

Heidi Huhtanen, Mikko Nyman, Antti Karlsson ja Jussi Hirvonen

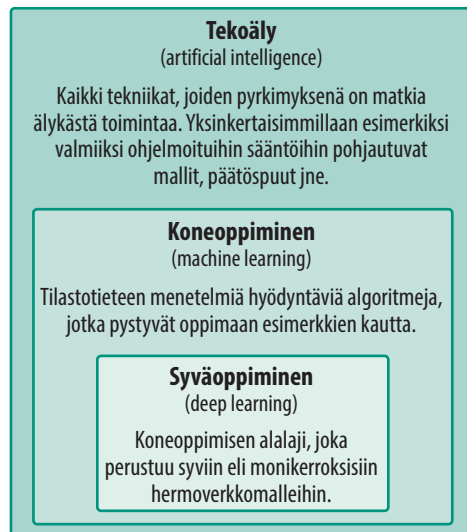
Tekoäly radiologiassa

Erilaiset tekoälymenetelmät kehittyvät nopeasti, ja niiden käyttö myös lääketieteessä lisääntyy. Syväoppimisessa (deep learning) voidaan käyttää yhä laajempia (syvempiä) hermoverkkoja, jotka mahdollistavat aikaisempaa monimutkaisempien tehtävien ratkaisemisen. Teknisen kehityksen ansiosta tekoälytutkimus onkin nykyisin mahdollista myös yksittäisissä akateemisissa keskuksissa ilman mittavia kustannuksia. Radiologian alalla tekoälymenetelmien tutkimus on lisääntynyt viime vuosina eksponentiaalisesti. Suurin osa menetelmistä liittyy kuvien automaattiseen analysointiin, kuten poikkeavien löydösten tunnistukseen ja luokitteluun sekä rakenteiden segmentointiin. Tekoälymenetelmät tuskin korvaavat radiologin tekemää työtä lähitulevaisuudessa, mutta ne voivat tehostaa toimintaa ja vähentää inhimillisiä virheitä.

Tekoälysovellusten käyttö lääketieteessä yleistyy kiihtyvällä vauhdilla, mutta käsitteenä ja tieteenalana tekoäly (artificial intelligence) sai alkunsa jo 1950-luvulla. Älykyydellä tarkoitetaan laajasti määriteltynä kykyä saavuttaa monimutkaisia tavoitteita (1). Tekoälyllä viitataan usein algoritmeihin, jotka pyrkivät jäljittelemään ihmisen älykästä toimintaa, päätöksentekoa ja ongelmanratkaisua. Varhaisimpia tekoälyalgoritmeja voi nykyään olla vaikea enää mieltää ”älykkäiksi”, ja tekoäly yhdistetäänkin nykyisin sen erityiseen osa-alueeseen, syväoppimiseen ja keinotekoiisiin hermoverkkoihin (2).


Vaikka alkeellisia hermoverkkoja tutkittiin jo 1950-luvulla, läpimurtonsa ne tekivät vasta 2010-luvulla. Keinotekoisien hermoverkkojen algoritmeja muokattiin silloin edelleen tehokkaammiksi esimerkiksi optimoimalla ne toimimaan rinnakkaislaskentaan kykenevillä suhteellisen edullisilla grafiikkaprosessoreilla. Nykyisin tekoälytutkimuksen aloittamiseen riittääkin jo suhteellisen edullinen tietokone, jossa on tehokas rinnakkaislaskennan mahdollistava näytönohjain.

Syväoppiminen ja koneoppiminen mielletään usein eri osa-alueiksi, vaikka syväoppi-



KUVA 1. Tekoäly, koneoppiminen ja syväoppiminen.

minen on koneoppimisen alalaji (KUVA 1) (2). Merkittävänä erona näissä kahdessa on kuitenkin se, että syväoppimisessa hermoverkot pystyvät käsittelemään monimutkaista dataa (kuten kuvia) sellaisenaan ja löytämään itse dataa parhaiten edustavat piirteet, kun taas tavanomaisessa koneoppimisessa ihmisen tulee etukäteen valita ja laskea datasta sitä edustavat



KUVA 2. Hermoverkon yhden solmun toiminta. Hermoverkko koostuu solmuista (ympyrät) ja niiden välisistä yhteyksistä (viivat). Informaatio käsitellään numeroina. Edellisen tason solmujen arvot (x_1 , x_2 ja x_3) kerrotaan kukin niistä lähtevien yhteyksien painokertoimilla (w_1 , w_2 ja w_3). Näiden yhteenlaskettuun summaan voidaan vielä lisätä solmulle ominainen vakioarvo b . Solmun lopullinen arvo y saadaan, kun tämä yhtälö käsitellään vielä jollain epälineaarisella funktiolla f . Kuvan alla on esitetty solmun toiminta matemaattisena kaavana.

piirteet, esimerkiksi kuvan rakeisuutta tai värejä kuvastavat laskennalliset arvot.

Keinotekoiset syvät hermoverkot

Syvät hermoverkot ovat saaneet inspiiraationsa biologisesta hermostosta, jossa vahvasti yksinkertaistettuna neuroni eli hermosolu saa useita signaaleja muilta hermosoluilta ja joko sallii tai estää signaalin eteenpäin välittymisen. Keinotekoisissa hermoverkoissa hermosoluja vastaavat solmut (nodes), jotka järjestäytyvät kerroksiksi (layers). Synapseja vastaavilla solmujen välisillä yhteyksillä on omat painokertoimet (weights) sekä sopiva epälineaarinen funktio, joilla signaalia vahvistetaan tai estetään (**KUVA 2**).

Verkon matalimmat kerrokset säätyvät (op-pivat) tunnistamaan esimerkiksi kuvien alkeellisia piirteitä, muun muassa reunoja ja kaaria, ja syvemmät kerrokset aina monimutkaisempia kokonaisuuksia, ilman ihmisen etukäteän määrittlemiä kriteereitä. Koska hermoverkot käsittelevät kuitenkin kaiken datan sen numeerisessa esitysmuodossa, on useimmiten keskimmäisillä kerroksilla tapahtuvaa signaalinkäsittelyä vaikeaa tulkita ihmisille ymmärrettävässä muodossa. Tämän vuoksi hermoverkot mielletään ”mustiksi laatikoiksi”.

Yleisimmät hermoverkkotyytit ovat konvoluutioverkot, jotka soveltuvat esimerkiksi hahmontunnistukseen kuvista, ja takaisinkytketyt hermoverkot, jotka soveltuvat erityisesti sarjojen, esimerkiksi luonnollisen kielen, analysointiin (**KUVA 3**). Joskus paras ratkaisu syntyy näiden kahden yhdistelmästä: esimerkiksi video koostuu yksittäisten kuvien sarjasta.

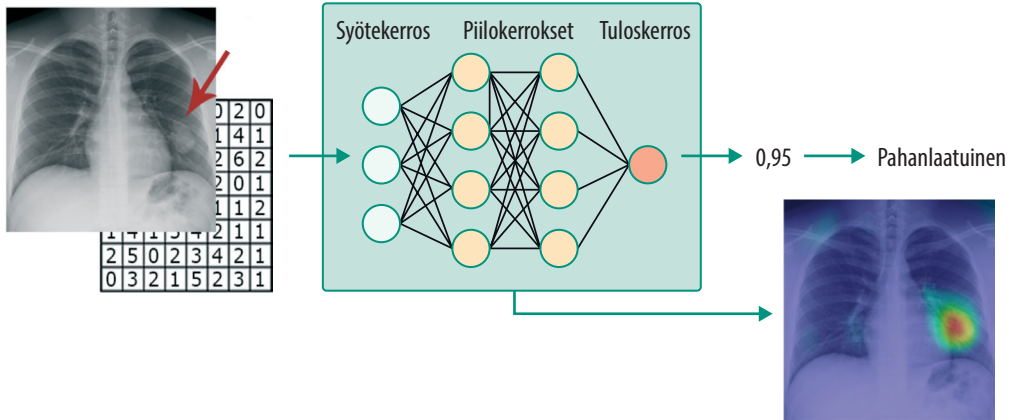
Hermoverkkojen opettaminen

Useimmissa käytännön sovelluksissa hermoverkkojen opetus on ohjattua (supervised learning), jolloin opetusaineisto on annotoitu eli esimerkiksi kuhunkin kuvaan on liitetty tieto oikeasta vastauksesta. Opetuksessa hermoverkon painokertoimet optimoituvat niin, että verkon tuottaman ennusteen ja oikean vastauksen välinen erotus olisi mahdollisimman pieni.

Hermoverkot vaativat hyvin suuria määriä opetusaineistoa, jolloin asiantuntijatasoista annotointityötä vaativissa yksityiskohtaisissa tehtävissä tämän laadukkaan opetusaineiston kokoaminen on usein rajoittava tekijä. Opetusta voidaan nopeuttaa mallin esiopetuksella (transfer learning), jolloin malli koulutetaan ensin jollain muulla, helpommin saatavalla mutta vain osittain vastaavalla aineistolla.

Radiologisissa sovelluksissa esiopetusaineisto voi esimerkiksi koostua eri kuvantamismuotojen kuvista, mutta yhtä hyviä tai jopa parempiakin tuloksia voidaan saada myös ei-lääketieteellisellä aineistolla. Tällainen on esimerkiksi julkinen ImageNet-aineisto, joka koostuu yli 14 miljoonasta tavanomaisesta valokuvasta, jotka on jaettu tuhansiin eri luokkiin (3). Näistäkin keinoista huolimatta opetusaineisto sisältää usein liian vähän vaihtelua löydöksen luonnolliseen vaihteluun nähden, mikä johtaa mallin ylisovittamiseen (overfitting). Tällöin malli toimii näennäisesti hyvin opetusaineistolla mutta huonosti täysin uudella aineistolla, koska malli ei ole vielä yleistynyt vastaamaan löydöksen todellista vaihtelevuutta.

Ylisovittamisen havaitsemiseksi opetusaineistosta erotetaan yleensä pieni osa validointiin, jolla mallin toimintaa testataan toistuvasti opetuksen aikana. Opetus lopetetaan, kun mallin suoritus validointi-aineistolla ei enää



KUVA 3. Keinotekoisien hermoverkkojen toiminta kaksiluokkaisessa luokittelutehtävässä, jossa tulos on joko pahanlaatuinen tai ei-pahanlaatuinen. Kuva syötetään numeerisena tietomatriisina hermoverkon syötekerrokselle, ja signaali välitettyä muokattuna kultakin kerrokselta seuraavalle. Tässä esimerkissä piilokerroksia on vain kaksi, mutta syvässä hermoverkoissa voi olla kymmeniä tai satoja piilokerroksia. Lopussa olevalla tuloskerroksella informaatio muutetaan sopivaan muotoon. Kaksiluokkaisessa luokittelutehtävässä vastaus on yleensä desimaaliluku, joka kuvastaa todennäköisyyttä, että löydös on poikkeava. Luku muutetaan lopulliseksi vastaukseksi käyttämällä esimerkiksi raja-arvoa 0,5 – jos löydös siis on yli 50 %:n todennäköisyydellä pahanlaatuinen, se luokitellaan pahanlaatuiseksi ja muussa tapauksessa ei-pahanlaatuiseksi. Hermoverkkomallin tulkittavuutta voidaan myös parantaa tuottamalla hermoverkosta lämpökartta (heatmap), joka kuvastaa, mitkä kohdat kuvassa vaikuttavat eniten hermoverkon tuottamaan vastaukseen. Tässä esimerkissä lämpökartassa (oikealla) eniten luokittelutulokseen vaikuttanut poikkeava alue on merkitty punaisella ja vähiten tulokseen vaikuttaneet alueet sinisellä (4).

parane. Lopuksi mallin toiminta testataan vielä erillisellä testiaineistolla, joka on eri aineisto kuin opetuksessa tai validaatiossa käytetty aineisto. Tämä kolmiportainen menetelmä (training, validation, testing) on yleisesti käytetty tapa opettaa hermoverkkoja ja myös kontrolloida niiden oppimista.

Tekoälymallin (hermoverkon) suoritusta arvioidaan yleensä ristiintaulukoimalla mallin tuottamat ennustukset ja oikeat vastaukset sekä laskemalla näistä tulosmuuttujia, kuten herkkyttä ja tarkkuutta. Kaksiluokkaisessa (binaarisessa) luokittelussa yleisenä mallin hyvyden arviona ilmaistaan usein receiver operating characteristics (ROC) -käyrän alle jäävä pinta-ala (area under the curve, AUC), mutta tutkimusasetelman mukaan tulosten tulkinnassa voidaan painottaa myös negatiivista tai positiivista poissulkuarvoa (negative and positive predictive value). Useamman luokan luokittelutehtävässä (esimerkiksi järjestysasteikko) tuloksia tarkastellaan usein koko mallin lisäksi myös jokaisen luokan osalta erikseen (KUVA 4).

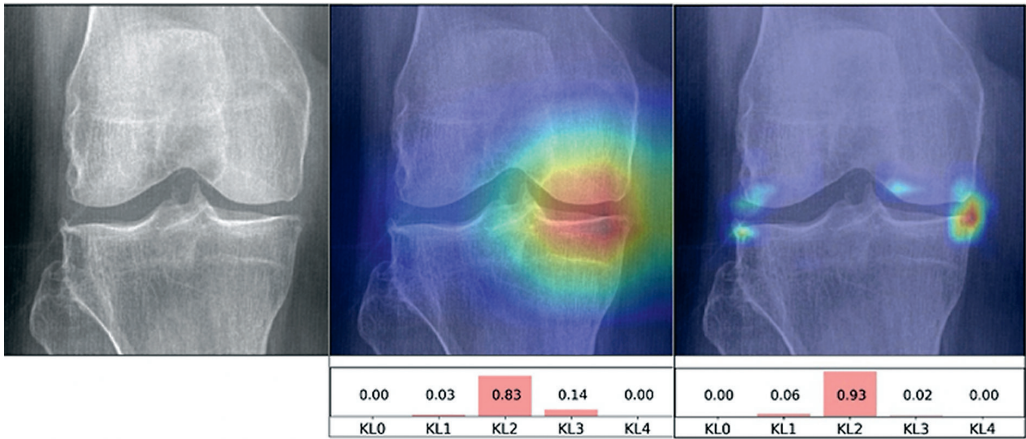
Tekoälytutkimuksen kulku käytännössä alkaa tutkimuskysymyksen muodostamisesta

ja tarvittavien lupien hankkimisesta (TAULUKKO 1). Keskeinen osa on tiedonkäsittelyn ammattilaisilla, jotka osaavat ylläpitää tekoälytutkimukseen tarvittavia laitteisto- ja ohjelmistojärjestelmiä, kouluttaa hermoverkkoja ja tulkita saatuja tuloksia tilastollisesti. Lisäksi olennaista on yhteistyö näiden tietojen käsittelyyn erikoistuneiden ammattilaisten sekä käytännön työtä tekevien lääkäreiden välillä.

Laadukas opetusaineisto ja hyvä kysymyksenasettelu ovat avainasemassa hermoverkkojen koulutuksen onnistumisessa. Tekoälymallin opettamisen voi aloittaa helposti edullisella

TAULUKKO 1. Tekoälytutkimuksen käytännön vaiheita.

- Tutkimuskysymyksen muodostaminen ja tutkimuksen suunnittelu
- Tutkimuslupien hakeminen
- Annotoitu ja strukturoitu tietoaaineisto
- Tietoaaineiston jakaminen koulutus-, validaatio- ja testi-osioihin
- Mallin rakentaminen ja koulutus
- Mallin testaus ja tulosten analysointi
- Käyttöliittymän luominen ja integraatio olemassa oleviin järjestelmiin



KUVA 4. Kaksi eri hermoverkkoa koulutettiin luokittelemaan nivelkuluma polven röntgenkuvasta (vasemmalla). Hermoverkkojen tuloksuvissa (keskellä ja oikealla) on väreillä ilmaistu ne kuvan alueet, jotka ovat eniten vaikuttaneet luokitteluun. Tuloksuvista käy ilmi, että eri hermoverkot voivat säätää tarkastelemaan kuvista erilaisia asioita ja päätyä silti hyvin samankaltaisiin tuloksiin: keskellä olevassa kuvassa huomio on kiinnittynyt kaventuneeseen luiseen nivelrakoon ja oikealla olevassa kuvassa nivelpintojen reunakerrostumiin. Tuloksuvien alla hermoverkon antamat todennäköisyydet kuvan kuulumisesta kuhunkin nivelkulumaluokkaan (KL = Kellgren-Lawrencen luokka). Kuva: Aleksei Tiulpin, Oulun yliopisto.

”pelitietokoneellakin”. Mallien monimutkaistuksessa ja aineiston laajentuessa tarvitaan kuitenkin usein useampia tehokkaita grafiikkasuorittimia, jotta laskenta-ajat pysyvät mielekkäinä. Tällöin tutkimuksessa käytettävän laitteiston hinta suurenee jo merkittäväksi.

Tekoälysovelluksia radiologiassa

Tekoäly voi hyödyttää kuvantamisprosessia monessa vaiheessa, aina resurssien ja kuvausprotokollien optimoinnista radiologisten tutkimusten kuvan laadun parantamiseen ja strukturoituun raportointiin. Eniten huomiota ovat kuitenkin saaneet erilaisten havainnointi- ja luokittelutehtävien tulokset (TAULUKKO 2) (5–17).

Toistaiseksi tekoälyalgoritmeja on koulutettu kapeasti rajattuihin tehtäviin, joissa ne ovat usein osoittautuneet vähintään yhtä hyväksi tai paremmiksi kuin radiologisten arviot. Tutkimuskohtainen datan määrä lisääntyy tekniikan kehittyessä, samoin kuvantamispalvelujen kysyntä ylipäättään. Tekoäly voi auttaa radiologian ison datamäärän kanssa: se voi vähentää virheitä, tehostaa toimintaa, pienentää kustannuksia ja tuottaa kuvantamispalveluja sellaiseen aikaan tai paikkaan, kun asiantuntijaa ei ole saatavilla.

Radiologin tueksi aiheesta on onneksi julkaistu hiljattain laadukkaita katsauksia (18–20).

Tekoälyalgoritmeja on koulutettu etsimään seulontamammografiakuvasta pahanlaatuisen kasvaimen kannalta epäilyttäviä löydöksiä (5,21). Seulontamammografia on hyvä esimerkki tutkimuksesta, jossa suuresta tietomäärästä pitää seuloa harvinaisia ja vaikeasti havaittavia muutoksia. Näiden julkaisujen mukaan tekoäly on vähintään yhtä hyvä tai parempi kuin yksittäinen radiologi tai kahden radiologin yhteisluenta. Toisaalta tekoäly paransi yksittäisen radiologin arvioita siten, että se vastasi usean radiologin yhteistä arviota (21). Tällainen algoritmi voi olla avuksi tilanteissa, joissa radiologiresurssista on puutetta.

Vastaavia tutkimuksia röntgenkuvien automaattisesta analyysistä on julkaistu runsaasti, muun muassa keuhkojen ja raajojen kuvauksista. Erityisen hyödylliseksi saattaa osoittautua algoritmi, joka on koulutettu havainnoimaan ja luokittelemaan sydän-keuhkokuvasta akuuttia hoitoa vaativia tiloja, kuten keuhkokuumeita tai ilmarintaa (9). Tekoälyalgoritmi on opetettu myös erottamaan COVID-19-keuhkokuume tavanomaisesta keuhkokuumeesta ja muista löydöksistä kohtalaisen hyvällä menestyksellä (22).

TAULUKKO 2. Esimerkkejä tekoälymenetelmien tuloksista radiologiassa (5–17).

Menetelmä	Kohde	Tulos tai vastaus	Viite
Röntgenkuvaus	Mammografia	Rintasyövän seulonta	(5)
Röntgenkuvaus	Raajat	Murtuman havaitseminen	(6)
Röntgenkuvaus	Polvinivel	Nivelkuluman havaitseminen ja luokittelu	(7)
Röntgenkuvaus	Olkanivel	Kiertäjäkavosimen repeämän poissulku	(8)
Röntgenkuvaus	Rintakehä	Akuuttitilanteen havaitseminen	(9)
Röntgenkuvaus	Rintakehä	Keuhkosityövän havaitseminen	(10)
Tietokonetomografia	Pää	Kallonsisäisen vuodon havaitseminen ja luokittelu	(11)
Tietokonetomografia	Pää	Akuutin infarktin havaitseminen	(12)
Tietokonetomografia	Vatsa	Akuuttitilanteen havaitseminen	(13)
Magneettikuvaus	Polvinivel	Eturistisiteen repeämän havaitseminen	(14)
Magneettikuvaus	Pää	Uusien MS-taudin leesioden havaitseminen	(15)
Magneettikuvaus	Pää	Etäpesäkkeiden havaitseminen ja mittaaminen	(16)
Magneettikuvaus	Pää	Gliooman isositraattidehydrogenaasi (IDH) -mutaation havaitseminen	(17)

Raajojen ja nivelten alueella algoritmeja on koulutettu tunnistamaan ja luokittelemaan automaattisesti murtumia ja nivelkulumaa (6,7). Tekoälyalgoritmi voi tunnistaa olkanivelen röntgenkuvasta kiertäjäkavosimen repeämän, kun koulutuksessa käytetyt röntgenkuvat on luokiteltu kaiku- ja magneettikuvaustietojen perusteella (8).

Röntgenkuvien lisäksi tekoälyalgoritmeja on kehitetty leikekuvantamisen analytiikkaan, lähinnä tietokonetomografiaan (TT) ja magneettikuvaukseen. Hermoverkko osaa tunnistaa ja luokitella pään natiivi-TT:stä kallonsisäiset vuodot sekä tuoreen infarktin, ja vatsan TT:stä akuuttia hoitoa vaativat tilat (11–13). Tekoäly osaa myös löytää polven magneettikuvauksesta eturistisiteen repeämän (14). Tällaiset algoritmit voivat osoittautua erittäin käyttökelpoisiksi triage-työkaluiksi päivystystilanteessa, jossa radiologin on nopeasti käytävä läpi suuri määrä tutkimuksia ja tehtävä niistä merkittäviä päätöksiä.

Magneettikuvauksessa käytetään nykyisin lukuisia erilaisia sekvenssejä, joten esimerkiksi automaattinen aivovaltimoaneurysmien havainnointi pään magneettiangiografiasta saattaa tehostaa radiologin työtä (23). Syöpäkuvantamisessa tekoälyllä on edellytyksiä tunnistaa

suoraan erilaisista magneettikuvaussekvensseistä hyvin monimutkaista informaatiota, kuten pahanlaatuisten gliomien molekuläärisiä alatyyppejä tai rintasyövän hoitovastetta (24,25).

Syrjäyttääkö tekoäly radiologin?

Mediassa näkee arveluja siitä, että radiologien työ voidaan kohta korvata tekoälyllä (26). Tämä perustuu kuitenkin puutteelliseen näkemykseen radiologian erikoislääkärin asiantuntijatyöstä ja siitä, miten nykyiset tekoälyalgoritmit toimivat. Erilaisia radiologin tekemiä tunnistus-, luokittelu- ja päättelytehtäviä on tuhansia, yksinkertaisista erittäin monimutkaisiin, kun taas nykyiset tekoälyalgoritmit on optimoitu hyvin kapeasti määriteltyihin yksittäisiin tehtäviin.

Tekoälyalgoritmit eivät myös vielä pysty ihmisen kaltaiseen tehokkaaseen toiminnanohjaukseen, jonka keskeisimpiä piirteitä ovat toiminnan tavoitteen määrittely ja päätöksenteko, toiminnan kohdistaminen aktiivisesti olennaiseen tietoon ja epäolennaisen tiedon aktiivinen suodattaminen, virheiden tunnistaminen ja korjaus, uusien enemmän resursseja vaativien tilanteiden tunnistus sekä sellaisten tilanteiden

Ydinasiat

- ▶ Tekoälyllä tarkoitetaan tietokonealgoritmeja, jotka jäljittelevät ihmisen älyllisiä toimintoja, kuten havainnointia ja ongelmanratkaisua.
- ▶ Radiologiassa käytetään keinotekoisia hermoverkkoja, jotka oppivat itse kuvista erilaisia ominaisuuksia.
- ▶ Hermoverkot tehostanevat merkittävästi radiologian toimintaa, mutta eivät korvaa radiologin työtä lähitulevaisuudessa.

tunnistus, jossa aiemmin opitut toimintamallit eivät ole mielekkäitä.

Lääketieteelliset ongelmat eivät juuri koskaan ole pelkistettävissä yksinkertaisiin luokitteluihin, joten radiologin työssä toiminnanohjaus eli kyky ohjata huomio tilanteessa keskeiseen asiaan on tärkeää. Samoin tiedon yhdistäminen muuhun hyvin erilaiseen tietoon ja mahdollisen lisätiedon hankinta ovat keskeisiä radiologin työn vaatimuksia. On myös hyvä ymmärtää, että radiologin työ on muuta kuin kuvien katsomista. Esimerkiksi tutkimusten suunnittelu ja lausunnon merkityksen kommunikointi kliinikolle kuuluu radiologin asiantuntijatehtäviin, samoin kuin aiempaa laajempi osallistuminen potilaan hoitoon esimerkiksi moniammatillisten asiantuntijaryhmien jäsenenä.

Ratkaiseva kysymys on kuitenkin se, miten radiologian alan tekoälymenetelmät parantavat potilaan hoitoa. Käytännön hyödyt hermoverkoista ovat pitkälti vielä osoittamatta etenevissä kliinisissä tutkimuksissa, ja algoritmien laajamittainen hyödyntäminen vaatinee saumatonta integraatiota olemassa oleviin tietojärjestelmiin ja tietokantoihin (27). Lisäksi on mahdollista, että osa käyttöön otettavista kaupallisista tekoälysovelluksista vaatii opettamista myös paikallisella aineistolla, mikä aiheuttaa omat vaatimuksensa ainakin tietosuojan näkökulmasta.

Näiden menetelmien tuottamat tulokset vaativat edelleen myös spesialistin arvioita. Esimerkiksi kuva-analyysien tuloksia tulkitsevan

radiologin tulee tuntea algoritmin toiminnan periaatteet, rajoitteet ja mahdolliset virhelähteet sekä pystyä tulkitsemaan algoritmin tuottamia ennusteita. Nämä vaatimukset muuttavat radiologin työkenttää aiempaa laajemmaksi. Tekoälymenetelmät tuskin korvaavat radiologia aivan lähiaikoina, vaan pikemminkin tehostavat kuvantamistoimintaa, jolloin radiologin rooli lääkärinä potilaan hoitoprosessissa edelleen korostuu (26).

Joitakin sovelluksia on jo virallisesti hyväksytty käyttöön Euroopassa ja Yhdysvalloissa, joten käyttöönotto on jo meneillään. Suomessa kliinisessä käytössä olevista ohjelmista esimerkiksi e-ASPECTS-ohjelmisto (brainomix.com) käyttää koneoppimista osana pään natiivi-TT-kuvien tulkintaa. Ohjelmiston tehtävänä on löytää pään TT-kuvista merkkejä tuoreesta iskeemiasta. Ohjelmisto on tarkoitettu avustamaan diagnoosin teossa, ja sillä on lääkinnällisen laitteen luokan I CE-merkintä. RAPID-AI-tuoteperheen (rapidai.com) ohjelmista esimerkiksi RAPID ICH -ohjelmisto käyttää syviä hermoverkkoja analyysin teossa, ja osalla tuoteperheen ohjelmista on CE-merkintä.

Vaikka tekoälyalgoritmit tuottavat suuren määrän informaatiota nopeasti ja melko luotettavasti, on niistä saatava tieto kuitenkin hyvin kapea-alaista ja altista erityyppisille virheille. Hermoverkkomallin tulkittavuutta voidaan parantaa tuottamalla hermoverkosta esimerkiksi lämpökartta (heatmap), joka kuvastaa, mitkä kohdat kuvassa vaikuttavat eniten hermoverkon tuottamaan vastaukseen (KUVA 3). Radiologille tämäntyyppiset tulosten visualisoinnit voivat olla erittäin hyödyllisiä mallin toiminnan arvioissa.

Hermoverkkojen tulosten selittäminen on oma tutkimusala, jonka tuottamista työkaluista lämpökartat ovat eräs esimerkki. Tekoälymallien tuottama uusi tieto tulee vielä yhdistää potilaan kokonaistilanteeseen, joten päätökset potilaan hoidosta perustuvat ainakin lähivuosikymmeninä edelleen ihmisten väliseen yhteistyöhön. Radiologia ei ole ainoa runsaasti lääketieteellistä tietoa tuottava ala, vaan myös esimerkiksi patologian alalla tekoäly muuttaa työn luonnetta – kenties nämä erikoisalalat lähentyvät toisiaan tulevaisuudessa, jolloin lääkä-

rin tehtäviin kuuluu “informaatiokesialistina” toimiminen (28).

Lopuksi

Tekoölymenetelmien nopea kehitys laajentaa lähitulevaisuudessa merkittävästi radiologien työkenttää. Nämä menetelmät kykenevät käsittelemään suuren määrän tietoa nopeasti ja luotettavasti ja voivat näin toimia radiologin tukena potilaiden tutkimuksessa ja hoidossa. Radiologien tulisi olla ensilinjassa omaksumassa näitä uusia menetelmiä myös kliiniseen käyttöön.

Hermoverkkojen koulutukseen käytettävän laadukkaan tietoaineiston kerääminen on ensiarvoisen tärkeää, ja siinä tulee huomioida ajankohtainen lainsäädäntö tunnistettavan

henkilötiedon käsittelystä (29). On niin ikään tärkeää varmistaa, että tekoölymenetelmät ovat eettisesti hyväksyttäviä: niiden tulee olla teknisesti luotettavia, avoimia, syrjimättömiä ja oikeudenmukaisia (30). Tietokonealgoritmien vastuuvollisuus on lisäksi juridinen ongelma – onko vastuu ensisijaisesti algoritmin tekijällä vai käyttäjällä? Jokapäiväisessä radiologin työssä näiden menetelmien tekemien virheiden tunnistaminen jää käytännössä radiologin tehtäväksi ja vastuulle. Lääketieteessä ihmisen rooli on siis jatkossakin keskeinen, myös radiologiassa. ■

* * *

Kiitämme professori Roberto Blanco Sequeirosia (Tyks, radiologia) käsikirjoituksen lukemisesta ja arvokkaista kommentteista.

HEIDI HUHTANEN, LL, tutkijakoulutettava, radiologiaan erikoistuva lääkäri

MIKKO NYMAN, LT, radiologian erikoislääkäri

JUSSI HIRVONEN, dosentti, radiologian erikoislääkäri

Tyks, kuvantaminen, radiologian vastuualue
Turun yliopisto, lääketieteellinen tiedekunta, radiologian oppiaine

ANTTI KARLSSON, FT, kehityspäällikkö

Auria Biopankki, Tyks
Turun yliopisto, lääketieteellinen tiedekunta

SIDONNAISUUDET

Heidi Huhtanen: Ei sidonnaisuuksia

Mikko Nyman: Ei sidonnaisuuksia

Jussi Hirvonen: Luentopalkkio/asiantuntijapalkkio (GE Healthcare), luottamustoimet (Acta Radiologica Foundation, board member, Nordic Society of Medical Radiology, board member)

Antti Karlsson: Luentopalkkio/asiantuntijapalkkio (Bayer, Medaffcon, Lääketietokeskus)

VASTUUTOIMITTAJA

Tuomas Mirtti

SUMMARY

Artificial intelligence in radiology

Artificial intelligence (AI) applications are rapidly evolving in medicine, especially in image processing fields such as radiology and pathology. Deep learning refers to the use of AI algorithms that employ artificial neural networks to achieve complex goals, such as speech recognition and classification of images. In radiology, deep learning is typically used to recognize, classify, or segment abnormal findings in images. These methods are now being used in exponentially increasing numbers in radiological research, mostly due to the availability of large datasets, pretrained artificial neural networks, and affordable parallel computing. As a result of this rapid development, AI algorithms are now surpassing human-level performance in narrowly defined tasks, such as finding malignant lesions in mammography. These methods are expected to increase the productivity of radiologists, although not fully replace the radiologist as the medical information specialist.

KIRJALLISUUTTA

1. Chollet F. On the Measure of Intelligence. arXiv 2019:1911.01547. <http://arxiv.org/abs/1911.01547>.
2. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521:436–44.
3. ImageNet -aineisto. www.image-net.org/.
4. Wang X, Peng Y, Lu L, ym. ChestX-ray8: hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *IEEE CVPR* 2017;3462–71.
5. McKinney SM, Sieniek M, Godbole V, ym. International evaluation of an AI system for breast cancer screening. *Nature* 2020;577:89–94.
6. Thian YL, Li Y, Jagmohan P, ym. Convolutional neural networks for automated fracture detection and localization on wrist radiographs. *Radiology: Artificial Intelligence* 2019;1:e180001
7. Tiulpin A, Klein S, Bierma-Zeinstra SMA, ym. Multimodal machine learning-based knee osteoarthritis progression prediction from plain radiographs and clinical data. *Sci Rep* 2019;9:20038
8. Kim Y, Choi D, Lee KJ, ym. Ruling out rotator cuff tear in shoulder radiograph series using deep learning: redefining the role of conventional radiograph. *Eur Radiol*, julkaistu verkossa 5.2.2020. DOI: 10.1007/s00330-019-06639-1.
9. Hwang EJ, Nam JG, Lim WH, ym. Deep learning for chest radiograph diagnosis in the emergency department. *Radiology* 2019;293:573–80.
10. Nam JG, Park S, Hwang EJ, ym. Development and validation of deep learning-based automatic detection algorithm for malignant pulmonary nodules on chest radiographs. *Radiology* 2019;290:218–28.
11. Kuo W, Häne C, Mukherjee P, ym. Expert-level detection of acute intracranial hemorrhage on head computed tomography using deep learning. *Proc Natl Acad Sci USA* 2019;116:22737–45.
12. Qiu W, Kuang H, Teleg E, ym. Machine learning for detecting early infarction in acute stroke with non-contrast-enhanced CT. *Radiology*, julkaistu verkossa 28.1.2020. DOI: 10.1148/radiol.2020191193.
13. Winkel DJ, Heye T, Weikert TJ, ym. Evaluation of an AI-based detection software for acute findings in abdominal computed tomography scans: toward an automated work list prioritization of routine CT examinations. *Investigative Radiology* 2019;54:55–9.
14. Liu F, Guan B, Zhou Z, ym. Fully automated diagnosis of anterior cruciate ligament tears on knee MR images by using deep learning. *Radiology: Artificial Intelligence* 2019;1:180091.
15. Salem M, Valverde S, Cabezas M, ym. A fully convolutional neural network for new T2-w lesion detection in multiple sclerosis. *Neuroimage Clin* 2020; 25:102149.
16. Xue J, Wang B, Ming Y, ym. Deep learning-based detection and segmentation-assisted management of brain metastases. *Neuro Oncol* 2020;22:505–14.
17. Yogananda CGB, Shah BR, Vejdani-Jahromi M, ym. A novel fully automated MRI-based deep-learning method for classification of IDH mutation status in brain gliomas. *Neuro Oncol* 2020;22:402–11.
18. Chartrand G, Cheng PM, Vorontsov E, ym. Deep learning: a primer for radiologists. *Radiographics* 2017;37:2113–31.
19. Soffer S, Ben-Cohen A, Shimon O, ym. Convolutional neural networks for radiologic images: a radiologist's guide. *Radiology* 2019;290:590–606.
20. Yao AD, Cheng DL, Pan I, ym. Deep learning in neuroradiology: a systematic review of current algorithms and approaches for the new wave of imaging technology. *Radiology: Artificial Intelligence*, julkaistu verkossa 4.3.2020. DOI:10.1148/ryai.2020190026.
21. Wu N, Phang J, Park J, ym. Deep neural networks improve radiologists' performance in breast cancer screening. arXiv 2019:1903.08297. <http://arxiv.org/abs/1903.08297>.
22. Li L, Qin L, Xu Z, ym. Artificial intelligence distinguishes COVID-19 from community acquired pneumonia on chest CT. *Radiology*, julkaistu verkossa 19.3.2020. DOI:10.1148/radiol.2020200905.
23. Ueda D, Yamamoto A, Nishimori M, ym. Deep learning for MR angiography: automated detection of cerebral aneurysms. *Radiology* 2019;290:187–94.
24. Chang P, Grinband J, Weinberg BD, ym. Deep-learning convolutional neural networks accurately classify genetic mutations in gliomas. *AJNR Am J Neuroradiol* 2018;39:1201–7.
25. Ha R, Chang P, Karcich J, ym. Predicting post neoadjuvant axillary response using a novel convolutional neural network algorithm. *Ann Surg Oncol* 2018;25:3037–43.
26. Langlotz CP. Will artificial intelligence replace radiologists? *Radiology: Artificial Intelligence* 2019;1:190058.
27. Recht MP, Dewey M, Dreyer K, ym. Integrating artificial intelligence into the clinical practice of radiology: challenges and recommendations. *Eur Radiol* 2020;30:3576–84.
28. Jha S, Topol EJ. Adapting to artificial intelligence: radiologists and pathologists as information specialists. *JAMA* 2016;316:2353.
29. Willeminck MJ, Koszek WA, Hardell C, ym. Preparing medical imaging data for machine learning. *Radiology*, julkaistu verkossa 18.2.2020. DOI:10.1148/radiol.2020192224.
30. Geis JR, Brady AP, Wu CC, ym. Ethics of artificial intelligence in radiology: summary of the joint European and North American multisociety statement. *Radiology* 2019;293:436–40.