

Milla Suomela

TEKOÄLY PRE- JA INTRAOPERATIIVISESSA ANESTESIOLOGIASSA

Syventävien opintojen kirjallinen työ

Kevätlukukausi 2024

Vastuhenkilö: Markku Taittonen

TURUN YLIOPISTO

Lääketieteellinen tiedekunta

SUOMELA, MILLA: Tekoäly pre- ja intraoperatiivisessa anestesiologiassa

Syventävien opintojen kirjallinen työ, 25 s.

Anestesiologia ja tehohoito

Maaliskuu 2024

Nykypäivän lääketiede nojaa vahvasti tutkimusnäyttöön, mutta tekoäly tarjoaa mahdollisuuden mullistaa terveydenhuollon käytäntöjä myös anestesiologian alalla. Tekoäly perustuu monimutkaisiin matemaattisiin algoritmeihin, joiden ymmärtäminen voi olla haastavaa.

Tämä kirjallisuuskatsaus pyrkii tiivistämään tutkimustuloksia tekoälyn käytöstä pre- ja intraoperatiivisessa anestesiologiassa. Tutkimuksissa on kehitetty useita koneoppimismalleja, jotka ennustavat perioperatiivisia riskejä, kuten leikkauksen jälkeistä sairastavuutta ja verensiirron tarvetta. Intraoperatiivisessa vaiheessa tekoälyllä on merkittävä potentiaali potilaan tilan seurannassa ja hoitopäätösten tukemisessa. Intraoperatiivinen automatisoitu anestesia on pitkän aikavälin tavoite, ja ensimmäiset tehdyt tutkimukset ovat tarjonneet lupaavia tuloksia.

Tekoälyn käyttö pre- ja intraoperatiivisessa anestesiologiassa tarjoaa mahdollisuuksia potilaiden hoidon parantamiseen. Kuitenkin on tärkeää tunnistaa ja ratkaista tekoälyyn liittyvät haasteet varmistaaksemme sen turvallisen ja tehokkaan integroinnin anestesiologian käytäntöihin.

SISÄLLYS

1. JOHDANTO
 2. TEKOÄLYN OSA-ALUEET
 - 2.1. Tekoäly
 - 2.2. Big data
 - 2.3. Koneoppiminen
 - 2.4. Neuroverkot ja syväoppiminen
 3. TEKOÄLYN ONGELMAT
 - 3.1. Luotettavuus
 - 3.2. Eettisyys
 - 3.3. Tietosuoja
 4. TEKOÄLYN POTENTIAALI ANESTESIOLOGIASSA
 - 4.1. Preoperatiivinen anestesiologia
 - 4.1.1. Preoperatiivinen arviointi
 - 4.1.2. Ilmatien arviointi
 - 4.1.3. Verensiirron ennakointi
 - 4.2. Intraoperatiivinen anestesiologia
 - 4.2.1. Hypotension ennustaminen
 - 4.2.2. Nestetasapainon ja verenpaineen hallinta
 - 4.2.3. Anestesian syvyyden monitorointi
 - 4.3. Automatisoitu anestesia
 5. POHDINTA
- LÄHTEET

1.1 JOHDANTO

Nykypäivän lääketiede perustuu suurelta osin tutkimusnäyttöön (engl. Evidence-based medicine). Kliinisiä yhteyksiä ja oivalluksia saadaan vertailemalla eri tutkimustuloksia ja luomalla malleja olemassa olevista tietokannoista. (3)

Tekoälyllä on potentiaalia muuttaa nykypäivän käytäntöjä ja avata uusia mahdollisuuksia teknologian kehitykselle. Sen soveltamismahdollisuudet lääketieteen ja terveydenhuollon alalla ovat lähes rajattomat. Tekoälyn käyttö lisääntyy jatkuvasti, mutta sen käyttöön liittyy haasteita, joita ei vielä täysin tunneta. Vaikka tekoäly on jo osa terveydenhuoltoa, sen käyttö on toistaiseksi melko rajoitettua. Sitä on hyödynnetty muun muassa verkkoajanvarausten tekemisessä, terveystietojen digitalisoinnissa, muistutusviestien lähettämisessä ja lääkeinteraktioiden havaitsemisessa lääkkeitä määrätessä (3). Radiologia on lääketieteen erikoisala, jossa tekoälyä on hyödynnetty muita erikoisaloja enemmän. Yhdysvalloissa on yhteensä 521 FDA:n (Food and Drug Administration) hyväksymää lääketieteellistä laitetta, jotka hyödyntävät tekoälyä ja koneoppimista. Näistä laitteista peräti 392 löytyy radiologialta. (7) Esimerkiksi CAD-ohjelmiston (computer-aided detection) käyttö mammografian esitulkinnessa on yleistynyt maailmalla. CAD-ohjelma kykenee tunnistamaan ja merkitsemään epäilyttävät rakenteet ja mikrokalkit mammografiakuivissa ja näin auttaa sekä nopeuttaa radiologin tekemää työtä. (3)

Aivot ovat erinomaiset arvioimaan esineiden liikettä ja vuorovaikutusta fyysisessä maailmassa, päättämään syy-seuraussuhteita rajoitetusta määrästä esimerkkejä ja ennakoimaan näiden esimerkkien avulla toimintasuunnitelmia uusien tilanteiden varalle. Tätä pohdintakykyä tukee muisti, joka alitajuisesti vertaa tapahtumia sekä olennaisiin että epäolennaisiin kokemuksiin. Aivot pystyvät myös säilyttämään nämä muistot jopa merkittävän fyysisen vaurion

yhteydessä. Muistin assosiatiivinen luonne tarkoittaa sitä, että menneistä kokemuksista ne osa-alueet, jotka ovat oleellisia nykyhetken tilanteelle, voidaan hyvinkin nopeasti palauttaa tietoiseen ajatteluun. Aivoilla on kuitenkin heikkouksia, jotka asettuvat näitä kykyjä vastaan: uupumus ja kognitiivinen laiskuus, joka ilmenee taipumuksena lyhentää henkistä työtä, sekä yksityiskohtainen lyhyen aikavälin työmuisti, joka on laajuudeltaan hyvin rajallinen. Aivot ovat hitaat ja virhealttiit suorittamaan jopa yksinkertaisimpiakin laskutoimituksia tai loogista päättelyä juuri näiden ominaisuuksien takia. (1) Tekoäly ei väsy, laiskottele tai ole ulkopuolisille ärsykkeille yhtä virhealtis kuin mitä aivot ovat.

Tämän systemaattisen kirjallisuuskatsauksen tavoitteena on koota yhteen tutkimustuloksia tekoälyn hyödyntämisestä pre- ja intraoperatiivisessa anestesiologiassa. Lisäksi tarkoituksena on pohtia tekoälyyn liittyviä haasteita ja arvioida, kuinka todennäköisesti ja nopeasti tekoälyn integrointi käytännön anestesiologiaan on mahdollista. Tässä työssä olen käyttänyt tekoälyä apuna käännoistyössä.

2. TEKOÄLYN OSA-ALUEET

Tämän päivän digitalisoituneessa maailmassa termit kuten tekoäly, big data ja koneoppiminen ovat tulleet osaksi arkipäiväämme. Ne edustavat teknologian kehityksen huippua ja vaikuttavat jo nyt monilla elämäntiloilla. Tekoäly, big data ja koneoppiminen ovat yhteydessä toisiinsa, mutta ne kuvaavat tekoälyn erilaisia toimintoja. Jotta niiden toimintaa voidaan arvioida paremmin ja luotettavammin, on tärkeää ymmärtää niiden perusideat.

2.1. Tekoäly

Tekoäly tai keinoäly (engl. Artificial Intelligence, AI) viittaa ohjelmistoihin tai koneisiin, jotka pystyvät suorittamaan älykkäitä tehtäviä, kuten päätöksentekoa, ongelmanratkaisua, oppimista ja kriittistä ajattelua. Tekoäly terminä viittaa tietokoneen kykyyn suorittaa toimintoja tavalla, joka muistuttaa ihmisen ajatteluprosessia. (3) Tekoäly hyödyntää matemaattisia algoritmeja ja tietokonemalleja, jotka käsittelevät suuria datamääriä mahdollistaen koneiden oppimisen ja sopeutumisen ympäristöönsä. Syväoppiminen on yksi tekoälyn perustekniikoista, jossa järjestelmä oppii tunnistamaan kaavoja ja malleja suuren datamäärän perusteella. Koneet käyttävät tätä oppimista päätösten tekemisessä, tulevien tapahtumien ennustamisessa ja tehtävien suorittamisessa, jotka aikaisemmin vaativat ihmisen osallistumista. (5)

Tekoäly jaetaan usein kahteen pääluokkaan: vahvaan ja heikkoon tekoälyyn. Vahva tekoäly kykenee monimutkaisiin ongelmanratkaisutehtäviin, jäljitellen ihmisen älykkyyttä ja sopeutuen eri tilanteisiin. Heikko tekoäly suoriutuu rajatuista ja spesifeistä tehtävistä, kuten käännöstyöstä tai kuvantunnistuksesta, mutta se ei pysty yleiseen ongelmanratkaisuun. (5, 26)

Tekoälyllä on merkittävä rooli nykypäivän lääketieteessä. Se auttaa diagnostiikassa esimerkiksi analysoimalla röntgenkuvia ja tukee lääkäreitä diagnoosien tekemisessä. Kliininen päätöksenteko, lääkekehitys ja robottikirurgia ovat kaikki hyötynneet tekoälyn kyvystä käsitellä suuria määriä tietoa nopeasti ja tarkasti.

2.2. Koneoppiminen

Koneoppiminen (engl. Machine learning, ML) on keskeinen tekoälyn sovellus, joka mahdollistaa koneiden oppimisen ja päätöksenteon datan ja kokemusten perusteella ilman erillistä ohjelmointia jokaiseen tehtävään. Se hyödyntää matemaattisia algoritmeja ja tietokonemalleja, jotka analysoivat suuria datamääriä, tunnistavat kaavoja ja oppivat ennustamaan tulevia tapahtumia. Koneoppiminen voidaan jakaa kolmeen pääluokkaan: valvottuun oppimiseen, valvomattomaan oppimiseen ja vahvistusoppimiseen (2). Valvotussa oppimisessa algoritmia opetetaan antamalla sille koulutusdataa, joka sisältää esimerkkejä ja niihin liittyviä oikeita vastauksia. Näin koneoppimismalli oppii ennustamaan vastauksia saamiensa esimerkkien avulla. Valvomaton oppiminen keskittyy tietorakenteiden löytämiseen ilman ennalta määrättyjä vastauksia. Järjestelmälle esitetään dataa, jonka avulla se pyrkii tunnistamaan kaavoja ja ryhmittymiä datassa itsenäisesti. Vahvistusoppimisessa malli oppii vuorovaikutuksessa ympäristön kanssa ja pyrkii optimoimaan toimintaansa saamallaan palkkioilla ja rangaistuksilla. Tavoitteena on oppia tekemään päätöksiä, jotka johtavat parhaisiin mahdollisiin tuloksiin. (18, 26)

2.3. Big Data

Big data viittaa massiivisiin ja monipuolisiin tietomääriin, joita perinteiset tietokannat eivät kykene tehokkaasti käsittelemään. Tieto syntyy eri lähteistä, kuten sosiaalisesta mediasta, antureista, liikenteestä ja muista digitaalisista interaktioista. Big datassa korostuvat kolme keskeistä ominaisuutta: määrä, monimuotoisuus ja nopeus. Big datasta saatava arvo piilee sen analysoinnissa, joka voi paljastaa piileviä yhteyksiä, trendejä ja malleja. Tämä analyysi voi tukea päätöksentekoa monilla aloilla, kuten terveydenhuollossa, markkinoinnissa ja

kaupankäynnissä. Lääketieteessä big data mahdollistaa suurien tietomäärien analysoinnin potilaiden geneettisistä tiedoista, kliinisistä raporteista ja laboratoriotuloksista. Tämä auttaa tunnistamaan sairauksien riskejä, ymmärtämään niiden mekanismeja ja kehittämään parempia hoitomuotoja ja lääkkeitä. (19, 26)

2.4. Neuroverkot ja syväoppiminen

Syväoppiminen (engl. Deep learning, DL) on pitkälle kehittynyt koneoppimisen muoto, joka pyrkii jäljittelemään ihmisen aivojen toimintaa tietojen käsittelyssä ja oppimisessa. Se perustuu neuroverkkojen käyttöön, jotka ovat monimutkaisia matemaattisia malleja ja koostuvat useista eri kerroksista. Näitä kerroksia kutsutaan piilo- tai syväkerroksiksi, mistä syväoppiminen saa nimensä. Syväoppiminen toimii syöttämällä suuren määrän dataa neuroverkolle ja mahdollistaa sen kouluttamisen tunnistamaan tiettyjä ominaisuuksia tai piirteitä datassa. Neuroverkkoja muokataan ja säädellään toistuvasti, kunnes ne tuottavat halutunlaisia tuloksia. Kun neuroverkko on koulutettu riittävän hyvin, se pystyy tunnistamaan, luokittelemaan tai ennustamaan uutta, aiemmin näkemätöntä dataa samankaltaisten piirteiden perusteella, joihin se on koulutettu. Tämä mahdollistaa monenlaisten tehtävien automatisoinnin ja älykkäiden järjestelmien luomisen. (6, 26)

3. TEKOÄLYN ONGELMAT

Tekoälyn käytössä nousee esiin paitsi sen potentiaali, mutta runsaasti huolenaiheita ja ongelmia, jotka eivät vielä ole täysin tunnettuja. Erityisesti terveydenhuoltoalalla tekoälyyn liittyy ilmeisiä uhkakuvia, kuten datan vinouma-

alttiutta, datan käsittelyn turvallisuus- ja yksityisyysnäkökulmia sekä yleisesti ottaen tekoälyn toiminnan puutteellista ymmärrystä.

3.1 Luotettavuus

Yksi tekoälyn ongelmista on sen luotettavuus. Tekoälyn käyttämät algoritmit ovat alttiita datan vinoumille, mikä vaikuttaa merkittävästi koneoppimisen koulutusdatan tarkkuuteen ja luotettavuuteen. Jos data ja ennustettu lopputulos heijastavat tietoista tai tiedostamatonta vinoumaa, se tarkoittaa, että malli tuottaa päätöksiä, jotka ovat vääristyneitä tai puolueellisia tiettyjen tekijöiden perusteella. (5) Esimerkiksi, jos kliiniset tutkimukset eivät kattavasti huomioi tiettyä potilasryhmää, tekoälyn malli voi olla vähemmän tarkka tai luotettava kyseisen potilasryhmän osalta. Lisäksi, jos hoitotilanteissa esiintyy ennakkoluuloja tai muita vääristymiä, nämä voivat vaikuttaa tekoälyn ennusteisiin ja siten myös lääketieteelliseen päätöksentekoon. Tämä korostaa tarvetta varmistaa, että koulutukseen käytetty data ja tekoälyn mallit ovat monipuolisia ja tasapuolisia, jotta päätökset olisivat oikeudenmukaisempia ja luotettavampia kaikille potilaille.

Koneoppiminen käyttää algoritmeja luodakseen toimintamalleja koulutusdatan avulla, joita se hyödyntää uuden tiedon käsittelyssä ja tuottamisessa. Tämä voi johtaa tilanteeseen, jossa tekoälyn kehittäjät eivät välttämättä ymmärrä, miten tekoäly on yhdistellyt dataa tuottaakseen pyydetyt vastaukset tai ennustukset. Tekoälyn tuottamat mallit voivat olla niin monimutkaisia ja inhimillisestä ajattelu- ja päättelyketjusta poikkeavia, että sen ajatteluprosessin ymmärtäminen ihmiselle on hyvin vaikeaa. Tätä tekoälyn tuottamaa prosessia, jota ihminen ei ymmärrä, kutsutaan usein "mustaksi laatikoksi". (4) Tekoälyjärjestelmä saattaa ilmoittaa klinikolle tekemästään ennustuksesta, mutta se ei välttämättä pysty

tarjoamaan lisätietoa siitä, miksi ja miten kyseinen ennustus tehtiin. Tällaisessa tilanteessa klinikolla voi olla vaikeuksia arvioida tilannetta ja päättää, miten siihen tulisi reagoida.

3.2 Eettisyys

Tekoälyn käytössä nousee esiin myös eettisiä kysymyksiä. Erityisesti vastuu virheistä on yksi suurimmista tekoälyyn liittyvistä eettisistä haasteista.

Nykykäsityksen mukaan vastuu potilaasta ja hänen hoidostaan on aina hoitavalla lääkäriellä. Mutta jos diagnoosiin ja hoitosuunnitelmaan päästään tekoälyn avulla, kuka lopulta kantaa vastuun virheistä? (4)

Eettiset kysymykset nousevat esiin myös tekoälyn kouluttamisessa, sillä tavoitteena on opettaa koneita tekemään päätöksiä ja ennustuksia ottaen huomioon myös eettiset näkökulmat. Miten kone voidaan opettaa ymmärtämään eettisyyttä samalla tavoin kuin ihmiset sen käsittävät? Esimerkiksi kuuluisa "trolley problem"-ajatuskoe asettaa henkilön tilanteeseen, jossa on valittava kahden huonon vaihtoehdon välillä. Siinä juna on menossa kohti viittä ihmistä, ja sinulla on mahdollisuus vaihtaa junan reittiä pelastaaksesi nämä viisi ihmistä, mutta samalla uhraat yhden ihmisen hengen. Ihmisille tämä on hankala eettinen dilemma, mutta miten tekoäly vastaisi tähän kysymykseen? (4) Kun tekoälyä käytetään potilaiden diagnoosien tekemisessä tai hoitosuunnitelman laatimisessa, miten varmistetaan, että päätökset ovat potilaan edun mukaisia ja eettisiä?

3.3 Tietosuojaja

Tietosuojaja määritellään Tietosuojavaltuutetun toimiston sivuilla seuraavasti: "Tietosuojaja on perusoikeus, joka turvaa rekisteröidyn oikeuksien ja vapauksien toteutumisen henkilötietojen käsittelyssä. Tietosuojajan tarkoituksena on osoittaa, milloin ja millä edellytyksillä henkilötietoja voidaan käsitellä". Erityisesti lääketieteessä tietosuojaja on termi, joka on jokaiselle terveydenhuollon ammattilaiselle tuttu ja josta puhutaan paljon jo opintojen aikana. Potilastiedot ovat salassa pidettävää tietoa, eikä niistä sovi keskustella ulkopuolisten kanssa saati julkisella paikalla. Kaikki terveydenhuollon käyttämät järjestelmät ovat tarkoin suojattuja, potilaiden terveystietoja sisältävät paperit hävitetään erikseen tietosuojajätteen mukana, ja kaikki työntekijät allekirjoittavat työsuhteen alussa tietosuojaja käsittelevän sopimuksen.

Teknälyn integrointi näihin suojattuihin järjestelmiin tuo mukanaan omat haasteensa. Diagnoosien ja ennusteiden tekemisessä tekoäly saattaa tarvita laajaa tietoa potilaasta ja tämän terveydentilasta. Tämä herättää kysymyksiä ja huolia siitä, miten potilaan yksityisyys voidaan taata ja kuinka estää arkaluonteisten tietojen väärinkäyttö. Lääketieteessä tekoälyn toiminta perustuu suurelta osin suurten tietomäärien analysointiin. Siksi on tärkeää varmistaa, että nämä tiedot säilytetään ja suojataan asianmukaisesti ulkoisilta uhilta, kuten tietomurroilta ja -vuodoilta. Lääketieteessä tekoälyn käytölle ei vielä välttämättä ole vakiintuneita standardeja tai asianmukaisia sääntelyjärjestelmiä.

Puutteelliset ohjeistukset ja standardit voivat johtaa epäyhtenäisiin käytäntöihin, mikä puolestaan heikentää tietosuojajan varmistamista.

4. TEKOÄLYN POTENTIAALI TULEVAISUUDEN ANESTESIOLOGIASSA

Anestesiologia on lääketieteen erikoisala, joka on kehittynyt merkittävästi viimeisten vuosikymmenien aikana muuttaen kirurgisia ja muita lääketieteellisiä toimenpiteitä turvallisemmiksi ja auttanut näiden kehityksessä. Anestesia toimii merkityksellisessä roolissa sekä potilaan mukavuuden- ja kivunhallinnassa, että mahdollistaa monet lääketieteelliset interventiot. (6) Tekoälyllä on mahdollisuus tuoda uusia lähestymistapoja potilaiden hoitoon, seurantaan ja päätöksentekoon myös anestesiologian alalla. Anestesiologia on erikoisala, jossa teknologiaa on integroitu käytännön työhön monia muita erikoisaloja aikaisemmin. Ylipaineventilaation keksiminen polioepidemian aikaan 1951 on yksi ensimmäisistä anestesiologiaan liittyvistä automatisoiduista keksinnöistä. (8)

Koneoppimismalleihin liittyvissä tutkimuksissa ensin opetetaan malli antamalla sille dataa tutkittavasta aiheesta. Lääketieteellisissä tutkimuksissa tämä data sisältää usein potilastietoja, kuten potilaan preoperatiivisia tietoja. Koulutuksen jälkeen mallin suorituskkyä eli kykyä suoriutua sille annetuista tehtävistä arvioidaan ulkoisen datajoukon avulla. Tätä suorituskvyn arviointia kutsutaan myös validoinniksi. Ulkoinen datajoukko voi sisältää esimerkiksi potilaiden preoperatiivisia tietoja, joita ei ole käytetty mallin koulutuksessa.

Koneoppimismallien suorituskkyä arvioidaan usein AUC-arvolla (engl. Area Under the Curve), joka ilmaisee, kuinka hyvin malli pystyy erottamaan kaksi luokkaa toisistaan. AUC-arvo vaihtelee välillä 0-1, missä 0 tarkoittaa täydellistä epäonnistumista ja 1 täydellistä onnistumista. Jos AUC-arvo on lähellä 0,5, se osoittaa, että malli tekee satunnaista arvaamista. (7)

4.1. Preoperatiivinen anestesiologia

Preoperatiivisessa vaiheessa tekoäly voi helpottaa yksilöllistä potilaan riskiarvion tekemistä ja tukea päätöksentekoa optimoimalla anestesian suunnittelua sekä ennustamalla käytettävien lääkeannosten määrää. (6)

4.1.1. Preoperatiivinen arviointi

Preoperatiivisen arvioinnin tavoitteena on tunnistaa potilaan riskitekijät ja optimoida hoito parhaan perioperatiivisen tuloksen saavuttamiseksi. Maailmanlaajuisesti eniten käytetty tapa kuvaamaan leikkaukseen tulevan potilaan sairastavuutta ja riskejä on ASA-luokitus (American Society of Anesthesiologists). (9). ASA-luokituksen yleisyys johtuu todennäköisesti sen yksinkertaisuudesta ja helposta saatavuudesta. Se on alunperin kehitetty tilastointikäyttöön, eikä se perustu mihinkään tiettyyn matemaattiseen malliin tai potilasaineistoon (9). ASA-luokituksen ongelmat liittyvät edellä mainittuihin seikkoihin — koska se ei perustu tiukkoihin standardeihin, pisteytys on täysin arvioijan subjektiivisen harkinnan varassa. Lisäksi ASA-luokituksessa ei tehdä erottelua erilaisten kirurgisten toimenpiteiden välillä, mikä lisää subjektiivista vinoumaa ja siten rajoittaa ASA-luokituksen tarkkuutta. (7)

Koneoppimismallit tarjoavat tarkkoja ennustuksia potilaan perioperatiivisista riskeistä. Algoritmit analysoivat monipuolisesti potilastietoja, kuten taustatietoja, liitännäissairauksia, laboratoriotuloksia ja jopa potilastietojärjestelmään kirjoitettua vapaamuotoista tekstiä. (7) Vuonna 2021 julkaistussa retrospektiivisessä tutkimuksessa kehitettiin tarkkoja neuroverkkoamalleja ennustamaan leikkauksen jälkeistä sairastuvuutta ja kuolleisuutta (10). Neuroverkkomallien kehittämiseen käytettiin American College of Surgeons

(ACS) National Surgical Quality Improvement -tietokantaa, joka kattaa tietoa 15 maasta ja 722 sairaalasta. Tutkimuksessa kehitettiin kolme koneoppimismallia yli 5 miljoonan potilaan tietojen ja hoitotulosten perusteella, ja niiden suorituskyky arvioitiin ulkoisella testijoukolla. Mallit osoittivat vakuuttavaa suoriutumista AUC-arvoilla 0,84-0,88. (7, 10) Tutkimuksen tulokset ovat lupaavia, sillä mallit kehitettiin noudattaen vakiintuneita ohjeita ja ne suoriutuivat paremmin kuin käytössä oleva ACS-SRC-riskilaskuri (The American College of Surgeons Surgical Risk Calculator). Merkittävä rajoitus kehitetyissä koneoppimismalleissa ja niiden käyttöönotossa on yksityiskohtaisten potilastietojen puute, kuten yleissairaudet, elämäntavat ja farmakologiset tiedot. (7, 10)

Vuonna 2022 julkaistussa tutkimuksessa kehitettiin XGB-malli (Extreme Gradient Boosting Model) ennustamaan 30 päivän postoperatiivista kuolleisuutta. Mallin kehittämiseen käytettiin 276 341 potilaan preoperatiivisia tietoja ja sen suorituskykyä arvioitiin ulkoisella datajoukolla, joka koostui 63 384 potilaasta. XGB-malli pystyi tarkasti ennustamaan 30 päivän kuolleisuusriskin 0,96 AUC-tarkkuudella. Menetelmän lisähyötynä oli selitettävien koneoppimismenetelmien käyttö, jotka kykenivät osoittamaan potilaasta ne riskitiedot, joiden perusteella ennustus tehtiin. (7, 11)

Perioperatiivista arviointia on mahdollista tehostaa (7). Vuonna 2022 julkaistussa tutkimuksessa hyödynnettiin luonnollisen kielen käsittelyä (engl. Natural language processing, NLP), jonka avulla koneet voivat prosessoida ja ymmärtää ihmisen luomaa tekstiä, mahdollistaen relevanttien tietojen tehokkaan erottamisen potilashistoriasta. Tutkimuksessa analysoitiin dataa 93 potilaasta ja 9765 potilaskertomusmerkinnästä, ja NLP pystyi nopeasti erottelemaan preoperatiivisesti merkittävät tiedot. Verrattuna kokeneen anestesia lääkäriin havaintoihin, malli ja anestesia lääkäri olivat samaa mieltä 80,2 prosentissa

tapauksista. Malli tunnisti myös lisätietoja, joita anestesialääkärit eivät huomanneet 16,6 % tapauksista. Toisaalta malli ei havainnut 2,2 % niistä tiedoista, jotka anestesialääkärit olivat tunnistaneet. Tämä pilottitutkimus keskittyi vain potilaskertomuksesta löytyviin tietoihin, eikä ottanut huomioon laboratoriotuloksia, vitaaliarvoja tai lääkityksiä. Pilottitutkimuksen perusteella tämä koneoppimismalli voisi säästää anestesialääkärin aikaa keskimäärin jopa 15 minuuttia jokaisen potilaan kohdalla. Tällaisten mallien integrointi preoperatiiviseen leikkausarvioon voisi säästää aikaa, kehittää preoperatiivisen arvioinnin tekemistä ja vähentää inhimillisiä virheitä. (7, 12)

4.1.2. Ilmatien arviointi

Ilmatien arviointi on yksi tärkeimmistä anestesialääkärin preoperatiivisista tehtävistä, sillä yleisin anestesian aiheuttama kuolinsyy on avoimen ilmatien menetys (7). Tämä arviointi perustuu potilaan taustatietoihin, fyysiseen tutkimukseen ja mahdollisiin havaittuihin poikkeavuuksiin (5). Perinteisesti arvio tehdään tarkastelemalla suun ja nielun tilaa, esimerkiksi Mallampati-luokituksen avulla. Kuitenkin nämä menetelmät saattavat epäonnistua tunnistamaan jopa 93% vaikean intubaation tapauksista. (7)

Tekoälyllä on potentiaalia helpottaa anestesialääkärin työtä käyttämällä erilaisia arviointimenetelmiä vaikean ilmatien havaitsemiseen. Jotkut tekoälymallit hyödyntävät objektiivisiä mittauksia, kuten painoindeksiä ja leuan ja kilpiruston etäisyyttä, kun taas toiset hyödyntävät tietokoneohjelmoitua kasvojen analysointia ja valokuvia ilmatien vaikeuden arvioinnissa (5). Vuonna 2021 julkaistussa pilottitutkimuksessa kehitettiin koneoppimismalli, joka tunnisti vaikean ilmatien pelkästä kasvojen etukuvasta tarkemmin kuin perinteinen bedside-arviointi (13). Vaikka kuva-analyysillä on potentiaalia suoriutua tietyistä

fyysisen tutkimuksen osa-alueista paremmin, sen käyttö edellyttäisi potilaiden standardoitujen kasvokuvien hankkimista, joissa voi esiintyä vaihtelua valaistuksen ja potilaiden kasvopiirteiden suhteen. Mahdollisessa jatkotutkimuksessa tulisi harkita fyysisen tutkimuksen ja kuva-analyysin yhdistämistä ja tämän lähestymistavan hyödyllisyyttä tulisi arvioida etukäteen. (7)

Automaattisesti generoitu varoitus vaikeasta ilmatiestä auttaa anestesialääkäreitä valmistautumaan asianmukaisilla välineillä ilmatien turvaamiseen ennen leikkausta. Lisäksi se mahdollistaa ennakoivan keskustelun potilaan kanssa, jotta hänellä olisi realistinen käsitys mahdollisista haasteista ja toimenpiteistä, jotka voidaan toteuttaa ilmatien varmistamiseksi. (5)

4.1.3 Verensiirron ennakointi

Monet koneoppimismallit pystyvät ennakoimaan verensiirron tarvetta preoperatiivisesti (7). Vuonna 2022 julkaistussa tutkimuksessa verrattiin perinteisen arvion ja koneoppimismallin suorituskykyä verensiirron tarpeen ennakkoinnissa (7, 14). Perinteinen menetelmä arvioi verensiirron tarvetta ainoastaan toimenpidekohtaisten tekijöiden perusteella. (7) Tutkimuksessa käytettiin American College of Surgeons (ACS) National Surgical Quality Improvement -tietokantaa neljän koneoppimismallin kouluttamiseen, jotta voitiin kehittää punasolusiirron tarvetta ennakoivia malleja. Nämä mallit hyödynsivät sekä leikkaus- että potilaskohtaisia muuttujia. Koneoppimismallit osoittautuivat merkittävästi tehokkaimmiksi kuin perinteinen arviointimenetelmä, saavuttaen 96%:n sensitiivisyyden yhdistämällä potilaskohtaiset riskitekijät ennustusprosessiin. (14) Tärkeimmät muuttujat

mallin ennustamisessa olivat toimenpidekohtainen siirtotarve, preoperatiivinen hematokriitti, potilaan ikä ja hyytymishäiriöiden laboratorioindikaattorit (7).

Verensiirtoon tarvittavan veren määrän ennustaminen on haastavampaa kuin pelkän verensiirron tarpeen ennustaminen (7). Eräässä pilottitutkimuksessa kehitettiin algoritmi, joka ennusti punasolusiirron tarvetta sydän- ja rintaelinkirurgiassa jakamalla ennustukset 0, 1-3 ja yli 4 yksikköön punasoluja (15). Malli perustui retrospektiivisiin preoperatiivisiin tietoihin 2847 potilaasta ja saavutti korkean ennustetarkkuuden 0.82 AUC-arvolla. (7, 15) Kaikki potilastiedot kerättiin University of Utah Health's Enterprise Data Warehouse -tietovarastosta (EDW) (15). Tutkimuksen tulosten luotettavuutta rajoittaa yhden instituution lähdetietojen käyttö. Jos instituution käytännöissä tapahtuu muutoksia, esimerkiksi siirryttäessä konservatiivisempaan verensiirtojen lähestymistapaan, mallit eivät välttämättä ole enää ajantasaisia ja vaativat uudelleensuunnittelua. (7)

4.2. Intraoperatiivinen anestesiologia

Intraoperatiivisesti eli leikkauksen aikana, tekoäly voi automatisoida monia tehtäviä, kuten lääkkeiden annostelua. Tekoäly pystyy ennustamaan tulevia tapahtumia, kuten hypotension esiintymistä, perustuen mitattavien suureiden, kuten verenpaineen, pulssin, anestesian syvyyden ja relaksaation arviointiin. Tällä tavoin se voi helpottaa anestesia lääkäriä työtä intraoperatiivisessa vaiheessa. Anestesian automatisointi on lopullinen päämäärä, joka tähtää täyteen automaatioon anestesian hallinnassa. Tämä tarkoittaa, että anestesian syvyyttä, lääkkeiden annostelua ja potilaan tilan seuranta hallitaan itsenäisesti ilman jatkuvaa ihmisen valvontaa. (7, 8)

4.2.1. Hypotension ennustaminen

Intraoperatiivisen hypotension määritelmäksi asetetaan usein keskiverenpaine (Mean Arterial Pressure, MAP) alle 60-70 mmHg. Hypotensio liitetään useisiin haitallisiin hoitotuloksiin, kuten akuuttiin munuaisvaurioon, sydänlihaskaurioon ja suurentuneeseen 30 päivän postoperatiiviseen kuolleisuuteen. Useita koneoppimismalleja on kehitetty ennustamaan intraoperatiivisen hypotension esiintymistä. Ne hyödyntävät säännöllisesti kerättyä biosignaalidataa, kuten verenpainetta tai elektrokardiogrammia (EKG), ennustaakseen hypotension esiintymistä seuraavien 5-15 minuutin aikana. Ensimmäinen kehitetty malli, Hypotension Prediction Index (HPI), käyttää valtimopulssiaallon piirteiden muutoksia ja on integroitu kaupallisesti saatavilla oleviin laitteisiin. Useat tutkimukset ovat osoittaneet hypotensiivisen tapahtuman ennustetarkkuuden 5-15 minuuttia ennen sen esiintymistä jopa sellaisilla potilailla, jotka eroavat niistä, joille malli alun perin kehitettiin. (7)

Vuonna 2021 julkaistussa tutkimuksessa Lee ja hänen kollegansa osoittivat tällaisten työkalujen toimivuuden. Retrospektiivisessä havainnointitutkimuksessa, joka käsitti yhteensä 3301 potilasta, syväoppimisen algoritmi kehitettiin ennustamaan intraoperatiivisia hypotensiivisiä tapahtumia, joiden rajaksi määriteltiin alle 65 mmHg MAP (7, 16). Syväoppimisen algoritmit kehitettiin ja validoitiin käyttäen potilaiden monitoreista kerättyä biosignaalidataa ei-sydänkirurgisissa toimenpiteissä. Invasiivisissa malleissa monikanavainen lähestymistapa, joka otti huomioon valtimopaineen aaltomuodon, EKG:n, happisaturaation ja kapnografian, osoitti suoriutuvan paremmin kuin pelkät valtimopainemallit (16). Viiden minuutin ennustehorisontilla parhaiten suoriutuva algoritmi saavutti AUC-arvon 0,93 ja 85% sensitiivisyyden hypotensiivisen tapahtuman ennustamisessa. Koska nämä mallit perustuivat yhden sairaalan eri leikkauspotilaiden tietoihin, tulokset

saattavat olla vinoutuneita, eikä niiden yleistettävyyttä ole vahvistettu ulkoisesti. Lisäksi niitä kliinisen tilanteen yksityiskohtia, joissa hypotensiiviset tapahtumat esiintyivät, ei ollut saatavilla, joka saattaa rajoittaa tämän työkalun soveltamista.

(7)

Intraoperatiivisen hypotension syiden tunnistaminen voi olla kliinisessä työssä haastavaa, etenkin kun useat mekanismit voivat vaikuttaa potilaan tilaan.

Toisessa analyysissä hyödynnettiin 82 potilaan prospektiivisesti kerättyjä hemodynaamisia tietoja, jotka koskivat suurten vatsakirurgisten toimenpiteiden läpikäyneitä potilaita. Tutkimuksessa analysoitiin yhteensä 615 hypotensiivista jaksoa, joista tunnistettiin kuusi erilaista hypotension mekanismia: sydänlihaksen toimintahäiriö, bradykardia, vasodilataatio sydämen minuuttitulavuuden indeksin nousun kanssa ja ilman, hypovolemia ja sekamuodot. Nämä tulokset osoittavat koneoppimismallien potentiaalinen avustaa intraoperatiivisen hypotension syiden tunnistamisessa ja hoidossa. (7)

4.2.2. Nestetasapainon ja verenpaineen hallinta

Leikkauksen aikana verenpaineen hallinnassa pyritään siihen, että verenpaine ei laske yli 10% potilaan preoperatiivisista verenpaine-arvoista. Yksilöllisen verenpaineen hallinnan on osoitettu parantavan hoitotuloksia ja vähentävän postoperatiivisia elinten toimintahäiriötä. (7)

Suljetun silmukan järjestelmän (engl. Closed-loop system) ja kohdennetun infuusion käyttö optimaalisen verenpaineen ylläpitämiseksi on osoitettu tutkimuksissa jo 1950-luvulta lähtien. Joosten ja kollegat osoittivat suljetun silmukan järjestelmään perustuvan noradrenaliini-infuusion ylivoimaisuuden verrattuna manuaaliseen noradrenaliini-infuusion annosteluun hypotension ehkäisemiseksi (7, 17). Tutkimukseen osallistui 38 potilasta, joista osa oli vatsa- ja

osa ortopedisistä leikkauksista. Jokaiselle potilaalle asetettiin radialisvaltimon verenpaineanturi, josta mitattiin potilaiden keskimääräistä valtimopainetta (MAP) leikkauksen aikana. Hypotensioksi määriteltiin MAP < 90% potilaan preoperatiivisesta perustasosta (7). Puolelle potilaista annosteltiin manuaalisesti noradrenaliinia ylläpitämään MAP 10% sisällä potilaan perustasosta. Toiselle ryhmälle annosteltiin noradrenaliinia suljetun silmukan järjestelmän periaatteiden mukaisesti. (17) Tutkimusryhmässä hypotensioita esiintyi 10 kertaa vähemmän verrattuna kontrolliryhmään. (7).

Intraoperatiivisessa verenpaineen hallinnassa on olennaista huolehtia potilaan nestetasapainosta, jotta voidaan ylläpitää optimaalista sydämen minuuttitulavuutta. Kamalin ja kollegoiden tekemässä prospektiivisessä kliinisessä tutkimuksessa osoitettiin, että automatisoidut nestebolukset johtivat useammin haluttuun sydämen minuuttitulavuuden kasvuun kontrolliryhmään verrattuna (20). Tutkimukseen osallistui 330 aikuispotilasta, jotka oli aikataulutettu keski- tai korkean riskin ei-sydänkirurgisiin toimenpiteisiin, joissa vaadittiin valtimopaineen mittaamista ja mekaanista ventilaatiota.

Tutkimuksessa avoimen silmukan järjestelmä analysoi potilaan hemodynaamisia muuttujia ja antoi suosituksia nesteboluksista, mutta lopullinen päätös nesteytyksen antamisesta oli anestesia lääkäriillä. Automatisoidun ohjelmiston ryhmän potilaat saivat 89% suositelluista nesteboluksista ja näistä 66% johti haluttuun sydämen minuuttitulavuuden lisääntymiseen. Kontrolliryhmässä, jossa klinikko itse arvioi nestebolusten tarpeen, vastaava osuus oli vain 41%, $p < 0.001$. (20) Tutkimuksessa nestebolukset annettiin klinikon toimesta, mutta tulosten perusteella voitaisiin olettaa, että tekoälyn integroiminen potilaan intraoperatiivisen nestetasapainon säätelyyn tuottaisi hyviä tuloksia ja näin helpottaisi klinikon työtä.

4.2.3. Anestesian syvyyden monitorointi

Yleisanestesian aikana potilas nukutetaan aivoihin vaikuttavilla lääkeaineilla. Anestesian syvyyden seuranta on kehittynyt merkittävästi viime vuosikymmenten aikana, mutta tahaton hereilläolo leikkauksen aikana on edelleen merkittävä kliininen ongelma. Tahatonta hereilläoloa esiintyy yleisanestesian aikana noin yhdellä tuhannesta leikkauspotilaasta. (22)

BIS-monitorointi (engl. Bispectral Index) on laajalti käytetty menetelmä anestesian syvyyden mittaamiseen, ja se perustuu aivojen sähköisen aktiivisuuden analysointiin. Se käyttää muokattua elektroenkefalogrammia (EEG), joka tuottaa numeerisen arvon välillä 0 ja 100 kuvaamaan potilaan tajunnan syvyyttä. Mitä pienempi BIS-arvo on, sitä syvempi on anestesian taso. Potilas on hereillä, kun BIS-luku on 90-100 ja kirurgiaan tarvittava anestesian syvyys on 40-60. (7) BIS-monitoroinnin ongelmana on, että sen käyttämät algoritmit ovat patentoituja, mikä rajoittaa muiden valmistajien mahdollisuuksia hyödyntää, tutkia ja kehittää tätä teknologiaa. Todellisuudessa emme siis täysin tiedä, mitä mittaamme. Jos ymmärtäisimme paremmin BIS-monitoroinnin periaatteita, pystyisimme arvioimaan pisteytyksen poikkeamien vaikutusta kliiniseen ennustukseen ja edistymään tutkimuksissa, jotka keskittyvät suljetun silmukan järjestelmän ohjaamiseen. (21)

Connor ja hänen kollegansa onnistuivat selvittämään BIS-monitoroinnin algoritmien toimintatavan ja niiden fysiologisen merkityksen. Tässä jälkianalysissä käytettiin BIS-monitorin keräämää EEG-dataa 12 leikkauspotilaalta. Tiedot käsittivät yhteensä 36 tuntia ja 16 minuuttia EEG-dataa, joka kattoi esivalmistelun, intraoperatiivisen ja heräämisen vaiheet. Data käsiteltiin kolmivaiheisessa uudelleentoteutuksessa ja kirjoitettiin uudelleen, jonka seurauksena syntyi *avoin-BIS* (engl. *Openibis*). BIS-algoritmien luotettava

uudelleentoteutus paljasti vahvan yhteyden EEG-signaalin sisältöön matala-gamma-alueella. Yllättäen mitään laskelmia, jotka perustuisivat bispektriin tai mihinkään bispektriseen indeksiin, ei havaittu. Toisin sanoen, BIS-arvo ei näytä olevan millään tavoin riippuvainen bispektrisestä indeksistä, vaikka sen nimi antaisi ymmärtää muuta. *Avoin-BIS*-algoritmi on nimensä mukaisesti avoin ja jokainen sen osa on selitetty perusteellisesti. Tämä lähestymistapa tarjoaa merkittävän edun verrattuna esimerkiksi mustaan laatikkoon perustuvaan neurooverkkomalliin, koska algoritmin toiminta tulee täysin selitetyksi. Tämän ansiosta voidaan rakentavasti pohtia, mitä koodi tarkoittaa ja miten sitä voisi mahdollisesti muokata tai parantaa. *Avoin-BIS*-algoritmi ratkaisee lopulta pitkäaikaiset kysymykset BIS-monitorin toiminnasta ja voi toimia perustavanlaatuisena työkaluna sekä kliinisessä anestesiologian tutkimuksessa että anestesian mekanismien tutkimuksessa. (21)

4.3. Automatisoitu anestesia

Anestesiassa käytettävät automatisoidut järjestelmät voidaan jakaa kahteen kategoriaan: suljetun silmukan ohjausjärjestelmiin ja kliinisiin päätöksenteon tukijärjestelmiin (engl. Clinical Decision Support System, CDSS). Suljetun silmukan ohjausjärjestelmät perustuvat palautteenhallinnan periaatteeseen, jossa laite mittaa jatkuvasti kiinnostuksen kohteena olevaa muuttujaa, vertaa sitä haluttuun tavoitteeseen ja säätelee tulosteita sen mukaisesti. Suljetun silmukan ohjausjärjestelmän etu on, että se pystyy jatkuvasti ylläpitämään haluttua muuttujaa lähellä tavoitearvoa. Nämä algoritmit toimivat perustana farmakologisten järjestelmien kehityksessä, jotka annostelevat anesteetteja ja ylläpitävät hemodynaamiikkaa. (8) Kliiniset päätöksenteon tukijärjestelmät (CDSS) on suunniteltu avustamaan lääkäreitä potilaan hoidon optimoinnissa. Niiden

avulla voidaan parantaa hoidon laatua, potilasturvallisuutta ja standardien mukaista toimintaa. Intraoperatiivinen CDSS voi vaihdella passiivisesta ja jälkikäteen tapahtuvasta toiminnasta aktiiviseen ja reaaliaikaiseen järjestelmään, joka havaitsee kliinisiä ongelmia ja poikkeamia hoitokäytännöistä. Reaaliaikainen CDSS tarjoaa lupaavimman potentiaalin, koska se pystyy tarjoamaan välittömiä hälytyksiä ja ohjeita, jotka voivat ohjata hoitohenkilökunnan toimintaa kohti näyttöön perustuvaa standardisoitua hoitoa tapahtumien aikana. (25) CDSS-järjestelmiä on otettu käyttöön monissa kliinisissä ympäristöissä, kuten muistutusjärjestelmissä, perioperatiivisen lääkeannostelun avustamisessa ja ultraääniohjatuissa toimenpiteissä (8).

Tavoiteohjatun infuusion-järjestelmät (engl. Target Control Infusion, TCI), ovat ensimmäinen askel lääkkeiden automatisoidussa annostelussa. Alun perin TCI-järjestelmät toimivat avoimen silmukan järjestelmän mukaisesti, eivätkä ne hyödyntäneet potilastietoja suorituskykynsä perustana. Uudemmat suljetun silmukan järjestelmät sen sijaan käyttävät potilaalta saatavaa tietoa lääkeaineen annostelun säätelyssä. Ensimmäiset automatisoidut farmakologiset järjestelmät olivat yksinkertaisia, seurasivat yhtä muuttujaa ja annostelivat yhtä lääkeainetta. Nykyiset mallit kykenevät monitoroimaan useita muuttujia ja annostelevaan useampia lääkeaineita. (8)

Nagata ja kollegat suorittivat kaksi tutkimusta, joiden tavoitteena oli kehittää automatisoitu anestesian hallintajärjestelmä, joka käyttää propofolia, ramifentaniilia ja rokuroniumia anestesian ylläpitämiseen. Vuonna 2021 tehdyssä tutkimuksessa ei havaittu merkittäviä eroja automatisoidun ja manuaalisen ryhmän välillä. (23) Vuonna 2023 julkaistussa jatkotutkimuksessa järjestelmää parannettiin lisäämällä siihen turvamekanismeja ja parantamalla lihasrelaksaation valvontaa. Tutkimukseen osallistui yhteensä 119 aikuispotilasta, jotka jaettiin automaatti- ja manuaaliryhmiin. Potilaiden

anestesiaa seurattiin EKG:lla, verenpainemittarilla, pulssioksimetrillä, BIS-monitorilla ja elektromyografialla (TOF, engl. train-of-four). Tulokset osoittivat, että automatisoitu järjestelmä oli yhtä tehokas kuin anestesia-lääkärin kontrolloima anestesia. Vaikka järjestelmä tarjosi lupaavia tuloksia, siinä on kuitenkin rajoituksia. Järjestelmä reagoi äkillisesti lisääntyneisiin invasiivisiin ärsykkeisiin, kuten kirurgin liikkeisiin tai sähköisen veitsen käyttöön.

Tutkimuksessa ei huomioitu puudutusten merkitystä, kuten epiduraalia tai johtopuudutusta, lisäksi lihasrelaksaation automaattinen hallinta oli joillakin potilailla haastavaa alhaisen tarkkuuden vuoksi. (24) Kokonaisuudessaan automatisoitu anestesian hallintajärjestelmä osoittautui lupaavaksi työkaluksi anestesiassa, mutta sen käyttöön liittyy vielä joitakin haasteita, jotka on otettava huomioon kliinisessä työssä.

Yhdistämällä CDSS-järjestelmien ominaisuudet suljettujen silmukkajärjestelmien yksityiskohtaiseen hoidon hallintaan, edistämme merkittävästi autonomisten anestesia-robottien kehitystä. Vaikka täysin autonomisia järjestelmiä ei todennäköisesti nähdä vielä lähitulevaisuudessa, ne muodostavat kiehtovan uuden kehityssuunnan, joka voi mullistaa anestesiakäytäntöjä. (8)

5. POHDINTA

Tekoälyn sovellukset anestesiologiassa ovat herättäneet kiinnostusta niin tutkijoiden kuin kliinistä työtä tekevien lääkäreiden keskuudessa. Tavoitteena on kehittää järjestelmiä, jotka voivat parantaa anestesian hallintaa, potilasturvallisuutta ja leikkausten tuloksia. Tekoäly, erityisesti koneoppiminen, tarjoaa uudenlaisia mahdollisuuksia anestesiologiaan. Sen kyky analysoida suuria tietomääriä nopeasti ja oppia monimutkaisista yhteyksistä tarjoaa tukea päätöksenteossa, riskinarvioinnissa sekä anestesian seurannassa ja ylläpidossa.

Tekoälyn käyttö mahdollistaa tarkan riskinarvioinnin, joka voi tukea päätöksentekoa ennen leikkausta. Tutkimusten perusteella tekoäly on osoittautunut tarkemmaksi ja nopeammaksi potilaan prekliinisessä arvioissa verrattuna perinteiseen anestesia­lääkärin arviointiin (7, 12). Vaikka tekoälyn ja koneoppimisen sovellukset anestesiologiassa ovat vielä alkuvaiheessa, tutkimus alalla jatkaa kasvuaan. Useat tutkimukset keskittyvät tekoälyn hyödyntämiseen anestesian hallinnassa, potilaiden tilan seurannassa ja ennustamisessa sekä lääkkeiden annostelussa. Suljetun silmukan järjestelmät voivat säädellä anestesian syvyyttä ja lääkkeiden annostelua potilaan tilan perusteella, mikä paitsi tehostaa potilaan hoitoa myös vähentää inhimillisiä virheitä (24). Vaikka täysin automatisoitu anestesia on vielä tutkimuksen kohteena, sen ensimmäiset tulokset ovat lupaavia ja viittaavat siihen, että se voisi olla yhtä tehokas kuin perinteinen anestesia, jota valvoo ja säätelee anestesia­lääkäri (24).

Tekoälyllä on paljon potentiaalia parantaa anestesiakäytäntöjä, mutta kohtaamme myös useita haasteita siihen liittyen. Eettiset kysymykset, tietoturvariskit ja luottamuksen rakentaminen sekä ammattilaisten että potilaiden keskuudessa ovat isoja teko­älyyn liittyviä huolenaiheita. Teko­älyn integroituminen käytännön anestesiologiaan ei ole vain tekninen, vaan myös institutionaalinen ja koulutuksellinen kysymys. Teko­älyn käyttämien prosessien ymmärtäminen on haastavaa ja monimutkaista, eikä sen kehittäjilläkään aina ole selkeää käsitystä siitä, miten teko­äly on päätenyt tekemäänsä ennustukseen. On tärkeää, että ammattilaiset saavat asianmukaista koulutusta ja teko­älyn käyttöönotto tapahtuu hallitusti ja huomioiden potilasturvallisuuden.

Teko­älyn tarjoamaa potentiaalia ei voi kiistää, mutta sen täydellinen integroituminen käytännön anestesiologiaan vaatii vielä aikaa ja ponnisteluja. Todennäköisesti teko­älyn käyttöönotto tapahtuu vähitellen, ja ensimmäiset sovellukset voisivat keskittyä preoperatiivisen riskinarvioinnin tukemiseen.

Tekoäly voi helpottaa ja nopeuttaa klinikon tekemää työtä, mutta lopulta vastuu potilaiden hoidosta säilyy lääkäriellä. Intraoperatiivisen tekoälyn sovellusten käyttöönotto vaatii lisää tutkimusta ja varmistettuja tuloksia ennen kuin ne voidaan integroida käytännön työhön. CDSS-järjestelmien käyttöönotto saattaa tapahtua muita sovelluksia aikaisemmin, sillä ne tarjoavat tukea ja ohjeistuksia hoitohenkilökunnalle ilman suoraa vaikutusta potilaan hoitoon. Täysin automatisoidun anestesian toteuttaminen on pitkän aikavälin tavoite, mutta sen toteutumista joudumme odottamaan vielä vuosia.

LÄHTEET

1. Connor CW. Artificial Intelligence and Machine Learning in Anesthesiology. *Anesthesiology*. 2019 Dec;131(6):1346-1359
2. Hashimoto DA, Witkowski E, Gao L, Meireles O, Rosman G. Artificial Intelligence in Anesthesiology: Current Techniques, Clinical Applications, and Limitations. *Anesthesiology*. 2020 Feb;132(2):379-394.
3. Amisha, Malik, P., Pathania, M., & Rathaur, V. K. (2019). Overview of artificial intelligence in medicine. *Journal of Family Medicine and Primary Care*, 8(7), 2328.
4. Siau, Keng, and Weiyu Wang. "Artificial Intelligence (AI) Ethics: Ethics of AI and Ethical AI." *JDM* vol.31, no.2 2020: pp.74-87.
5. Kendale S. The role of artificial intelligence in preoperative medicine. *Int Anesthesiol Clin*. 2022 Jan 1;60(1):69-73.
6. Singam A. Revolutionizing Patient Care: A Comprehensive Review of Artificial Intelligence Applications in Anesthesia. *Cureus*. 2023 Dec 4;15(12):e49887
7. Davoud SC, Kovacheva VP. On the Horizon: Specific Applications of Automation and Artificial Intelligence in Anesthesiology. *Curr Anesthesiol Rep*. 2023 Jun;13(2):31-40.
8. Neymark D. Automation of Anesthesiology - Will Artificial Intelligence Replace Clinicians. *Int J Anesthetic Anesthesiol* 2022, 9:147 Volume 9, Issue 2

9. Kontinen V, Hynynen M. Mitä ASA-luokka kertoo leikkausriskistä? *Finnanest* 2003, 36 (4)
10. Bonde A, Varadarajan KM, Bonde N, Troelsen A, Muratoglu OK, Malchau H, Yang AD, Alam H, Sillesen M. Assessing the utility of deep neural networks in predicting postoperative surgical complications: a retrospective study. *Lancet Digit Health*. 2021 Aug;3(8):e471-e485
11. Choi B, Oh AR, Lee SH, Lee DY, Lee JH, Yang K, Kim HY, Park RW, Park J. Prediction Model for 30-Day Mortality after Non-Cardiac Surgery Using Machine-Learning Techniques Based on Preoperative Evaluation of Electronic Medical Records. *J Clin Med*. 2022 Nov 1;11(21):6487.
12. Suh HS, Tully JL, Meineke MN, Waterman RS, Gabriel RA. Identification of Preanesthetic History Elements by a Natural Language Processing Engine. *Anesth Analg*. 2022 Dec 1;135(6):1162-1171.
13. Tavolara TE, Gurcan MN, Segal S, Niazi MKK. Identification of difficult to intubate patients from frontal face images using an ensemble of deep learning models. *Comput Biol Med*. 2021 Sep;136:104737.
14. Lou SS, Liu H, Lu C, Wildes TS, Hall BL, Kannampallil T. Personalized Surgical Transfusion Risk Prediction Using Machine Learning to Guide Preoperative Type and Screen Orders. *Anesthesiology*. 2022 Jul 1;137(1):55-66.
15. Wang Z, Zhe S, Zimmerman J, Morrissey C, Tonna JE, Sharma V, Metcalf RA. Development and validation of a machine learning method to predict intraoperative red blood cell transfusions in cardiothoracic surgery. *Sci Rep*. 2022 Jan 25;12(1):1355.
16. Lee S, Lee HC, Chu YS, Song SW, Ahn GJ, Lee H, Yang S, Koh SB. Deep learning models for the prediction of intraoperative hypotension. *Br J Anaesth*. 2021 Apr;126(4):808-817.
17. Joosten A, Rinehart J, Van der Linden P, Alexander B, Penna C, De Montblanc J, Cannesson M, Vincent JL, Vicaut E, Duranteau J. Computer-assisted Individualized Hemodynamic Management Reduces Intraoperative Hypotension in Intermediate- and High-risk Surgery: A Randomized Controlled Trial. *Anesthesiology*. 2021 Aug 1;135(2):258-272.
18. Meier JM, Tschoellitsch T. Artificial Intelligence and Machine Learning in Patient Blood Management: A Scoping Review. *Anesth Analg*. 2022 Sep 1;135(3):524-531.

19. Maheshwari K, Ruetzler K, Saugel B. Perioperative intelligence: applications of artificial intelligence in perioperative medicine. *J Clin Monit Comput.* 2020 Aug;34(4):625-628.
20. Maheshwari K, Malhotra G, Bao X, et al. Assisted fluid management software guidance for intraoperative fluid administration. *Anesthesiology.* 2021;135:273-83.
21. Connor CW. Open Reimplementation of the BIS Algorithms for Depth of Anesthesia. *Anesth Analg.* 2022 Oct 1;135(4):855-864.
22. Yli-Hankala A, Scheinin H. Voiko anestesian syvyyttä mitata aivosähkökäyrällä? *Duodecim* 2015; 131(20):1929-36
23. Nagata O, Matsuki Y, Ogino Y, Shigemi K. Safety and efficacy of an automated anesthesia delivery system for total intravenous anesthesia with propofol, remifentanyl, and rocuronium: a non-inferiority randomized controlled trial versus manually controlled anesthesia. *J Anesth.* 2022 Feb;36(1):96-106.
24. Nagata O, Matsuki Y, Matsuda S, Hazama K, Fukunaga S, Nakatsuka H, Yasuma F, Maehara Y, Fujioka S, Tajima K, Kondo I, Ginoza I, Hayashi M, Kakinohana M, Shigemi K. Anesthesia Management via an Automated Control System for Propofol, Remifentanyl, and Rocuronium Compared to Management by Anesthesiologists: An Investigator-Initiated Study. *J Clin Med.* 2023 Oct 19;12(20):6611
25. Nair BG, Gabel E, Hofer I, Schwid HA, Cannesson M. Intraoperative Clinical Decision Support for Anesthesia: A Narrative Review of Available Systems. *Anesth Analg.* 2017 Feb;124(2):603-617.
26. ChatGPT, <https://chat.openai.com>