

**Tuomas Nordlund**

**Neuroverkkoihin pohjautuvat koneoppimismallit  
aivokuvantamismenetelmien tukena**

Tietotekniikan kandidaatintutkielma

20. joulukuuta 2022

Jyväskylän yliopisto

Informaatioteknologian tiedekunta

**Tekijä:** Tuomas Nordlund

**Yhteystiedot:** tuomas.v.p.nordlund@student.jyu.fi

**Ohjaaja:** Timo Tiihonen

**Työn nimi:** Neuroverkkoihin pohjautuvat koneoppimismallit aivokuvantamismenetelmien tukena

**Title in English:** Artificial neural network -based machine learning models in brain imaging

**Työ:** Kandidaatintutkielma

**Sivumäärä:** 34+0

**Tiivistelmä:** Keinotekoiset neuroverkot ovat tehokkaita laskennallisia työkaluja merkityksellisten piirteiden irrottamiseen suurista datamassoista. Aivokuvantamismenetelmien kehittyessä aivoista saadaan yhä enemmän dataa terveydenhuollon ja tieteellisen tutkimuksen tarpeisiin. Näiden datamäärien käsittely manuaalisesti vaatii kuitenkin suuria inhimillisiä ponnisteluja. Siitä huolimatta kaikkea sitä tietoa, joka voisi olla hyödyllistä tai tarpeellista, ei siltikään saada irti, eikä sitä välttämättä edes osata etsiä. Neuroverkkoja kehitetään jatkuvasti vastaamaan näihin kasvaviin haasteisiin, ja tutkimusten perusteella ne soveltuvat hyvin moniulotteisen aivokuvantamisdatan käsittelyyn. Neuroverkot pystyvät oppimaan monien eri sairauksien piirteitä aivoista tallennetuista signaaleista. Neuroverkot voidaan opettaa tunnistamaan terveiden aivojen eri tiloja esimerkiksi tehtävien ja koettujen tunteiden aikana. Neuroverkkoja voidaan myös hyödyntää aivokäyttöliittymäsovelluksissa, jossa ne tulkitsevat nopeasti EEG-datasta käyttäjän antaman käskyn.

**Avainsanat:** Keinotekoinen neuroverkko, aivokuvantaminen, syväoppiminen, neuroni, aivosähkökäyrä, magneettikuvaus, konvoluutioverkko

**Abstract:** Artificial neural networks are powerful computational tools for extracting meaningful features from big datasets. As brain imaging techniques develop further, more and more data is being gathered from the brain to meet the needs of healthcare and scientific research. Processing all of this data manually requires great human effort. Nevertheless, all of the information which could be useful or important cannot be extracted, and some of it we

do not even know to search. Neural networks are being constantly developed to meet these increasing demands, and based on research they are well suited for the processing of multi-dimensional brain imaging data. Neural networks are able to learn the features of many different disorders from the signals recorded from the brain. Neural networks can also be taught to recognize different states of a healthy brain, for example during tasks or experienced emotions. Neural networks can also be applied in brain-computer interface applications, where they rapidly interpret the commands of the user from EEG data.

**Keywords:** Artificial neural network, brain imaging, deep learning, neuron, electroencefalography, magnetic resonance imaging, convolutional neural network

## **Kuviot**

Kuvio 1. Eteenpäinsyöttävä neuroverkko. Alkuperäinen kuva: TseKiChun / Wikimedia Commons, CC BY-SA 4.0 .....	8
Kuvio 2. Konvoluutio, koonti ja esimerkki konvoluutioverkosta. Alkuperäinen kuva: Andreas Maier / Wikimedia Commons, CC BY 4.0 .....	9

# Sisällys

1	JOHDANTO .....	1
2	AIVOKUVANTAMINEN .....	2
2.1	Rakenteellinen magneettikuvaus .....	2
2.2	Toiminnallinen magneettikuvaus .....	3
2.3	Aivosähkökäyrä .....	3
2.4	Aivomagneetikäyrä .....	4
3	KEINOTEKOISET NEUROVERKOT .....	5
3.1	Neuroni .....	6
3.2	Neuroverkkoarkkitehtuurit .....	7
4	NEUROVERKKOARKKITEHTUURIT AIVOKUVANTAMISESSA .....	11
4.1	Datan esikäsittely ja augmentointi .....	12
4.2	Aivojen toimintahäiriöt ja sairaudet .....	13
4.2.1	Rakenteellinen kuvantaminen .....	13
4.2.2	Toiminnallinen kuvantaminen .....	15
4.3	Terveiden aivojen kuvantaminen .....	17
5	POHDINTA .....	19
6	YHTEENVETO .....	22
	LÄHTEET .....	23

# 1 Johdanto

Teknologinen kehitys on mahdollistanut täysin uudenlaisia tapoja kuvata aivoja. Nykyaikaisilla menetelmillä tästä suunnattoman monimutkaisesta rakenteesta on mahdollista saada monenlaista anatomista ja funktionaalista tietoa koko aivojen mittakaavasta aina neuronitasolle asti (Yang ja Yuste 2017). Uusien tekniikoiden kehityksen myötä myös käsiteltävän tiedon määrä lisääntyy, eikä tallennettavan tiedon merkitystä, tai mitä siitä voidaan päätellä, välttämättä edes käsitellä.

Räjähdysmäinen tiedon määrän kasvu asettaa alati kasvavaa painetta kehittää työkaluja, joilla tuota tietoa voidaan hallita ja joilla erotellaan merkityksellinen informaatio muusta tiedosta. Biologisten aivojen toiminnan pohjalta kehitetyt keinotekoiset neuroverkot ovat tällä hetkellä tehokkaimpia keinoja, joilla tietomassoista voidaan irroittaa niitä määritteleviä piirteitä. Neuroverkkojen opetus on laskennallisesti vaativaa, mutta toimiessaan ne voivat esimerkiksi auttaa ja nopeuttaa sairauksien diagnosointia sekä paljastaa jopa sellaista uutta tietoa, joka ei muuten olisi ihmisen havaittavissa.

Tutkielman rakenne on seuraavanlainen. Kappaleessa 2 esitellään aivokuvantamismenetelmiä. Kappale 3 keskittyy keinotekoisien neuroverkkojen peruskäsitteisiin. Kappaleessa 4 perehdytään neuroverkkojen käyttöön normaalien ja poikkeavien aivojen kuvantamisen yhteydessä. Kappale 5 pohtii esitettyjen tietojen merkitystä. Lopuksi kappale 6 päättää tutkielman.

## 2 Aivokuvantaminen

Aivokuvantamisella tarkoitetaan aivoista eri tekniikoiden avulla havaittujen signaalien tallentamista ja sen tavoitteena on tutkia aivojen rakennetta ja toimintaa. Aivojen rakennetta tutkitaan muodostamalla kaksi- tai kolmiulotteisia leikekuvia halutuista kohdista. Tässä tutkielmassa rakenteelliseen kuvaukseen kehitetyistä menetelmistä keskitytään rakenteelliseen magneettikuvaukseen (engl. *structural magnetic resonance imaging*, sMRI). Aivojen toimintaa voidaan puolestaan tutkia mittaamalla aivojen sähköimpulsseja, niiden aiheuttamia magneettikentän muutoksia tai aivojen aktiivisuudesta aiheutuneita veren virtauksen muutoksia (Abhang, Gawali ja Mehrotra 2016; Hansen, Kringelbach ja Salmelin 2010; Buxton 2009). Sähköistä toimintaa tutkitaan aivosähkökäyrällä eli elektroencefalografialla (EEG). Magneettikentässä tapahtuvia muutoksia on mahdollista havaita aivomagneettikäyrällä eli magneetoencefalografialla (MEG). Hemodynamiikkaan perustuvaa tekniikkaa puolestaan kutsutaan toiminnalliseksi magneettikuvaukseksi (engl. *functional magnetic resonance imaging*, fMRI). Tarkastellaan seuraavaksi lyhyesti mitä näillä tekniikoilla havaitut signaalit ovat, kuinka ne kerätään ja miten niitä voidaan hyödyntää.

### 2.1 Rakenteellinen magneettikuvaus

Rakenteellisessa magneettikuvauksessa kohde asetetaan keskelle suurikokoista magneettikenttää, jonka voimakkuus voi magneettikenttien voimakkuutta kuvaavissa mittayksikkö tesloissa mitattuna ja kuvauslaitteesta riippuen vaihdella alle 0,5 teslasta yli kymmeneen teslaan (Moser ym. 2017). Magneettikuvaus perustuu ydinmagneettiseen resonanssiin (engl. *nuclear magnetic resonance*, NMR), jossa magneettikentän suuntaisesti kääntyneet (yleensä vetyatomien ydinten) protonit ”kallistetaan” radiotaajuuspulsseilla hetkellisesti kohtisuoralle tasolle. Palautuessaan takaisin vallitsevan magneettikentän suuntaiseksi protonit vapauttavat energiaa, jonka magneettikuvantamislaitte muuntaa ihmiselle ymmärrettäväksi kuvaksi (Plewes ja Kucharczyk 2003).

Energiaa vapautuu eri kudoksissa eri nopeuksilla, joka tuottaa kuviin niissä havaitut kontrastit. Edellä kuvatulla mekaniikalla voidaan tuottaa niin kutsuttuja T1-painotettuja kuvia, joissa

esimerkiksi rasvakudos näyttää kirkkaammalta kuin vesi (Plewes ja Kucharczyk 2003). Toinen magneettikuvantamismenetelmä perustuu protonien spinien ominaisuuksiin. Kun protonit asetetaan voimakkaaseen magneettikenttään, niiden spinit ovat aluksi synkronoituneina. Ajan myötä ja vallitsevan magneettikentän epätasaisuuksien vuoksi spinit desynkronoituvat. Tätä kutsutaan vaihepoikkeamaksi, ja tämä tuottaa niin kutsutun T2-signaalin, joka näkyy magneettikuvissa eri kontrastein kuin T1-signaali (Plewes ja Kucharczyk 2003) . Riippuen siitä, mitä halutaan tutkia, voidaan kuviin painottaa joko T1- tai T2-signaalia. Magneettikuville voidaan tutkia esimerkiksi aivojen leesioita.

## **2.2 Toiminnallinen magneettikuvaus**

Toiminnallinen magneettikuvaus pohjautuu samaan teknologiaan kuin rakenteellinen magneettikuvauskin, mutta signaalin muodostuksessa hyödynnetään veren happipitoisuuden muutoksia. Happea siirtävä veri pitää sisällään hapettunutta hemoglobiinia eli oksihemoglobiinia, joka on magneettikenttää hylkivää eli diamagneettista. Kun veri luovuttaa hapen, se pitää sisällään magneettikenttää vahvistavaa eli paramagneettista deoksihemoglobiinia. Aivoalueiden aktiivisuuden uskotaan kasvattavan hapenkulutusta, joka näkyy deoksihemoglobiinin lisääntymisenä kyseisellä alueella. Tämä muutos pystytään vastaavasti havaitsemaan T2-signaaliin perustuvassa magneettikuvassa. Toiminnallisella magneettikuvauksella kerätty data on käytännössä neliulotteista, kolme avaruudellista ulottuvuutta ja aikaulottuvuus. (Buxton 2009).

## **2.3 Aivosähkökäyrä**

Päänahkaan kiinnitettävien elektrodien avulla voidaan mitata aivojen oskilloivaa sähköistä toimintaa. Elektrodit asetetaan eri puolille päänahkaa toiminnallisesti eriävien aivoalueiden kohdalle 10-20-järjestelmän mukaisesti (Abhang, Gawali ja Mehrotra 2016). Elektrodeja voi olla vaihteleva määrä, ja jokainen niistä muodostaa oman kanavansa. Koska elektrodit ovat kallon ja päänahan ulkopuolella, on niiden havaitsema signaali seurausta suurten hermosolupopulaatioiden samanaikaisesta aktivaatiosta. EEG mittaa pääasiassa elektrodeja lähinnä olevien hermosolujen, siis aivokuoren, aktiivisuutta. Koska yhdellä alueella tapahtuva ak-



tivaatio voi esiintyä usean eri kanavan signaalissa, on EEG:n spatiaalinen tarkkuus heikko (Luck ja Kappenman 2011). Menetelmän vahvuuksia taas ovat ajallinen tarkkuus, sen helpokäyttöisyys ja noninvasiivisuus. (Teplan ym. 2002).

Usein kiinnostuksen kohteina ovat signaalista eroteltavissa olevat eri taajuusalueet, joiden on havaittu edustavan erilaisia toisistaan riippumattomia toimintoja aivoissa (Herrmann ym. 2016). Yleisesti EEG-signaali voidaan jakaa neljään taajuusalueeseen (engl. *frequency band*), jotka ovat delta (2-4 Hz), theeta (4-8 Hz), alfa (8-13 Hz), ja beeta (13-30 Hz) (Teplan ym. 2002). Signaalissa voidaan myös olla kiinnostuneita niin kutsutuista herätepotentiaaleista (engl. *event-related potential*, ERP), jotka ovat voimakkaita, automaattisia ja ajallisesti sidottuja vasteita sisäisiin tai ulkoisiin ärsykeisiin (Abhang, Gawali ja Mehrotra 2016). EEG:tä on hyödynnetty esimerkiksi vireystasoa, epilepsiaa, sekä kognitiivisia ja motorisia toimintoja koskevissa tutkimuksissa (Teplan ym. 2002).

## 2.4 Aivomagneettikäyrä

Aivomagneettikäyrällä eli MEG:lla mitataan aivojen sähköisestä toiminnasta aiheutuvia magneettikenttiä. Mittauksessa käytetään pään ulkopuolelle asetettavia antureita, jotka tuottavat samankaltaista signaalia kuin EEG:kin. Magneettikenttien havaitseminen vaatii suprajohtavia, nestemäiseen heliumiin upotettuja SQUID-antureita (engl. *superconductive quantum interference device*) sekä niihin liitettyjä vuomuuntajia (engl. *flux transformer*) (Hansen, Kringelbach ja Salmelin 2010). Nykyaikaisissa laitteissa näitä antureita on yli 300 (Hari ja Salmelin 2012). Kuten EEG:kin tapauksessa, myös MEG:n signaalin oletetaan syntyvän pitkälti aivokuoren pyramidisolupopulaatioiden synkronoidusta aktivaatiosta johtuen niiden kohtisuoruudesta suhteessa kalloon ja näin ollen antureihin. MEG on ajallisesti tarkka, eivätkä antureita ja hermosoluja erottavat väliaineet, kuten kallo, tuota signaaliin samanlaista häiriötä kuin EEG-mittauksessa, jonka ansiosta menetelmä on myös spatiaalisesti EEG:aa tarkempi. Menetelmä kärsii kuitenkin EEG:n tavoin inversio-ongelmasta, eli signaalin lähteen tarkka paikantaminen on haasteellista. EEG:llä ja MEG:llä voidaan tutkia pitkälti samoja asioita, mutta MEG-laite on raskas ja vaatii ulkopuolelta tulevilta sähkömagneettisilta häiriöiltä suojatun huoneen eikä siksi sovellu mobiliteettia vaativiin tutkimuksiin. (Hansen, Kringelbach ja Salmelin 2010).

### 3 Keinotekoiset neuroverkot

Keinotekoiset neuroverkot (engl. *artificial neural network*, ANN) ovat koneoppimisessa käytettyjä laskennallisia työkaluja, joiden perusrakenne muodostuu syötekerroksesta (engl. *input layer*), ulostulokerroksesta (engl. *output layer*) sekä vähintään yhdestä piilokerroksesta (engl. *hidden layer*). Kun piilokerroksia on enemmän kuin yksi, puhutaan syvästä neuroverkosta ja syväoppimisestä. Syväoppimiseen perustuvien menetelmien teho perustuu niiden kykyyn käsitellä tehtäviä monessa eri vaiheessa lähtien liikkeelle yksinkertaisista piirteistä ja siirtyen kohti monimutkaisempia rakenteita.

Keinotekoiset neuroverkot soveltuvat hyvin esimerkiksi kuvan- ja puheentunnistukseen sekä luonnollisen kielen prosessointiin. Goodfellow'n, Bengion ja Courvillen (2016) mukaan yleisimpiä koneoppimismenetelmillä ratkottavia ongelmia ovat:

- **Luokittelu:** Ulostulona luokka, johon annettu syöte kuuluu, esim. kuvantunnistus
- **Regressio:** Ulostulona luku annetun syötteen pohjalta
- **Transkriptio:** Ulostulona annettu syöte muutettuna merkkijonoksi, esim. puheentunnistus
- **Kielen kääntäminen:** Syötteenä ja ulostulona merkkijonot eri kielillä
- **Strukturoitu ulostulo:** Ulostulon datalla on tarkka järjestys, jossa arvot määräytyvät suhteessa toisiinsa
- **Anomalioiden havaitseminen:** Algoritmi poimii syötedatasta poikkeavat yksiköt
- **Datan syntetisointi:** Syötteenä harjoitusdata, jonka pohjalta algoritmi generoi uutta samankaltaista dataa
- **Syötteen tyhjien arvojen täyttö:** Syötteenä ”reikäinen” data, ulostulona ennustukset tai arviot siitä, mitä syötteen tyhjiissä kohdissa tulisi olla
- **Kohinan siivous datasta:** Syötteenä korruptoitunut data, ulostulona ennuste alkuperäisestä datasta ennen sen korruptoitumista

Neuroverkkojen toiminta perustuu niiden kykyyn irroittaa niille annetusta harjoitusyötteestä tälle ominaisia, kiinnostuksen kohteena olevia piirteitä. Mitä enemmän ja monipuolisempaa harjoitusdataa verkolle syötetään, sitä paremmiksi ne voivat piirteiden tunnistamisessa kehity-

tyä. Tätä kutsutaan verkon opetuksi. Kun verkko oppii luotettavasti tunnistamaan nämä tehtävän kannalta relevantit piirteet, se pystyy käsittelemään myös sellaisia syötteitä, joita ei alkuperäisestä harjoitusdatasta löydy. (Goodfellow, Bengio ja Courville 2016).

Neuroverkkoja voidaan opettaa joko ohjatusti tai ohjaamattomasti. Ohjattu oppiminen edellyttää ihmisen merkitsemää tai nimikoimaa dataa, jonka perusteella verkko voi arvioida omaa suoritustaan. Toisin sanoen jos harjoitussyöte on esimerkiksi merkitty kuuluvan luokkaan A, mutta verkko asetti syötteen luokkaan B, pystyy verkko havaitsemaan tehdyn virheen ja tekemään tarvittavia korjauksia, jotta arvio olisi seuraavalla ”kierroksella” tarkempi. Ohjaamattomassa oppimisessä taas verkko oppii itsenäisesti tunnistamaan harjoitussyötteen eri piirteitä ja ryhmittelemään syötteitä niiden perusteella. (Goodfellow, Bengio ja Courville 2016).

### 3.1 Neuron

Neuroverkkojen perusyksikköä sanotaan neuroniksi. Neuronit pohjautuvat biologisiin hermosoluihin: ne ottavat syötteitä useista eri lähteistä ja niiden eteenpäin lähettämä ulostulo, ”signaalin voimakkuus”, riippuu niiden syötteiden yhteisvaikutuksesta (Tuominen ym. 2019). Neuroverkon syötekerroksen neuronien määrä vastaa syötteen muuttujien määrää. Ulostulokerroksen neuronien määrä taas riippuu tehtävästä. Mikäli kyseessä on esimerkiksi luokittelutehtävä, jonka lopputulos voi olla vain toinen kahdesta vaihtoehdosta, riittää ulostulolle yksi neuron. Mikäli taas vaihtoehtoja on enemmän kuin kaksi, tarvitaan jokaiselle luokalle oma ulostuloneuron. Samoin regressiotehtävään riittää yksi ulostuloneuron. (Goodfellow, Bengio ja Courville 2016).

Yksittäisen neuronin ulostulo  $a$  voidaan laskea yhtälöllä

$$a = \varphi\left(\sum_{i=1}^N w_i x_i + b\right),$$

missä  $x_i$  on syötteiden  $1, \dots, N$  arvot,  $w_i$  on syötteiden ja neuronin välisille yhteyksille määritellyt painokertoimet,  $b$  on vakiotermin, ja  $\varphi$  on niin kutsuttu aktivaatiofunktio (Tuominen ym. 2019). Aktivaatiofunktion avulla saadaan lineaarinen syöte muunnettua epälineaariseksi, jolloin koneen on mahdollista oppia monimutkaisempia, epälineaarisia tietorakenteita. Jos tällaisessa yhden neuronin muodostamassa kokonaisuudessa esimerkiksi haluttaisiin esittää ulostulo välillä  $]0, 1[$ , voitaisiin aktivaatiofunktioksi valita sigmoid-funktio,

$\sigma(x) = 1/(1 + e^{-x})$ . (Tuominen ym. 2019).

Edellä mainittiin, kuinka neuroverkkoja opetetaan laskemalla odotetun ja saadun arvon välinen virhe (engl. *loss, cost*). Virhe voidaan laskea usealla eri virhefunktiolla, joista yleisimpiä ovat regressiotehtäville soveltuva keskineliösumma (engl. *mean squared error*) sekä luokitelutehtävissä käytetty logistisen regression virhefunktio (engl. *cross-entropy cost function*). Keskineliösummaa kuvataan kaavalla

$$E = \frac{1}{2N} \sum_{x=1}^N \|t - y\|^2,$$

missä  $x$  on harjoitussyöte,  $N$  on harjoitussyötteiden kokonaismäärä,  $t$  on saatu arvo ja  $y$  on odotettu arvo. Logistisen regression virhefunktiota puolestaan kuvaa yhden neuronin tapauksessa kaava

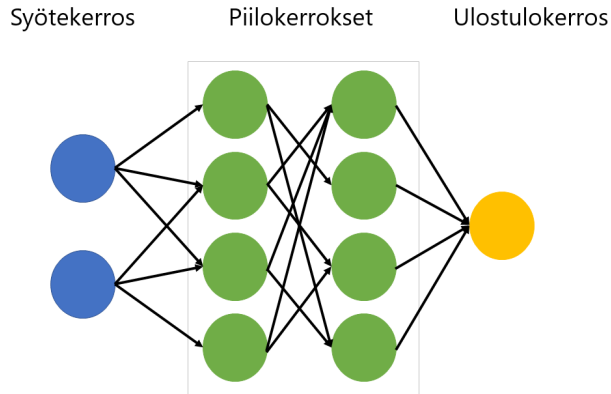
$$E = -\frac{1}{N} \sum_{x=1}^N (y \log t + (1 - y) \log(1 - t)).$$

Koska tavoitteena on tietenkin mahdollisimman hyvin toimiva malli, halutaan tuo virhe mahdollisimman pieneksi. Yhden neuronin tapauksessa tämä tapahtuisi muokkaamalla neuronin ja syötteiden välisiä painokertoimia sekä neuronin vakiokerrointa niin, että virhe saadaan minimoitua. (Tuominen ym. 2019).

### 3.2 Neuroverkkoarkkitehtuurit

Edellä on esitelty neuroverkkojen toiminnan perusteita käyttäen esimerkkinä yhtä neuronua. Tällaisia neuroneita yhdistelemällä on mahdollista muodostaa hyvinkin suuria neuroverkkoja, joista tavanomaisin on niin sanottu eteenpäinsyöttävä neuroverkko (engl. *feed-forward network*), jossa informaatio siis tulee syötekerrokselta ja etenee yhteen suuntaan piilokerrokselta toiselle ja lopulta ulostulokerrokselle (Goodfellow, Bengio ja Courville 2016). Yksinkertainen eteenpäinsyöttävä neuroverkko on esitetty kuviossa 1.

Paitsi ulostulokerroksen neuroneilla, myös kaikissa piilokerroksissa on käytössä aktivaatiofunktiot, jotka muuntavat verkolle syötetyn informaation epälineaariseksi, jotta verkon on mahdollista oppia syötteestä monimutkaisempia tietorakenteita. Myös piilokerroksissa aktivaatiofunktiona voidaan käyttää sigmoid-funktiota, mutta sen ongelmana on arvojen välisten erojen katoaminen suurilla ja pienillä  $x$ :n arvoilla (Goodfellow, Bengio ja Courville 2016).




Kuvio 1. Eteenpäinsyöttävä neuroverkko. Alkuperäinen kuva: TseKiChun / Wikimedia Commons, CC BY-SA 4.0

Tästä syystä funktion derivaatta lähestyy suurilla ja pienillä  $x$ :n arvoilla nollaa. Neuroverkkojen opetus pohjautuu yleensä virhefunktioiden osittaisderivaattojen laskemiseen, joten opetus saattaa olla sigmoid-funktiota käytettäessä hidasta (Tuominen ym. 2019). Nykyään piilokerrosten aktivaatiofunktiona käytetäänkin useimmiten mieluummin ReLU-funktiota (engl. *rectified linear unit*), minkä ulostulo on sama kuin syöte silloin, kun  $x > 0$ , ja muuten 0. Ulostulokerroksessa puolestaan voidaan käyttää usean luokitteluvaihtoehdon tapauksessa sigmoid-funktion yleistettyä versiota, niin kutsuttua softmax-funktiota, joka antaa todennäköisyysjakauman eri vaihtoehdoille. Softmaxia kuvaa yhtälö

$$\text{softmax}(z)_i = \frac{e^{z_i}}{\sum_j e^{z_j}},$$

missä  $z_i$  on se ulostulo, jolle softmax-arvo lasketaan  $z_j$ :n käydessä läpi kaikki ulostuloarvot. (Goodfellow, Bengio ja Courville 2016).

**Konvoluutioverkko:** Konvoluutioverkot, tai konvoluutioneuroverkot (engl. *convolutional neural networks*, CNN), ovat eteenpäin syöttäviä neuroverkkoja, joille ominaisia osia ovat konvoluutiokerros, koontikerros (engl. *pooling layer*) sekä täysin yhdistetty kerros (engl. *fully connected layer*, FC) (Goodfellow, Bengio ja Courville 2016; Merlin Praveena, Angelin Sarah ja Thomas George 2022). Konvoluutiokerroksen syöte on yleensä moniulotteinen taulukko, jonka kaikki arvot kerrotaan kerrokselle määritellyn suodattimen arvoilla ja summaa yhteen konvoluutio-operaatiolla. Koontikerroksessa puolestaan valitaan koontifunk-



Kuvio 2. Konvoluutio, koonti ja esimerkki konvoluutioverkosta. Alkuperäinen kuva: Andreas Maier / Wikimedia Commons, CC BY 4.0

tion avulla konvoluutio-operaatiolla muodostetun taulukon tietyltä alueelta jokin tietty tätä aluetta edustava arvo. Tämä voi olla esimerkiksi taulukon vierekkäisten arvojen suurin arvo (engl. *max pooling*) tai näiden arvojen keskiarvo (engl. *mean pooling*). Koonnin avulla voidaan vähentää pienten muutosten vaikutusta lopputulokseen sekä säädellä seuraavan kerroksen syötteen kokoa. Konvoluutioverkon tuotetta voidaan kutsua piirrekartaksi (engl. *feature map*) (Goodfellow, Bengio ja Courville 2016). Yleinen esimerkki konvoluutio-operaatiosta on esitetty kuviossa 2.

**Takaisinkytketty neuroverkko:** Takaisinkytketyt neuroverkot (engl. *recurrent neural network*, RNN) pystyvät säilyttämään aiempaa kontekstuaalista informaatiota ja oppimaan näin piirteitä, joiden havaitseminen perinteisillä neuroverkoilla ei olisi mahdollista (Graves 2012; Yin, Li ja Wu 2022). Toisin kuin eteenpäin syöttävässä neuroverkossa, takaisinkytketyissä neuroverkoissa tiedon siirtyminen verkossa taaksepäin ja neuronien kehämäiset yhteydet ovat sallittuja (Graves 2012). Takaisinkytkettyjen neuroverkkojen syötettä kutsutaan aikasarjaksi, mutta sarjan etenemisen ei kuitenkaan tarvitse olla konkreettisesti sidottu ajan kulkuun *per se*, vaan syötteeksi sopii mikä tahansa järjestetty kokonaisuus, jonka myöhempien osien sisältö riippuu jollakin tavalla aiemmista syötteen osista (Goodfellow, Bengio ja Courville 2016). Tällainen sarja voi esimerkiksi olla luonnollinen lause.

Käytännössä takaisinkytkettyjen verkkojen ”muisti” on kuitenkin melko rajattua, eli kaukai-  
sempi kontekstuaalinen informaatio katoaa. Ratkaisuksi näiden verkkojen ongelmiin on kehitetty niin sanottuja pitkän lyhytkestoisen muistin (engl. *long short-term memory*, LSTM) lohkoja tai soluja. (Yu ym. 2019). LSTM-lohkot muodostuvat itseensä yhdistetystä solusta sekä kolmesta sigmoid-funktiolla säädellystä portista (engl. *gate*), joiden avulla lohko pystyy

säätelemään tilaansa. Syöte- ja ulostuloportit määräävät, mitä informaatiota lohkoon laske-  
taan sisälle ja siitä ulos, ja unohdusportti (engl. *forget gate*, oma suom.) määrää sen mitä  
sisäisestä tilasta voidaan unohtaa. (Yu ym. 2019).

## 4 Neuroverkkoarkkitehtuurit aivokuvantamisessa

Aivokuvantamisella voidaan tuottaa monenlaista dataa. Rakenteellisessa kuvantamisessa data on kaksi- tai kolmiulotteisia kuvia, jotka siis vastaavasti koostuvat pikseleistä tai vokseleistä. EEG- ja MEG-signaalit taas ovat käytännössä elektrodikanavien ja ajan tuottamia kaksiulotteisia taulukoita (Craik, He ja Contreras-Vidal 2019). Funktionaalinen magneettikuvaus puolestaan tuottaa kolmiulotteisia kuvia aivoista eri ajanhetkinä, eli kokonaisuudessaan data on nelikulotteista.

Näillä metodeilla voidaan tutkia monia eri asioita. Kiinnostuksen kohteena voi olla esimerkiksi eri sairauksien aiheuttamat muutokset (mm. Oh ym. 2020, Riaz ym. 2020), ärsykkeisiin reagointi (mm. Y. Zhang ym. 2020) tai kognitiiviset toiminnot, kuten aivojen aktiivisuus tehtävien aikana (mm. Huang, Xiao ja Wu 2021, Papanicolaou ym. 1986). Usein samaa asiaa voidaan tutkia monin eri keinoin, ja on tutkijan vastuulla päättää, mikä menetelmä tuottaa tutkimuskysymykseen parhaiten sopivaa tietoa. Neuroverkkojen käytön tavoitteena aivokuvantamisen yhteydessä on yleensä tarkka ja luotettava signaalin luokittelu. Edellä mainittujen tutkimuskysymysten kohdalla tavoitteena voisi olla esimerkiksi sairaiden aivojen erottaminen terveistä aivoista magneettikuvien perusteella tai henkilön kokeman tunnetilan tunnistaminen aivosähkökäyrän perusteella.

Tässä luvussa tarkastellaan aluksi lyhyesti datan esikäsittelyä ja augmentointia, jotta neuroverkkomallien käyttö olisi mahdollista. Tämän jälkeen siirrymme hahmottelemaan neuroverkkomallien käyttöä aivokuvantamisdatan käsittelyssä kahdesta näkökulmasta, joista ensimmäinen keskittyy aivoissa esiintyviin poikkeavuuksiin ja toinen terveisiin aivoihin. Aivojen toimintahäiriöitä voidaan tutkia sekä rakenteellisen että toiminnallisen kuvantamisen kautta, joten tämä alaluku on jaettu vastaavasti. Toisaalta myös terveiden aivojen toiminnan ymmärtäminen on kiinnostavaa, joten seuraava alaluku käsittelee sitä, miten tätä voidaan tutkia ja miten neuroverkkomallit voivat näissä tutkimuksissa olla hyödyksi.

Aivokuvantaminen on kirjava tutkimuksen kenttä ja koneoppimisen tarjoamien työkalujen käyttö tuolla kentällä on alati kasvava tutkimuksen kohde, eikä seuraavat kappaleet siten pyri olemaan läheskään kaiken kattavia, vaan esittelemään pienen osan niistä lukuisista mah-



dollisuuksista, mitä tällä monitieteisellä alalla on tarjota. Kappaleessa ei myöskään keskitytä yksittäisten esiteltyjen tutkimusten tuloksiin sinänsä, vaan niissä käytettyihin metodeihin. Kaikkien tutkimusten tekijät kuitenkin ilmoittavat heidän käyttämänsä mallin suoriutuneen luokittelutehtävästä paremmin kuin ne mallit, joihin niitä kussakin artikkelissa verrattiin.

## 4.1 Datan esikäsittely ja augmentointi

Aivokuvantamisdata pitää usein sisällään ei-toivottuja signaaleja, jotka voivat heikentää koneoppimismenetelmien tarkkuutta ja tehoa. Näiden signaalien takia dataa täytyy esikäsitellä, jotta se on käyttökelpoista. EEG:n kohdalla haasteena on menetelmän suhteellisen matala signaali-kohina-suhde (engl. *signal-to-noise ratio*, SNR) (Bozhkov 2016; Antoniadis ym. 2018), joka aiheutuu muun muassa siitä, että mittaamiseen käytetyt elektrodit eivät diskriminoi signaalin lähteitä, jolloin esimerkiksi silmänräpäykset ja lihasten toiminta voivat tuottaa signaaliin ei-toivottuja artefakteja (X. Zhang ym. 2019). EEG-signaalin esikäsitelyyn voi tavoitteesta riippuen kuulua esimerkiksi artefaktien ja ulkoisten häiriöiden poistaminen, datan normalisointi, kiinnostuksen kohteena olevien taajuusalueiden erittely sekä käytettävien elektrodien valinta (Al-Saegh, Dawwd ja Abdul-Jabbar 2021).

Rakenteellisissa ja toiminnallisissa magneettikuvissa taas on mukana rakenteita, jotka ovat diagnostiikan ja luokittelun kannalta epäoleellisia, kuten kallo. Magneettikuvien esikäsitelyssä nämä epäoleelliset osat poistetaan, kuvat muunnetaan samankokoisiksi ja muokataan kohinan vähentämiseksi (esim. Pan ym. 2020). Toiminnallisten magneettikuvien tapauksessa tehdään myös pään liikkeitä korjaavaa käsittelyä (esim. Li, Lin ja Chen 2020).

Syvät oppimismenetelmät vaativat toimiakseen suuren määrän dataa, jota aivokuvantamisen tapauksessa on kuitenkin harvoin suoraan saatavilla (Antoniadis ym. 2018). Mallien tarkkuuden parantamiseksi dataa voidaan luoda keinotekoisesti olemassa olevan datan pohjalta (engl. *data augmentation*). EEG- ja MEG-dataa voidaan luoda esimerkiksi lisäämällä olemassa olevaan dataan kohinaa, vaihtamalla kahden signaalin ajallisesti tai taajuuden puolesta toisiaan vastaavia osia keskenään, sekä poistamalla, venyttämällä tai tiivistämällä joitakin kohtia signaalista (Huang ym. 2020; Roy 2022b). Magneettikuvia taas voidaan augmentoida monilla niin sanotusti tavallisissa kuvantunnistustehtävissä käytetyillä menetelmillä. Näistä

suoraviivaisimpia ovat affinit muunnokset, eli kuvien kierto, skaalaus, rajaus, ja siirto (Nalepa, Marcinkiewicz ja Kawulok 2019). Nämä ovat mahdollisia myös kolmiulotteisille kuville, mikäli halutaan käyttää kolmiulotteista syötettä (Kompanek, Tamajka ja Benesova 2019). Magneettikuvia voidaan myös sekoittaa yhteen (engl. *blending*) käyttäen erilaisia maskeja (Sanaat ym. 2022).

## 4.2 Aivojen toimintahäiriöt ja sairaudet

Aivot voivat kärsiä monenlaisista häiriöistä. Nämä häiriöt voivat johtua sairauksien tai ulkoisten syiden aiheuttamista rakenteellisista muutoksista, eli leesioista, tai niiden taustalla voi olla esimerkiksi geenivirhe. Useat sairaudet ja häiriöt ilmenevät muuttuneena tiedon käsittelyinä, joka puolestaan voi heijastua toimintaan ja käyttäytymiseen.

Koneoppimismenetelmien kehittyessä yhä tehokkaammiksi voi niillä olla keskeinen rooli sairauksien aikaisessa tunnistamisessa, ehkäisemisessä sekä niiden kehittymisen ennustamisessa. Koneoppimisen avulla voidaan myös saada uusia, objektiivisiin kriteereihin perustuvia keinoja diagnosoida sairauksia, joissa aiemmin on jouduttu luottamaan asiantuntijan arvioon, kuten keskittymisen ja autismikirjon häiriöiden tapauksessa.

### 4.2.1 Rakenteellinen kuvantaminen

Rakenteellisella kuvantamisella, millä tämän tekstin kontekstissa tarkoitetaan rakenteellista magneettikuvausta, voidaan tuottaa tarkkaa anatomista tietoa aivoista. Neuroverkot ovat osoittaneet tehonsa ennen kaikkea kuvantunnistamiseen liittyvissä tehtävissä, ja neuroverkot voidaankin opettaa tunnistamaan luotettavasti erilaisia rakenteellisia muutoksia. Esimerkiksi Lian ym. (2020) kehittivät mallin, jonka tavoitteena oli tunnistaa automaattisesti Alzheimerin taudille tyypilliset aivojen rakennemuutokset rakenteellisista magneettikuvista sekä tämän tiedon pohjalta oppia luokittelemaan magneettikuvia. 12-kerroksiselle konvoluutioverkolle syötettyjen kolmiulotteisten kuvien pohjalta malli loi aluksi taudin aiheuttamille muutoksille keskeisiä alueita korostavia tautihavaintokarttoja (engl. *disease attention map*, oma suom.). Näitä käytettiin syöteenä kaksihaariselle, niin kutsutulle HybNet-verkolle. Toinen verkon haaroista, globaali haara, erotteli *koehenkilöille spesifiä informaatiota koko aivoista*

kaksikerroksisella konvoluutioverkolla. Toisessa, lokaalissa haarassa taas eroteltiin keskiarvoistetun tautihavaintokartan pohjalta löydetty alueet pienempiin osiin, jotta pystyttiin tunnistamaan tarkempia, *koehenkilöiden välisiä rajattujen alueiden piirteitä*. Jokaisen alueen keskeiset piirteet irrotettiin kuusikerroksisen konvoluutioverkon avulla ja ryhmiteltiin suuremmiksi kokonaisuuksiksi niiden keskinäisten etäisyyksien perusteella. Lopulta haarojen ulostulot yhdistettiin täysin yhdistetyn verkon syötteeksi.

Myös mielenterveyden häiriöt perustuvat pohjimmiltaan rakenteellisiin muutoksiin ja voivat täten olla tunnistettavissa rakenteellisista kuvista. Oh ym. (2020) pyrkivät mallinsa avulla havaitsemaan magneettikuvista skitsofrenian aiheuttamia muutoksia. Tehtävään käytettiin videoiden luokitteluun kehitettyä nelikerroksista 3D-konvoluutioverkkoa. Tätä varten kallopohjasta pääläen suuntaan poikittaiset magneettikuvaleikkeet kasattiin videoksi. Tutkijat myös selvittivät, millä alueilla oli luokittelun kannalta suurin merkitys jakamalla videot kahdeksaan sektoriin ja peittämällä alueet yksitellen. Mallin havaittiin käyttäneen luokitteluperusteena informaatiota samoilta alueilta, joissa on aiemmissa tutkimuksissa havaittu skitsofrenian aiheuttamia muutoksia.

Toisessa tutkimuksessa (Wang, Gong ja Fu 2021) puolestaan selvitettiin, miten neuroverkkomallilla voidaan tutkia masennukseen liittyviä rakenteellisia muutoksia. Tutkijat kertovat artikkelissaan, ettei vakavasta masennuksesta kärsivistä potilaista ole yksityisyydensuojan takia saatavilla suuria tietokantoja. Kiertääkseen tämän puutteen opetettiin tutkimuksessa käytetty 3D-konvoluutioverkko aluksi tunnistamaan Alzheimerin taudille ominaisia piirteitä rakenteellisista magneettikuvista. Tämän jälkeen luokittelukerroksen parametrit hienosäädettiin masennuksen luokitteluun sopiviksi (engl. nk. *transfer learning*). Tällä menettelyllä saatiin hyvä, noin 84 %:n luokittelutarkkuus.

Kun tutkimuksen kohteena ovat aivokasvaimet, on tavoitteena usein magneettikuvan segmentointi, eli kuvan jakaminen osiin sen perusteella, mitkä alueet ovat kasvaimen kannalta relevantteja (Magadza ja Viriri 2021). Koska kasvaimet voivat sijaita eri puolilla aivoja, olla kooltaan ja muodoltaan hyvin vaihtelevia ja muodostaa vain pienen osan kuvasta, niiden tunnistaminen voi olla koneelle haasteellista, mutta toisaalta juuri nämä tiedot ovat arvokkaita kasvainta hoitavalle henkilökunnalle (Ranjbarzadeh ym. 2021). Esimerkiksi Ranjbarzadeh ym. (2021) pyrkivät ratkaisemaan näitä ongelmia käyttämällä mallinsa syötteenä tehokkaasti

esikäsiteltyjä kuvia useilla eri kontrasteilla, kuten T1- ja T2-painotettuja kuvia. Heidän mallinsa käytti kasvaimen odotettua sijaintia sen tarkempaan lokalisaatioon ja hyödynsi Lianin ym. (2020) kehittämän mallin tapaan lokaaleja ja globaaleja konvoluutioverkkoja (artikkelissa engl. *cascade CNN*).

#### 4.2.2 Toiminnallinen kuvantaminen

Aivojen toimintahäiriöitä voidaan tutkia paitsi rakenteellisten muutosten kautta, myös sen perusteella, miten ne käsittelevät tietoa. Monien aivotoiminnan häiriöiden myötä tiedon käsittely aivoissa muuttuu tai toimii joissain tapauksissa ikään kuin virheellisesti (Papp ym. 2020; Babij ym. 2022). Toiminnallisella kuvantamisella on mahdollista seurata, miten aivot toimivat lepotilassa tai esimerkiksi tehtävien aikana.

Eräs tapa selvittää aivojen toimintaa on aivojen niin sanotun konnektiivisuuden tutkiminen. Aivot muodostavat toisistaan toiminnallisesti riippuvien alueiden kokonaisuuden, ja näiden eri yhteyksien tutkiminen on välttämätöntä aivojen toiminnan ymmärtämiseksi. Aivojen konnektiivisuudessa esiintyvien muutosten on myös havaittu korreloivan monien eri toimintahäiriöiden kanssa (Riaz ym. 2020). Toiminnallisen magneettikuvan tuottama data soveltuu sen neliulotteisuuden sekä sen korkean spatiaalisen tarkkuuden ansiosta hyvin aivojen konnektiivisuuden tutkimiseen, mutta myös muun muassa EEG-kanavien riippuvuuksia tutkimalla on pyritty havaitsemaan lievää masennusta (Li ym. 2020).

Esimerkiksi Riazin ym. (2020) kehittämän neuroverkon tavoitteena oli tunnistaa fMRI-syötteen perusteella ADHD:sta kärsivät koehenkilöt sekä tutkia tähän liittyviä muutoksia konnektiivisuudessa. Käytetty neuroverkko oli alusta loppuun opetettu kokonaisuus (engl. *end-to-end network*), joka koostui piirteet erottelevasta moduulista, konnektiivisuuden havaitsevasta osasta sekä lopullisen luokittelun tekevästä osasta. Aivot jaettiin 90 alueeseen (engl. *region of interest*, ROI). Jokaisesta näistä alueesta irroitettiin piirteet 15-kerroksisella konvoluutioverkolla. Kaikilla näistä verkoista oli jaetut parametrit, jolloin myös muutokset näihin parametreihin vaikuttivat kaikkiin verkkoihin. Aivoalueparien samankaltaisuus selvitettiin kolmikerroksisella, täysin yhdistetyllä verkolla ja lopullinen ennuste saavutettiin nelikerroksisella, täysin yhdistetyllä verkolla.

Sheynin ym. (2021) taas kehittivät mallin, jonka tavoitteena oli traumaperäisen stressihäiriön (engl. *posttraumatic stress disorder*, PTSD) ennustaminen selvittämällä eri aivoalueiden konnektiivisuuden yhteyttä traumaperäisen stressihäiriön eri oirekuviin sekä tästä parantumiseen. Tutkimuksessa käytettiin sekä lepotilassa (engl. *resting state fMRI*, rs-fMRI) että kahden tehtävän aikana kerättyä fMRI-dataa. Malli irroitti 114 aivoalueen aikasarjoista piirteet yksiulotteisella konvoluutioverkolla sekä laski alueparien väliset korrelaatiot kolmikerroksisella eteenpäin syöttävällä neuroverkolla. Tästä syntyneitä korrelaatiomatriiseja käyttäen laskettiin piirrekartalle painokertoimet joiden perusteella luotiin uusi korrelaatiomatriisi.

Li, Lin ja Chen (2020) puolestaan selvittivät Alzheimerin taudin tunnistamista fMRI-signaalista. Tutkijoiden mukaan fMRI:n neliulotteinen data muunnetaan monissa tutkimuksissa 2D- tai 3D-kuviksi, joka usein johtaa tiedon katoamiseen. Heidän ratkaisunsa tähän oli yhdistää rakenteelliset piirteet tunnistava 3D-konvoluutioverkko aikasarjoille soveltuvaan LSTM-kerrokseen. Koska LSTM-verkolle ei voi suoraan syöttää neliulotteista dataa, heidän mallinsa käytti 3D-konvoluutioverkkoa piirteiden erotukseen jokaisessa aikasarjan kuvassa. Näiden verkkojen ulostuloja käytettiin sitten LSTM-kerroksen syötteenä.

Dubreuil-Vall, Ruffini ja Camprodon (2020) vertailivat, miten konvoluutioverkko, LSTM-verkko sekä ”tavallinen”, piilokerroksia vailla oleva verkko suoriutuivat ADHD:n luokittelussa EEG-datasta. Testissä koehenkilöt suorittivat pienen tehtävän, jonka aiheuttamassa herätepotentiaalissa 100 ms:n kohdalla havaittavien erojen perusteella mallit oppivat tunnistamaan, kärsiikö koehenkilö ADHD:sta vai ei. Parhaiten tästä suoriutui konvoluutioverkko noin 88 %:n tarkkuudella. Tutkijat selvittivät myös tarkemmin, mistä nämä erot johtuivat. Farsi ym. (2020) taas vertailivat kaksikerroksista LSTM-verkkoa ja 2- ja 4-kerroksisia neuroverkkoja, kun tehtävänä oli tunnistaa alkoholistit EEG-datasta. Tästä puolestaan suoriutui parhaiten LSTM-verkko 93 %:n tarkkuudella.

Zheng ym. (2021) puolestaan pyrkivät tunnistamaan skitsofreniaa fMRI-datasta käyttämällä valmiiksi opetetun VGG16-nimisen konvoluutioverkon parametreja tehtävään paremmin soveltuvaksi muokatussa VGG16-verkossa. Samoin kuin aiemmin mainitussa tutkimuksessa (Wang, Gong ja Fu 2021), tässäkin saavutettiin vastaavanlaisella parametrien siirrolla hyvä, miltei 88 %:n luokittelutarkkuus.

### 4.3 Terveiden aivojen kuvantaminen

Aivojen toimintahäiriöiden ymmärtäminen on tärkeää niiden hoidon ja ennaltaehkäisyn takia. Kuitenkin, jotta voidaan ymmärtää poikkeavia aivoja, tulee meillä olla mahdollisimman hyvä käsitys myös siitä, miten terveet aivot toimivat. Kuten edellisestä kappaleesta käy ilmi, on tärkeää ymmärtää, miten aivot prosessoivat tietoa ja reagoivat ärsykkeisiin. Me reagoimme ensisijaisesti tunteidemme kautta, ja emootioiden tunnistaminen koneoppimismenetelmillä onkin keskeinen osa niin kutsuttua affektiivista laskentaa (engl. *affective computing*) (Bos ym. 2006). On havaittu, että esimerkiksi EEG-signaalista voidaan tunnistaa eri emootioille ominaisia piirteitä (Sammler ym. 2007; Mathersul ym. 2008). Nämä piirteet ovat tällöin myös neuroverkkojen opittavissa.

Monissa emootioiden tunnistamista koskevissa tutkimuksissa (Dadebayev, Goh ja Tan 2021) hyödynnetään tunteiden luokittelussa kaksikulotteista kiihtymisen ja valenssin mallia (engl. *arousal-valence model*), jossa kiihtyminen viittaa ärsykkeen aiheuttamaan aktivaatioon ja valenssi taas koetun tunteen positiivisuuteen tai negatiivisuuteen (Bos ym. 2006). Dadebayevin, Gohin ja Tanin (2021) mukaan suuressa osassa emootioiden tunnistamisesta käytetyistä koneoppimismenetelmistä hyödynnetään ohjaamattoman oppimisen algoritmeja.

Esimerkkinä neuroverkkojen kyvystä oppia tunnistamaan emootioita toimii Zhangin ym. (2020) tutkimus, jossa eri neuroverkkoarkkitehtuurit luokittelivat tunteita valmiiksi esikäsittelystä EEG-datasta. Tässä tutkimuksessa luokittelutehtävästä selvisivät parhaiten neljästä konvoluution ja suurimman arvon koontifunktion lohkoista koostunut konvoluutioverkko, sekä hybridiverkko, jossa ensimmäisen kerroksen muodosti konvoluutioverkko ja seuraavat kaksi kerrosta olivat LSTM-yksiköitä. Näistä jälkimmäinen suoriutui tehtävästä paremmin.

Reaktioiden lisäksi on tärkeää saada käsitys siitä, mitä aivoissa tapahtuu ihmisen – ja muiden eläinten – toiminnan aikana. Huang, Xiao ja Wu (2021) esimerkiksi tutkivat, kuinka hyvin heidän neuroverkkomallinsa oppi tunnistamaan erilaisia tehtäviä fMRI-datasta. Tehtävätyyppejä oli seitsemän ja niihin kuului muun muassa emootioiden tunnistamista kasvokuvista, puheen merkityksen hahmottamista sekä motorisia tehtäviä. Heidän mallinsa pyrki säilyttämään datan ajallisen informaation suorittamalla konvoluutio-operaatioita eri ajanhetkillä. Kolmiulotteisia konvoluutioverkkoja seurasi kaksisuuntaisesti kytketyt LSTM-kerrokset

sekä niin kutsuttu huomiomekanismi (engl. *attention mechanism*), jonka tarkoituksena oli korostaa tärkeitä piirteitä.

Neuroverkkoja voidaan myös hyödyntää kun halutaan määrittellä, vastaavatko ihmisen aivot hänen kronologista ikäänsä. Suuri kontrasti ihmisen kronologisen iän ja hänen aivojensa välillä saattaa olla merkki alkavasta sairaudesta (Kaufmann ym. 2019). Feng ym. (2019) opettivat tavallisen kolmiulotteisen neuroverkkomallin luokitteluun terveistä aivoista otetut rakenteelliset magneettikuvat iän perusteella. Tutkimuksessa selvitettiin myös muun muassa sitä, minkä aivoalueen kuvista saatiin luotettavimmat tulokset ikäryhmiin luokittelun suhteen.

Aivokuvantamisen ja koneoppimismallien rajapinnassa ehkä eniten huomiota saanut sovel-lusalue on niin kutsutut aivokäyttöliittymät. Aivokäyttöliittymät ovat koneita, joita voidaan ohjata aivoista mitatuilla signaaleilla. Mittaukseen käytetään useimmiten EEG:tä, sillä se mahdollistaa signaalien mittaamisen päänahalta eikä edellytä käyttäjän liikkumattomuutta (Bozhkov 2016), mutta myös invasiiviset mittausmenetelmät ovat mahdollisia (McFarland ja Wolpaw 2008). Aivokäyttöliittymät edellyttävät artefakteille herkän EEG-signaalin paitsi tarkkaa, myös nopeaa luokittelua. Tehtävää vaikeuttavat myös käyttäjien yksilölliset erot (Roy 2022b). Syväoppimisen käyttö aivokäyttöliittymien kehityksessä on perustel-tua, sillä vaikka tutkimuksissa pyritään usein parantamaan mallien tehoa tiedon esikäsitte-lyllä, syväoppimismallit pystyvät ottamaan syötteenä myös suoraan käsittelemätöntä dataa (Tibrewal, Leeuwis ja Alimardani 2022). Edellä mainittuihin haasteisiin on pyritty vastaa-maan esimerkiksi syöttämällä eri taajuusalueiden signaalit moniskaalaiselle konvoluutioloh-kolle (Roy 2022b), kasaamalla päällekkäin ohjaamattomaan oppimiseen perustuvia neuro-verkkoja (Kundu ja Ari 2020) sekä hyödyntämällä erillisiä, eri taajuusalueiden piirteiden erotteluun suunniteltuja algoritmeja (esim. nk. *filter bank common spatial pattern*, FBCSP) ja parametrien siirtoa (Roy 2022a; R. Zhang ym. 2021).

## 5 Pohdinta

Tässä tutkielmassa esitettyjen menetelmien perusteella voidaan koneoppimisen soveltaminen neurotieteiden kontekstissa jakaa kolmeen tehtävään. Ensinnäkin, koneoppimista voidaan hyödyntää terveydenhuollossa diagnostisena työvälineenä. Kuten kappaleessa 4.2 mainittiin, joudutaan monien tautien toteamisessa luottamaan alan ammattilaisten arvioon. Kouluttautuminen alalle ja käytännön kokemuksen kerääminen ovat kalliita sekä ajallisesti että taloudellisesti, eikä virheellisiltä diagnooseilta siltikään voida välttyä. Virheelliset diagnoosit puolestaan voivat aiheuttaa merkittävää haittaa potilaalle tai johtaa jopa kuolemaan. Monissa toimintahäiriöissä, kuten ADHD:ssa, diagnosointi on usein hidasta ja virheellistä (Peng ym. 2013), josta syystä tarve objektiivisiin kriteereihin nojaaville diagnostisille työkaluille on suuri. Tässä tutkielmassa on esitelty vain pieni osa neuroverkkomallien, ja laajemmassa mittakaavassa koneoppimismenetelmien perhettä, mutta silti voidaan havaita, kuinka monenlaisia sairauksia ne voivat oppia tunnistamaan.

Työtä on kuitenkin vielä jäljellä. Tässä esiteltyissä tutkimuksissa on tietenkin tähdätty mahdollisimman hyvään luokitteluprosenttiin, ja useimmat artikkelit ilmoittivatkin saavuttaneensa sen hetkisiä, niin sanottuja *state-of-the-art*-menetelmiä paremman tuloksen tarkalla datan esikäsittelyllä ja verkkoarkkitehtuurin suunnittelulla. Luokittelun parantamisen keinot ovat hyvä tutkimusaihe itsessään, mutta korkea luokitteluprosentti ei yksin saa olla arvo sinänsä. Mikäli halutaan kehittää terveydenhuoltoon soveltuvia välineitä, täytyy niihin sisältyä enemmän tai vähemmän automatisoitu datan esikäsittely verkolle sopivaan muotoon.

Tämän lisäksi tulee neuroverkkotutkimuksessa kiinnittää huomiota tautien päällekkäisyyteen. Monet taudit voivat muistuttaa toisiaan, jolloin täytyy selvittää, kuinka hyvin neuroverkkomalli pystyy diskriminoimaan näiden tautien välillä. Tätä pohtivat esimerkiksi Oh ym. (2020) artikkelissaan. Toisaalta etenkin mielenterveyden häiriöihin liittyy usein komorbiteettia (Plana-Ripoll ym. 2019), mikä voi osoittautua haasteeksi koneoppimismalleille. Onko neuroverkoilla edes mahdollista erotella päällekkäin vaikuttavia sairauksia toisistaan? Tätä ei tämän tutkielman puitteissa pyritty selvittämään, mutta kirjoittajan oletus on, että kehittyneillä ohjaamattoman oppimisen malleilla sairauksien ryhmittely voisi onnistua. Tällaisten tehtävien ratkaisu voi vaatia yhä monimutkaisempia hybridimalleja, joissa esimer-



kiksi toisistaan erilliset verkot oppivat tunnistamaan eri sairauksiin kuuluvia piirteitä, jonka jälkeen nämä tiedot yhdistyisivät yhdessä verkossa.

Aivotutkimuksen alkuaikoina on tieto terveiden aivojen toiminnasta jouduttu päättämään erilaisista leesioiden aiheuttamista muutoksista. Toisaalta, kuten luvussa 4.3 todettiin, vaatii aivojen poikkeavan toiminnan tunnistaminen pohjalleen lähtökohtaisesti juuri tietoa siitä, miten tavalliset aivot toimivat. Tästä pääsemme toiseen tapaan hyödyntää koneoppimismalleja neurotieteissä, eli niiden käyttö tutkimuksessa. Toisin sanoen niitä voidaan parhaimmassa tapauksessa käyttää tuottamaan täysin uutta tietoa aivoista. Käyttäytymisessä ja reagoitavoissa on yksilöiden välillä suurta vaihtelua, joten olisi mielenkiintoista selvittää, havaitisiko esimerkiksi ohjaamaton neuroverkko toisistaan erottuvia ryhmiä samoja ärsykeitä esitettäessä. Emootioita tunnistamaan opetettua neuroverkkoa voisi käyttää tutkimaan, kuinka eri ihmiset tulkitsevat vaikkapa luettua tekstiä tai sosiaalisia tilanteita. Liikkeen aloittamista ja sen yhteyttä tietoisuuteen on myös tutkittu paljon (Guggisberg ja Mottaz 2013), ja voisi olla kiinnostavaa selvittää, pystyisikö neuroverkko luokittelemaan liikkeen aloituksen oikein, ja kuinka nopeasti luokittelu todella tapahtuisi.

Liikkeeseen, etenkin kuviteltuun sellaiseen, liittyvät ominaispiirteet ovat eräitä tärkeimmistä signaaleista, joita aivokäyttöliittymien käytössä pyritään hyödyntämään. Kolmas kategoria, missä neuroverkkoja voidaan käyttää aivokuvantamisen tukena, ovatkin erilaiset sovellukset. Aivokäyttöliittymät ovat herättäneet suurta kiinnostusta niiden suuren potentiaalinvuoksi. Ne voivat tarjota esimerkiksi uusia tapoja käyttää koneita ja hallita proteeseja sekä parempia keinoja, joilla halvaantuneet voivat kommunikoida. Aivokäyttöliittymien mahdollisuuksissa vain mielikuvitus on rajana. Filosofisesti voidaan pohtia, että jos aivokäyttöliittymien toiminnan rakentaminen kuvitellun liikkeen varaan häivyttää tarpeen fyysisille raajoille, missä kulkevat tulevaisuudessa kehomme rajat. Minkälaista liikettä pystymme kuvittelemaan ja onko tällainen liike mahdollista muuntaa fyysiseksi käskyksi? Kuinka luonnolliseksi osaksi päivittäistä toimintaamme voi koneen liike tulla koneoppimisen kehittyessä paremmaksi yksilöllisten signaalien ja raajien aivosignaalidatan tulkitsemisessä?

Kun tietokoneet tulevat yhä lähemmäs ihmistä, ei ole kuitenkaan enää niin, että vain ihmiset pyrkivät tulkitsemaan tietokonetta, vaan myös koneet pyrkivät tulkitsemaan ihmistä: mitä me tunnemme tai mitä haluamme tapahtuvan. Tähän liittyy väistämättä myös ymmärrys

ihmisten eri tunnetiloista. Näiden prosessointiin tähtää kappaleessa 4.3 esitelty affektiivinen laskenta. Emootioiden ymmärrys avaa mahdollisuuden esimerkiksi puheen ja tekstin semanttisten merkitysten tulkitsemiselle. Neuroverkot oppivat niille annetusta syötteestä merkityksellisiä piirteitä, mutta se, mikä on esimerkiksi ihmisen puheessa merkityksellisintä, voi hyvinkin vaihdella puhujan tunnetilan mukaan. Tunteiden ymmärrys avaa myös oven ihmisten manipulaatioon, mistä syystä yhä älykkäämpien koneiden toteutukseen täytyy saada liitettyä mukaan myös ymmärrystä empatiasta ja etiikasta.

Keinotekoisia neuroverkkoja voidaan siis soveltaa hyvin monin tavoin aivokuvantamisdatan prosessoimisessa monilla tieteen ja tekniikan aloilla. Pohdinnan alusta saattaa saada kuvan, että tutkielma esittäisi neuroverkot esimerkiksi tulevaisuuden korvikkeena lääketieteen alan ammattilaisille. Näin ei suinkaan ole. Neuroverkkoja käytettäessä tulee harjoittaa suurta varovaisuutta ja tarkkaavaisuutta, sillä etenkin ohjatut verkot oppivat juuri sen, mitä niille opetetaan. Virheellisen informaation syöttö verkolle voi johtaa itseään ruokkivaan kehään, mikä voi puolestaan esimerkiksi terveydenhuollossa johtaa juuri sellaisiin vääriin diagnooseihin, joita neuroverkkojen kaltaisilla työkaluilla halutaan ehkäistä. Luotettavan, monipuolisen ja tasapainoisen harjoitusdatan tekeminen edellyttää valtavasti tutkimusta ja asiantuntijuutta, ja sittenkin neuroverkkoihin ja antamiin luokittelutuloksiin tulee ainakin vielä toistaiseksi suhtautua korkeintaankin suuntaa-antavana, joskin hyvin lupaavana apuvälineenä.

## 6 Yhteenveto

Tässä tutkielmassa on luotu katsaus siihen, millaisia tutkimuskysymyksiä aivokuvantamisen avulla voidaan tutkia ja miten neuroverkkoihin pohjautuvia malleja voidaan käyttää aivokuvantamistulosten käsittelyssä. Jo muutamilla koneoppimisen perusmalleilla voidaan tutkia monia eri ilmiöitä, ja toisaalta samasta ilmiöstä voidaan tallentaa ja tarkastella monia eri signaaleja, joita voidaan puolestaan tutkia monilla eri koneoppimismalleilla.

Aivokuvantamistekniikat voidaan jakaa rakenteellisiin ja toiminnallisiin tekniikoihin. Rakenteellisista kuvantamistekniikoista esiteltiin rakenteellinen magneettikuvaus ja toiminnallisen kuvantamisen keinoista tarkasteltiin toiminnallista magneettikuvausta, aivosähkökäyrää sekä aivomagneettikäyrää. Keinotekoiset neuroverkot koostuvat neuroneista ja ne pysyvät aktivaatiofunktioiden ja virheen minimoimisen avulla oppimaan epälineaarisia tietorakenteita niille syötetystä datasta ohjatusti tai ohjaamattomasti. Neuroverkoarkkitehtuureista esiteltiin eteenpäin syöttävä neuroverkko, konvoluutioverkko sekä takaisinkytketty neuroverkko ja tästä kehitetty LSTM-yksikkö.

Konvoluutioverkot ovat osoittautuneet tehokkaiksi työvälineiksi ja ne soveltuvat hyvin moniin eri koneoppimistehtäviin, kuten luokitteluun. LSTM-verkkojen käyttö on puolestaan perusteltua silloin, kun halutaan tutkia pitkän aikavälin tai etäisyyden riippuvuussuhteita sarjoista, kuten EEG- tai fMRI-datasta. Neuroverkot voivat oppia tunnistamaan magneettikuvista monien sairauksien, kuten kasvainten, Alzheimerin taudin, skitsofrenian ja masennuksen aiheuttamia rakenteellisia muutoksia aivoista. Neuroverkoille voidaan myös opettaa mitä muuttuneet aivoalueiden väliset yhteydet näyttävät eri sairauksissa ja toimintahäiriöissä, kuten ADHD:ssa, traumaperäisessä stressihäiriössä sekä Alzheimerissa.

Terveiden aivojen toiminnasta neuroverkot voivat oppia esimerkiksi tunnistamaan emootioita EEG-signaalin perusteella, luokittelemaan fMRI-datasta mitä tehtävää ihminen on suorittamassa sekä arvioimaan ihmisen ikää magneettikuvien perusteella. Neuroverkojen kehitys on todennäköisesti välttämätön edellytys hyvin ja nopeasti toimiville aivokäyttöliittymille.

## Lähteet

Abhang, Priyanka A, Bharti Gawali ja Suresh Mehrotra. 2016. *Introduction to EEG-and speech-based emotion recognition*. Academic Press.

Antoniades, Andreas, Loukianos Spyrou, David Martin-Lopez, Antonio Valentin, Gonzalo Alarcon, Saeid Sanei ja Clive Cheong Took. 2018. “Deep neural architectures for mapping scalp to intracranial EEG”. *International journal of neural systems* 28 (08): 1850009. <http://dx.doi.org/10.1142/S0129065718500090>.

Babij, Rachel, Camilo Ferrer, Alexander Donatelle, Sam Wacks, Amanda M Buch, James E Niemeyer, Hongtao Ma, Zhe Ran S Duan, Robert N Fetcho, Alicia Che ym. 2022. “Gabbr3 is required for the functional integration of pyramidal neuron subtypes in the somatosensory cortex”. *Neuron*, <http://dx.doi.org/10.1016/j.neuron.2022.10.037>.

Bos, Danny Oude, ym. 2006. “EEG-based emotion recognition”. *The influence of visual and auditory stimuli* 56 (3): 1–17.

Bozhkov, Lachezar. 2016. “Overview of deep learning architectures for classifying brain signals”. *KNOWLEDGE SOCIETY*, 54.

Buxton, Richard B. 2009. *Introduction to functional magnetic resonance imaging: principles and techniques*. Cambridge university press. <http://dx.doi.org/10.1017/CBO9780511605505>.

Craik, Alexander, Yongtian He ja Jose L Contreras-Vidal. 2019. “Deep learning for electroencephalogram (EEG) classification tasks: a review”. *Journal of neural engineering* 16 (3): 031001. <http://dx.doi.org/10.1088/1741-2552/ab0ab5>.

Dadebayev, Didar, Wei Wei Goh ja Ee Xion Tan. 2021. “EEG-based emotion recognition: Review of commercial EEG devices and machine learning techniques”. *Journal of King Saud University-Computer and Information Sciences*, <http://dx.doi.org/10.1016/j.jksuci.2021.03.009>.

- Dubreuil-Vall, Laura, Giulio Ruffini ja Joan A Camprodon. 2020. “Deep learning convolutional neural networks discriminate adult ADHD from healthy individuals on the basis of event-related spectral EEG”. *Frontiers in neuroscience* 14:251. <http://dx.doi.org/10.3389/fnins.2020.00251>.
- Farsi, Leila, Siuly Siuly, Enamul Kabir ja Hua Wang. 2020. “Classification of alcoholic EEG signals using a deep learning method”. *IEEE Sensors Journal* 21 (3): 3552–3560. <http://dx.doi.org/10.1109/JSEN.2020.3026830>.
- Feng, Xinyang, Zachary C Lipton, Jie Yang, Scott A Small ja Frank A Provenzano. 2019. “Estimating brain age based on a healthy population with deep learning and structural MRI”. *arXiv preprint arXiv:1907.00943*, <https://doi.org/10.48550/arXiv.1907.00943>.
- Goodfellow, Ian, Yoshua Bengio ja Aaron Courville. 2016. *Deep Learning*. [Http://www.deeplearningbook.org](http://www.deeplearningbook.org). MIT Press.
- Graves, Alex. 2012. *Supervised Sequence Labelling with Recurrent Neural Networks*. Ni-de 385. Springer Science & Business Media. <http://dx.doi.org/10.1007/978-3-642-24797-2>.
- Guggisberg, Adrian G, ja Anaïs Mottaz. 2013. “Timing and awareness of movement decisions: does consciousness really come too late?” *Frontiers in human neuroscience* 7:385. <http://dx.doi.org/10.3389/fnhum.2013.00385>.
- Hansen, Peter, Morten Kringelbach ja Riitta Salmelin. 2010. *MEG: an introduction to methods*. Oxford university press.
- Hari, Riitta, ja Riitta Salmelin. 2012. “Magnetoencephalography: From SQUIDs to neuroscience: Neuroimage 20th anniversary special edition”. *Neuroimage* 61 (2): 386–396. <http://doi.org/10.1016/j.neuroimage.2011.11.074>.
- Herrmann, Christoph S, Daniel Strüber, Randolph F Helfrich ja Andreas K Engel. 2016. “EEG oscillations: from correlation to causality”. *International Journal of Psychophysiology* 103:12–21. <http://dx.doi.org/10.1016/j.ijpsycho.2015.02.003>.

- Huang, Weijian, Li Wang, Zhenxiong Yan ja Yanjun Liu. 2020. “Classify motor imagery by a novel CNN with data augmentation”. *Teoksessa 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 192–195. IEEE. <http://dx.doi.org/10.1109/EMBC44109.2020.9176361>.
- Huang, Xiaojie, Jun Xiao ja Chao Wu. 2021. “Design of Deep Learning Model for Task-Evoked fMRI Data Classification”. *Computational Intelligence and Neuroscience 2021*. <http://dx.doi.org/10.1155/2021/6660866>.
- Kaufmann, Tobias, Dennis van der Meer, Nhat Trung Doan, Emanuel Schwarz, Martina J Lund, Ingrid Agartz, Dag Alnæs, Deanna M Barch, Ramona Baur-Streubel, Alessandro Bertolino ym. 2019. “Common brain disorders are associated with heritable patterns of apparent aging of the brain”. *Nature neuroscience* 22 (10): 1617–1623. <http://dx.doi.org/10.1038/s41593-019-0471-7>.
- Kompanek, Matej, Martin Tamajka ja Wanda Benesova. 2019. “Volumetric Data Augmentation as an Effective Tool in MRI Classification Using 3D Convolutional Neural Network”. *Teoksessa 2019 International Conference on Systems, Signals and Image Processing (IWSSIP)*, 115–119. IEEE. <http://dx.doi.org/10.1109/IWSSIP.2019.8787315>.
- Kundu, Shubhasri, ja Samit Ari. 2020. “A deep learning architecture for p300 detection with brain-computer interface application”. *Irbm* 41 (1): 31–38. <http://dx.doi.org/10.1016/j.irbm.2019.08.001>.
- Li, Wei, Xuefeng Lin ja Xi Chen. 2020. “Detecting Alzheimer’s disease Based on 4D fMRI: An exploration under deep learning framework”. *Neurocomputing* 388:280–287. <http://dx.doi.org/10.1016/j.neucom.2020.01.053>.
- Li, Xiaowei, Rong La, Ying Wang, Bin Hu ja Xuemin Zhang. 2020. “A deep learning approach for mild depression recognition based on functional connectivity using electroencephalography”. *Frontiers in neuroscience* 14:192. <http://dx.doi.org/10.3389/fnins.2020.00192>.
- Lian, Chunfeng, Mingxia Liu, Yongsheng Pan ja Dinggang Shen. 2020. “Attention-guided hybrid network for dementia diagnosis with structural MR images”. *IEEE transactions on cybernetics*, <http://dx.doi.org/10.1109/TCYB.2020.3005859>.

- Luck, Steven J, ja Emily S Kappenman. 2011. *The Oxford handbook of event-related potential components*. Oxford university press.
- Magadza, Tirivangani, ja Serestina Viriri. 2021. “Deep learning for brain tumor segmentation: a survey of state-of-the-art”. *Journal of Imaging* 7 (2): 19. <http://dx.doi.org/10.3390/jimaging7020019>.
- Mathersul, Danielle, Leanne M Williams, Patrick J Hopkinson ja Andrew H Kemp. 2008. “Investigating models of affect: relationships among EEG alpha asymmetry, depression, and anxiety.” *Emotion* 8 (4): 560. <http://dx.doi.org/10.1037/a0012811>.
- McFarland, Dennis J, ja Jonathan R Wolpaw. 2008. “Brain-computer interface operation of robotic and prosthetic devices”. *Computer* 41 (10): 52–56. <http://dx.doi.org/10.1109/MC.2008.409>.
- Merlin Praveena, D, D Angelin Sarah ja S Thomas George. 2022. “Deep learning techniques for EEG signal applications—a review”. *IETE Journal of Research* 68 (4): 3030–3037.
- Moser, Ewald, Elmar Laistler, Franz Schmitt ja Georg Kontaxis. 2017. “Ultra-high field NMR and MRI—the role of magnet technology to increase sensitivity and specificity”. *Frontiers in Physics* 5:33. <http://dx.doi.org/10.3389/fphy.2017.00033>.
- Nalepa, Jakub, Michal Marcinkiewicz ja Michal Kawulok. 2019. “Data augmentation for brain-tumor segmentation: a review”. *Frontiers in computational neuroscience* 13:83. <http://dx.doi.org/10.3389/fncom.2019.00083>.
- Oh, Jihoon, Baek-Lok Oh, Kyong-Uk Lee, Jeong-Ho Chae ja Kyongsik Yun. 2020. “Identifying schizophrenia using structural MRI with a deep learning algorithm”. *Frontiers in psychiatry* 11:16. <http://dx.doi.org/10.3389/fpsy.2020.00016>.
- Pan, Dan, An Zeng, Longfei Jia, Yin Huang, Tory Frizzell ja Xiaowei Song. 2020. “Early detection of Alzheimer’s disease using magnetic resonance imaging: a novel approach combining convolutional neural networks and ensemble learning”. *Frontiers in neuroscience* 14:259. <http://dx.doi.org/10.3389/fnins.2020.00259>.

Papanicolaou, Andrew C, David W Loring, Georg Deutsch ja Howard M Eisenberg. 1986. "Task-related EEG asymmetries: a comparison of alpha blocking and beta enhancement". *International Journal of Neuroscience* 30 (1-2): 81–85. <http://dx.doi.org/10.3109/00207458608985658>.

Papp, Szilvia, László Tombor, Brigitta Kakuszi, Livia Balogh, János M Réthelyi, István Bitter ja Pál Czobor. 2020. "Impaired early information processing in adult ADHD: a high-density ERP study". *BMC psychiatry* 20 (1): 1–10. <http://dx.doi.org/10.1186/s12888-020-02706-w>.

Peng, Xiaolong, Pan Lin, Tongsheng Zhang ja Jue Wang. 2013. "Extreme learning machine-based classification of ADHD using brain structural MRI data". *PloS one* 8 (11): e79476. <http://dx.doi.org/10.1371/journal.pone.0079476>.

Plana-Ripoll, Oleguer, Carsten Bøcker Pedersen, Yan Holtz, Michael E Benros, Søren Dalsgaard, Peter De Jonge, Chun Chieh Fan, Louisa Degenhardt, Andrea Ganna, Aja Neergaard Greve ym. 2019. "Exploring comorbidity within mental disorders among a Danish national population". *JAMA psychiatry* 76 (3): 259–270. <http://doi.org/10.1001/jamapsychiatry.2018.3658>.

Plewes, DB, ja W Kucharczyk. 2003. "The Physics of MRI-Basic Spin Gymnastics". *Proc. Intl. Soc. Mag. Reson.*

Ranjbarzadeh, Ramin, Abbas Bagherian Kasgari, Saeid Jafarzadeh Ghouschi, Shokofeh Anari, Maryam Naseri ja Malika Bendeche. 2021. "Brain tumor segmentation based on deep learning and an attention mechanism using MRI multi-modalities brain images". *Scientific Reports* 11 (1): 1–17. <http://dx.doi.org/10.1038/s41598-021-90428-8>.

Riaz, Atif, Muhammad Asad, Eduardo Alonso ja Greg Slabaugh. 2020. "DeepFMRI: End-to-end deep learning for functional connectivity and classification of ADHD using fMRI". *Journal of neuroscience methods* 335:108506. <http://dx.doi.org/10.1016/j.jneumeth.2019.108506>.



- Roy, Arunabha M. 2022a. “Adaptive transfer learning-based multiscale feature fused deep convolutional neural network for EEG MI multiclassification in brain–computer interface”. *Engineering Applications of Artificial Intelligence* 116:105347. <http://dx.doi.org/10.1016/j.engappai.2022.105347>.
- . 2022b. “An efficient multi-scale CNN model with intrinsic feature integration for motor imagery EEG subject classification in brain-machine interfaces”. *Biomedical Signal Processing and Control* 74:103496. <http://dx.doi.org/10.1016/j.bspc.2022.103496>.
- Al-Saegh, Ali, Shefa A Dawwd ja Jassim M Abdul-Jabbar. 2021. “Deep learning for motor imagery EEG-based classification: A review”. *Biomedical Signal Processing and Control* 63:102172. <https://doi.org/10.1016/j.bspc.2020.102172>.
- Sammler, Daniela, Maren Grigutsch, Thomas Fritz ja Stefan Koelsch. 2007. “Music and emotion: electrophysiological correlates of the processing of pleasant and unpleasant music”. *Psychophysiology* 44 (2): 293–304. <http://dx.doi.org/10.1111/j.1469-8986.2007.00497.x>.
- Sanaat, Amirhossein, Isaac Shiri, Sohrab Ferdowsi, Hossein Arabi ja Habib Zaidi. 2022. “Robust-Deep: A Method for Increasing Brain Imaging Datasets to Improve Deep Learning Models’ Performance and Robustness”. *Journal of Digital Imaging*, 1–13. <http://dx.doi.org/10.1007/s10278-021-00536-0>.
- Sheynin, Shelly, Lior Wolf, Ziv Ben-Zion, Jony Sheynin, Shira Reznik, Jakob Nimrod Keynan, Roe Admon, Arieh Shalev, Talma Hendler ja Israel Liberzon. 2021. “Deep learning model of fMRI connectivity predicts PTSD symptom trajectories in recent trauma survivors”. *Neuroimage* 238:118242. <http://dx.doi.org/10.1016/j.neuroimage.2021.118242>.
- Teplan, Michal, ym. 2002. “Fundamentals of EEG measurement”. *Measurement science review* 2 (2): 1–11.
- Tibrewal, Navneet, Nikki Leeuwis ja Maryam Alimardani. 2022. “Classification of motor imagery EEG using deep learning increases performance in inefficient BCI users”. *Plos one* 17 (7): e0268880. <http://dx.doi.org/10.1371/journal.pone.0268880>.

Tuominen, Heli, Pekka Neittaanmäki, Esko Niinimäki, Ilkka Pölönen, Ilkka Rautiainen, Sami Äyrämö, Toni Ruohonen, Riku Nyrhinen, Anniina Ojalainen, Petri Vähäkainu ym. 2019. “Tekoälyn perusteita ja sovelluksia”, <http://urn.fi/URN:ISBN:978-951-39-7796-2>.

Wang, Yu, Ning Gong ja Changyang Fu. 2021. “Major depression disorder diagnosis and analysis based on structural magnetic resonance imaging and deep learning”. *Journal of Integrative Neuroscience* 20 (4): 977–984. <http://dx.doi.org/10.31083/j.jin2004098>.

Yang, Weijian, ja Rafael Yuste. 2017. “In vivo imaging of neural activity”. *Nature methods* 14 (4): 349–359. <http://dx.doi.org/10.1038/nmeth.4230>.

Yin, Wutao, Longhai Li ja Fang-Xiang Wu. 2022. “Deep learning for brain disorder diagnosis based on fMRI images”. *Neurocomputing* 469:332–345. <http://dx.doi.org/10.1016/j.neucom.2020.05.113>.

Yu, Yong, Xiaosheng Si, Changhua Hu ja Jianxun Zhang. 2019. “A review of recurrent neural networks: LSTM cells and network architectures”. *Neural computation* 31 (7): 1235–1270. [http://dx.doi.org/10.1162/neco\\_a\\_01199](http://dx.doi.org/10.1162/neco_a_01199).

Zhang, Ruilong, Qun Zong, Liqian Dou, Xinyi Zhao, Yifan Tang ja Zhiyu Li. 2021. “Hybrid deep neural network using transfer learning for EEG motor imagery decoding”. *Biomedical Signal Processing and Control* 63:102144. <http://dx.doi.org/10.1016/j.bspc.2020.102144>.

Zhang, Xiang, Lina Yao, Xianzhi Wang, Jessica Monaghan, David Mcalpine ja Yu Zhang. 2019. “A survey on deep learning based brain computer interface: Recent advances and new frontiers”. *arXiv preprint arXiv:1905.04149* 66.

Zhang, Yaqing, Jinling Chen, Jen Hong Tan, Yuxuan Chen, Yunyi Chen, Dihan Li, Lei Yang, Jian Su, Xin Huang ja Wenliang Che. 2020. “An investigation of deep learning models for EEG-based emotion recognition”. *Frontiers in Neuroscience* 14:622759. <http://dx.doi.org/10.3389/fnins.2020.622759>.

Zheng, JinChi, XiaoLan Wei, JinYi Wang, HuaSong Lin, HongRun Pan ja YuQing Shi. 2021. “Diagnosis of Schizophrenia Based on Deep Learning Using fMRI”. *Computational and Mathematical Methods in Medicine* 2021. <http://dx.doi.org/10.1155/2021/8437260>.