [29]. Verkkokalvon hermosäiekeroksen oheneminen viittaa glaukoomaan ja paksumpi kerros terveisiin silmiin. Malli piti juuri näitä ominaisuuksia tärkeinä luokittelua suoritettaessa. Tämän perusteella luokka-aktivaatiokarttojen hyödyntäminen parantaisi mallin tulkittavuutta ja luotettavuutta. Luokka-aktivaatiokarttojen lisääminen syväoppimismalleihin edistäisi niiden sopivuutta kliiniseen käyttöön.

5 Yhteenveto

Tässä tutkielmassa tarkasteltiin konvoluutioneuroverkkojen soveltamista glaukooman diagnosointiin OCT-kuvista. Glaukooman varhaisen diagnoosin avulla vakavien, näkökykyyn vaikuttavien hermovaurioiden syntymistä saadaan estettyä. OCT-kuvauksella silmän verkkokalvon hermosäiekerrosta ja näköhermoa saadaan kuvannettua sekä helposti että tarkasti. OCT-kuvia voitaisiin luokitella terveiksi ja glaukoomaa sairastaviksi konvoluutioneuroverkkomallien avulla. Konvoluutioneuroverkkomalleilla diagnosointia saataisiin nopeutettua ja tarkennettua. Konvoluutioneuroverkot rakentuvat useista kerroksista, joissa neuronit eristävät kuvista haluttuja piirteitä ja suorittavat niiden perusteella kuvan luokittelun. Konvoluutioneuroverkkomallien hyödyntäminen OCT-kuvien analysointiin on uutta ja siihen liittyy haasteita. Johdannossa esitettyihin tutkimuskysymyksiin voidaan vastata kirjallisuuskatsauksen pohjalta seuraavasti:

TK1: Glaukooman diagnosointiin OCT-kuvista on hienosäädetty useita kuvantunnistukseen kehitettyjä konvoluutioneuroverkkomalleja. Hienosäädettyjä malleja ovat VGG16, VGG19, ResNet50 ja Inception V3. Mallit on koulutettu valmiiksi erittäin suurella datamäärällä ja niillä on ennalta yleistä osaamista kuvantunnistusta varten. Muihin tarkoituksiin kehitetyt mallit on uudelleen koulutettu OCT-kuvien avulla. Malleja on sovellettu glaukooman diagnosointiin lisäämällä niihin kerroksia, joiden avulla malli luokittelee OCT-kuvat terveisiin ja glaukoomaa sairastaviin. Glaukooman diagnosointiin on kehitetty myös täysin uusia konvoluutioneuroverk-

komalleja. Niiden arkkitehtuurit on suunniteltu itse tutkimusryhmien toimesta ja ne on koulutettu alusta alkaen OCT-kuvilla. Kaikkien glaukooman diagnosointiin sovellettujen konvoluutioneuroverkkomallien tavoite ja toimintaperiaate on samanlainen. Syötteenä on OCT-kuva. Erilaisten kerrosten avulla mallit eristävät kuvista glaukooman piirteitä ja lopuksi suorittavat kuvalle luokittelun terveisiin tai glaukoomaa sairastaviin. Mallit eroavat toisistaan arkkitehtuureiltaan, kerrosten rakenteilta ja lukumääriltä.

TK2: Konvoluutioneuroverkkomalleilla on saatu lupaavia, mutta vaihtelevia tuloksia. Uudet konvoluutioneuroverkkomallit pystyivät luokittelemaan potilaita melko hyvällä tarkkuudella terveisiin ja glaukoomaa sairastaviin. Hienosäädetyt mallit, erityisesti VGG16 ja VGG19 saavuttivat tutkimuksissa selkeästi muita malleja paremmat tulokset. Mallien suorituskykyä arvioidaan useilla parametreilla, ja niiden kaikkien perusteella VGG16 on osoittanut parhaita tuloksia. VGG16 pystyy luokittelemaan potilaiden OCT-kuvia oikein ja tarkasti glaukoomaa sairastaviksi tai terveiksi. Tulosten perusteella VGG16 malli soveltuu glaukooman diagnosointiin OCT-kuvista.

Konvoluutioneuroverkkomallien hyödyntäminen glaukooman diagnosoinnissa voisi merkittävästi parantaa ja tehostaa diagnostiikkaa. Tulevaisuudessa malleja tulisi vertailla samanlaisilla datasarjoilla sekä yhdenmukaisella koulutuksella. Näin saataisiin varmuutta mallien toimivuuteen sekä tarkkuuteen. Jotta konvoluutioneuroverkkomalleja voitaisiin ottaa kliniseen käyttöön, täytyy niiden luokittelun tarkkuuteen luottaa täysin. Luotettavuutta lisäisi luokka-aktivaatiokarttoihin perustuvat lämpökartat, joiden perusteella diagnoosin oikeellisuus voidaan varmistaa. Konvoluutioneuroverkkomallien hyödyntämisestä glaukooman diagnosointiin tarvitaan lisää tutkimustietoa ja näyttöä niiden toimivuudesta. Kattavan tutkimustiedon avulla konvoluutioneuroverkot voitaisiin saada osaksi asiantuntijoiden päivittäistä työtä, avustamaan ja tehostamaan glaukooman diagnosointia.

Lähdeluettelo

- [1] H. Uusitalo, *Glaukooman diagnostiikan ja hoidon periaatteet*, Duodecim Oppiportti, 2022. url: <https://www.oppiportti.fi/oppikirjat/sil00166>, (viitattu 22.10.2025).
- [2] Glaucoma Research Foundation, *Glaucoma Facts and Stats*, 2024. url: <https://glaucoma.org/articles/glaucoma-facts-and-stats>, (viitattu 29.9.2025).
- [3] M. Seppänen, *Silmänpainetauti (glaukooma)*, Duodecim Terveyskirjasto, 2021. url: <https://www.terveyskirjasto.fi/dlk00452>, (viitattu 22.10.2025).
- [4] J. P. Kytö ja P. Tommila, ”Silmänpohjan valokerroskuvaus”, *Duodecim*, vol. 121, nro 15, s. 1645–1652, 2005.
- [5] V. Pavani et al., ”Glaucoma Detection using Convolution Neural Networks”, teoksessa *2023 7th International Conference on Computing Methodologies and Communication (ICCMC)*, 2023, s. 368–372. DOI: 10.1109/ICCMC56507.2023.10083864.
- [6] J. S. Schuman, M. De Los Angeles Ramos Cadena, R. McGee, L. A. Al-Aswad ja F. A. Medeiros, ”A Case for the Use of Artificial Intelligence in Glaucoma Assessment”, *Ophthalmology Glaucoma*, vol. 5, nro 3, 2022. DOI: 10.1016/j.ogla.2021.12.003.

- [7] X. Huang et al., ”Artificial intelligence in glaucoma: opportunities, challenges, and future directions”, *BioMedical Engineering OnLine*, vol. 22, nro 1, s. 126, 2023. DOI: 10.1186/s12938-023-01187-8.
- [8] M. F. Bear, B. W. Connors ja M. A. Paradiso, *Neuroscience : exploring the brain*, Enhanced fourth edition. Burlington, MA: Jones ja Bartlett Learning, 2016, ISBN: 9781284618747.
- [9] H. Uusitalo ja M. Seppänen, *Silmän perusanatomia*, Duodecim Oppiportti, 2022. url: <https://www.oppoportti.fi/sil00257>, (viitattu 22.10.2025).
- [10] H. Uusitalo, *Primaarinen avokulmaglaukooma (glaucoma simplex)*, Duodecim Oppiportti, 2022. url: <https://www.oppoportti.fi/sil00283>, (viitattu 22.10.2025).
- [11] H. Uusitalo, *OCT glaukooman diagnostiikassa*, Duodecim Oppiportti, 2022. url: <https://www.oppoportti.fi/sil00170>, (viitattu 22.10.2025).
- [12] D. P. Popescu et al., ”Optical coherence tomography: fundamental principles, instrumental designs and biomedical applications”, *Biophysical Reviews*, vol. 3, nro 3, s. 155, 2011. DOI: 10.1007/s12551-011-0054-7.
- [13] J. A. Izatt ja M. A. Choma, ”Theory of Optical Coherence Tomography”, teoksessa *Optical Coherence Tomography: Technology and Applications*, Springer, 2008, s. 47–72. DOI: 10.1007/978-3-540-77550-8_2.
- [14] S. Aumann, S. Donner, J. Fischer ja F. Müller, ”Optical Coherence Tomography (OCT): Principle and Technical Realization”, teoksessa *High Resolution Imaging in Microscopy and Ophthalmology: New Frontiers in Biomedical Optics*, Springer, 2019, s. 59–85. DOI: 10.1007/978-3-030-16638-0_3.
- [15] F. Lexer, C. K. Hitzenberger, A. F. Fercher ja M. Kulhavy, ”Wavelength-tuning interferometry of intraocular distances”, *Applied Optics*, vol. 36, nro 25, s. 6548–6553, 1997. DOI: 10.1364/AO.36.006548.

- [16] L. M. Pennington ja B. Smith, *OCT: What's Under the Hood?*, Review of Optometry, 2022. url: <https://www.reviewofoptometry.com/article/oct-whats-under-the-hood>, (viitattu 22.10.2025).
- [17] Optician Village, *OCT*, url: <https://www.thevillageoptician.com/eye-tests/oct/>, (viitattu 7.12.2025).
- [18] F. Chollet, *Deep Learning with Python, Second Edition*. Manning, 2021, ISBN: 9781617296864.
- [19] S. Vieira, W. H. Lopez Pinaya, R. Garcia-Dias ja A. Mechelli, "Chapter 9 - Deep Neural Networks", teoksessa *Machine Learning*, Academic Press, 2020, s. 157–172, ISBN: 978-0-12-815739-8. DOI: 10.1016/B978-0-12-815739-8.00009-2.
- [20] W. H. Lopez Pinaya, S. Vieira, R. Garcia-Dias ja A. Mechelli, "Chapter 10 - Convolutional Neural Networks", teoksessa *Machine Learning*, Academic Press, 2020, s. 173–191, ISBN: 978-0-12-815739-8. DOI: 10.1016/B978-0-12-815739-8.00010-9.
- [21] Y. LeCun, Y. Bengio ja G. Hinton, "Deep Learning", *Nature*, vol. 521, nro 7553, s. 436–444, 2015. DOI: 10.1038/nature14539.
- [22] D. S. Ting et al., "Deep Learning in Ophthalmology: The Technical and Clinical Considerations", *Progress in Retinal and Eye Research*, vol. 72, 2019, ISSN: 1350-9462. DOI: 10.1016/j.preteyeres.2019.04.003.
- [23] P. Thanapol, K. Lavangnananda, P. Bouvry, F. Pinel ja F. Leprévost, "Reducing Overfitting and Improving Generalization in Training Convolutional Neural Network (CNN) under Limited Sample Sizes in Image Recognition", teoksessa *2020 - 5th International Conference on Information Technology (InCIT)*, 2020, s. 300–305. DOI: 10.1109/InCIT50588.2020.9310787.

- [24] D. Kim, G. Lee, M. Lee, S. U. Kang ja D. Kim, *Normalized Convolutional Neural Network*, arXiv, 2025. DOI: 10.48550/arXiv.2005.05274.
- [25] V. H. Phung ja E. J. Rhee, ”A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets”, *Applied Sciences*, vol. 9, nro 21, 2019, ISSN: 2076-3417. DOI: 10.3390/app9214500.
- [26] K. Maharana, S. Mondal ja B. Nemade, ”A review: Data pre-processing and data augmentation techniques”, *Global Transitions Proceedings*, vol. 3, nro 1, s. 91–99, 2022, ISSN: 2666285X. DOI: 10.1016/j.g1tp.2022.04.020.
- [27] D. M. W. Powers, *Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation*, arXiv, 2020. url: <https://arxiv.org/abs/2010.16061>, (viitattu 22.10.2025).
- [28] A. A. Soofi ja Fazal-e-Amin, *Exploring Deep Learning Techniques for Glaucoma Detection: A Comprehensive Review*, arXiv, 2023. url: <https://arxiv.org/abs/2311.01425>, (viitattu 22.10.2025).
- [29] S. Anandhi, A. Amarnath Kumaran, P. Sivakamasundari, K. Vijayakumar, Y. J. Birnica ja S. Senthil Pandi, ”Early Detection of Glaucoma Utilizing Retinal Nerve Fiber Layer (RNFL) Investigation”, teoksessa *2024 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSES)*, 2024, s. 1–6. DOI: 10.1109/ICSES63760.2024.10910601.
- [30] M. Shafiq ja Z. Gu, ”Deep Residual Learning for Image Recognition: A Survey”, *Applied Sciences*, vol. 12, nro 18, 2022, ISSN: 2076-3417. DOI: 10.3390/app12188972.
- [31] H. Elmannai, M. Hamdi, S. Meshoul, A. A. Alhussan, M. Ayadi ja A. Ksibi, ”An Improved Deep Learning Framework for Automated Optic Disc Loca-

- lization and Glaucoma Detection”, *CMES - Computer Modeling in Engineering and Sciences*, vol. 140, nro 2, s. 1429–1457, 2024, ISSN: 1526-1492. DOI: 10.32604/cmes.2024.048557.
- [32] B. B. Sinha, A. Wary, R. Dhanalakshmi ja K. Balakrishnan, ”Transfer Learning-Based Detection of Retina Damage from Optical Coherence Tomography Images”, teoksessa *Computational Methods and Deep Learning for Ophthalmology*, Elsevier, 2023, s. 71–88. DOI: 10.1016/B978-0-323-95415-0.00002-4.
- [33] J. Nishanth ja R. Janarthanan, ”Automatic Identification of Glaucoma from Circumpapillary OCT Images Through the Use of Convolutional Neural Networks”, teoksessa *2023 International Conference on Data Science, Agents & Artificial Intelligence (ICDSAAI)*, 2023, s. 1–7. DOI: 10.1109/ICDSAAI59313.2023.10452491.
- [34] G. Litjens et al., ”A Survey on Deep Learning in Medical Image Analysis”, *Medical Image Analysis*, vol. 42, s. 60–88, 2017, ISSN: 1361-8415. DOI: 10.1016/j.media.2017.07.005.
- [35] R. Mahmoudzadeh, M. Salabati, J. Hsu ja M. A. Khan, ”Agreement of optical coherence tomography thickness measurements between Heidelberg Eye Explorer and ImageJ software”, *Canadian Journal of Ophthalmology*, vol. 57, nro 5, s. 344–349, 2022, ISSN: 0008-4182. DOI: 10.1016/j.jcjo.2021.05.018.
- [36] A. S. Abdi ja A. M. Abdulazeez, ”A comprehensive review of deep learning in OCT image segmentation and classification”, *Medicine in Novel Technology and Devices*, vol. 28, 2025, ISSN: 2590-0935. DOI: 10.1016/j.medntd.2025.100396.