
Konvoluutioneuroverkot aivokasvainten magneettikuvauksessa

TkK-tutkielma
Turun yliopisto
Tietotekniikan laitos
Lääketieteellinen tekniikka
ja terveysteknologia
2024
Mikko Happonen

TURUN YLIOPISTO
Tietotekniikan laitos

MIKKO HAPPONEN: Konvoluutioneuroverkot aivokasvainten magneettikuvauksessa

TkK-tutkielma, 23 s.
Lääketieteellinen tekniikka
ja terveysteknologia
Maaliskuu 2024

Tekoälyn käyttäminen osana lääketiedettä kasvaa jatkuvasti. Syväoppimiseen perustuvat konvoluutioneuroverkot tarjoavat muita tekoälymenetelmiä tehokkaamman ja tarkemman tavan esimerkiksi lääketieteellisten kuvien tulkintaan. Tämä tutkielma on kirjallisuuskatsaus, jonka tarkoituksena on perehtyä konvoluutioneuroverkkojen käyttöön magneettikuvien analysoinnissa ja aivokasvainten tunnistamiseen magneettikuvista eri konvoluutioneuroverkkoihin perustuvien arkkitehtuurien avulla. Konvoluutioneuroverkot ovat laskennallisia tiedon käsittelyn malleja, jotka perustuvat ihmisaivojen rakenteeseen ja matemaattiseen konvoluutioon. Konvoluutioneuroverkot sopivat hyvin analysoimaan esimerkiksi aivojen magneettikuvia ja tunnistamaan magneettikuvasta kasvaimen. Magneettikuvaus on kehossa olevien vetyytimien protoneiden kvanttimekaanisiin ominaisuuksiin perustuva menetelmä, jolla saadaan tarkkoja kuvia esimerkiksi aivojen kudoksista. Magneettikuvan käsittely konvoluutioneuroverkossa tapahtuu sen kerrosten ja luokittelijoiden ominaisuuksien avulla. Tutkielmassa käsitellyt konvoluutioneuroverkkojen arkkitehtuurit, EfficientNet, HTTU-Net ja GoogLeNet, onnistuvat kaikki analysoimaan aivojen magneettikuvan ja tunnistamaan siitä aivokasvaimen.

Asiasanat: syväoppiminen, konvoluutioneuroverkko, magneettikuvaus, aivokasvain

Sisällys

1	Johdanto	1
2	Tausta	3
2.1	Magneettikuvaus	3
2.1.1	Ydinmagneettinen resonanssi	4
2.1.2	T1- ja T2-relaksaatiot	5
2.1.3	Aivokasvaimet magneettikuvissa	8
2.2	Syväoppimisen matemaattinen perusta	10
2.3	Konvoluutioneuroverkkojen perusta	12
3	Aivokasvaimen tunnistaminen	15
3.1	Konvoluutioneuroverkko ja kuva	15
3.2	EfficientNet-arkkitehtuuri	17
3.3	HTTU-Net-arkkitehtuuri	18
3.4	GoogLeNet-arkkitehtuuri	20
4	Yhteenveto	21
	Lähdeluettelo	24

Termistö

CNN Convolutional Neural Network

FC Fully Connected

HTTU-Net Hybrid Two-Track U-Net

MRI Magnetic Resonance Imaging

NMR Nuclear Magnetic Resonance

ReLU Rectified Linear Unit

RF Radio Frequency

SVM Support Vector Machine

1 Johdanto

Tekoälyn käyttö lääketieteessä on yleistynyt nopeasti, mikä on luonut mahdollisuuksia parantaa terveydenhuollon hoitokäytäntöjä (Chakraborty ym. 2024). Monet tekoälysovellukset perustuvat koneoppimiseen, jonka yksi osa-alue on syväoppiminen (engl. *deep learning*). Syväoppiminen on usean kerroksen neuroverkkoihin perustuva menetelmä, joka mahdollistaa laajojen aineistojen ja monimutkaisten sääntöjen käsittelyn. Syväoppimismenetelmät ratkaisevat yhä monimutkaisempia ongelmia kasvavalla tarkkuudella. (Goodfellow, Bengio & Courville 2016, s. 1–11) Näiden ominaisuuksiensa takia syväoppiminen on lääketieteellisessä käytössä tehokkaampi ja mahdollistaa tarkemman diagnostisen tarkkuuden kuin muut tekoälymenetelmät. Jo nyt erilaisia syväoppimismenetelmiä käytetään useilla lääketieteen aloilla, mutta kehittyessään syväoppimismenetelmät tulevat olemaan yhä arvokkaampi apuväline terveydenhuollossa. (Chakraborty ym. 2024) Yksi tapa syväoppimisen soveltamiseen on konvoluutioneuroverkko (CNN), jota voidaan käyttää esimerkiksi magneettikuvauksesta (MRI) saadun kuvan automatisoituun analysointiin. Tämä mahdollistaa poikkeavuuksien tunnistamisen tietokoneavusteisesti magneettikuvista.

Tämän tutkielman tarkoituksena on selvittää, miten kasvaimia voidaan tunnistaa aivojen magneettikuvista konvoluutioneuroverkkoihin perustuvien syväoppimismenetelmien avulla. Erityisesti tutkielmassa tarkastellaan kolmea erilaista konvoluutioneuroverkon arkkitehtuuria ja niiden avulla saatuja tuloksia. Tutkielmassa pyritään löytämään vastaukset seuraaviin tutkimuskysymyksiin.

Tutkimuskysymys 1: Miten konvoluutioneuroverkolla analysoidaan aivojen magneettikuvaa?

Tutkimuskysymys 2: Millaisilla konvoluutioneuroverkoilla aivokasvain voidaan tunnistaa magneettikuvasta?

Tutkielma suoritetaan kirjallisuuskatsauksena. Aineistohaku tehtiin IEEE Xplore -hakukannasta hakulauseella “deep learning” AND (“magnetic resonance imaging” OR mri) AND “brain tumor” AND (detection OR recognition) AND (“convolutional neural network” OR cnn). Hakutulokset suodatettiin kattamaan vain vuonna 2015 tai myöhemmin julkaistut englanninkieliset artikkelit. Kaikki näillä ehdoilla löytyi 46 artikkelia, joita arvioitiin ensin otsikon ja abstraktin perusteella sekä sitten kokonaisuudessaan sisällön perusteella niin, että tässä tutkielmassa käytettiin vain tutkimuskysymysten kannalta relevantteja ja vertaisarvioituja, usein lainattuja artikkeleja. Vertaisarviointi tarkistettiin Volter-tietokannasta. Lisäksi tarkistettiin, että kunkin artikkelin julkaisukanavan JUFO-luokituksen taso on vähintään 1.

Tämän tutkielman luvussa 2 taustoitetaan syväoppimisen matemaattisen perustan ja CNN:n perusteiden lisäksi MRI:n periaatteita. Tutkielman luvussa 3 perehdytään aineistohaussa löytyneiden artikkelien avulla tarkemmin kolmeen magneettikuvien tulkinnessa käytettyyn CNN-arkkitehtuuriin. Kaikkien arkkitehtuurien osalta selvitetään toimintaperiaatteiden lisäksi niillä saatuja tuloksia aivokasvaimen havaitsemisessa magneettikuvasta. Tutkielman luvussa 4 kootaan aineistojen perusteella saadut vastaukset tutkimuskysymyksiin ja tehdään niiden pohjalta johtopäätöksiä.

2 Tausta

Syväoppimisen matemaattinen perusta pohjautuu vahvasti lineaarialgebraan, kuten vektori- ja matriisilaskentaan. Kehittyneemmät menetelmät ja käytössä olevat algoritmit perustuvat lisäksi todennäköisyyslaskennan ja numeeriseen laskennan eri osaluokiin, kuten optimointiin (Goodfellow, Bengio & Courville 2016, s. 80). CNN perustuu nimensä mukaisesti matemaattiseen konvoluutioon, joka on eräs lineaarinen operaatio. CNN:ää voi kuvata neuroverkkona, joka käyttää ainakin yhdessä kerroksessaan konvoluutiota matriisien sijasta. (Goodfellow, Bengio & Courville 2016, s. 330) Neuroverkot ovat kehitetty ohjaamattomalla oppimisella, vahvistusoppimisella tai ohjatulla oppimisella, jota käytetään CNN:ien opettamiseen (Ker ym. 2018). Tässä tutkielmassa ei käsitellä eri tapoja opettaa neuroverkkoa eikä perehdytä ohjatun oppimisen menetelmiin. MRI:n osalta tässä luvussa keskitytään fysikaaliseen toimintaperiaatteeseen, kuvanmuodostamiseen ja kuvissa näkyviin aivokasvaimiin.

2.1 Magneettikuvaus

MRI:n käytön määrä on kasvanut, koska siinä käytetty teknologia, kuten voimakkaat magneetit, ovat kehittyneet. MRI mahdollistaa kuvantamisessa suuren kontrastitiherkkyuden ja turvallisen tutkimuksen potilaalle, minkä vuoksi se on syrjäyttänyt muita kuvantamismenetelmiä. (Guy & fytche 2005, s. 402) Tässä luvussa käydään läpi magneettikuvauksen fysiikan teoriaa ja siitä johdettuja kuvanmuodostukseen vaikuttavia parametreja sekä magneettikuvien avulla tutkittavia aivokasvaimia.

2.1.1 Ydinmagneettinen resonanssi

MRI on ydinmagneettiseen resonanssiin (NMR) perustuva noninvasiivinen ja ei-ionisoiva kuvantamismenetelmä. NMR on atomin ytimen, eli protonien ja neutronien, magneettisista ominaisuuksista aiheutuva ilmiö, jossa atomi ulkoisessa magneettikentässä ollessaan absorboi energiaa (Bushberg ym. 2011, s. 402). MRI perustuu tästä aiheutuvaan vety-ytimen protonien energian muutoksen mittaamiseen.

Yleisesti johtimessa oleva liikkuva varaus aiheuttaa magneettikentän, jonka pohjoinen napa on kenttäviivojen lähtöpiste ja etelänapa paluupiste. MRI-laitteessa johtimesta muodostetaan kela, jolloin magneettikentän kokonaisvoimakkuus kelan sisällä kasvaa ja sen ulkopuolella laskee. Useissa MRI-laitteissa magneettikenttä on vaakasuora potilaan kraniokaudaalista akselia (engl. *cranial–caudal axis*) pitkin. MRI perustuu magneettivuon tiheyden B eli magneettikentän kenttäviivojen tiheyden säätelyyn. Tämä onnistuu vain voimakkaalla, ≥ 1 T, magneettikentällä, jonka saavuttaminen edellyttää johtimen suprajohtavuutta eli resistiivisyyden häviämistä ja sähkövirran häviöttömyyttä. (Bushberg ym. 2011, s. 403–405)

Protoneilla on kvanttimekaaninen ominaisuus spin, jota voidaan klassisessa mekaniikassa approksimoida magneettina, jonka suuntaa magneettikenttä muuttaa (Bushberg ym. 2011, s. 409). MRI-laitteen aiheuttamassa ulkoisessa magneettikentässä ollessaan protonien spinit kääntyvät samansuuntaisiksi (Berger 2002). Spinien summaa voidaan tarkastella vektorina, nettomagnetitumana, jotta jokaista ydintä ei tarvitsisi tarkastella erikseen (Blanco Sequeiros ym. 2017, s. 437–452).

Magneettikentässä protonit alkavat prekessoimaan, eli pyörimään oman akselinsa ympäri samalla, kun akselin suunta muuttuu siten, että kaltevuuskulma pysyy vakiona ja kaltevuussuunta kiertyy. Prekessointi tapahtuu jaksollisella Larmor-taajuudella $\omega = \gamma B$, jossa γ on vakio. Larmor-taajuus määräytyy jaksollisesta radiotaajuudesta (RF), jolla magneettikenttää muokataan. (Hamberg & Aronen 1992)

Prekessoidessaan protonit absorboivat sähkömagneettisen kentän energiaa, eli tapahtuu NMR. Absorboitunut energia saa protonien spinin kääntymään vastakkaisuuntaiseksi, jolloin myös nettomagnetointuma kääntyy vastakkaisuuntaiseksi ja protonit virittyvät. Kun RF-pulssi pysäytetään, niin protonien spinin relaksoituvat eli ne alkavat palata kohti tasapainoa. Relaksaatiossa, joka jaetaan T1- ja T2-relaksaatioihin, protonit emittoivat sähkömagneettista säteilyä, jonka taajuus vastaa edelleen RF- ja Larmor-taajuuksia. (Blanco Sequeiros ym. 2017, s. 437–452)

2.1.2 T1- ja T2-relaksaatiot

T1-relaksaatiossa eli pitkittäisessä relaksaatiossa protonit emittoivat viritysenergiansa ympäristöön ja T2-relaksaatiossa eli poikittaisessa relaksaatiossa toisille spinneille (Hamberg & Aronen 1992). T1 on se aika, jona pitkittäinen nettomagnetointuma suhteessa ulkoiseen magneettikenttään on vaimennut 63 %:iin. Tällöin

$$M_z(t) = M_0 \left(1 - e^{-\frac{t}{T_1}}\right), \quad (2.1)$$


jossa $M_z(t)$ on pitkittäinen nettomagnetointuma, ja kun $t = T_1$, niin $M_z = 0,63M_0$. T2 on se aika, jona poikittainen nettomagnetointuma suhteessa ulkoiseen magneettikenttään on vaimennut 37 %:iin alkuperäisestä. Tällöin

$$M_{xy}(t) = M_0 e^{-\frac{t}{T_2}}, \quad (2.2)$$

jossa $M_{xy}(t)$ on poikittainen nettomagnetointuma, ja kun $t = T_2$, niin $M_{xy} = 0,37M_0$. (Bushberg ym. 2011) T1-relaksaatiossa pitkittäinen nettomagnetointuma palautuu ulkoisen magneettikentän suuntaiseksi ja T2-relaksaatiossa poikittainen nettomagnetointuma häviää, kun protonien spinien epäjärjestys kasvaa (Blanco Sequeiros ym. 2017, s. 437–452).

Magneettikuva muodostetaan toistamalla virityksiä ja mittaamalla relaksaatioissa protonien emittoima säteily kelalla, jolla myös magneettikenttä luodaan (Blanco Sequeiros ym. 2017, s. 437–452). Eri kudosten vety-ytimien protoneilla on erilaiset relaksaatioajat, joiden avulla kudokset erotetaan kuvissa (Berger 2002). Mitkään kudokset eivät relaksoidu kokonaan ennen uutta viritystä, mutta lyhyen relaksaatioajan kudokset ehtivät lähemmäs tasapainoa ja emittoivat siten enemmän energiaa. T1-painotetussa magneettikuvassa lyhyen relaksaatioajan kudokset näkyvät kirkkaina, koska pitkittäisen nettomagnetituman ja ulkoisen magneettikentän ero on pienempi kuin pitkän T1-relaksaatioajan kudoksilla, jotka näkyvät tummina. Lyhyen T2-relaksaatioajan kudoksilla spinien epäjärjestys on suurempi, ja ne näkyvät T2-painotetussa kuvassa tummempina kuin T2-relaksaatioajan kudokset. (Blanco Sequeiros ym. 2017, s. 437–452)

RF-pulssin parametrit siis määrittävät, kuinka paljon nettomagnetituman erisuuntaiset komponentit vaimenevat eli kuinka paljon T1- ja T2-relaksaatioita käytännössä tapahtuu. Näin ollen RF-pulssin parametreja muuttamalla saadaan T1- tai T2-painotettuja magneettikuvia. Kuvassa 2.1 on esimerkki samasta aivojen magneettikuvasta eri T1- ja T2-painotuksilla.



Kuva 2.1: Vasemmalla T1-painotettu aivojen aksiaalinen magneettikuva ja oikealla T2-painotettu aivojen aksiaalinen magneettikuva (Bushberg ym. 2011, s. 430).

Protonien emittoimista signaaleista muodostetaan kuva gradienttikentillä eli heikoilla magneettikentillä, joiden voimakkuus kasvaa tietyssä suunnassa. Gradienttikentän voimakkuuden kasvaessa protonin Larmor-taajuus ja siten myös RF-pulssin taajuus kasvavat. Tätä ominaisuutta ja gradienttikenttien säätämistä hyödyntäen saadaan halutun paksuinen kuvaleike. Protonien Larmor-taajuudet kasvavat gradientin voimakkuuden suunnassa, mitä kutsutaan paikkakoodaukseksi. Gradienttien sammuttua protonien Larmor-taajuudet palautuvat alkuperäisiksi, mutta eri taajuuksisilla protoneilla on vaihe-ero. Tätä kutsutaan vaihekoodaukseksi. Signaalin eritaajuiset ja -vaiheiset komponentit kootaan k -avaruuteen eli käänteisavaruuteen, jossa sen jokainen piste sisältää koko kuvan tietyllä taajuudella ja tietyssä vaiheessa. Magneettikuva muodostetaan k -avaruudessa olevasta datasta käänteisen Fourier'n muunnoksen (engl. *inverse Fourier transform*) avulla. (Blanco Sequeiros ym. 2017, s. 437–452)

Fourier'n muunnos tarkoittaa siirtymistä todellisesta avaruudesta k -avaruuteen ja toisaalta käänteinen Fourier'n muunnos tarkoittaa siirtymistä k -avaruudesta todelliseen avaruuteen. Fourier'n muunnos siis muuntaa jatkuvan taajuusspektrin funktioksi. Käänteinen Fourier'n muunnos taas dekodaa taajuustason vaihtelut kullekin k -avaruuden sarakkeelle ja muodostaa näin kuvan (Bushberg ym. 2011, s. 446). Matemaattisesti Fourier'n muunnos on

$$\mu(x, y) = \iint \mathcal{F}\{f(k)\} e^{i(k_x x + k_y y)} dk_x dk_y, \quad (2.3)$$

jossa $\mu(x, y)$ on todellisen avaruuden kuva, $\mathcal{F}\{f(k)\}$ on k -avaruudessa olevan kuvan funktion Fourier'n muunnos sekä k_x ja k_y ovat k -avaruuden x- ja y-dimensiot (Guy & ffytche 2005, s. 348). Kaava 2.3 pätee kaksiulotteiselle kuvalle. Yleisesti Fourier-analyysi on työkalu, joka tarjoaa tavan hajottaa kuva ensin osiin, koota kuvan osat k -avaruuteen ja yhdistää ne sitten takaisin alkuperäiseksi kuvaksi (Guy & ffytche 2005, s. 13).

Magneettikuvaa muokataan eri sekvensseillä eli kuva-asetuksilla. Pulssisekvenssi on RF- ja gradienttipulssien sarja protonien virityksestä signaalin keräykseen. Se toteutetaan virittämällä leike kerrallaan tai monia yhtäaikaisesti hieman poikkeavilla taajuuksilla. Spinkaikusekvenssi (engl. *spin echo*) kääntää jäljellä olevan poikittaisen nettomagnetituman vaihetta 180° , mikä aiheuttaa nopeimmin pyörivien protonien muuttumisen hitaimmiksi ja päinvastoin. Näin protonit päätyvät samaan vaiheeseen, mikä vahvistaa signaalia. Gradienttikaikusekvenssi (engl. *gradient echo*) aiheuttaa kunkin suunnan gradientille epävaiheistumisen, minkä jälkeen vastakkaissuuntaisella gradientilla fokusoidaan uusi vaihe-ero. (Blanco Sequeiros ym. 2017, s. 437–452)


2.1.3 Aivokasvaimet magneettikuvissa

Aivokasvaintyypeistä yleisimpiä ovat glioomat, jotka muodostuvat hallitsemattomasti kasvavista aivojen gliosoluista, ja meningeoomat, jotka muodostuvat lukinkalvon soluista ja kiinnittyvät aivokalvon uloimpaan kovakalvoon. Muita kasvaintyyppisiä ovat hermoston Schwannin soluista muodostuva Schwannooma ja aivolisäkkeen kasvain hypofyysiadenooma. (Soinila & Kaste 2006, s. 396–400)

Glioomat sijaitsevat aivokudoksessa ja ne kasvavat infiltraatiivisesti eli laajentuen ympäröivässä kudoksessa. Glioomat voidaan jakaa neljään luokkaan I–IV pahalaatuisuutensa perusteella. Erilaistumisasteen gradus I glioomat ovat hyvälaatuisimpia eli hitaasti kasvavia ja gradus IV glioomat pahalaatuisimpia. Pahalaatuisin gliooma, glioblastooma, on tunkeutunut aivokudokseen ja sillä on usein epätasainen rengasmainen rakenne, keskiosan nekroosialue sekä usein massavaikutus aivoissa. Meningeoomat ovat aivokudoksen ulkopuolisia kasvaimia, joiden vaarallisuus riippuu niiden koosta ja sijainnista. Suurin osa hyvälaatuisista kasvaimista on meningeoomia. Vaarallisimmillaan meningeoomat ovat painaessaan elintoimintojen kannalta tärkeitä rakenteita, kuten hengityskeskusta. (Blanco Sequeiros ym. 2017, s. 204–206)

On myös mahdollista, että kallon ulkopuolella sijaitsevat pahalaatuiset kasvaimet lähettävät etäpesäkkeitä, jotka alkavat kasvaa aivokudoksessa aiheuttaen samankaltaisia oireita primaarien aivokasvainten kanssa. Yleensä hyvälaatuiset kasvaimet näkyvät paremmin T2-painotetuissa kuvissa ja pahalaatuiset kasvaimet näkyvät paremmin T1-painotetuissa kuvissa. MRI on tarkan erottelukykynsä takia paras ja luotettavin kuvausmenetelmä. (Blanco Sequeiros ym. 2017, s. 204–206)

Aivokasvainten näkyvyyttä magneettikuvissa voidaan parantaa varjoaineilla, kuten erilaisilla gadolinium-yhdisteillä. Varjoaineen käyttö MRI:n osana perustuu tietyn kohdekudoksen T1- tai T2-relaksaatioajan lyhentämiseen. Relaksaatioajan lyhenemisestä seuraa signaalin voimistuminen kuvassa. (Soinila & Kaste 2006, s. 102–109) Käytännössä tämän seurauksena kohteesta muodostuvassa magneettikuvassa on enemmän kudosten välistä kontrastia, jolloin eri kudokset erottuvat paremmin toisistaan ja siten myös kasvainten tunnistaminen kuvasta on helpompaa. Kuvassa 2.2 on esimerkki kahden erityyppisen ja -laatuisen aivokasvaimen varjoaineella tehostetusta magneettikuvasta.



Kuva 2.2: Vasemmalla T1-painotettu gadoliniumtehosteinen aivojen aksiaalinen magneettikuva, jossa gradus II gliooma ja oikealla T1-painotettu aivojen aksiaalinen magneettikuva, jossa glioblastooma (Blanco Sequeiros ym. 2017, s. 204–206).

2.2 Syväoppimisen matemaattinen perusta

Neuroverkko on aivojen rakenteeseen perustuva tiedon käsittelyn malli, joka koostuu toisiinsa yhdistyneistä neuroneista. Aivojen neuronin koostuu dendriiteistä eli tuoja-haarakkeista, somasta eli solukeskuksesta ja aksoneista eli viejähaarakkeista. Syväoppimisen neuroverkko toimii samalla periaatteella: neuronien tiedonkäsittely perustuu toisilta neuroneilta saatuihin syötteisiin, neuronin ominaisuuksista riippuvaan syötteen muokkaamiseen ja neuronin ulostuloon. Aivojen ja neuroverkon toimintaperiaate on siis samanlainen, koska molemmat koostuvat suuresta määrästä toisiinsa yhdistyviä neuroneja, tiedonsiirto perustuu neuronien väliseen signaaliverkkoon ja jokainen neuronin käsittelee viereisistä neuroneista saadut signaalit. (Kelleher 2019, s. 65–67; Sarker 2021) Neuronin toiminnan vaiheet voidaan kuvata matemaattisesti, mikä mahdollistaa neuroverkkojen spesifin muokkaamisen.

Neuronit muodostavat syväoppivan neuroverkon syöte-, piilo- ja ulostulotasot. Neuroverkkoa voidaan pitää syväoppivana, jos siinä on vähintään kaksi piilokerrosta (Kelleher 2019, s. 67–68). Käytännössä piilokerrosten määrä on kuitenkin aina huomattavan paljon suurempi, jotta niistä saataisiin tehokkaita. Neuronien välillä signaali kulkee vain yhteen suuntaan, ja neuronissa kullakin saapuvalla syötteellä on paino (engl. *weight*), joka määrittää syötteen vaikutuksen (Kelleher 2019, s. 70).

Neuronissa tapahtuva tiedonkäsittely perustuu summafunktioon ja aktivaatiofunktioon. Neuronin summafunktio laskee yhteen syötteet ja aktivaatiofunktio kuvaa (engl. *map*) summafunktion antaman tuloksen neuronin ulostuloksi (Kelleher 2019, s. 71). Olkoon neuronilla n syötettä, jolloin syötevektori on $\mathbf{s} = (s_1, s_2, \dots, s_n)^\top$ ja painovektori on $\mathbf{p} = (p_1, p_2, \dots, p_n)^\top$. Neuronin syötefunktio on tällöin

$$\sum_{i=1}^n s_i p_i. \quad (2.4)$$

Aktivaatiofunktio määrittelee tavan, jolla neuroni käsittelee tietoa. Siksi aktivaatiofunktio vaihtelee: se voi olla esimerkiksi kynnysfunktio, hyperbolinen tangenttifunktio, logistinen funktio tai tasasuuntautunut lineaarinen funktio (Kelleher 2019, s. 74). Olkoon neuronin aktivaatiofunktio φ , jolloin neuronin ulostulofunktio on

$$\varphi \left(\sum_{i=1}^n s_i p_i \right). \quad (2.5)$$

Jokaisen neuronin summafunktio on aina lineaarinen, kun taas aktivaatiofunktio voi olla joko lineaarinen tai epälineaarinen. Mikäli neuroverkolla siis halutaan mallintaa myös epälineaarisia ilmiötä, joita monet todelliset ilmiöt ovat, niin aktivaatiofunktion määrittely on neuroverkon toiminnan kannalta hyvin olennaista. (Kelleher 2019, s. 77–79) Neuronia, jonka syötteenä ovat syötevektori ja painovektori, ja jonka toiminta perustuu summafunktioon ja aktivaatiofunktioon, kutsutaan perseptroniksi (Anaya-Isaza, Mera-Jiménez & Zequera-Diaz 2021).

Neuronille voidaan määritellä kolme eri avaruutta (engl. *space*): syöteavaruus, painoavaruus ja aktivaatioavaruus. Syöteavaruus ja painoavaruus muodostavat päätösrajan (engl. *decision boundary*), joka rajaa alueen, jossa kyseisen muuttujan vektorin täytyy kyseisessä avaruudessa säilyä (Kelleher 2019, s. 83–86). Esimerkiksi neuronin, jonka syötteiden määrä on n , syöteavaruus on n -ulotteisessa avaruudessa kaikkien syötteiden kombinaatioiden muodostama alue. Tällöin syötevektori alkaa päätösrajan ja origon leikkauskohdasta osoittaen syötteiden määrittämälle alueelle. Sama periaate pätee myös painoavaruudelle, mikä helpottaa mallintamaan eri parametrien muuttamisen vaikutusta neuroniin. Kaavan 2.5 mukaisesti aktivaatioavaruuteen vaikuttavat syöteavaruus, painoavaruus ja aktivaatiofunktio (Kelleher 2019, s. 87). Aktivaatioavaruutta voidaan muokata myös lisäämällä syötefunktioon vakio-termi (engl. *bias*), jonka avulla päätösraja saadaan siirrettyä haluttuun suuntaan (Kelleher 2019, s. 88–91). Näin neuronin toimintaa muokataan halutunlaiseksi.

2.3 Konvoluutioneuroverkkojen perusta

CNN on käytössä kuvien analysoinnissa, koska se hyödyntää syötteen rakenteessa olevaa tietoa paremmin kuin muut neuroverkot. CNN pystyy ottamaan syötteenä suoraan kaksi- tai kolmiulotteisia kuvia, siirtämään ne konvoluutiokerroksien käsiteltäväksi ja tunnistamaan niistä automaattisesti relevantteja ominaisuuksia. (S. K. Zhou, Greenspan & Shen 2017) Konvoluutiokerroksien matemaattinen konvoluutio on kahden reaaliarvoisen funktion \mathbf{x} ja \mathbf{w} operaatio. Konvoluutio on muotoa

$$\mathbf{s}(t) = \int \mathbf{x}(a) \mathbf{w}(t - a) da = (\mathbf{x} * \mathbf{w})(t), \quad (2.6)$$

jossa \mathbf{x} on syöte, t on aika tai sijainti ja \mathbf{w} on ydin (engl. *kernel*). Ulostulo \mathbf{s} on ominaisuuskuvauks (engl. *feature map*). (Goodfellow, Bengio & Courville 2016, s. 331–332) Ydin on painokertoimena toimiva ja diskreeteistä arvoista tai lukuarvoista koostuva matriisi, joka suodattaa tietoa seuraavalle kerrokselle. Käytännössä konvoluutio muokkaa syötettä ytimen avulla paloittain, kunnes syöttestä saadaan muokattua sopiva ulostulomatriisi eli ominaisuuskuvauks. (Alzubaidi ym. 2021)

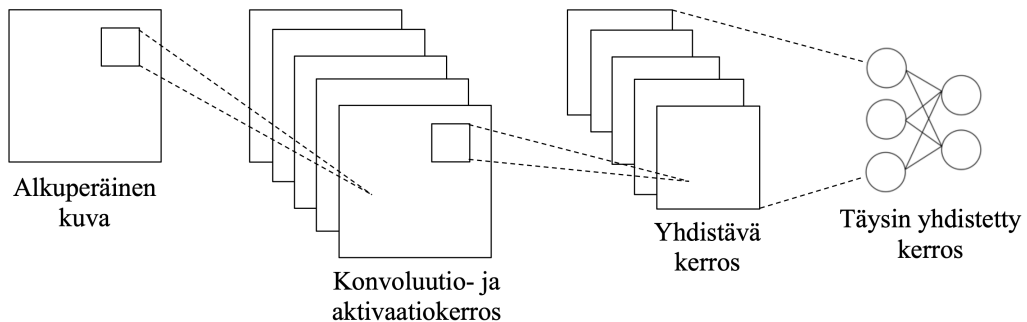
CNN on hyödyllinen prosessoitaessa syötteitä, joilla on vaihtelevat tilaulottuvuudet. Usein erikokoisten kuvien kokoelmille on vaikea luoda perinteiselle neuroverkolle sopiva yhteinen painomatriisi. Koska CNN hyödyntää konvoluutiota, niin ytimiä voidaan lisätä eri määrä syötteen määrän mukaan ja ulostulo skaalautuu aina vastaavasti. Näin MRI:n kolmiulotteista dataa voidaan käyttää syötteenä niin, että myös lopputulos on oikeanlainen. (Goodfellow, Bengio & Courville 2016, s. 360–362)

CNN:ssä on myös aktivaatiokerroksia, yhdistäviä kerroksia (engl. *pooling layer*) ja täysin yhdistettyjä (FC) kerroksia. Konvoluution lineaariset ulostulot toimivat syötteenä epälineaarille aktivaatiofunktioille, joka tekee päätöksen syötteen siirtämi-

sestä neuroverkossa eteenpäin tai sen pysäyttämisestä. Olkoon aktivaatiofunktio f , jolloin neuroverkon aktivaatiokerroksessa suoritettava operaatio on

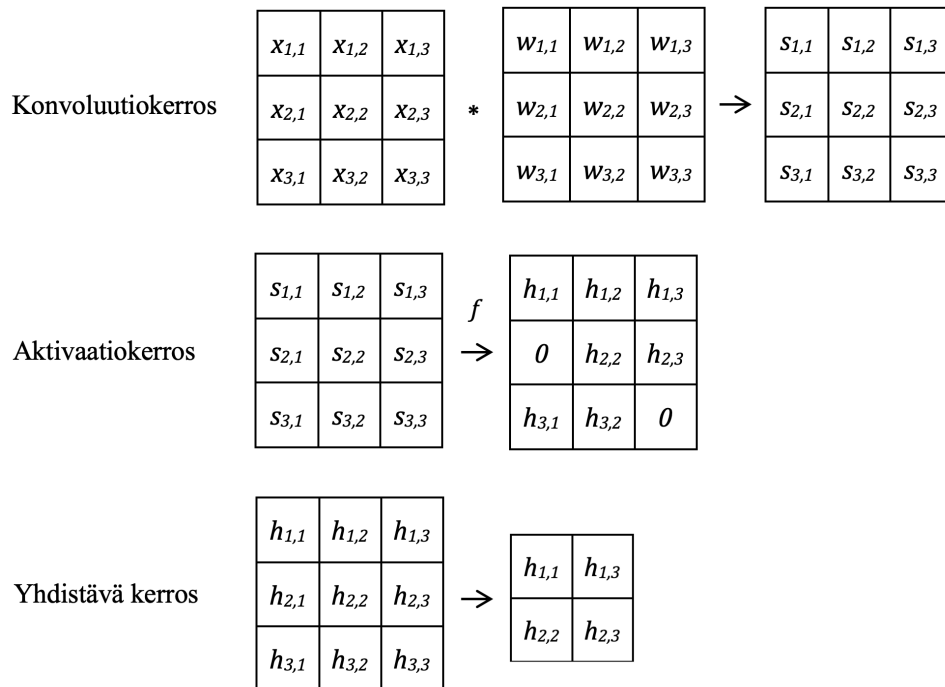
$$\mathbf{h}^k = f(W^k \mathbf{s} + \mathbf{b}^k), \quad (2.7)$$

jossa \mathbf{h}^k on ulostulo, \mathbf{s} on syöte, \mathbf{b}^k on vakiotermi, W^k on painokerroin ja k on neuroverkon kerros. (Alzubaidi ym. 2021) Yhdistävä kerros käyttää tätä ulostuloa syöteenään, jonka yhdistysfunktio kuvaa ulostuloksi. Yhdistysfunktio vähentää datapisteitä tiivistämällä edellisissä kerroksissa määritettyjä ominaisuuskuvauksia. Kerros korvaa tietyt pisteet lähellä olevilla pisteillä tilastollisten menetelmien, kuten suurimman arvon (engl. *max pooling*) ja keskiarvon (engl. *average pooling*), avulla. (Goodfellow, Bengio & Courville 2016, s. 339–347) CNN:n lopussa voi olla lisäksi FC-kerros, jossa kukin neuroni yhdistetään kaikkiin edellisten kerrosten neuroneihin. Kerrosta kutsutaan luokittelijaksi: se luo lopullisen syöteen luokan (Alzubaidi ym. 2021). Kuvassa 2.3 on esitettyä, kuinka alkuperäisen kuvan osa toimii syöteenä samassa kerroksessa oleville konvoluutio- ja aktivaatiokerroksille, sekä sen jälkeen ensin yhdistävälle ja sitten FC-kerrokselle.



Kuva 2.3: Alkuperäisestä kuvan osasta saatavan syöteen kulku CNN:ssä olevien konvoluutio-, aktivaatio- ja yhdistävän kerroksen läpi.

CNN hyödyntää harvempia vuorovaikutuksia, parametrien jakamista ja ekvivariantteja (engl. *equivariant*) esitysmuotoja. Perinteinen neuroverkko toimii matriisien kertolaskuilla, jolloin jokainen syöte ja ulostulo vaikuttavat toisiinsa. CNN:ssä keskinäisiä vuorovaikutuksia on vähemmän, koska ydin on aina syötettä pienempi. CNN:ssä yhtä ydintä voidaan käyttää myös syötteen jokaisessa osassa. Näin operaatioiden määrää vähenee ja tilastollinen tarkkuus kasvaa. Ekvivariantteja muotoja käytetään kuvan analysoinnissa: konvoluutio luo kuvauksen syötteen ominaisuuksista, ja syötettä liikuttaessa sen esitys liikkuu saman verran myös ulostulon osalta. Matemaattisesti funktio $f(x)$ on ekvivariantti muoto funktioon g , jos $f(g(x)) = g(f(x))$. (Goodfellow, Bengio & Courville 2016, s. 335–339) Kuvassa 2.4 on konvoluutio-, aktivaatio- ja FC-kerroksien esimerkkioperaatiot sekä syötteiden siirtyminen kerrokselta toiselle.



Kuva 2.4: Konvoluutiokerroksessa konvoluution kuvaus on aktivaatiokerroksen syöte ja aktivaatiokerroksen aktivaatiofunktion kuvaus on yhdistävän kerroksen syöte.

3 Aivokasvaimen tunnistaminen

CNN pystyy käsittelemään kaksi- tai kolmiulotteisia kuvia. Lisäksi sen avulla on mahdollista käsitellä kutakin kuvaa yksi pikseli kerrallaan, mikä mahdollistaa kuvan tarkan analysoinnin (LeCun, Bengio & Hinton 2015). Kun konvoluutioneuroverkkoa käytetään magneettikuvan analysointiin, niin eri vaiheita on useita. Tässä luvussa käydään läpi ensin yleisellä tasolla ja sitten tarkemmin kolmella eri CNN:n arkkitehtuurilla toteutettuna prosessi, jonka seurauksena magneettikuvasta voidaan havaita aivokasvain.

3.1 Konvoluutioneuroverkko ja kuva

Jotta magneettikuvat voidaan syöttää CNN:ään, ne täytyy esikäsitellä eli muuttaa vakionuotoisiksi. Esikäsitelyn ensimmäisessä vaiheessa magneettikuvat rekisteröidään eli niille tehdään spatiaalinen kohdistus samanlaiseen anatomiseen tilaan. Tällä pyritään kohdistamaan eri sekvenssien kuvat samanlaisiksi, jotta saataisiin monikanavainen esitys aivojen tarkasta tilasta. Seuraavaksi pääkallo rajataan pois kuvasta, koska kuvassa on tarkoituksenmukaista keskittyä vain kallonsisäiseen kudokseen. Lisäksi tehdään virhekentän korjaaminen (engl. *bias field correction*) eli magneettikentän epähomogeenisuudesta johtuvien kontrastivaihteluiden korjaus sekä intensiteetin normalisointi eli kaikkien kuvien intensiteettien kuvaus referenssiskaalauksen mukaisiksi. Viimeisenä magneettikuvista vähennetään niissä esiintyvää kohinaa. (Akkus ym. 2020)

Varsinainen CNN:ssä tapahtuva magneettikuvan käsittely voidaan jakaa segmentointiin (engl. *segmentation*), kohteiden paikallistaminen (engl. *localization*), kohteiden tunnistamiseen (engl. *detection*) ja viimeisenä CNN:ssä tapahtuvaan kohteiden luokitteluun (engl. *classification*). (Ker ym. 2018)

Segmentointi tarkoittaa ääriviivojen muodostamista kohdeobjektien, eli tässä tapauksessa aivokasvaimien, ympärille. Tällöin valitut kohteet saadaan eroteltua muista kohdeobjekteista. Erityisesti kirurgisten operaatioiden kannalta kasvaimien tarkka erottelu on tärkeää, koska muiden aivoalueiden uhraaminen voi aiheuttaa neurologisia häiriöitä. (Ker ym. 2018) Lisäksi magneettikuvasta on oleellista erotella valkoinen aine, harmaa aine ja selkäydinneste. Kaksi yleistä tapaa luoda segmentointiin tarkoitettu CNN ovat alueellinen tapa (engl. *patch-wise*) ja semanttinen tapa (engl. *semantic-wise*). Alueellisessa tavassa kuvan jokaisen pikselin ympärillä oleva neliön muotoinen alue (engl. *patch*) poimitaan ja CNN opetetaan näiden alueiden ja annettujen alueiden luokittelujen avulla tunnistamaan kasvain. Valmis alueellisen tavan CNN sisältää useita konvoluutio-, aktivointi-, yhdistys- ja FC-kerroksia peräkkäin. Semanttisessa tavassa CNN tekee ennusteita koko kuvan jokaiselle pikselille. Tämä perustuu siihen, että poimitaan yksittäisiä ominaisuuksia, jotka yhdistetään korkeamman tason ominaisuuksiksi eli esimerkiksi kuvassa olevaksi kasvaimeksi. (Akkus ym. 2020)

Kohteiden paikallistamisella tarkoitetaan rajauslaatikon muodostamista yhden kuvan kohteen ympärille. Tämä ei ole usein tarpeellista lääkärin ollessa läsnä, vaan sitä käytetään lähinnä täysin automatisoiduissa syväoppimissovelluksissa. Kohteiden tunnistaminen on rajauslaatikoiden muodostamista useiden, eri luokista muodostuvien kokonaisuuksien ympärille. Tämä on tärkeää, koska magneettikuvassa olevan poikkeaman huomaamatta jääminen voi aiheuttaa seurauksia sekä potilaalle että lääkärille. (Ker ym. 2018)


Varsinainen kasvaimen luokittelu suoritetaan FC-kerroksessa. Luokittelun tarkoituksena on luokitella löytyneen kasvaimen tyyppi ja gradus. Tämä voidaan tehdä käyttämällä CNN:n ominaisuuksien lisäksi esimerkiksi tukivektorikonetta (SVM) tai satunnaista metsää (engl. *random forest*), jotka ovat perinteisiä koneoppimisalgoritmeja. (Ker ym. 2018)

Aivokasvaimien tunnistamisen tuloksien kuvaamiseen käytetään sekaannusmatriisia (engl. *confusion matrix*), joka tekee yhteenvedon kullakin arkkitehtuurilla saaduista tuloksista. Se on kaksiulotteinen matriisi, jonka vaakariveillä on luokittelijan kohteelle muodostama luokka (engl. *assigned class*) ja pystyriveillä kohteen todellinen luokka (engl. *actual class*). Kun käytetään molemmissa positiivista ja negatiivista luokkaa, niin matriisissa on neljä alkia: TP (engl. *true positives*), FP (engl. *false positives*), TN (engl. *true negatives*) ja FN (engl. *false negatives*). Näiden arvojen perusteella saadaan johdettua tulosten sensitiivisyys kaavalla $TP / (TP + FN)$ ja spesifisyys kaavalla $TP / (TN + FP)$. Lisäksi saadaan johdettua tulosten täsmällisyys (engl. *precision*) kaavalla $TP / (TP + FP)$ ja tarkkuus (engl. *accuracy*) kaavalla $(TP + TN) / (TP + TN + FP + FN)$. (Ting 2017)

3.2 EfficientNet-arkkitehtuuri

Konvoluutiokerroksista koostuva EfficientNet perustuu CNN:n suorituskyvyn parantamiseen optimoimalla syvyyttä, leveyttä ja resoluutiota. (Tayyab Khushi ym. 2023; Vaiyapuri ym. 2023) Yhdistelmäskaalausmenetelmällä (engl. *composite scaling method*) siitä voidaan johtaa EfficientNet-B0:n perusmalli, josta saadaan eräs EfficientNet-arkkitehtuuri lisäämällä viisi kerrosta ja sigmoidifunktioon perustuva luokittelija. Kerrokset ovat litteä kerros (engl. *flattened layer*), 2 tiheää kerrosta (engl. *dense layer*), pudottava kerros (engl. *dropout layer*) sekä aktivaatiokerros, jossa on oikaistu ja lineaarinen (ReLU) aktivaatiefunktio. (Shah ym. 2022)

Arkkitehtuuri kokonaisuudessaan on esitettyä kuvassa 3.1. EfficientNet-arkkitehtuurin sensitiivisyys aivokasvaimen löytämiseen magneettikuvasta on 99,5 %. Spesifisyys on 99,2 % ja tarkkuus on 98,8 %. Efficient-arkkitehtuurin opetuksessa on käytetty ImageNet-datasettiä, joka sisälsi yhteensä 3762 magneettikuvaa. Niistä muodostettiin 3060 kuvan osajoukko, josta 1500 sisälsi kasvaimen ja 1500 ei sisältänyt kasvainta. Näistä 3000 kuvasta 2400 käytettiin opettamiseen ja 600 validointiin. Loput 60 kuvaa olivat käytössä arkkitehtuurin testaamisessa. (Shah ym. 2022)



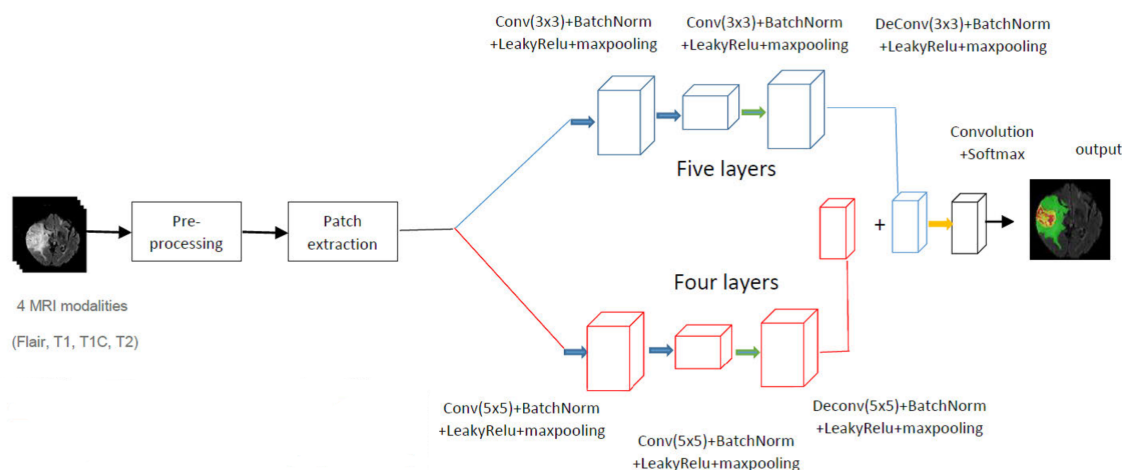
Kuva 3.1: EfficientNet kasvaimen tunnistamiseen (Shah ym. 2022).

3.3 HTTU-Net-arkkitehtuuri

Hybridi kaksiväyläinen U-Net (HTTU-Net) perustuu U-Net-arkkitehtuuriin, joka koostuu koodaavasta ja dekodeavasta osasta. Tämä mahdollistaa isomman tiedonkäsittelyn kapasiteetin ja siten tarkemmat tulokset. (Zhang ym. 2020; Wu ym. 2019) Eräs HTTU-Net-arkkitehtuuri rakentuu kahdesta väylästä, joista ensimmäisen väylän ytimet ovat pienempiä kuin toisen väylän ytimet. Lisäksi ensimmäisessä väy-

lässä on 5 konvoluutiokerrosta ja toisessa 4. Konvoluutiokerrokseen on liitetty myös suurimman arvon periaatteella toimivia yhdistäviä kerroksia, aktivaatiokerroksia, joissa on ReLU-aktivaatiofunktio, sekä käsitellyn alueen normalisointi. Molempien väylien jälkeen luokittelijana käytetään Softmax-funktiota. Kaksiväyläisyys mahdollistaa erikokoisten kasvainten prosessoinnin sekä vähentää luokkien epätasapainoa. Arkkitehtuuri kokonaisuudessaan on esitetty kuvassa 3.2. (Aboelenein ym. 2020)

HTTU-Net-Arkkitehtuurin sensitiivisyyden keskiarvo aivokasvaimen löytämiseen magneettikuvasta on kasvaimen ytimelle 82,0 %, tehostuvalle (engl. *enhancing*) kasvaimelle 76,8 % ja koko kasvaimelle 88,5 %. Spesifisyyden keskiarvo kasvaimen ytimelle on 99,7 %, tehostuvalle kasvaimelle 99,9 % ja koko kasvaimelle 99,8 %. HTTU-Net-arkkitehtuurin opetuksessa käytettiin Brats 2018 -datasettiä, joka sisältää 210 magneettikuvaa, joissa on matala-asteinen gliooma ja 75 magneettikuvaa, joissa on korkea-asteinen gliooma. Kunkin kuvan koko on 240 x 240 x 155. 160 kuvaa käytettiin opettamiseen ja 40 kuvaa validointiin. (Aboelenein ym. 2020)




Kuva 3.2: HTTU-Net kasvaimen tunnistamiseen (Aboelenein ym. 2020).

3.4 GoogLeNet-arkkitehtuuri

GoogLeNet on muokattu syvä CNN, joka on suunniteltu eri kasvainluokkien luokittelamiseen. Kasvaimien luokittelu tapahtuu käyttämällä koneoppimisalgoritmeja, kuten SVM ja lähin naapuri (engl. *K-nearest Neighbor*). Eräs GoogLeNet-arkkitehtuuri koostuu konvoluutiokerroksista, joihin on liitetty myös keskiarvojen periaatteella toimiva yhdistävä kerros, FC-kerroksesta sekä erillisestä luokittelukerroksesta. Luokittelukerros jakautuu Softmax-funktiolla toimivaan luokittelijaan sekä SVM- tai lähin naapuri -luokittelijaan, jotka tarkentavat saatuja luokkia. Arkkitehtuuri kokonaisuudessaan on esitettyä kuvassa 3.3. (Sekhar ym. 2022)

Käytettäessä SVM-luokittelijaa HTTU-Net-arkkitehtuurin täsmällisyys aivokasvaimen löytämiseen magneettikuvasta on gliomalle 98,76 %, meningiomalle 94,71 % ja hypofyysiadenoomalle 98,40 %. Spesifisyys on gliomalle 98,93 %, meningiomalle 98,40 % ja hypofyysiadenoomalle 99,30 %. HTTU-Net-arkkitehtuurin opetuksessa on käytetty FigShare-datasettiä. Se koostuu 3064 magneettikuvasta, jotka on luokiteltu valmiiksi kasvaintyyppien mukaisesti. Kaikkien magneettikuvien koko on 512 x 512. Datasetti on jaettu 5 lähes yhtä suureen osajoukkoon, joista yhden ollessa käytössä testauksessa muut ovat käytössä opetuksessa. (Sekhar ym. 2022)



Kuva 3.3: GoogLeNet kasvaimen tunnistamiseen (Sekhar ym. 2022).

4 Yhteenveto

CNN:llä analysoidaan aivojen magneettikuvaa siten, että esikäsitelty magneettikuvan data kulkee arkkitehtuurista riippuvien kerrosten ja luokittelijoiden läpi. Tästä lopputuloksena saadaan selville, onko kuvassa kasvain ja mikä on mahdollisen kasvaimen tyyppi. Aivokasvaimen tunnistamiseen käytettävän CNN:n rakenne on aina samankaltainen, mutta sen yksityiskohdat vaihtelevat. Taulukossa 4.2 on tutkielmassa tarkastelluissa EfficientNet-, HTTU-net- ja GoogLeNet-arkkitehtuureissa käytettyjen kerrosten ja luokittelijoiden tyypit. Taulukossa 4.1 on vertailtu tutkielmassa tarkastelluilla arkkitehtuureilla saatuja tuloksia aivokasvaimen tunnistamisessa magneettikuvasta. Kaikkien kolmen arkkitehtuurin kesken vertailukelpoinen tulos saadaan vain spesifisyydestä. HTTU-Net-arkkitehtuurin osalta spesifisyyden ja sensitiivisyyden vertailussa käytetään eri kasvaimen osien tuloksien keskiarvoa. Niin ikään GoogLeNet-arkkitehtuurin spesifisyyden ja täsmällisyyden osalta käytetään eri kasvainluokkien tuloksien keskiarvoa.

Taulukko 4.1: Tutkielmassa tarkasteltujen EfficientNet-, HTTU-net- ja GoogLeNet-arkkitehtuurien eri tulokset aivokasvaimen tunnistamiseen magneettikuvasta.

CNN-arkkitehtuuri	Spesifisyys	Sensitiivisyys	Tarkkuus	Täsmällisyys
EfficientNet (Shah ym. 2022)	0,992	0,995	0,988	-
HTTU-Net (Aboelenein ym. 2020)	0,998	0,824	-	-
GoogLeNet (Sekhar ym. 2022)	0,989	-	-	0,973

Taulukko 4.2: Tutkielmassa tarkastelluissa EfficientNet-, HTTU-net- ja GoogLeNet-arkkitehtuureissa käytettyjen neuroverkkojen kerrosten ja luokittelijoiden tyypit.

	EfficientNet (Shah ym. 2022)	HTTU-Net (Aboe- lenein ym. 2020)	GoogLeNet (Sek- har ym. 2022)
Konvoluutio- kerros	x	x	x
Litteä kerros	x		
Tiheä kerros	x		
ReLU- aktivaatiokerros	x	x	
Pudottava kerros	x		
Yhdistävä kerros		x	x
FC- kerros			x
Sigmoidi- luokittelija	x		
Softmax- luokittelija		x	x
SVM- luokittelija			x

Kaikki kolme tutkielmassa tarkasteltua CNN-arkkitehtuuria, EfficientNet-, HTTU-net- ja GoogLeNet, onnistuvat tunnistamaan kerroksien ja luokittelijoiden ominaisuuksien avulla aivokasvaimen magneettikuvasta. Kunkin arkkitehtuurin spesifisyys aivokasvaimen tunnistamiseen on $\geq 98,9\%$. Tarkimman tuloksen saavuttaa HTTU-Net-arkkitehtuuri, jonka spesifisyys on $99,8\%$. Kaikkien arkkitehtuurien spesifisyys kasvaimen tunnistamiseen on korkea, mutta se tarkoittaa kykyä tunnistaa terve tila ja tuottaa vähän vääriä kasvainhavaintoja, joten muutkin tulokset on huomioitava.

Sensitiivisyyden, eli kyvyn tunnistaa kasvain ja tuottaa vähän vääriä terveitä havain-
toja, tulokset vaihtelevat enemmän ja ovat epätarkemmat eli kasvaimen tunnistamisen toimivuutta ei voi yleistää laajasti. EfficientNet-arkkitehtuurin sensitiivisyys kasvaimen tunnistamiseen on 99,5 %, mutta HTTU-Net-arkkitehtuurin sensitiivisyys on vain 82,4 %. EfficientNet-arkkitehtuurin tarkkuus on 98,8 % ja GoogLeNet-arkkitehtuurin täsmällisyys on 97,3 %. Otettaessa huomioon kaikki nämä arkkitehtuurien eri tulokset voidaan EfficientNet-arkkitehtuurin todeta olevan tutkielmas-
sa tarkastelluista arkkitehtuureista kokonaisvaltaisesti tarkin ja varmin tunnistamaan aivokasvain magneettikuvasta. Kuitenkin kaikki saadut tulokset perustuvat tiettyihin, verrattain pieniin, datasetteihin. Siksi täysin automatisoitujen menetelmien käyttöönotto laajasti kliinisessä potilastyössä vaatii lisätutkimusta.

Tarkasteltujen arkkitehtuurien rakenne koostuu konvoluutio- ja muista kerroksista sekä luokittelijoista. GoogLeNet-arkkitehtuurissa on Softmax- ja SVM-luokittelija eli sen toiminta painottuu luokitteluun, mikä näkyy kyvyssä luokitella eri kasvaintyyppit tarkasti. EfficientNet-arkkitehtuurilla saadaan parhaat tulokset, koska siinä on yhteensä 5 erilaista kerrostyyppiä eli tiedonkäsittelyä tapahtuu enemmän. HTTU-Net-arkkitehtuurissa on vähiten kerrostyyppejä, mutta kaksiväyläisyyden takia samanlaisia kerroksia on enemmän. Tämä näyttäisi johtavan epävarmempiin tuloksiin sensitiivisyyden osalta, mutta tarkkoihin tuloksiin spesifisyyden osalta. Yleisesti U-Net-arkkitehtuurin variaatiot ovat paljon käytettyjä ja kaksiväyläisyyden takia tehokkaita lääketieteellisten kuvien segmentoinnissa (X. Zhou ym. 2024).

Tekoälymenetelmät eivät korvaa lääkäreitä, vaan radiologin on jatkossa tunnettava CNN:n periaatteet kuvien tulkinnessa. Siksi radiologin työkenttä jopa laajenee ja rooli korostuu (Huhtanen ym. 2020). Tutkielmassa tarkasteltujen syväoppimismenetelmien soveltaminen kliinisessä työssä perustuu pitkälti syötettyyn koulutusdataan, jonka on vaikea ottaa huomioon esimerkiksi potilaan nykytila tai sairaushistoria. Tekoäly ei siis tule korvaamaan ihmisiä, mutta se voi olla hyödyllinen työkalu.

Lähdeluettelo

- Aboelenein, N. M., P. Songhao, A. Koubaa, A. Noor & A. Afifi (2020). "HTTU-Net: Hybrid Two Track U-Net for Automatic Brain Tumor Segmentation". *IEEE Access* 8, s. 101406–101415.
- Akkus, Z., A. Galimzianova, A. Hoogi, D. L. Rubin & B. J. Erickson (2020). "Deep Learning for Brain MRI Segmentation: State of the Art and Future Directions". *Journal of Digital Imaging* 30.4, s. 449–459.
- Alzubaidi, L., J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaría, M. A. Fadhel, M. Al-Amidie & L. Farhan (2021). "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions". *Journal of Big Data* 8.1, s. 53.
- Anaya-Isaza, A., L. Mera-Jiménez & M. Zequera-Diaz (2021). "An overview of deep learning in medical imaging". *Informatics in Medicine Unlocked* 26.
- Berger, A. (2002). "Magnetic resonance imaging". *BMJ* 324, s. 35.
- Blanco Sequeiros, R., S. Koskinen, H. Aronen, N. Lundbom, Vannin R. & O. Teronen (2017). *Kliininen radiologia*. 1. painos. Duodecim.
- Bushberg, J. T., J. A. Seibert, E. M. Leidholdt Jr & J. M. Boone (2011). *The Essential Physics of Medical Imaging*. 3rd edition. Wolters Kluwer Health.
- Chakraborty, C., M. Bhattacharya, S. Pal & S S. Lee (2024). "From machine learning to deep learning: Advances of the recent data-driven paradigm shift in medicine and healthcare". *Current Research in Biotechnology* 7, s. 100164.

- Goodfellow, I., Y. Bengio & A. Courville (2016). *Deep Learning*. MIT Press.
- Guy, C. & D. ffytche (2005). *An Introduction to The Principles of Medical Imaging*. Revised edition. Imperial College Press.
- Hamberg, L. & H. Aronen (1992). ”Magneettikuvauksen perusteet ja tutkimusmenetelmät”. *Duodecim* 108.8, s. 713–724.
- Huhtanen, H., M. Nyman, Karlsson A. & Hirvonen J. (2020). ”Tekoäly radiologiasa”. *Duodecim* 136.17, s. 1957–1964.
- Kelleher, J. D. (2019). *Deep learning*. MIT Press.
- Ker, J., L. Wang, J. Rao & T. Lim (2018). ”Deep Learning Applications in Medical Image Analysis”. *IEEE Access* 6, s. 9375–9389.
- LeCun, Y., Y. Bengio & G. Hinton (2015). ”Deep learning”. *Nature* 521.7553, s. 436–444.
- Sarker, I. H. (2021). ”Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions”. *SN Computer Science* 2.6, s. 420.
- Sekhar, A., S. Biswas, R. Hazra, A. K. Sunaniya, A. Mukherjee & L. Yang (2022). ”Brain Tumor Classification Using Fine-Tuned GoogLeNet Features and Machine Learning Algorithms: IoMT Enabled CAD System”. *IEEE Journal of Biomedical and Health Informatics* 26.3, s. 983–991.
- Shah, H. Ali, F. Saeed, S. Yun, J. H. Park, A. Paul & J. M. Kang (2022). ”A Robust Approach for Brain Tumor Detection in Magnetic Resonance Images Using Finetuned EfficientNet”. *Informatics in Medicine Unlocked* 10, s. 65426–65438.
- Soinila, S. & M. Kaste (2006). *Neurologia*. 2. painos. Duodecim.
- Tayyab Khushi, H. M., T. Masood, A. Jaffari, M. Rashid & S. Akram (2023). ”Improved Multiclass Brain Tumor Detection via Customized Pretrained EfficientNetB7 Model”. *IEEE Access* 11, s. 117210–117230.

- Ting, K. M. (2017). "Confusion Matrix". *Encyclopedia of Machine Learning and Data Mining*, s. 260.
- Vaiyapuri, T., J. Mahalingam, S. Ahmad, E. Yang & S. Y. Jeong (2023). "Ensemble Learning Driven Computer-Aided Diagnosis Model for Brain Tumor Classification on Magnetic Resonance Imaging". *IEEE Access* 11, s. 91398–91406.
- Wu, J., Y Zhang, K. Wang & X. Tang (2019). "Skip Connection U-Net for White Matter Hyperintensities Segmentation From MRI". *IEEE Access* 7, s. 155194–155202.
- Zhang, J., Z. Jiang, J. Dong, Y. Hou & B. Liu (2020). "Attention Gate ResU-Net for Automatic MRI Brain Tumor Segmentation". *IEEE Access* 8, s. 58533–58545.
- Zhou, S. K, H. Greenspan & D. Shen (2017). *Deep Learning for Medical Image Analysis*. 1st edition. Elsevier Science, s. 3–24.
- Zhou, X., P. Shi, B. Sheil & S. Suryasantanac (2024). "Knowledge-based U-Net and transfer learning for automatic boundary segmentation". *Advanced Engineering Informatics* 59, s. 102243.