TURUN YLIOPISTO

Tietokonetomografia ja tekoäly traumaattisten aivoverenvuotojen diagnosoinnissa

Lääketieteellinen tekniikka ja terveysteknologia
Tietotekniikan laitos, Teknillinen tiedekunta
Kandidaatintutkielma

Laatija:
Auriina Puhakainen

Marraskuu 2025

Turun yliopiston laatujärjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -järjestelmällä.

Kandidaatintutkielma
Tietotekniikan laitos, Teknillinen tiedekunta
Turun yliopisto

Tutkinto-ohjelma: Lääketieteellinen tekniikka ja terveysteknologia
Tekijä: Auriina Puhakainen
Otsikko: Tietokonetomografia ja tekoäly traumaattisten aivoverenvuotojen diagnosoinnissa
Sivumäärä: 28 sivua
Päivämäärä: Marraskuu 2025

Tämä kirjallisuuskatsaus käsittelee tietokonetomografian ja tekoälyn roolia traumaattisten aivoverenvuotojen diagnosoinnissa. Traumaattiset aivovammat vaikuttavat miljooniin ihmisiin vuosittain ja ovat merkittävä kuolinsyy maailmanlaajuisesti. Tietokonetomografia on ensisijainen menetelmä aivoverenvuotojen tunnistamiseen, sillä se on nopea ja tarkka.

Tutkielmassa tarkastellaan perinteisiä ja tekoälyavusteisia kuvien rekonstruktiomenetelmiä sekä tekoälyn käyttöä diagnosointiprosessissa. Tietoa tutkielmaa varten on haettu PubMed-tietokannasta, Google Scholarista, Web of Science -tietokannasta ja Turun yliopiston kirjaston Volter-palvelussa. Tarkastelun perusteella tekoälyn syväoppimismallit, kuten konvoluutioneuroverkot, parantavat kuvien laatua, vähentävät kohinaa ja nopeuttavat rekonstruoitujen kuvien tuottamista. FDA:n hyväksymät algoritmit, kuten qER.ai ja Viz.ai, ovat osoittaneet lupaavia tuloksia aivoverenvuotojen tunnistamisessa tietokonetomografiakuvista, ja myös useat kehitteillä olevat menetelmät näyttävät lupaavilta.

Tekoälystä on todennäköisesti tulossa tärkeä työkalu terveydenhuollossa, sillä se voi vähentää inhimillisiä virheitä ja tukea ammattilaisten päätöksentekoa. Eettiset ja tekniset haasteet on ratkaistava ennen laajamittaista käyttöönottoa.

Asiasanat: tietokonetomografia, tekoäly, syväoppiminen, traumaattinen aivoverenvuoto

Sisällysluettelo

1 Johdanto 1

2 Traumaattinen aivoverenvuoto 4

2.1 Traumaattinen aivovamma 4

2.2 Aivoverenvuodon tyypit 6

3 Tietokonetomografia aivoverenvuotojen diagnosoinnissa 10

3.1 Tietokonetomografian toimintaperiaate 10

3.2 Kuvien rekonstruktio ja suodatus 13

3.3 Traumaattisten aivoverenvuotojen TT-kuvantaminen 15

4 Tekoälyn hyödyntäminen kuvantamisessa 17

4.1 Tekoälyn hyödyt diagnostiikassa 18

4.2 Tekoälyn haasteet ja rajoitukset 22

5 Pohdinta 25

6 Yhteenveto 27

Lähdeluettelo 29

1 Johdanto

Vuosittain noin 69 miljoonaa potilasta maailmanlaajuisesti saa diagnoosiksi traumaattisen aivovamman [1]. Korkean tulotason maissa tapauksia on noin 18 miljoonaa vuosittain ja keski- ja matalan tulotason maissa noin 50 miljoonaa tapausta. Lähes jokaisen vakavan aivovamman seurauksena on jonkinlaista aivoverenvuotoa. Aivoverenvuoto voi johtaa kallonsisäisen paineen nousemiseen, toimintakyvyn heikkenemiseen ja pahimmillaan kuolemaan. [2] Traumaattisten aivovammojen yleisimpiä uhreja ovat 15–44-vuotiaat ihmiset, joiden voidaan iän puolesta katsoa olevan parhaassa työiässä. Traumaattiset aivovammat aiheuttavat täten merkittävää taloudellista rasitusta, joka näkyy paitsi sairaaloiden ja terveydenhuollon kuormituksessa, myös laajemmin yhteiskunnan sekä valtiontalouden kestävyydessä. Traumaattiset aivovammat ja niistä syntyvät seuraukset ovat yksi merkittävimmistä kuolleisuuden ja vammaisuuden syistä maailmassa. On myös arvioitu, että vammat yleistyvät entistä enemmän esimerkiksi liikenteen lisääntymisen seurauksena. Nämä ongelmat korostavat ennaltaehkäisyn ja varhaisen hoidon merkitystä. [3]

Erityisen tärkeää on tunnistaa ja hoitaa aivovammojen vakavimmat seuraukset, joista merkittävimpiä on traumaattinen aivoverenvuoto. Aivoverenvuodon aiheuttaa vakava aivovamma, ja sillä tarkoitetaan kalloluun sisäpuolella tapahtuvaa verenvuotoa, joka johtuu aivoverisuonen hajoamisesta. Traumaattiset aivoverenvuodot ovat traumaattisen aivovamman seurauksia ja johtuvat täten potilaaseen aiheutuvasta traumasta. Traumaattisen aivovamman määritelmä on aivojen toiminnan muutos, joka aiheutuu ulkoisesta voimasta, kuten päähän kohdistuneesta iskusta. Isku voi johtua esimerkiksi törmäyksestä tai voimakkaasta tärinästä. Näistä aiheutuvan voiman takia aivot ”törmäävät” kalloluuhun, joka voi johtaa aivoverenvuotoon. [4] Tilastojen mukaan tällaisen vammaan syynä on yleensä kaatuminen, päähän kohdistunut isku, ajoneuvokolari, pahoinpitely tai tahallinen itsensä vahingoittaminen [1]. Tässä tutkielmassa keskitytään ainoastaan traumaattisiin aivoverenvuotoihin, jotka ovat aina traumaattisen aivovamman seuraus. Lisäksi käsitellään ainoastaan lävistämättömiä aivovammoja, eli vammoja missä mikään ulkoinen esine ei vahingoita aivoja.

Tänä päivänä aivoverenvuotojen tunnistamiseen käytetään tietokonetomografiaa, joka tunnetaan myös nimellä TT-kuvaus. TT-kuvaus otettiin käyttöön ensimmäisen kerran vuonna 1972. Se toi muutoksen lääketieteelliseen kuvantamiseen tarjoamalla mahdollisuuden kudosten tarkkaan kuvantamiseen ja kolmiulotteisen mallin muodostamiseen. Tätä samaa tekniikkaa käytetään vielä tänä päivänä. [5] TT-kuvaus toimii samanlaisen röntgenputken

avulla, jota käytetään natiiviröntgenissä. Ero natiiviröntgeniin on putken sekä antureiden liikkumistapa. TT-kuvantamisessa käytetty laite liikkuu potilaan ympärillä ja täten saadaan 3D kuvia, röntgenin perinteisten 2D kuvien sijaan. Tietokonetomografia on yhä ensisijainen menetelmä lääketieteellisissä hätätilanteissa, koska se on sekä nopea että tarkka tutkimusmenetelmä. Tietokonetomografia on ollut yli 50 vuotta käytössä ja on myös saatavilla useimmissa sairaaloissa. Menetelmää kutsutaankin kultaiseksi standardiksi ja sitä suositaan esimerkiksi magneettikuvan sijaan juuri nopeuden sekä sen helpon saatavuuden vuoksi. TT-kuvaus on myös kustannuksiltaan huomattavasti halvempi kuin magneettikuvaus. [2]

Kuten kaikilla menetelmillä myös TT-kuvantamisella on haittansa. Yksi isoimmista huolenaiheista on laitteen tuottama säteily, joka voi mahdollisesti edesauttaa potilaan syöpäsolujen kehittymistä. Myös mittaustiedon kasaaminen käyttökelpoisiksi kuviksi on haasteellista, sillä kuvantamisen aikana aiheutuu kohinaa, joka vaikuttaa saatujen kuvien laatuun. Kohina johtuu röntgensäteilyssä olevien fotoneiden satunnaisesta jakaantumisesta. Tämä heikentää kuvien laatua ja vaikeuttaa pienten poikkeusten havaittavuutta. Lisäksi kuvien tulkitsemisessa voi ilmetä radiologilla haasteita, esimerkiksi erittäin pienten vuotojen tunnistamisessa. Varsinkin hätätilanteissa, joissa päätös täytyy tehdä nopeasti, on oleellista, että potilaalle saadaan oikea diagnoosi. Myös potilaiden kasvava määrä aiheuttaa haasteita, sillä se kasvattaa radiologien työkuormaa. Näitä ongelmia pyritään ratkomaan tekoälyn avulla. Tekoäly on jo käytössä sairaaloissa työn tukena monessa eri tehtävässä, kuten tietokonetomografiassa kuvien rekonstruktiossa. Tekoälyä voisi myös hyödyntää monessa muussa vaiheessa. Tämä on mahdollista vasta kun tekoäly on kehittynyt riittävästi ja kun siihen kohdistuviin eettisiin kysymyksiin on vastattu, sekä sen tämänhetkiset toiminnalliset ongelmat on ratkaistu. Tässä tutkielmassa tekoälyllä tarkoitetaan koneoppimista (engl. machine learning) ja syväoppimista (engl. deep learning). [5]

Tässä kirjallisuuskatsauksessa tarkastellaan tietokonetomografian tehokkuutta traumaattisten aivoverenvuotojen diagnosoinnissa sekä tekoälyn käyttöä prosessin tukena ja optimoinnissa. Tutkielmassa käsitellään traumaattisia aivoverenvuotoja, niiden aiheuttajia, diagnosointiprosessia, käytettävää kuvantamismenetelmää, tietokonetomografian toimintamallia sekä kuvien rekonstruktiota ja sen tuottamia haasteita. Näiden lisäksi tarkastellaan tekoälyn roolia tässä prosessissa ja sen mahdollisia hyötyjä ja haittoja. Kirjallisuuskatsauksen tavoitteena on myös vastata asetettuihin tutkimuskysymyksiin ja tuottaa kokonaiskuva nykytilanteesta sekä tulevaisuudesta.

Tämä kirjallisuuskatsaus pyrkii vastaamaan seuraaviin kysymyksiin:

Tutkimuskysymys 1: Miten tietokonetomografia toimii, ja miksi juuri sitä käytetään traumaattisten aivoverenvuotojen tunnistamiseen?

Tutkimuskysymys 2: Millä tavalla tekoäly voisi parantaa kuvantamista ja diagnosointiprosessia?

Tutkimuskysymys 3: Mitkä ovat tämänhetkiset ongelmat tekoälyn käyttämisessä kuvantamisprosessin aikana?

Aineistonhaku tähän kirjallisuuskatsaukseen suoritettiin PubMed-tietokannassa, Google Scholarista, Web of Science -tietokannasta ja Turun yliopiston kirjaston Volter-palvelussa. Hakusanoina käytetiin “CT”, “Computer tomography”, “Traumatic brain injury”, “TBI”, “Brain bleed”, “Hematoma”, “AI”, “Artificial intelligence”, “imaging”, “medical imaging”, “X-ray” ja “Brain”. Haussa hyödynnettiin myös Boolean operaattoreita kuten OR ja AND. Käytetyt hakulauseet olivat: ”Traumatic brain injury AND ”CT” OR ”Computer tomography”, ”medical imaging” AND ”Brain” sekä ”AI” OR “artificial intelligence” AND “CT” OR “Computer tomography*” AND “traumatic brain injury*” OR “TBI”. Tämän lisäksi tiedonhakuprosessissa on hyödynnetty löydettyjen tiedostojen lähteitä, sekä ScienceDirectin antamia suosituksia.

Valintakriteereinä käytettiin pääsääntöisesti vuotta 2020 ja myöhempiä julkaisuja sekä englanninkielisiä aikuisia koskevia tutkimuksia. Aineistojen valinnat tehtiin otsikkojen, avainsanojen, abstraktin ja alustavan tarkastelun seurauksena.

Tutkielman rakenne perustuu kuuteen lukuun. Tutkielman toisessa luvussa käsitellään aivojen fysiologiaa, traumaattisia aivovammoja ja erilaisia aivoverenvuotoja. Tässä luvussa käsitellään myös diagnosointiprosessia, eli miten hoitoprosessissa päädytään ottamaan TT-kuva ja mitä kuvista mahdollisesti nähdään. Kolmannessa luvussa tarkastellaan TT-laitteen toimintamallia sekä sen hyötyjä ja haittoja. Luvussa 4 käsitellään tekoälyn käyttöä apuna aivoverenvuotojen diagnosoimisessa ja perehdytään tekoälyn käyttöön kuvien tulkinnassa, sekä sen käyttöön kuvien rekonstruktioprosessissa. Tutkielman luvussa 5 pohditaan tekoälyn mahdollista käyttöä tulevaisuudessa sekä sen mahdollisia haittoja. Tutkielman viimeisessä luvussa tiivistetään tutkielma ja vastataan alussa esitettyihin kysymyksiin.

2 Traumaattinen aivoverenvuoto

Aivoverenvuoto tarkoittaa kallonsisäistä verenvuotoa, joka aiheutuu aivoverisuonen hajoamisesta. Taustalla voi olla trauma eli potilaan loukkaantuminen tai potilaan terveydentilaan liittyvä ongelma, kuten korkea verenpaine. Aivoverenvuodot, joiden syy on muu kuin trauma, ovat yleisimpiä vanhemmilla ihmisillä. Tämä tutkielma keskittyy ainoastaan traumaattisiin aivoverenvuotoihin. Vuodot saavat aikaiseksi kallonsisäisen paineen nousun ja häiritsevät hermokudoksen normaalia toimintaa. Paineen nousun seurauksena aivot eivät saa riittävästi happea ja ravintoaineita. Ilman happea aivosolut kuolevat noin 3–4 minuutissa, mikä voi aiheuttaa potilaalle elinikäisiä vaurioita. Koska aivosolut ovat pysyviä soluja eivätkä ne kykene jakautumaan tai uusiutumaan, voi trauma johtaa pysyvään toimintakyvyn heikkenemiseen tai kuolemaan. Paineen nousun myötä elintärkeät toiminnot kuten hengitys ja verenkierto häiriintyvät. Tämä johtuu aivorungon puristuksesta, sillä aivorunko säätelee muun muassa hengitystä. Kun aivojen sisäinen paine nousee, aivorunko puristuu kasaan eikä pysty suorittamaan toimintaansa normaalisti. Aivoverenvuoto itsessään oireilee monilla tavoin. Tyypillisimpiä oireita ovat: päänsärky, pahoinvointi, kehon yhden puolen tunnottomuus, huimaus ja hämmennys. [4]

2.1 Traumaattinen aivovamma

Kun potilaalla todetaan traumaattinen aivovamma, tulee aina selvittää, onko hänellä myös tästä johtuvaa aivoverenvuotoa. [1] Traumaattisen aivovamman oireita on muun muassa päänsärky, oksentaminen, muistinmenetys, tajuttomuus, levottomuus ja traumanjälkeiset epileptiset kohtaukset. Vakavat aivovammat ovat merkittävä kuolinsyy ja ne voivat aiheuttaa potilaassa pitkäkestoisen toimintakyvyn heikkenemisen. Näissä tapauksissa potilas tarvitsee apua päivittäisissä toiminnoissa. [2]

Traumaattiset aivovammat luokitellaan Glasgow’n kooma-asteikon mukaisesti. Asteikkoa käytetään apuna potilaiden alkuvaiheen diagnosointiin ja sen avulla tehdään päätös potilaan mahdollisesta kuvantamisesta aivoverenvuodon epäilyn todentamiseksi. Glasgow’n kooma-asteikko analysoi potilaan tajunnan tasoa, silmien liikettä sekä verbaalista ja motorista reaktiota annettuun ärsykkeeseen. Asteikon avulla potilaan vammat diagnosoidaan joko lieviksi, keskivaikeiksi tai vaikeiksi. [3]

Jos potilaan tulos on keksivaikea tai vaikea, lähes kaikissa tapauksissa potilas ohjataan tietokonetomografiakuvaukseen. Päätökseen kuvantamisesta vaikuttaa edellä mainitun

tuloksen lisäksi myös muut tekijät kuten esimerkiksi: oksentaminen, päänsärky ja potilaan päihtymystila. Jos Glasgow'n asteikon tulos on pienempi kuin 14, potilaasta otettaan aina TT-kuva. [6] Taulukossa 2.1 on esitetty Glasgow'n kooma-asteikko.

Taulukko 2.1 Taulukossa esitetään Glasgow'n kooma asteikon vaatimukset ja pistemäärät. Potilaan tilaa tarkastellaan kolmella eri tavalla ja annetusta vasteesta annetaan pisteittä. Näistä pisteistä kootaan lopullinen tulos, jonka avulla tehdään hoito päätös. Taulukko on tehty lähteen [4] perusteella

Pisteet	Silmien avaus	Puhe	Liikevaste
1	Ei vastetta	Ei vastetta	Ei mitään
2	Kivulle	Käsittämätöntä	Ekstensio kivulle
3	Puheelle	Irrallinen	Fleksio kivulle
4	Spontaanisti	Sekava	Väistää kipua
5	-	Orientoitunut	Paikallistaa kivun
6	-	-	Seuraa ohjeitta

Glasgow'n kooma asteikon avulla arvioidaan vamman vakavuutta, mutta se ei kerro minkälainen vamma on kyseessä. Aivovammat voidaan luokitella niiden syntymekanismiin mukaan joko primaarisiksi tai sekundaariksi. Primaarit vammat ovat trauman suorat seuraukset, kuten esimerkiksi kallonmurtuma, aivotyrän ja aivonkuoren ulkopuoliset verenvuodot. Nämä saavat alkunsa vamman syntyhetkellä ja ne näkyvät myös ensin TT-kuvissa ja diagnoosia tehdessä. [2]

Sekundaarit vammat kehittyvät viiveellä, tunteja tai jopa päiviä myöhemmin, primaarien vammojen komplikaation seurauksena. Aivoverenvuotojen seuraukset ovat sekundaarisia vammoja ja ne johtavat potilaan tilan heikkenemiseen. Esimerkkejä sekundaarisista vammoista ovat: aivoihin keräytyvä neste ja aivokudoksen siirtyminen. Keskiviivan siirtyminen eli aivojen painautuminen yhdelle puolelle, on myös sekundaarinen aivovamma ja se johtaa aivojen sisäisen paineen nousuun. Sekundaariset aivovauriot heikentävät aivojen hapetusta ja aineenvaihduntaa. Vammat voivat joissain tapauksissa olla vaarallisempia kuin primaarit vammat, sillä ne kehittyvät viiveellä. Potilas on alussa oireeton ja kun oireet alkavat, on hoidon toteuttamiseen enää rajoitetusti aikaa. [1] Sekundaarisia aivovammoja koetetaan välttää seuraamalla aivojen sisäisen paineen muutoksia. Diagnosointi tapahtuu yleensä tietokonetomografialla. Myös magneettikuvaa voidaan käyttää diagnosointiin. Tätä käytetään harvemmin, sillä se vie enemmän aikaa. Magneettikuvaus on kuitenkin käytössä potilaan tilan seuraamisessa, jos on epäily sekundaarisen vamman mahdollisuudesta. [2]

2.2 Aivoverenvuodon tyypit

Aivoverenvuodot jaetaan neljään päätyyppiin: epiduraalivuoto (engl. epidural hemorrhage, EDH), subduraalihematooma (engl. subdural hemorrhage, SDH), intraventrikulaarinen verenvuoto (engl. intraventricular hemorrhage, IVH) ja lukinkalvonalainen aivoverenvuoto (engl. subarachnoid hemorrhage, SAH). Ne eroavat toisistaan sijainnin (missä aivovälikössä ne ovat), syntymekanismin ja vuodon lähteen perusteella. Vuodot sijoittuvat eri paikkoihin aivoissa riippuen päähän kohdistuneen iskun voimasta ja vahingoittuneen suonen sijainnista. Aivoverenvuotojen eri tyypit ovat nimetty sen mukaan minkä aivokerroksen kohdalla ne sijaitsevat. [4] Eri aivokerrokset voidaan nähdä Kuvassa 1.

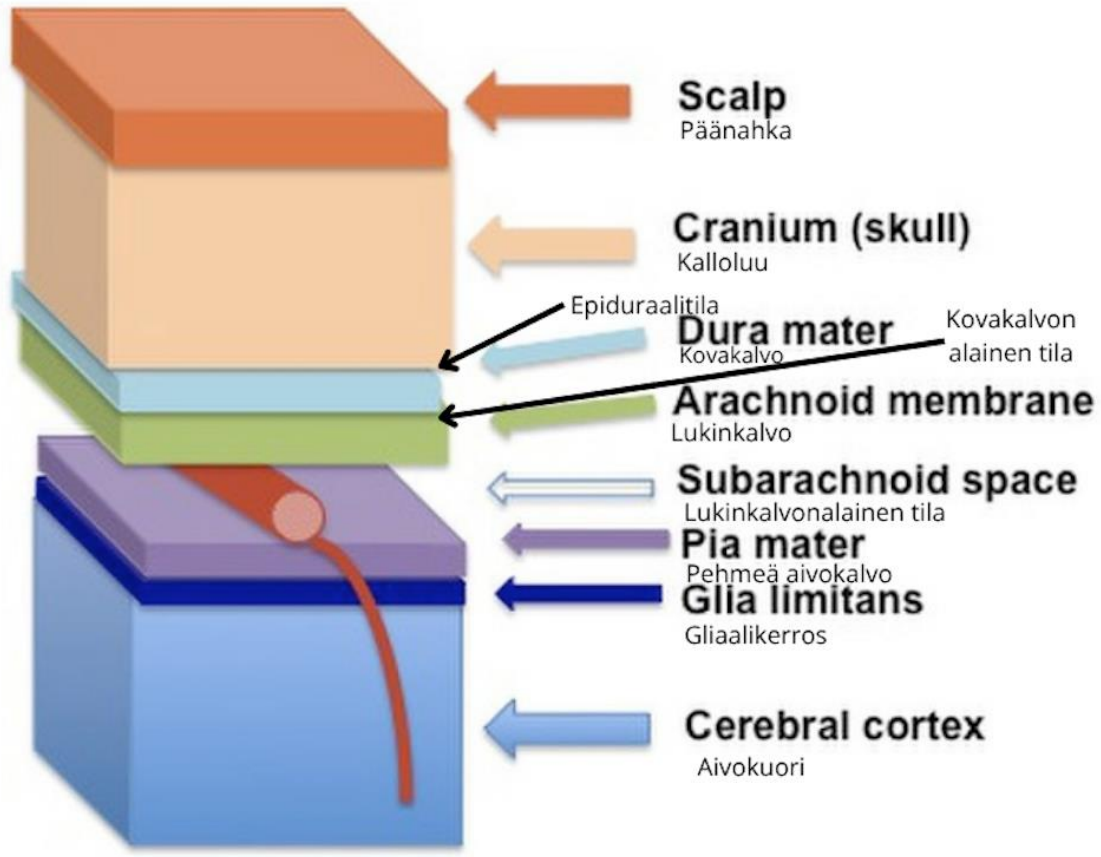

Kuva 1. Kuva aivojen eri kerroksista. Yläpuolella englanninkielinen nimi ja sen alla nimi suomeksi. Lähde: Mukailtu [7], kuvan käyttöoikeudet: CC BY-SA 4.0.

Epiduraalivuoto sijoittuu kallon ja kovan aivokalvon väliin. Siksi epiduraalivuodon yhteydessä todetaan myös usein kallonmurtuma. Vuoto johtuu usein aivon kovakalvonvaltimon vammasta. Epiduraalivuodoista noin 90 % johtuu valtimon vuodosta ja 10 % laskimon vuodosta. Valtimovuodot sijaitsevat useimmiten isoaivojen alueella. Vuodot

eivät ylitä kallon luusaumoja vaan pysyvät iskun kohdalla. Jos vuoto taas on laskimossa, sijoittuu se tyypillisesti ohimolohkon etuosaan. Valtimoiden verenvuodoissa jopa 50 % potilaista kokee niin sanotun lucid interval-vaiheen, joka tarkoittaa potilaan tilan äkillistä paranemista ja sen jälkeistä yhtäkkistä heikentymistä. Paranemisvaiheessa potilas on hetken oireeton - muutamasta minuutista moneen tuntiin. Lucid-interval-vaihe on tärkeä tunnistaa mahdollisimman nopeasti, sillä vaikka potilas vaikuttaa toipuneelta, vuoto on silti olemassa. Jos tilaa ei tunnisteta, voi tämä johtaa hoidon viivästymiseen, joka nostaa sekä pysyvän aivovamman, että kuoleman riskiä. [1] Epiduraalivuodon seurauksena kallonsisäinen paine nousee, johtuen veren kertymisestä kallon ja aivokalvon väliin. Sen seurauksena aivokalvo painautuu alaspäin ja aivoihin kohdistuu paine. Hoito perustuu usein kirurgisiin toimenpiteisiin, jolloin verenvuoto tyrehdytään ja kallonsisäinen paine pyritään palauttamaan normaaliksi. [6], [4]

Subduraalihematooma (toiselta nimeltään kovakalvonalainen verenvuoto) on verenvuoto, jossa kovakalvon alle vuotaa verta. Vuoto aiheutuu useimmiten siltalaskimoiden vaurioista. Toisin kuin epiduraalivuodot, subduraalihematoomat etenevät yleensä hitaammin. Johtuen siitä, että ne ovat laskimoperäisiä. Verta ei samalla tavalla kulkeudu aivoihin, kuin valtimoperäisissä vuodoissa. [1], [4], [6] Kuten epiduraalivuodot myös subduraalihematoomat nostavat kallonsisäistä painetta. Koska veri kertyy suoraan kovakalvon alle, niin subduraalihematoomat voivat johtaa aivokudoksen vaurioihin ja olla siten vaarallisempia kuin epiduraalivuodot. Vuodot voivat myös siirtää aivojen keskiviivaa, joka vuorostaan entisestään nostaa aivojen painetta ja heikentää potilaan tilaa. Kaikki subduraalihematoomat eivät kuitenkaan ole isoja ja pienet subduraalihematoomat voivat kadota itsestään ajan myötä, eivätkä tarvitse hoitoa. Isot subduraalihematoomat hoidetaan epiduraalihematoomien tavoin leikkauksella. [2]

Intraventrikulaarisella verenvuodolla tarkoitetaan verenvuotoa aivojen kammioihin. Tällaiset vuodot eivät aina ole traumaperäisiä. Yleisimpiä vuodot ovat ennenaikaisesti syntyneillä keskosilla. Vuodon seurauksena verta voi levitä myös lukinkalvonalaisiin tiloihin. Intraventrikulaariset vuodot voivat vahingoittaa erityisesti aivojen valkoista ainetta. Suurin osa intraventrikulaarisista vuodoista on niin sanottuja sekundaarisia ja syntyvät jonkin muun vaurion tai tilan seurauksena, kuten esimerkiksi subduraalihematooman seurauksena. Myös intraventrikulaarinen vuoto voi johtaa kallonsisäisen paineen nousuun ja täten pitkäaikaisiin neurologisiin ongelmiin. [4], [6]

Lukinkalvonalainen verenvuoto tapahtuu aivojen pinnan ja sisimmän aivokalvokerroksen välissä (pehmeänkalvon) lukinkalvon alatilassa. Lukinkalvonalaisen verenvuodon yleisin aiheuttaja on trauma, mutta se voi aiheutua myös aivovaltimon pullistumasta. Jos vuoto on traumaperäinen, on veri useimmiten peräisin pehmeäkalvon läpi kulkevista laskimoista. Veri kerääntyy lukinkalvon alatilaan ja voi sieltä levitä laajasti aivojen pinnalle. [4], [6] Lukinkalvonalainen verenvuoto voi johtaa useisiin komplikaatioihin, kuten verisuoninen kouristusmaiseen supistukseen, aivolisäkkeen toimintahäiriöön ja aivojen sisäisen paineen nousuun. [3] Kuvassa 2 esitettään miltä eri aivoverenvuodot näyttävät tietokonetomografia kuvissa.

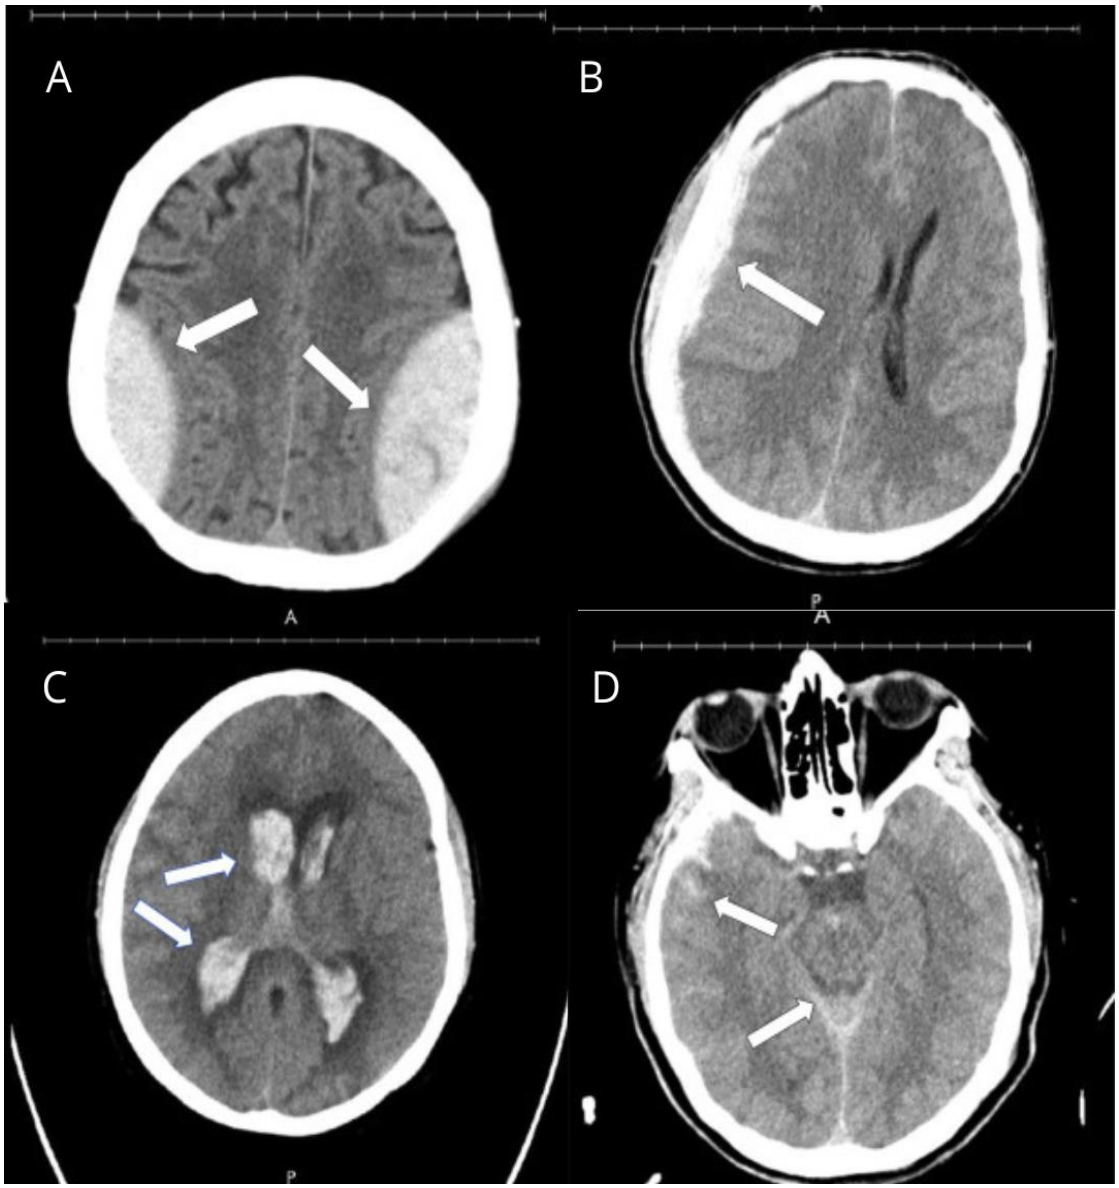

Kuva 2. Eri aivoverenvuotojen ulkonäkö tietokonetomografia kuvassa. Kuvissa aivojen poikkileikkauskuvat. Valkoiset nuolet osoittavat vuodon sijainnin A. Epiduraalihematooma B. Subduralihematooma C. Intraventrikulaarinen verenvuoto D. Lukinkalvonalainen verenvuoto. Lähde: Mukailtu [4], kuvan käyttöoikeudet: Elsevierin myöntämä lupa (lisenssinro 6140830713006).

Kuvasta 2 voidaan havainnoida miten eri vuodot sijoittuvat eri puolille aivoja. Kuvista erottuu myös vuotojen eri koot ja muodot, mikä korostaa eri verenvuotojen kliinisiä eroja. Kuvissa näkyvät vuodot ovat esimerkinomaisia, eivätkä vuodot aina ilmenne yllä esitetyllä tavalla, mutta antavat asiasta yleispätevän kuvan. Yllä olevat poikkileikkauskuvat näyttävät selkeästi, kuinka verenvuotojen ulkonäkö vaihtelee TT-kuvissa. Epiduraalihematooma on usein linssimäinen ja veri on valkoista. Subduraalihematoomat ovat sirppimäisiä ja esiintyvät usein erittäin tiheinä alueina. Ne aiheuttavat usein myös aivojen keskiviivan siirtymää, jonka voi havainnoida kuvassa. Intraventrikulaarinen vuoto taas näkyy aivojen sivukammioissa. Kuvassa kammiot ovat erittäin tummat, sillä ne ovat täytyneet verestä. Lukinkalvonalainen vuoto ilmenee erittäin tiheinä alueina juuri lukinkalvon alaisessa tilassa.

3 Tietokonetomografia aivoverenvuotojen diagnosoinnissa

TT-kuvantaminen eli tietokonetomografia on kuvantamismenetelmä, joka pyörivän röntgenputken sekä antureiden avulla kuvaa potilasta. TT-kuvantamisessa potilaan elimistä muodostetaan kolmiulotteinen kuva, jonka perusteella potilas diagnosoidaan. Se perustuu samaan tekniikkaan, kun natiiviröntgen (perinteinen röntgenkuvaus), mutta kuvia otetaan monta ja monesta eri kulmasta. Kuvantamismenetelmää käytetään useiden eri sairauksien diagnosoinnin apuna kuten syöpien, traumaperäisten aivovammojen, keuhkosairauksien sekä sydänperäisten sairauksien. TT-kuvia otetaan myös murtumista, erityisesti jos ne sijoittuvat nivelten lähelle. [8], [9]

TT-kuvantamista on kahta erilaista, kontrastiton TT-kuvaus sekä TT-kuvaus kontrastin kera. Kontrastin kera tapahtuvassa kuvauksessa potilaaseen injektoidaan väriainetta, jonka tarkoituksena on kertyä tietynlaisen rakenteen ympärille. Aine pysäyttää röntgensäteet ja tämän seurauksena kyseinen elin/alue näkyy paremmin tuotetuissa kuvissa. Esimerkiksi syöpäpotilaiden osalta käytetään ainetta, joka kertyy kasvaimen ympärille, jolloin itse kasvain näkyy kuvissa paremmin. Kontrastillista TT-kuvantamista käytetään harvemmin aivoverenvuotojen diagnosoinnissa, sillä se ei ole tarpeellista vuodon paikantamiseksi. [8], [9]

Tietokonetomografian suuri ongelma on sen tuottama säteily. Kuvantaminen tuottaa ionisoivaa säteilyä, joka on haitaksi potilaalle. Säteilyn määrä riippuu kuvassa käytetystä jännitteestä sekä kuvantamisajasta. Tämän vuoksi radiologeille on luotu asiaa koskeva ohje: ALARA (as low as reasonably achievable) eli niin alhainen säteilyannos kuin kohtuudella on mahdollista saavuttaa. Ohjeistus tarkoittaa potilaisiin kohdistuvan säteilyn määrän vähentämistä, joka pyritään toteuttamaan lyhentämällä kuvantamisaikaa sekä varmistamalla, että potilaasta otetaan kuva ainoastaan silloin, kun kuvan tuottamat hyödyt ovat suuremmat kuin säteilystä mahdollisesti aiheutuvat haitat. [10]

3.1 Tietokonetomografian toimintaperiaate

Natiiviröntgenkuvantaminen (ja täten myös TT-kuvaus) perustuu sähkömagneettiseen säteilyyn. Röntgenputkessa elektronit kiihdytetään katodia pitkin kohti anodissa olevaa volframipalaa suuren jännitteen avulla. Seuraavaksi elektronit lähetetään röntgenputken kautta potilasta kohti. Elektronien törmätessä anodiin suurin osa niiden kineettisestä energiasta muuttuu lämmöksi ja ainoastaan pienestä osasta tulee röntgensäteilyä, jota kuvantamisessa tarvitaan. TT-kuvantamisessa käytetty jännite on noin 100–150 kV. Jännitteen suuruus

vaikuttaa kuvan laatuun, ja sitä säädetään sen mukaan, millaiset vaatimukset tarkkuudelle on asetettu. Mitä korkeampi jännite on, sitä tarkempi kuva saadaan, mutta samalla potilaan säteilyaltistus kasvaa. Röntgensäteilyn määrä on mahdollista laskea Krestelin yhtälön avulla seuraavasti:

$$\eta = aUZ \quad (1)$$

Missä η on röntgensäteilyn määrä, a on vakio, jonka arvo on $1{,}1 \cdot 10^{-9}\frac{1}{V}$, U on potentiaali ja Z on käytetyn metallin järjestysluku [9]

Käytettäessä volframia ja 100 kV jännitettä, voidaan kaavan 1 avulla laskea röntgensäteilyn määrä. Tulos on 0,0081 eli < 0,1 %. Suurin osa kineettisestä energiasta muuttuu täten lämmöksi. On erittäin tärkeää, että niin röntgenlaite kuin tietokonetomografialaite kestävät kuumenemista ja että ne voidaan jäähdyttää tehokkaasti, jotta laitteet toimivat mahdollisimman hyvin ja niistä ei aiheudu vaaraa potilaalle.

Elektronien törmätessä anodiin niiden vauhti hidastuu. Se johtaa kineettisen energian menetykseen, joka taas johtaa lämmön sekä sähkömagneettisen säteilyn syntymiseen. Muodostunut säteily on röntgensäteilyä. Säteily suunataan potilasta kohti ja läpituleva määrä riippuu kudoksen tiheydestä. Sijoittamalla antureita potilaan kuvatun elimen vastakkaiselle puolelle voidaan mitata läpipääsevän säteilyn määrää. Mittauksen avulla tietokone rekonstruoi kuvan potilaan eri kudoksista. Tällä tavoin saadaan kattava kaksiulotteinen kuva halutusta kehon osasta. Menetelmä on erityisen toimiva kuvaamaan luita ja muita tiheitä kudoksia. [8] ,[9] Kuva numero 3 röntgenputken toiminnasta.

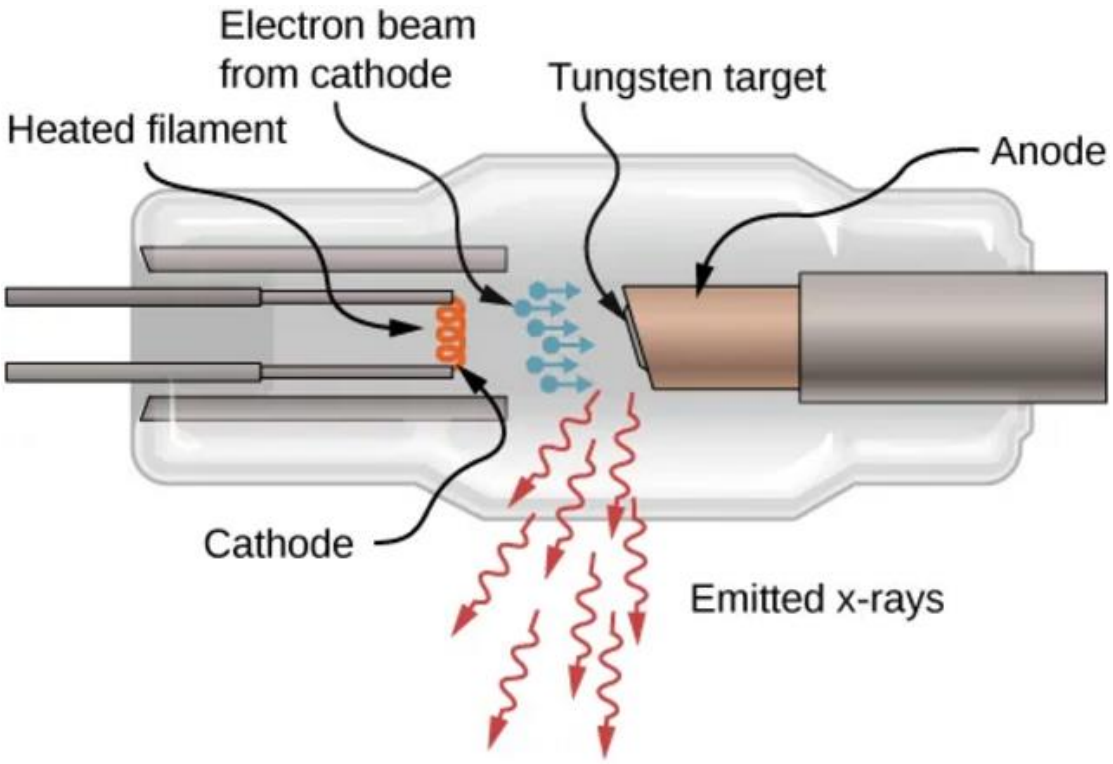

Kuva 3 Röntgenlaitteen toimintaperiaate. Kuvassa esitetään röntgenputken rakenne ja sen keskeiset osat. Vasemmalla näkyy katodi (cathode), josta elektronit (sinisellä) vapautuvat ja kiihdytetään kohti oikealla olevaa kuparista anodia (anode). Anodissa on volframi pala (tungsten target), johon elektronit törmäävät. Törmättyään anodiin elektronien liike-energia muuttuu lämmöksi sekä röntgensäteilyksi (punainen). Lähde: [11], kuvan käyttöoikeudet: CC BY-SA 4.0.

TT-kuvantaminen eroaa perinteisestä röntgenkuvauksesta siinä, että potilaasta otetaan suuri määrä röntgenkuvia eri kulmista. Tämä tapahtuu pyörivän röntgenputken sekä antureiden avulla. Näitä kuvia kutsutaan viipaleiksi. Viipaleet yhdistetään laskennallisesti, jolloin saadaan muodostettua kolmiulotteinen kuva ilman päällekkäisyyksiä. Otettujen kuvien eli projektiokuvien muodostama kokonaisuus on nimeltään sinogrammi. Sinogrammi sisältää kaikista eri kulmista kerätyt mittaustiedot, jotka muunnetaan myöhemmin käyttökelpoiseen muotoon rekonstruktion avulla. [8], [9] Tätä käsitellään tarkemmin kappaleessa 3.2.

TT-kuvantamisessa käytetään sensoreissa puolijohdeilmaisimia, kuten scintillaattori–fotodiodiyhdistelmiä. Sensorit vaikuttavat röntgensäteilyn kanssa ja saavat aikaiseksi näkyvää valoa. Luotu valo konvertoidaan sähkövirraksi fotodiodin avulla. Tietokone luo näistä signaaleista lopullisen kuvan, jota voidaan tarkastella monesta eri kulmasta. Usein potilaan kehonosa tai elin, jota kuvataan, on pyöreä, kuten esimerkiksi aivot. Tämän vuoksi on käytössä filttereitä, joita kutsutaan säteen muotoilusuodattimeksi. Filttereiden avulla röntgensäteilyä muokataan siten, että se jakautuu tasaisesti kuvattavan elimen yli, mikä mahdollistaa kuvan maksimaalisen tarkkuuden. Ilman filttereitä säteily olisi keskittyneempi reunoihin ja keskellä oleva osa olisi epätarkka ja täynnä kohinaa. Jos käytössä ei ole filtteriä,

joudutaan säteilyn määrä lisäämään, jotta kuvasta tulisi tarkempi ja sitä pystytäisiin käyttämään. Tämä ei ole potilaan kannalta suositeltavaa, eikä myöskään ALARA:n mukaista. Filttereiden ansiosta TT-kuvantaminen on tarkempaa [8], [9] Kuva numero 4 TT-kuvantamislaitteen rakenteesta.

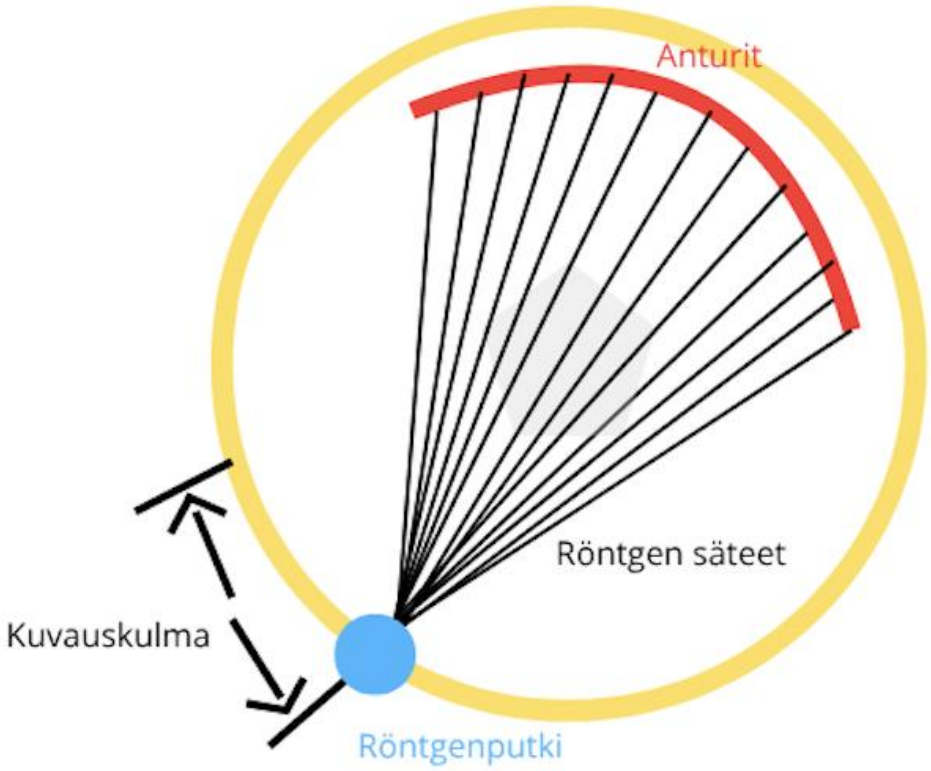

Kuva 4 Tietokonetomografian toimintaperiaate. Kuvassa on esitetty kuinka röntgenputki on kiinnitetty pyörivän kehikon päälle, minkä avulla kuvauskulmaa voidaan muuttaa. Kuvassa näkyy myös röntgensäteet sekä kuvattavan kohteen toisella puolella olevat anturit, jotka vastaanottavat läpi päästetyn säteilyn. Kuva tehty lähteen [8] perusteella.

3.2 Kuvien rekonstruktio ja suodatus

Tietokonetomografia ei automaattisesti tuota valmista kuvaa, vaan kaikki laitteen keräämät viipaleet yhdistetään matemaattisten menetelmien avulla. Tätä prosessia kutsutaan rekonstruktioksi, ja sen toteuttamiseen on kehitetty useita erilaisia algoritmia. Tällä hetkellä kuvia rekonstruoidaan kolmen eri päämenetelmän avulla. Näihin kuuluu suodatettu takaisinkuvaus (engl. filtered back projection, FBP), iteratiivinen jälleenrakennus (engl. iterative reconstruction) sekä tekoäly. Tekoäly pois lukien menetelmät ovat olleet käytössä ja vuosia. Ensimmäinen, vuonna 1972, käyttöönotettu menetelmä oli iteratiivinen jälleenrakennus. Sen käyttö lopetetiin, sillä sen pitkä käsittelyaika ja laskentatehon puute

tekivät siitä heikon. Tämän jälkeen otettiin käyttöön FBP-menetelmä. Sen käyttö yksin tuotti vaikeuksia, sillä menetelmä olettaa, että kaikki mitattava data on täydellistä. Jonka vuoksi kuvissa on runsaasti kohinaa, mikä aiheuttaa niiden epätarkkuutta. TT-kuvantamisen kehityksen myötä viipaleiden leveys on pienentynyt, mikä on samalla lisännyt kohinan määrää. Kapeampien viipaleiden avulla saadaan kuvia, jossa yhä pienemät yksityiskohdat näkyvät. Vuonna 2009 iteratiivinen jälleenrakennus otettiin parannettuna uudestaan käyttöön. Tämän mahdollisti parantunut laskentatekniikka sekä sen yhdistäminen FBP-menetelmän kanssa. Iteratiivista jälleenrakennusta pystyy käyttämään yksinomaan, mutta myös yhdessä FBP-menetelmän kanssa. Näiden kahden menetelmän yhdistäminen eli niin sanottu hybridimenetelmä on tällä hetkellä suosituin. Tekoälyä käyttävät menetelmät yleistyvät koko ajan, sillä edellä mainitut menetelmät eivät ole täydellisiä ja erityisesti nopeutta pyritään lisäämään. [10]

FBP-menetelmä toimii takaisinsuodatuksen avulla. Kun kaikki viipaleet ovat valmiita, eli kun projektiodatan sinogrammi on valmis, suodatetaan viipaleet matemaattisen filtterin avulla. Suodatus tehdään yleensä Fourier-muunnosta hyödyntäen. Fourier-muunnos on matematiikan jatkuva integraalimuunnos, jota käytetään usein signaalinkäsittelyssä. Suodattaminen on välttämätöntä, sillä ilman sitä takaisinkuvauksesta saatu kuva on sumea, koska kukin viipale levittää tietoa hieman liian laajalle alueelle. Tällöin kuvattava elin kyllä näkyy, mutta sen rajat ovat epäselvät. Sumeuden poistamisen jälkeen suodatetut projektiot projisoidaan takaisin kuvaan niiden mittauskulmien mukaan. Menetelmä on nopea, mutta herkkä kohinalle ja siksi ei yhtä tarkka kuin muut. [8], [9]

Toinen rekonstruktio menetelmä on iteratiivinen jälleenrakennus, joka ensivaiheessa toimii samalla tavalla kuin FBP. Ensimmäisen kuvan muodostamisen jälkeen kuvaa iteroidaan kohinanpoiston tai muiden mukautuvien suodatusmenetelmien avulla. Tämä tehdään, jotta kuvasta tulisi mahdollisimman tarkka. Menetelmä sisältää eteenpäin- ja takaisinheijastusvaiheita, joita toistetaan, kunnes ennalta määritelty pysäytyskriteeri täyttyy. Tehdyt iteraatiot poistavat kuvasta kohinaa. Menetelmiä on monia, mutta useimmiten käytettyjä, ovat tilastolliset iteratiiviset jälleenrakennusmenetelmät, jotka hyödyntävät fotonien laskentamalleja. Malli tarkastellee kohinan ja fotonimäärän välistä suhdetta ja tekee sen perusteella tarvittavat iteraatiot. Menetelmässä täytyy olla tarkka, että ei iteroi liian pitkälle. Jos näin käy, kuvista tulee yliprosessoituja ja ne näyttävät ”muovimaisilta”. Iteratiivinen jälleenrakennus kestää kauemmin kuin FBP, mutta se on tarkempi ja tuottaa potilaille vähemmän säteilyä, sillä kuvantamisvaiheessa käytetään pienempää jännitystä.

Tarkkuus johtuu siitä, että iteratiivinen jälleenrakennus ei oleta, että data on täydellistä ja täten kohina saadaan paremmin pois. Menetelmän suurin ongelma on sen kestoaika. Kuvan rekonstruktio voi kestää jopa 90 min. Aika-arvioksi tälle menetelmälle annetaan yleensä 10–90 minuuttia, jonka vuoksi se ei ole esimerkiksi hätätilanteissa ideaalinen. [8], [10], [12]

Kolmas menetelmä perustuu tekoälyyn ja syväoppimisverkkoon [8]. Tätä käsitellään tarkemmin luvussa 4.

3.3 Traumaattisten aivoverenvuotojen TT-kuvantaminen

Tietokonetomografia on pääsääntöinen kuvantamismenetelmä traumaattisen aivovamman jälkeen. Menetelmä havaitsee herkästi ja täsmällisesti kallonsisäiset vuodot sekä kallomurtumat. Tietokonetomografia on myös erittäin nopea, sillä kuvan saa jopa alle 5 sekunnissa. Toinen menetelmä aivojen kuvantamiseen on magneettikuvaus (engl. magnetic resonance imaging, MRI). Magneettikuvauksella on rajoitteita, joita TT-kuvantamisella ei ole. Jos potilaasta otetaan magneettikuva, tulee ensin varmistaa, ettei hänellä ole esimerkiksi sydämentahdistinta tai muuta metallia kehon sisällä. Varmistamien vie aikaa, jota hätätilanteessa ei välttämättä ole. Magneettikuvantamisessa itse kuvantamisprosessi kestää myös kauemmin, noin 30–60 minuuttia ja potilaan pitää olla koko ajan maaten. Maakuuasennossa oleminen näin pitkään voi aiheuttaa joissain aivovammapotilaissa ongelmia, sillä heillä voi esiintyä esimerkiksi huimausta ja pahoinvointia. Tämän lisäksi muita lääkinnällisiä laiteitta, joita usein käytetään apuna traumaattisten aivovamojen seurannassa ja diagnosoimisessa voidaan käyttää samaan aikaan TT-kuvantamisen kanssa, mutta tämä ei ole mahdollista MRI-kuvauksen aikana. Tietokonetomografian kanssa samanaikaisesti voidaan suorittaa esimerkiksi aivosähkökäyrän mittausta (EEG). EEG:n avulla seurataan aivojen sähköistä toimintaa ja kun se yhdistetään TT-kuvaan lääkärit saavat kuvan aivojen rakenteesta sekä mahdollisista sähköisistä ongelmista. [2], [13]

Magneettikuvauksella on myös hyvät puolensa. Se on TT-kuvausta tarkempi ja tunnistaa myös pienemmät aivoverenvuodot. Se ei kuitenkaan ole käytössä hätätilanteissa sen hitauden vuoksi. Siksi magneettikuvantamista käytetään usein potilaiden tilan seuraamiseen myöhemmässä vaiheessa tai jos kyseessä ei ole akuutti aivovamma. Magneettikuvantamista käytetään erityisesti, jos TT-kuvassa ei näy ongelmia, mutta potilas silti oireilee. Paremman tarkkuuden vuoksi kuvista voi löytyä poikkeuksia, joita ei TT-kuvantamisessa havaittu. Magneettikuvantamislaiteita ei myöskään ole yhtä laajasti tarjolla, kun TT-laiteita. TT-

kuvantaminen tarvitsee myös vähemmän henkilöstöresursseja, mikä helpottaa sen käyttöä. [2], [13]

Tietokonetomografia soveltuu hyvin traumakuvaukseen, sillä se on nopea ja riittävän tarkka tunnistamaan hätätilanteissa oleelliset asiat. Tarkkuutta parannetaan esimerkiksi käyttämällä säteilyä ohjaavia filttereitä ja kehittämällä kuvien rekonstruktiotekniikoita. Tietokonetomografiaa käytetään ensisijaisesti sen nopeuden vuoksi. Mikäli magneettikuvaus kehittyisi tulevaisuudessa yhtä nopeaksi, TT-kuvantamisen käyttö saattaisi vähentyä merkittävästi. Johtuen magneettikuvan paremmasta tarkkuudesta sekä säteilyn puutteesta. Vaikka tietokonetomografia ei välttämättä tunnista kaikkein pienempiä vuotoja, se tunnistaa hyvin niin epiduraali- kuin subduraalihematoomat sekä kallomurtumat. Edellä mainitut vauriot vaativat nopean diagnosoinnin ja välittömän hoidon. Tietokonetomografiakuvan perusteella tehdään päätökset potilaan jatkohoidosta, kuten esimerkiksi mahdollisista kirurgisista toimenpiteistä. Havaitsemistarkkuuteen ja säteilyaltistukseen liittyvistä haasteista huolimatta tietokonetomografia on edelleen ensisijainen kuvantamismenetelmä akuuteissa tapauksissa. [13]

4 Tekoälyn hyödyntäminen kuvantamisessa

Tekoälyn käyttö lääketieteessä yleistyy jatkuvasti. Tietokonetomografiassa tekoälyä käytetään kuvien rekonstruktioon. Lisäksi tekoälyä käytetään kliinisesti apuna mammografioiden ja kolonoskopiakuvien tulkinnassa, mikä osoittaa sen potentiaalin kuvantamisen analyysissä. Traumaattisten aivoverenvuotojen diagnostiikassa tekoälyn sovelluksia tutkitaan aktiivisesti kuvien automaattiseen tulkintaan, ennustemallien ja hoitosuunnittelun tukena. Koska tekoäly on jo osoittanut hyödyllisyytensä muiden kuvantamismenetelmien tulkinnassa, sen käyttö myös TT-kuvien analysoinnissa vaikuttaa lupaavalta. [10]

Koneoppiminen on tekoälyn osa-alue, joka käyttää dataa toiminnan perusteena tunnistamaan, luokittelemaan ja ennustamaan asioita. Haluttu lopputulos on järjestelmä, joka pystyy itsenäisesti tunnistamaan sille annetuista kuvista tietyn piirteen. Esimerkiksi lääketieteellisessä sovelluksessa koneelle syötetty data voi sisältää kuvia keuhkoista ja niissä olevista syöpäsoluista. Kun konetta on koulutettu riittävästi, sille annetaan uusi kuva keuhkoista, josta sen pitäisi pystyä tunnistamaan, jos kuvassa ilmenee syöpäsoluja. Koneoppiminen jaetaan kolmeen eri pääluokkaan: ohjattuun koneoppimiseen, ohjamattomaan koneoppimiseen sekä vahvistettuun oppimiseen. Ohjatussa koneoppimisessa koneelle syötetään kuvia, joihin on merkitty esimerkiksi syöpäsolujen sijainnit. Menetelmä perustuu siihen, että konetta opetetaan ihmisen aiemmin tekemän työn avulla: opetusdata on valmiiksi merkitty ja luokiteltu. Ohjaamaton koneoppiminen toimii siten, että kuvat syötetään koneelle ilman ennalta merkittyjä luokkia. Tässä menetelmässä kone oppii itse datasta ja pyrkii tunnistamaan eri rakenteet esimerkiksi ryhmittelemällä ne tiettyjen piirteiden perusteella. Vahvistetussa oppimisessa kone oppii vuorovaikutuksessa ympäristön kanssa. Oppiminen perustuu positiivisiin ja negatiivisiin palkkioihin. [10], [14]

Syväoppimisen voidaan katsoa olevan koneoppimisen alaluokka. Syväoppiminen käyttää keinotekoisia neuroverkkoja (engl. artificial neural network). Neuroverkko koostuu niin sanotuista neuroneista. Neuronit on organisoitu kerroksiin: syötekerros, piilokerrokset ja ulostulokerros. Syvissä neuroverkoissa on aina enemmän kuin yksi piilokerros. Neuroni laskee painotetun summan kerroksen syötemuuttujista, ja summa syötetään aktivaatiofunktiolle, joka siirtää tuloksen eteenpäin seuraavalle neuronille, kunnes päästään viimeiseen kerrokseen. Neuroverkkoja on myös monenlaisia. Lääketieteellisessä kuvantamisessa yleisin käytetty menetelmä on konvoluutioverkko (engl. convolutional neural

network, CNN). Se toimii sekä suodattimen, että neuroverkkojen avulla. Menetelmä vaatii suuren määrän dataa ja sen käyttö on täten mahdollistunut vasta viime vuosina. [10], [14]

4.1 Tekoälyn hyödyt diagnostiikassa

Ilman tekoälyä toimivat kuvien rekonstruktiotekniikat eivät ole täydellisiä. Rekonstruktioiden laatiminen kestää kauan, ja kuvat eivät aina ole tarkkoja. Jonka vuoksi jännitemäärää on lisättävä ja potilaan saama säteilymäärä nousee. Tekoälyn käyttöön perustuvien tekniikoiden kehittämisen avulla pyritään vähentämään potilaisiin kohdistuvaa säteilymäärää heikentämättä kuvien laatua. Tällä hetkellä on käytössä kolme tekoälyyn perustavaa tekniikkaa (algoritmia), jotka auttavat rekonstruktiossa. Kaikki tekniikat ovat FDA:n (Food and Drug Administration) hyväksymiä. [10], [15]

Kaksi käytössä olevaa algoritmia ovat Canon Medicalin Advanced Intelligent Clear-IQ Engine (AiCE) sekä Phillips healthcaren kehittämä Precise Image. Molemmat menetelmät perustuvat syvien konvoluutioneuroverkkojen (engl. deep convolutional neural network, DCNN) hyödyntämiseen, joiden avulla pyritään vähentämään kuvakohinaa ja parantamaan signaalin laatua. Järjestelmät koulutetaan korkeanlaatuisilla referenssikuvilla, jolloin ne oppivat erottamaan todellisen kuvasignaalin kohinasta. Molemmat menetelmät toimivat hybridimallin (FBP:n ja iteratiivisen jälleenrakennuksen yhdistelmän) pohjalta. Menetelmät täydentävät kyseistä hybridimenetelmää, eli ne eivät kykene toimimaan itsenäisesti. Menetelmien avulla voidaan tuottaa tarkempia kuvia ja parempia tuloksia pidentämättä kuvantamisprosessia, mikä mahdollistaa alhaisemman jännitteen käytön. [10]

Kolmas menetelmä on GE Healthcaren menetelmä nimeltään TrueFidelity™ DLR. Tämä menetelmä käyttää syväoppimiseen perustuvaa kuvien rekonstruktiomenetelmää, joka toimii syvien neuroverkkojen (engl. deep neural network, DNN) avulla. Toisin kuin aiemmin mainitut menetelmät, TrueFidelity rekonstruoi kuvan suoraan sinogrammin raakadatasta, joka on kerätty matalalla sädeannoksella. Tässä ei tarvita FBP:tä tai iteratiivista jälleenrakennusta esikäsittelyyn. Menetelmä koulutetaan FBP-menetelmän rekonstruoiduilla kuvilla, jotka on otettu optimaalisissa olosuhteissa ja suurella jännitteellä. Koulutuksen seuraavassa vaiheessa järjestelmälle annetaan huonolaatuisia kuvia, joissa on paljon kohinaa. Näin se oppii erottamaan kohinan todellisesta kuvasignaalista. Menetelmä vähentää tarpeetonta kohinaa samalla kun se säilyttää kuvan tekstuurin, mikä parantaa kuvan yleistä laatua, verrattuna muihin rekonstruktiomenetelmiin. [10], [15]

Syväoppimiseen perustuvia kuvien rekonstruktiomenetelmiä kehitetään jatkuvasti. Yksi kehityksessä oleva menetelmä on nimeltään iCTU-Net, joka on suunniteltu vähentämään metallista aiheutuvaa kuvakohinaa. Tällainen kohina syntyy esimerkiksi potilaan kehoon asetetuista metalliesineistä, kuten neuloista tai implanttien osista. iCTU-Net toimii TrueFidelityn tavoin käyttämällä raakaa sinogrammidataa, eikä tarvitse perinteisiä menetelmiä avukseen. Menetelmä koulutetaan ohjatusti käyttämällä sekä korkealaatuisia kuvia, että metallin aiheuttamia kohinaisia kuvia. iCTU-net ei vielä pysty rekonstruoimaan hyvin pieniä rakenteita ja se ei ole kliinisessä käytössä. [16]

Koska käytössä olevat perinteiset menetelmät ovat puutteellisia, tekoälyn hyödyntäminen tarjoaa uusia mahdollisuuksia. Perinteiset menetelmät epäonnistuvat korkealaatuisten kuvien tuotossa, kun olosuhteet eivät ole ihanteelliset ja kun kuvantamiseen tehdään muutoksia. Säteilyannoksen vähentämiseksi on otettu käyttöön harvanäkymänotanta (engl. sparse view), joka tarkoittaa, että skannauksen aikana projektiokulmien kokonaismäärää vähennetään. Perinteisille rekonstruktiomenetelmille tämä tuottaa vaikeuksia, sillä ne edellyttävät tiheää kulmanäytteenottoa. [12] Kehitteillä oleva menetelmä nimeltä Dual-domain deep Prior-guided Multi-scale fusion Attention (DPMA) pyrkii ratkaisemaan ongelman, yhdistämällä oppimispohjaiset ja mallipohjaiset lähestymistavat. Menetelmä hyödyntää matemaattisia operaatioita kuten eteenpäin- ja taaksepäin-projektioita ja on suunniteltu toimimaan itsenäisesti ilman perinteisiä algoritmeja. DPMA ei ole vielä kliinisessä käytössä. [17]

Käytössä on myös rajoitettu kulmakuvaus (limited-angle CT), jossa tiedonkeruu rajataan pienempään kulma-alueeseen. Tavoitteena on lyhyempi kuvausaika ja parempi ajallinen resoluutio. Tämäkin lähestymistapa tuottaa perinteisille menetelmille ongelmia sen epätarkkuuden vuoksi. Tekoälypohjaiset menetelmät voivat ratkaista ongelmat, sillä ne eivät perustu pelkästään analyyttisiin malleihin, kuten FBP ja iteratiivinen jälleenrakennus. Tekoälyn suorituskyky on ollut hyvä ratkaistessaan sparse-view ja limited-angle ongelmia. Tekoälyn avulla pystytään lyhentämään kuvantamisaikaa sekä vähentämään laadukkaan kuvan saamiseen vaadittavaa datan määrää. [12]

Tietokonetomografian kuvien tulkitseminen on usein haastavaa ja aikaa vievää. Hätätilanteissa tarkka ja nopea tulkinta on välttämätöntä, sillä päätöksiä on tehtävä viipymättä. Kuvien tulkinnassa voi esiintyä myös inhimillisiä virheitä ja vaihtelua. Lisäksi radiologien tulkinnat voivat vaihdella, mikä johtaa vaihteleviin johtopäätöksiin. Erityisesti yöllä otetuissa kuvissa, joita nuoremmat ja vähemmän kokeneet radiologit tulkitsevat,

havaitaan keskimääräistä enemmän tulkintaeroja ja virheitä [18]. Näitä haasteita pyritään ratkaisemaan tekoälyn avulla ja tätä kutsutaan tietokoneavusteiseksi diagnostiikaksi (engl. Computer aided diagnosis, CAD). Kuten kuvien rekonstruktiossa, myös CAD-järjestelmässä hyödynnetään koneoppimista. Tekoälyä on jo mahdollista käyttää kuvien tulkinnassa ja menetelmiä kehitetään jatkuvasti. Tekoälyn tehokas hyödyntäminen edellyttää kuitenkin laajaa ja monipuolista opetusdataa. [19] Tutkimusten mukaan tekoäly on yleensä jopa radiologia tarkempi tunnistamaan kuvista poikkeuksia. Esimerkiksi keuhkosyövän tunnistamisessa tekoälyn tunnistamisprosentti oli 56,4–95,7 %, kun taas radiologin oli 23,2–76 %. [20] Tällä hetkellä markkinoilla ei ole vielä vakiintunutta CAD-menetelmää. Suurin osa kehitteillä olevista ratkaisuista hyödyntää konvoluutioneuroverkkoja löytääkseen kuvista poikkeuksia. Koska tunnistettavia rakenteita ja poikkeuksia on useita ja ne voivat näyttää hyvin erilaisilta, yhden järjestelmän on vaikea kattaa kaikkia tapauksia. Tämän vuoksi olemassa olevat järjestelmät tulisi yhdistää siten, että saataisiin aikaan yksi toimiva järjestelmä, jota voitaisiin käyttää diagnoosiprosessissa. [19]

Yksi esimerkki kliinisessä käytössä testatusta menetelmästä on qER.ai, jota on kehitetty Intiassa ja testattu ranskalaisessa sairaalassa. Menetelmä on saanut FDA:n hyväksynnän ja on saatavilla markkinoilla. Kyseinen ohjelmisto (qER-NCCTv1.0) toimii esikoulutettujen konvoluutioneuroverkkojen avulla ja sisältää neljä algoritmia, joista jokainen havaitsee tietyn poikkeavuuden: kallonsisäiset verenvuodot, kallonmurtumat, aivokudoksen siirtymisen ja keskiviivan siirtymisen. Tutkimuksessa käytettiin 682 potilaan kuvia, joista tekoäly sai 91,6 % oikein. Tutkimuksessa huomattiin, että tekoäly antaa suhteellisen korkean määrän vääriä positiivisia tuloksia, tarkoittaen, että tekoäly havaitsi kuvista niissä olemattomia poikkeuksia. [18] Tätä voisi todennäköisesti parantaa hiomalla tekoälyn ohjelmistoa, esimerkiksi suuremman koulutusdatan avulla. Taulukossa 4.1 esitellään tutkimuksen tuloksia.

Taulukko 4.1Tekoälyn saamat tulokset vamman vakavuuden perusteella, taulukko on tehty lähteen [18] perusteella

Tulos:	Lievä vamma	Vakava vamma	Yhteensä
Oikea positiivinen:	47	40	87
Väärä positiivinen:	37	9	46
Oikea negatiivinen	478	60	538
Väärä negatiivinen:	8	3	11

Lisäksi tutkimuksessa vertailtiin tekoälyn ja kokemattomampien radiologien tuloksia. Tulokset osoittivat, että tarkkuus on paras, (98,8 %) kun radiologit käyttivät tekoälyä apuna

tulkinnassa. Tämä viittaa siihen, että tekoälyllä voisi tulevaisuudessa olla merkittävä rooli diagnostiikan tukena, erityisesti tilanteissa, joissa kokeneita radiologeja ei ole saatavilla ja päätöksiä on tehtävä nopeasti. [18] Tutkimuksen tulokset ovat Taulukossa 4.2.

Taulukko 4.2 Tekoälyn sekä kokemattomampien radiologien saamat tulokset, taulukko on tehty lähteen [18] perusteella.

Tulos:	Kokemattomampi radiologi	Tekoäly	Kokemattomampi radiologi + tekoäly
Oikea positiivinen:	19	18	20
Väärä positiivinen:	6	1	1
Oikea negatiivinen	137	142	142
Väärä negatiivinen:	2	3	1

Toinen tekoälypohjainen menetelmä, joka on saanut FDA:n hyväksynnän, on Viz.ai. Hyväksyntä koskee tällä hetkellä subduraalihematoomien tunnistamista. Viz.ai perustuu konvoluutioneuroverkkoihin, joita on koulutettu TT-kuvilla. Floridassa tehdyssä tutkimuksessa käytetiin 4203 pään TT-kuvaa ja menetelmä saavutti 98 % tarkkuuden. Tutkimuksessa oikeiden negatiivisten tunnistamisen tarkkuus oli 99 % ja oikeiden positiivisten vuorostaan 81 %. Järjestelmää kehitetään jatkuvasti ja esimerkiksi aivojen keskiviivan siirtymää pyritään tunnistamaan. [21]

Lisäksi on useita muita kehitteillä olevia menetelmiä, jotka hyödyntävät konvoluutioneuroverkkoja ja muita syväoppimisen ja koneoppimisen tekniikoita poikkeavuuksien automaattiseen tunnistamiseen. Menetelmiä on useita, jotka ovat eri vaiheissa validointiprosessia. Taulukossa 4.3 on kerätty 7 eri menetelmää, joita kehitetään parhaimmillaan. [22] Taulukossa ML tarkoittaa koneoppimista ja DL syväoppimista.

Taulukko 4.3 Tekoälypohjaiset menetelmät aivoverenvuotojen diagnostiikassa. Taulukko tehty lähteen [22] perusteella.

ML/DL	Algoritmi/ menetelmä	Aineiston koko	TBI:hin liittyvä kliininen arviointi	Suorituskyky
ML	MDRLSE, hierarkkinen luokittelija (käyttäen pikselin intensiteettiä ja SVM-luokittelijaa)	627	EDH-, SDH- ja IVH-verenvuotojen tunnistaminen	Tarkkuus: Ensimmäinen luokittelija: 0,90 Toinen luokittelija: 0,94
DL	Laajennettu CNN	62	Hematooman rajaaminen	Tarkkuus: 0,95
DL	DenseNet-verkko, huomiointimekanismi ja toistuva neuroverkko	329	Akuutin hematooman tunnistaminen	Tarkkuus: 0,818 Herkkyys: 0,886
ML	Intensiteettiin perustuva alueen kasvatus -algoritmi	18	Hematooman rajaaminen	Vastaavuussuhde : 0,80
DL	U-net -pohjainen CNN	144	Hematooman rajaaminen ja tilavuuden arviointi	Rajaaminen: 0,697 Tilavuusarvio: 0,966
DL	Sym-TransNet	1357	Aivoverenvuotojen rajaaminen	Dice-kerroin: EDH: 0,359 SDH: 0,534 IVH: 0,68
DL	LSTM (Long Short-Term memory) toistuvan neuroverkon muoto	Koulutus ja testaus: 1554, validointi: 386	Aivoverenvuotojen havainnointi	Tarkkuus: 0,96

Tutkimusten perusteella voidaan todeta, että vaikka tekoäly ei vielä pysty itse tekemään diagnooseja, sen käyttö hoitohenkilökunnan rinnalla on lupaavaa. Monet tutkimukset osoittavat, että tekoälyn hyödyntäminen yleistyy tulevina vuosina, ja sen avulla voidaan vähentää inhimillisiä virheitä sekä nopeuttaa päätöksentekoa. Lisäksi tekoäly voi tulevaisuudessa parantaa diagnostiikan tarkkuutta, varsinkin jos kokeneita radiologeja ei ole saatavilla.

4.2 Tekoälyn haasteet ja rajoitukset

Tekoälyä käytetään jo apuna terveydenhuollossa, mutta sen käytössä on vielä ongelmia ja epäselvyyksiä, jotka täytyy ratkoa. Tekoälyn avulla voidaan parantaa tarkkuutta diagnosointiprosessissa sekä nopeuttaa diagnoosin saamista. Tekoäly voi myös vähentää terveydenhuollon ammattilaisten työmäärää sekä inhimillisiä virheitä. Jonka vuoksi sen käyttöönottoon liittyvien ongelmien ratkaiseminen on tärkeää.

Yksi suurimmista huolenaiheista tekoälyn käytöstä terveydenhuollossa on niin sanottu blackbox ongelma. Tällä tarkoitetaan sitä, että syväoppimismallit toimivat ns. ”mustina laatikoina” eli ihmisille ei ole selvää miksi tekoäly tekee tietyn päätöksen. Haaste johtuu siitä, että ihmiset eivät ymmärrä mitä neuroverkkojen jokaisessa kohdassa tapahtuu. Tämän vuoksi tekoäly voi tuottaa lopputuloksia, joiden taustalla olevaa päätösprosessia ei voida tarkasti seurata, mikä saattaa heikentää järjestelmän luotettavuutta. Mikäli tekoäly ei kykene perustelemaan, miten se on päätynyt tiettyyn johtopäätökseen, lääkärillä ei ole riittävää pohjaa rakentaa hoitosuunnitelmaa sen perusteella. Ongelman ratkaisemiseksi on kehitelty niin sanottu selittävä tekoäly (engl. explainable AI), jonka tehtävänä on selittää neuroverkkojen toimintaa ja tekoälyn päätöksentekoa. Selittävä tekoäly parantaa luottamusta terveydenhuollon ammattilaisten ja tekoälyn välillä. [20], [12]

Erityisesti luottamuksen puute on yksi tekoälyn käyttöönoton suurista haasteista. Terveydenhuollon ammattilaiset ovat tottuneet tekemään työtään tietyllä tavalla ja sen muuttaminen tekoälyn integroinnilla voi joissain tapauksissa johtaa ongelmiin. Uuden mallin implementaatio sairaaloihin voi olla haastavaa, jos siellä olevat ammatinharjoittajat eivät luota malliin tai eivät ymmärrän sen käyttöä. Varsinkin vanhemmat ihmiset eivät välttämättä osaa käyttää, eivätkä luota uuteen tekniikkaan. Luottamuksen puute voi johtaa hoidon viivästymiseen. Tämän vuoksi on tärkeää kouluttaa terveydenhuollon ammattilaisia tekoälyn käytössä ja varmistaa että kaikki ymmärtävät miten se toimii ja kuinka sen käyttö voi helpottaa potilastyötä, varsinkin hätätilanteissa. Tekoäly on kuitenkin suunniteltu käytettäväksi ammattilaisten rinnalla, ja heidän täytyy pystyä luottamaan siihen. [20], [12]

Tekoäly voi myös hallusinoida. Tämä tarkoittaa, että tekoäly huomaa jotain kuvassa olematonta. Kuvien rekonstruktiossa tekoäly voi pahimmassa tapauksessa lisätä kuviin jotain sinne kuulumatonta, tai poistaa niistä jotain niihin kuluvaa. Tämä vältetään tarkalla koulutuksella. On tärkeää, että hoitohenkilökunta pystyisi varmistamaan, jos prosessissa on tapahtunut mahdollista hallusinaatiota. Tähän ei ole tällä hetkellä selvää ratkaisua. [12]

Haasteena on myös tekoälyn tietoturvallisuus. Tekoälyn kouluttamiseen vaaditaan suuri määrä dataa. Datan täytyy olla oikeaa potilasdataa, jonka käyttäminen ja säilyttäminen johtaa tietoturvariskeihin. Jos potilasdataa säilytetään pilvipalveluissa, voi potilaiden yksityisyyden suoja vaarantua. Tekoälyn koulutuksessa käytetty data tulee suojata monella tavalla, mutta riskiä ei kuitenkaan pystytä täysin poistamaan. Myös muut potilaiden yksityisyyttä koskevat kysymykset tulee ratkaista. Jos tekoälyä käytetään tulkitsemaan esimerkiksi potilaan TT-

kuvia, tulee siihen olla potilaan lupa. Joka voi olla vaikea saada varsinkin hätätilanteissa. Jos potilaalta ei pyydetä lupaa ja kuvat ladataan tekoälypalveluun, voi tämä olla yksityisyyden suojan loukkaus. [20]

Tekoälyn käyttöön liittyy myös eettisiä haasteita. Suurin kysymys on kuka kantaa vastuun virheen tapahtuessa. Varsinkin terveydenhuollossa, kun kyse on ihmishengistä, tämä on suuri ongelma. Jos tekoälyn tekemän päätöksen perusteella tapahtuu hoitovirhe, kohdistetaanko vastuu hoitavalle lääkärille vai tekoälyjärjestelmän tuottajalle, on edelleen epäselvää. Tekoälymalleja testataan monta vuotta, jotta voidaan varmistaa mahdollisimman luotettava lopputulos. Tekoälyn toiminnan on havaittu olevan ajoittain ennakkoluuloista, mikä johtuu usein sen koulutukseen käytetyn datan laadusta ja alkuperästä. Suurin osa opetusaineistosta on peräisin länsimaista, mikä heijastaa myös laajempaa ongelmaa terveydenhuoltoon liittyvässä tutkimuksessa. Tutkimus on edelleen vahvasti painottunut niin sanottuihin WEIRD-alueisiin, eli länsimaisiin (engl. western), koulutettuihin (engl. educated), teollistuneisiin (engl. industrialized), vauraisiin (engl. rich) ja demokraattisiin (engl. democratic) väestöihin. Tämän seurauksena tekoälyn mallit eivät välttämättä toimi yhtä tarkasti muiden väestöryhmien kohdalla, joiden biologiset ja sosioekonomiset taustatekijät voivat poiketa opetusaineiston edustamista. Aivojen rakenteissa ja toiminnoissa on havaittu muutoksia, jotka esimerkiksi korreloivat sosioekonomisten tekijöiden kanssa. Tämä korostaa tarvetta monipuolisemmalle ja edustavammalle koulutusdatalle, jotta tekoälyn antamat suositukset olisivat luotettavia, potilasryhmästä riippumatta. Muutoin tämä voi pahimmassa tapauksessa johtaa siihen, että potilas saa virheellistä hoitoa puutteellisen ja ennakkoluuloisen koulutusdatan ansiosta. [20]

Mallien käyttöönotossa on myös paljon teknisiä ongelmia. Kehitetyt mallit toimivat usein hyvin pienimuotoisissa kokeissa. Kun ne siirretään laajempaan käyttöön, ilmenee usein ongelmia tarkkuuden, nopeuden ja integroinnin kanssa. Myös eri sairaaloiden erilaiset tietojärjestelmät ja eri valmistajien laitteet aiheuttavat ongelmia. Siksi kehitetään erilaisia pilvipalveluita sekä yritetään tehdä ohjelmista yhteensopivia mahdollisimman monen eri laitteen ja tietojärjestelmän kanssa. [20]

5 Pohdinta

Tietokonetomografia on vielä ehdoton ykkösvaihtoehto traumaattisten aivoverenvuotojen diagnosoinnissa. Vaikka magneettikuvaus vaikuttaa lupaavalta sen tarkkuuden vuoksi, se ei pysty kilpailemaan tietokonetomografian nopeuden kanssa. Nopea diagnosointi on potilaan ennusteen kannalta ratkaisevaa, sillä viivästynyt hoito voi aiheuttaa pysyviä vaurioita. Tietokonetomografian asemaa on lisäksi vahvistanut tekoälyllä parannettu rekonstruktiotekniikka, jonka ansiosta kuvat saadaan nopeammin ja niiden laatu on parempi kuin aikaisemmin. Varsinkin GE Healtcarein kehittämä ratkaisu tuo huomattavaa parannusta, sillä se ohittaa totaalisesti tarpeen perinteisille rekonstruktiomenetelmille. Tekoälyllä on myös potentiaali nopeaan kuvien tulkintaan ja sellaisten poikkeavuuksien havaitsemiseen, jotka saatavat jäädä ihmisiltä huomaamatta. Vaikka tietokonetomografiasta potilaalle aiheutuva säteily on huolestuttavaa, sen vähentämiseksi kehitetyt tekniikat ovat hyviä, ja ALARA:a noudattaminen parantaa potilaan asemaa. Filttereiden, kuvakulman muutoksen ja projektiokulmien vähentämisen avulla, säteilymäärää saadaan pienennettyä ja potilaan kuvantaminen on turvallisempaa. Tekoälyn poikkeuksellisen suorituskyvyn avulla nämä menetelmät ovat suora ratkaisu säteilyn vähentämiseen ja parempaan potilasturvallisuuteen.

Jotta tekoälyä voidaan tulevaisuudessa hyödyntää mahdollisimman hyvin, tarvitaan kattavaa ja monipuolista koulutusdataa. Tekoäly täytyy kouluttaa olemaan ennakkoluuloton ja luotettava joka tilanteessa. Tämä edellyttää menetelmien jatkuvaa kehittämistä ja hienosäätöä. Ainoastaan WEIRD koulutusdatan käytöstä tulisi päästä eroon, jotta lopputulos olisi laadukas. Tähän vaaditaan, että myös muista maista olisi käyttökelpoista dataa tarjolla. Datan kerääminen edellyttäisi riittäviä resursseja. Myös itse tekoälyn käytön vaatima resurssimäärä aiheuttaa ongelmia. Varsinkin matalan tulotason mailla ei välttämättä ole mahdollisuuksia hyödyntää tekoälyä sen kaikessa laajuudessa. Myös tekoälyn koulutusta tulisi seurata tarkemmin niin että blackbox-ongelmaa ei olisi, ja tekoälyn ja hoitohenkilökunnan välinen luottamus olisi mahdollisimman hyvä. Luottamuksen puute voi johtaa hoidon viivästymiseen.

Vaikka tekoälyn käyttö diagnostiikassa on yhä kehitysvaiheessa ja siihen liittyy useita avoimia kysymyksiä, sen potentiaali on merkittävä. Mikä on havaittavissa esimerkiksi syövän tunnistamisessa. Toimivien mallien käyttöönotto on mahdollista ja ne voivat parantaa hoidon laatua. Lisäksi toimivat mallit voivat nopeuttaa päätöksentekoa ja parhaimmillaan pelastaa ihmishenkiä. Samalla on tärkeää varmistaa, että tekoälyn käyttö on vastuullista. Sen päätöksiä on seurattava tarkasti ja vastuunjaon tulee olla selkeä. Ihmisen tulee olla koko prosessissa

mukana, niin että lopullista kliinistä päätöstä ei tehdä ainoastaan koneen perusteella. Voidaan katsoa, että tekoäly toimii parhaiten hoitohenkilön tukena, eikä korvaajana. Tällainen hybridimalli on jo osoittautunut toimivaksi ja se helpottaa sekä potilaiden että hoitohenkilökunnan arkea. Akuuttia terveydenhuoltoa voidaan tekoälyn kehityksen myötä tehostaa, ja siitä voidaan tehdä turvallisempaa ja inhimillisempää. Tulevaisuudessa kuvien rekonstruktio tehdään todennäköisesti ainoastaan tekoälyn avulla ja diagnosoinnissa se toimii työn tukena.

6 Yhteenveto

Tässä kirjallisuuskatsauksessa on käsitelty tietokonetomografian sekä tekoälyn rooleja traumaattisten aivoverenvuotojen diagnosoinnissa. Tarkastelu osoitti, että traumaattisten aivoverenvuotojen diagnosoinnissa tarvittavan nopeuden vuoksi tietokonetomografia on yhä ensisijainen menetelmä. TT-kuvantaminen on nopea ja tarkka kuvantamismenetelmä ja kuvan saa jopa alle 5 sekunnissa. Hätätilanteissa nopeus on kriittinen tekijä, sillä päätös potilaan hoidosta täytyy tehdä mahdollisimman nopeasti, jotta potilas välttyy pysyviltä vaurioilta. Tietokonetomografia havaitsee herkästi kallonsisäiset vuodot ja se on myös laajalti saatavilla, magneettikuvauksen sijaan. Menetelmää myös kehitetään jatkuvasti ja sitä pyritään saamaan vielä nopeammaksi ja tarkemmaksi, esimerkiksi hyödyntämällä harvanäkymäotantaa ja rajoittamalla kuvauskulmaa. Kuvauksesta aiheutuva säteily ja puutteellinen kuvien rekonstruktio tuottaa edelleen haasteita. Näitä pyritään ratkaisemaan tekoälyn avulla.

Tekoäly tarjoaa uusia mahdollisuuksia tietokonetomografiaan sekä diagnosointiin. Varsinkin syväoppiminen on ollut tässä kehityksessä tärkeä, ja sitä hyödyntävät kuvien rekonstruktiomallit ovat jo käytössä. Nämä algoritmit parantavat kuvien laatua ilman että potilaaseen kohdistuva säteilymäärä nousee. Varsinkin GE Healtcaren TrueFidelity menetelmä on poikkeuksellisen toimiva sillä se sivuttaa perinteiset rekonstruktiomenetelmät. Tekoälyä hyödyntävät menetelmät ratkaisevat haastavia rekonstruktio-ongelmia kuten esimerkiksi rajoitetun kulman TT-kuvan tuottaminen. Myös diagnostiikassa voidaan hyödyntää tekoälyä kuvien tulkitsemiseen. Tekoälyä kehitetään parhaillaan kuvien automaattiseen tulkintaan ja sillä on potentiaalia havaita poikkeuksia, jotka voisi jäädä ihmiseltä huomaamatta. Lisäksi tekoäly on nopea ja tämä on erittäin tärkeää traumaattisten aivoverenvuotojen diagnosoinnissa. Tutkimukset ovat osoittaneet, että tulkinnan tarkkuus paranee (98,8 %) kun radiologit käyttävät tekoälyä apuna kuvien tulkintaprosessissa. Tekoäly kykenee vähentämään inhimillisiä virheitä.

Tekoälyn käyttöönottoon liittyy vielä useita avoimia kysymyksiä ja haasteita. Yksi näistä on blackbox ongelma, jonka seurauksena voi olla hallusinaatioita sekä tekoälyn ja hoitohenkilökunnan välinen luottamuksen puute. Tämän ratkaisemiseksi on kehitetty selittävä tekoäly, joka pyrkii ymmärtämään tekoälyn prosessia ja selittämään sen ihmisille. Myös koulutusdatan rajallisuus voi aiheuttaa ongelmia, sillä sen perusteella tekoäly voi olla ennakkoluuloinen ja tämä voi johtaa virheelliseen hoitoon. Potilaiden yksityisyyttä sekä tietoturvallisuutta koskevia ongelmia on myös paljon. Yksi suurimmista kompastuskivistä on

tekoälyä koskevat eettiset ongelmat. Tekoälyn päätösten vastuunjako täytyisi selvittää, jotta mahdollisten virheiden sattuessa toimintamalli olisi selvä.

Tulevaisuudessa tekoäly tulee todennäköisesti toimimaan hoitohenkilökunnan tukena eikä korvaajana traumaattisten aivoverenvuotojen diagnosoinnissa. Tämä hybridimalli on jo osoittautunut toimivaksi useissa muissa sairauksissa. Malli mahdollistaa akuutin terveydenhuollon tehostamisen tekemällä siitä turvallisempaa ja nopeampaa. Jotta tekoälyä voidaan hyödyntää täysin, täytyy ratkaista blackbox ongelma, varmistettava vastuu, ja taattava kattava sekä ennakkoluuloton koulutusdata kaikissa tilanteissa.

Kaiken kaikkiaan tietokonetomografia on yhä paras menetelmä traumaattisten aivoverenvuotojen kuvantamiselle ja tekoäly voisi tehdä tästä vielä tehokkaamman. Tämä olisi mahdollista tietokoneavusteisen diagnostiikan sekä kuvien rekonstruktioalgoritmien avulla. Ongelmia tekoälyn käytössä löytyy vielä ja ne täytyisi ratkaista, jotta se voidaan ottaa maailmanlaajuisesti käyttöön. Tekoälyn ja tietokonetomografian yhdistäminen voi tulevaisuudessa mullistaa aivovammojen diagnostiikan, parantaa hoidon laatua ja vähentää inhimillisiä virheitä.

Lähdeluettelo

[1] A. Sriyook ja R. Gupta, ”Imaging of Head Trauma”, *Radiol. Clin. North Am.*, vol. 61, s. 535–549, 2023, doi: 10.1016/j.rcl.2023.01.008.

[2] R. Curran ja K. Cunningham, ”Severe Traumatic Brain Injuries”, *Physician Assist. Clin.*, vol. 10, s. 591–609, 2025, doi: 10.1016/j.cpha.2025.05.002.

[3] D. P. Griswold, L. Fernandez, ja A. M. Rubiano, ”Traumatic Subarachnoid Hemorrhage: A Scoping Review”, *J. Neurotrauma*, vol. 39, s. 35–48, 2022, doi: 10.1089/neu.2021.0007.

[4] A. Capizzi, J. Woo, ja M. Verduzco-Gutierrez, ”Traumatic Brain Injury: An Overview of Epidemiology, Pathophysiology, and Medical Management”, *Med. Clin. North Am.*, vol. 104, s. 213–238, 2020, doi: 10.1016/j.mcna.2019.11.001.

[5] R. Singh, W. Wu, G. Wang, ja M. K. Kalra, ”Artificial intelligence in image reconstruction: The change is here”, *Phys. Med.*, vol. 79, s. 113–125, 2020, doi: 10.1016/j.ejmp.2020.11.012.

[6] A. M. Doppenberg ja A. R. Tuttle, ”Imaging of traumatic brain injury”, *Dis. Mon.*, vol. 65, s. 100856, 2019, doi: 10.1016/j.disamonth.2019.02.009.

[7] K. Ahlers, *Brain layers*. 2011. URL: https://commons.wikimedia.org/wiki/File:Brain_layers.jpg

[8] J. T. Bushberg ja J. A. Seibert, *The Essential Physics of Medical Imaging Study Guide*. Philadelphia, Pennsylvania: Wolters Kluwer, 2023.

[9] G. Michael, ”X-ray computed tomography”, *Phys. Educ.*, vol. 36, s. 442–451, 2001, doi: 10.1088/0031-9120/36/6/301.

[10] Z. Zhang ja E. Seeram, ”The use of artificial intelligence in computed tomography image reconstruction - A literature review”, *J. Med. Imaging Radiat. Sci.*, vol. 51, s. 671–677, 2020, doi: 10.1016/j.jmir.2020.09.001.

[11] OpenStax, *A sketch of an X-ray tube*. 2016. URL: https://commons.wikimedia.org/wiki/File:OpenStax_UPhysicsV3_8.21_X-ray_tube_sketch.webp

[12] R. Zhang, T. P. Szczykutowicz, ja G. V. Toia, ”Artificial Intelligence in Computed Tomography Image Reconstruction: A Review of Recent Advances”, *J. Comput. Assist. Tomogr.*, vol. 49, s. 521, 2025, doi: 10.1097/RCT.0000000000001734.

[13] M. M. Dabas *ym.*, ”Comparative Efficacy of MRI and CT in Traumatic Brain Injury: A Systematic Review”, *Cureus*, 2024, doi: 10.7759/cureus.72086.

[14] H. Tuominen, ”Tekoälyn perusteita ja sovelluksia”, Jyväskylän yliopisto. URL: https://urn.fi/URN:ISBN:978-951-39-7796-2

[15] L. Melazzini *ym.*, ”AI for image quality and patient safety in CT and MRI”, *Eur. Radiol. Exp.*, vol. 9, s. 28, 2025, doi: 10.1186/s41747-025-00562-5.

[16] D. F. Bauer, C. Ulrich, T. Russ, A.-K. Golla, L. R. Schad, ja F. G. Zöllner, ”End-to-End Deep Learning CT Image Reconstruction for Metal Artifact Reduction”, *Appl. Sci.*, vol. 12, s. 404, 2021, doi: 10.3390/app12010404.

[17] J. Wu *ym.*, ”Dual-Domain deep prior guided sparse-view CT reconstruction with multi-scale fusion attention”, *Sci. Rep.*, vol. 15, s. 16894, 2025, doi: 10.1038/s41598-025-02133-5.

[18] L. Mabit, M. Lepoittevin, M. Valls, C. Thomas, R. Guillevin, ja G. Herpe, ”Real-Life Performance of a Commercially Available AI Tool for Post-Traumatic Intracranial Hemorrhage Detection on CT Scans: A Supportive Tool”, *J. Clin. Med.*, vol. 14, s. 4403, 2025, doi: 10.3390/jcm14134403.

[19] A. Hibi *ym.*, ”Automated identification and quantification of traumatic brain injury from CT scans: Are we there yet?”, *Medicine (Baltimore)*, vol. 101, s. e31848, 2022, doi: 10.1097/MD.0000000000031848.

[20] Y. A. Fahim, I. W. Hasani, S. Kabba, ja W. M. Ragab, ”Artificial intelligence in healthcare and medicine: clinical applications, therapeutic advances, and future perspectives”, *Eur. J. Med. Res.*, vol. 30, s. 848, 2025, doi: 10.1186/s40001-025-03196-w.

[21] M. P. Roshan *ym.*, ”Revolutionizing Intracranial Hemorrhage Diagnosis: A Retrospective Analytical Study of Viz.ai ICH for Enhanced Diagnostic Accuracy”, *Cureus*, 2024, doi: 10.7759/cureus.66449.

[22] F. Rajaei, S. Cheng, C. A. Williamson, E. Wittrup, ja K. Najarian, ”AI-Based Decision Support System for Traumatic Brain Injury: A Survey”, *Diagnostics*, vol. 13, s. 1640, 2023, doi: 10.3390/diagnostics13091640.