



**VILNIAUS UNIVERSITETAS**  
**MEDICINOS FAKULTETAS**

Medicina

Radiologijos, branduolinės medicinos ir medicinos fizikos katedra, Biomedicinos mokslų institutas

Gytė Gužauskaitė, VI kursas, 6 grupė

VIENTISŪJŲ STUDIJŲ MAGISTRO BAIGIAMASIS DARBAS

**Dirbtinis intelektas radiologijoje: privalumai, trūkumai ir ateities perspektyvos**

**Artificial Intelligence in Radiology: Advantages, Disadvantages and Future  
Prospects**

Darbo vadovas

Prof. dr. Nomedą Rima Valevičienė

Katedros ar klinikos vadovas

Prof. dr. Algirdas Edvardas Tamošiūnas

Vilnius, 2026

Studento elektroninio pašto adresas: [gyte.guzauskaite@mf.stud.vu.lt](mailto:gyte.guzauskaite@mf.stud.vu.lt)

# TURINYS

|                                                                                             |    |
|---------------------------------------------------------------------------------------------|----|
| 1. SANTRUMPOS .....                                                                         | 3  |
| 2. SANTRAUKA .....                                                                          | 4  |
| 3. SUMMARY .....                                                                            | 5  |
| 4. ĮVADAS .....                                                                             | 6  |
| 5. DARBO METODIKA .....                                                                     | 8  |
| 6. REZULTATAI .....                                                                         | 8  |
| 6.1. Dirbtinis intelektas .....                                                             | 8  |
| 6.1.1. Dirbtinio intelekto sąvoka ir istorija .....                                         | 8  |
| 6.1.2. Dirbtinio intelekto tipai .....                                                      | 9  |
| 6.1.2.1. Mašininis mokymasis (angl. machine learning) .....                                 | 9  |
| 6.1.2.2. Gilusis mokymasis (angl. deep learning) .....                                      | 11 |
| 6.1.2.3. Didieji kalbos modeliai (angl. large language models) .....                        | 13 |
| 6.1.3. Dirbtinio intelekto pritaikymas radiologijoje .....                                  | 13 |
| 6.2. Dirbtinio intelekto privalumai radiologijoje .....                                     | 15 |
| 6.2.1. Darbo efektyvumo didinimas .....                                                     | 15 |
| 6.2.2. Rūšiavimas .....                                                                     | 17 |
| 6.2.3. Diagnostinis tikslumas .....                                                         | 18 |
| 6.2.4. Prognozavimas .....                                                                  | 21 |
| 6.2.5. Jonizuojančiosios spinduliuotės apšvitos mažinimas ir vaizdo kokybės gerinimas ..... | 22 |
| 6.2.6. Radiologinių vaizdų sintezė .....                                                    | 25 |
| 6.2.7. Mokymas .....                                                                        | 26 |
| 6.3. Dirbtinio intelekto trūkumai radiologijoje .....                                       | 27 |
| 6.3.1. Neteisingai apibrėžiamos anatominių struktūrų bei patologinių darinių ribos .....    | 27 |
| 6.3.2. Ribotas duomenų prieinamumas .....                                                   | 28 |
| 6.3.3. Duomenų apsauga .....                                                                | 29 |
| 6.3.4. Duomenų šališkumas .....                                                             | 29 |
| 6.3.5. Neaiškus veikimo principas .....                                                     | 30 |
| 6.3.6. Gydytojų nepasitikėjimas .....                                                       | 31 |
| 6.4. Dirbtinio intelekto ateities perspektyvos radiologijoje .....                          | 32 |
| 7. REZULTATŲ APIBENDRINIMAS .....                                                           | 34 |
| 8. IŠVADOS .....                                                                            | 37 |
| 9. REKOMENDACIJOS .....                                                                     | 37 |
| 10. LITERATŪROS ŠALTINIAI .....                                                             | 38 |

# 1. SANTRUMPOS

1p/19q – 1 chromosomos trumpasis petys (p) ir 19 chromosomos ilgasis petys (q)

ALARA – principas, kuriuo remiantis turi būti dedamos visos pastangos radiologinį tyrimą atlikti taip, kad pacientas patirtų kuo mažesnę jonizuojančiosios spinduliuotės apšvitos dozę, išlaikant pakankamą vaizdų kokybę (angliškai *As Low As Reasonably Achievable*)

angl. – angliškai

CE – patvirtintas Europos (angliškai *European Conformity*)

DI – dirbtinis intelektas

FDA – maisto ir vaistų administracija (angliškai *Food and Drug Administration*)

FLAIR – skysčio slopinimo inversijos-atkūrimo seka (angliškai *fluid-attenuated inversion recovery*)

Hv – Hounsfieldo vienetai

KT – kompiuterinė tomografija

min. – minutės

mln. – milijonai

mlrd. – milijardai

MRT – magnetinio rezonanso tomografija

mSv – milisivertas

pav. – paveikslas

PET – pozitronų emisijos tomografija

SPECT – vieno fotono emisijos kompiuterinė tomografija

T1 – magnetinio rezonanso tyrimo režimas

T1-weighted – magnetinio rezonanso tyrimo režimas

T2 – magnetinio rezonanso tyrimo režimas

T2-FLAIR – magnetinio rezonanso tyrimo režimas (angliškai *T2-weighted-Fluid-Attenuated Inversion Recovery*)

T2-weighted – magnetinio rezonanso tyrimo režimas

## 2. SANTRAUKA

**Darbo pagrindimas.** Dirbtinis intelektas šiuo metu yra taikomas daugelyje medicinos sričių, viena iš jų – radiologija. Radiologijoje dirbtinis intelektas gali būti naudojamas radiologinių vaizdų analizei bei patologinių pakitimų identifikavimui. Dėl šios priežasties dirbtinio intelekto technologijos radiologijoje tampa vis svarbesnės. Vis dėlto, nemažai specialistų vis dar abejoja dirbtinio intelekto patikimumu, todėl yra labai svarbu aiškiai suprasti jo veikimo principus, privalumus, trūkumus ir ateities perspektyvas. Tai leidžia geriau įvertinti dirbtinio intelekto potencialą ir kritiškai vertinti jo pateikiamus rezultatus.

**Darbo tikslas.** Apžvelgti naujausius literatūros šaltinius apie dirbtinį intelektą, jo taikymą radiologijoje bei susijusius privalumus, trūkumus ir ateities perspektyvas.

### Uždaviniai:

1. Apžvelgti dirbtinio intelekto struktūrinius komponentus ir veikimo principus bei įvertinti jo taikymą radiologijoje.
2. Įvertinti, kokiais tikslais dirbtinis intelektas gali būti naudojamas radiologijoje bei kokius privalumus jis suteikia.
3. Įvertinti, su kokiais trūkumais, iššūkiais ir ribojančiais veiksniais susiduriama taikant dirbtinį intelektą radiologijoje.
4. Apžvelgti dirbtinio intelekto panaudojimo galimybes ir ateities perspektyvas radiologijoje.

**Darbo metodika.** Mokslinės literatūros analizė „PubMed“ ir „ScienceDirect“ duomenų bazėse. Į apžvalgą įtraukti 64 straipsniai publikuoti anglų kalba 2016–2026 metais.

**Rezultatai.** Dirbtinis intelektas – tai kompiuterinių sistemų pagalba sukurtas specialus algoritmas. Dirbtinis intelektas radiologijoje yra plačiai naudojamas radiologinių vaizdų analizei. Ši technologija gali padidinti radiologų darbo efektyvumą, užtikrinti automatizuotą radiologinių tyrimų rūšiavimą, gerinti diagnostinį tikslumą bei prognozuoti ligų eigą ir gydymo baigtis. Taip pat nustatyta, kad dirbtinio intelekto taikymas gali sumažinti pacientų gaunamą jonizuojančiosios spinduliuotės apšvitą ir kartu pagerinti radiologinių vaizdų kokybę. Be to, dirbtinis intelektas gali atlikti radiologinių vaizdų sintezę ir gali būti naudojamas radiologijos rezidentų mokymo procese. Nepaisant šių privalumų, dirbtinis intelektas taip pat turi ir daug trūkumų. Nustatyta, kad dirbtinis intelektas ne visada tiksliai apibrėžia anatominių struktūrų bei patologinių darinių ribas. Taip pat pastebima, jog dirbtinio intelekto sistemų kūrimui ir taikymui dažnai nepakanka kokybiškų duomenų dėl riboto jų prieinamumo, duomenų apsaugos ir galimo duomenų šališkumo. Be to, dirbtinio intelekto veikimo principas nėra iki galo aiškus, todėl dalis specialistų skeptiškai vertina jo integravimą į klinikinę

praktiką. Vis dėlto, dirbtinis intelektas pasižymi dideliu potencialu radiologijoje ir manoma, jog jis ateityje taps reikšmingu radiologo pagalbininku.

**Išvados.** Dirbtinio intelekto technologijos, apimančios mašininį mokymąsi, gilųjį mokymąsi ir didžiuosius kalbos modelius, tampa svarbia radiologijos dalimi. Dirbtinis intelektas padeda tiksliau vertinti radiologinius vaizdus ir priimti pagrįstus diagnostinius sprendimus, jis pasižymi dideliu potencialu automatizuoti sudėtingas užduotis ir sumažinti radiologų darbo krūvį. Nepaisant plačių taikymo galimybių, jo efektyvų naudojimą riboja techniniai, etiniai ir teisiniai aspektai. Ateityje tikimasi platesnio multimodalinių sistemų taikymo, tačiau šiuo metu manoma, jog dirbtinis intelektas išliks pagalbine, o ne radiologus pakeičiančia priemone.

**Raktažodžiai.** Dirbtinis intelektas; radiologija; radiologiniai vaizdai; mašininis mokymasis; gilusis mokymasis; didieji kalbos modeliai.

### 3. SUMMARY

**Rationale of the study.** Artificial intelligence is currently applied across many fields of medicine, one of which is radiology. In radiology, artificial intelligence can be used for the analysis of radiological images and the identification of pathological changes. For this reason, artificial intelligence is becoming progressively more important in the field of radiology. However, many specialists still question the reliability of artificial intelligence; therefore, it is essential to clearly understand its underlying principles, advantages, disadvantages, and future prospects. This allows for a better assessment of the potential of artificial intelligence and a more critical evaluation of its results.

**Aim of the study.** To review the latest literature on artificial intelligence, its application in radiology, as well as its associated advantages, disadvantages, and future prospects.

#### **Objectives:**

1. To review the structural components and operating principles of artificial intelligence and evaluate its application in radiology.
2. To evaluate the purposes for which artificial intelligence can be used in radiology and the advantages it provides.
3. To evaluate the disadvantages, challenges, and limiting factors encountered in the application of artificial intelligence in radiology.
4. To review the potential applications and future prospects of artificial intelligence in radiology.

**Methods and materials.** Analysis of scientific literature in the „PubMed“ and „ScienceDirect“ databases. The review included 64 articles published in English between 2016 and 2026.

**Results.** Artificial intelligence is a specialized algorithm developed using computer systems. Artificial intelligence in radiology is widely applied for the analysis of radiological images. This technology can enhance the efficiency of radiologists' work, enable automated triaging of radiological examinations, improve diagnostic accuracy, and support the prediction of disease progression and treatment outcomes. Furthermore, it has been demonstrated that the implementation of artificial intelligence may reduce patients' exposure to ionizing radiation while simultaneously improving the quality of radiological images. In addition, artificial intelligence can be utilized for the synthesis of radiological images and in the education and training of radiology residents. Despite these advantages, artificial intelligence also has several limitations. Evidence suggests that artificial intelligence does not always correctly perform the segmentation of anatomical and pathological structures. In addition, the development and application of artificial intelligence systems are often hindered by a lack of high-quality data, due to limited availability, data protection concerns, and potential data bias. Moreover, the operating principles of artificial intelligence are not yet fully understood; therefore, some specialists are skeptical about its integration into clinical practice. Nevertheless, artificial intelligence demonstrates significant potential in radiology and is expected to become an important assistant to radiologists in the future.

**Conclusions.** Artificial intelligence technologies, including machine learning, deep learning, and large language models, are becoming an important part of radiology. Artificial intelligence helps to improve the evaluation of radiological images and support diagnostic decision-making; it has significant potential to automate complex tasks and reduce the workload of radiologists. Despite its wide range of applications, its effective use is limited by technical, ethical, and legal challenges. In the future, broader use of multimodal systems is expected; however, at present, artificial intelligence is considered a supportive tool rather than a replacement for radiologists.

**Keywords.** Artificial intelligence; radiology; radiological images; machine learning; deep learning; large language models.

## 4. ĮVADAS

Šiuolaikinė medicina yra neatsiejama nuo sparčiai besivystančių skaitmeninių technologijų, tarp kurių ypatingą vietą užima dirbtinis intelektas (DI) (1). Radiologija yra viena iš medicinos sričių, kurioje DI vis plačiau taikomas klinikinėje praktikoje (2). Didėjant radiologinių vaizdų kiekiui ir įvairovei, radiologams tenka vis didesnis darbo krūvis, todėl atsiranda poreikis

priemonėms, galinčioms padidinti diagnostikos greitį, tikslumą ir efektyvumą (3). DI gali būti panaudojamas įvairiuose diagnostikos procesuose – nuo vaizdų analizės iki pagalbos priimant klinikinius sprendimus (2). Taigi DI tampa ne tik technologine naujove, bet ir svarbiu įrankiu, galinčiu pakeisti radiologo vaidmenį bei visą diagnostikos procesą (3).

Nepaisant sparčiai augančio DI taikymo, vis dar išlieka abejonių dėl jo patikimumo. Daugeliui specialistų, įskaitant radiologus, kyla klausimas, ar tikrai galima pasitikėti DI technologijomis. Šį nepasitikėjimą lemia įvairios priežastys, viena iš jų – ne visi specialistai turi pakankamai žinių apie DI (4,5). Taigi gydytojų nepasitikėjimą DI technologijomis galėtų sumažinti specialistų gilesnis DI metodų supratimas. Gydytojai turėtų žinoti, kaip yra sudarytas DI, kaip veikia jo algoritmai, kaip jis atlieka savo funkcijas ir kokios yra jo taikymo galimybės medicinoje (6). Taip pat labai svarbu, jog specialistai, naudodamiesi DI technologijomis, būtų susipažinę su tam tikrais DI privalumais ir trūkumais, nes tik tuomet galės kritiškai vertinti DI pateikiamus rezultatus (4–6). Be to, sveikatos priežiūros specialistai nerimauja, kad DI gali visiškai pakeisti gydytojus. Ar taip iš tikrųjų gali nutikti? Norint atsakyti į šį klausimą reikia suprasti, kaip DI yra naudojamas dabar ir kokios yra jo ateities perspektyvos (7–9).

Šiuo metu tarptautinėje mokslinėje literatūroje analizuojami įvairūs DI taikymo aspektai radiologijoje. Tačiau jo privalumai, trūkumai ir galimos ateities perspektyvos vis dar nėra pakankamai išsamiai ir sistemiškai apibendrintos. Dėl šios priežasties tikslinga apžvelgti ir apibendrinti esamus mokslinės literatūros duomenis, siekiant įvertinti DI vaidmenį šiuolaikinėje radiologijoje.

**Darbo tikslas** – apžvelgti naujausius literatūros šaltinius apie DI, jo taikymą radiologijoje bei susijusius privalumus, trūkumus ir ateities perspektyvas.

#### **Uždaviniai:**

1. Apžvelgti DI struktūrinius komponentus ir veikimo principus bei įvertinti jo taikymą radiologijoje.
2. Įvertinti, kokiais tikslais DI gali būti naudojamas radiologijoje bei kokius privalumus jis suteikia.
3. Įvertinti, su kokiais trūkumais, iššūkiais ir ribojančiais veiksniais susiduriama taikant DI radiologijoje.
4. Apžvelgti DI panaudojimo galimybes ir ateities perspektyvas radiologijoje.

## **5. DARBO METODIKA**

Darbo tipas – išplėstinė literatūros apžvalga. Literatūros apžvalga buvo atlikta 2024–2026 metais. Paieškos metu buvo siekiama surasti mokslinius straipsnius, susijusius su DI radiologijoje. Straipsniai buvo ieškomi „PubMed“ ir „ScienceDirect“ duomenų bazėse. Paieškos metu buvo naudojami tokie raktiniai žodžiai kaip „Artificial intelligence“, „Machine learning“, „Deep learning“, „Large language models“, „Radiology“, „Medicine“, „Medical imaging“ ir jų deriniai. Paieškų rezultatai buvo peržvelgti rankiniu būdu.

Įtraukimo kriterijai: straipsniai publikuoti 2016–2026 metais; straipsniai parašyti anglų kalba; pilno teksto moksliniai straipsniai. Atmetimo kriterijai: straipsniai parašyti ne anglų kalba; pasikartojantys straipsniai; straipsniai be viso teksto prieigos; konferencijų tezės; laiškai redaktoriams.

Straipsniai, atitikę įtraukimo kriterijus pagal jų pavadinimą, santrauką ir reikšminius žodžius, buvo atrinkti detalesnei pilno teksto analizei. Į galutinę literatūros apžvalgą įtraukti 64 anglų kalba publikuoti moksliniai straipsniai, kurių turinys buvo tiesiogiai susijęs su DI taikymu radiologijoje ir atitiko šio darbo tikslą.

## **6. REZULTATAI**

### **6.1. Dirbtinis intelektas**

#### **6.1.1. Dirbtinio intelekto sąvoka ir istorija**

Dirbtinis intelektas (DI) – tai kompiuterinių sistemų pagalba sukurtas specialus algoritmas, kuris gali nuspėti bei atlikti įvairius veiksmus reikalaujančius žmogui būdingo intelekto ir kognityvinių gebėjimų (10,11). Iš esmės, DI yra labai plati sritis, apimanti daug skirtingų metodų, skirtų tam, kad mašinos galėtų imituoti tokias žmogaus funkcijas kaip problemų sprendimas, vaizdų atpažinimas, mokymasis, kalbos supratimas bei įvairių sprendimų priėmimas (7,11).

Dirbtinių būtybių, gebančių mąstyti ir elgtis kaip žmonės, kūrimo idėja siekia senovės mitus ir legendas (7). Svarstymai, jog protingos mašinos galės pakeisti žmones, aptinkami ir senovės Graikijoje, Aristotelio darbuose. Viena savo veikalo „Politika“ skyriuje jis teigė: „Jeigu kiekvienas įrankis sugebėtų atlikti savo darbą, kai jam yra įsakoma, arba iš anksto tai suvokdamas, (...) meistrams nereikėtų nei padėjėjų, nei vergų“ (12). 1950-ieji tapo svarbiu etapu, nulėmusiu DI kūrimo pradžią. Alanas Turingas pasiūlė „Turingo testą“ – vertinimo metodą, skirtą nustatyti, ar mašinos geba imituoti

žmogaus intelektą. Šiuo darbu jis padėjo pamatus DI technologijų atsiradimui ir įgijo „DI tėvo“ (angl. „father of artificial intelligence“) vardą (7,13). Oficiali DI mokslo pradžia siejama su 1956 metais, kai Dartmuto konferencijoje pirmą kartą buvo pristatyta ir apibrėžta DI sąvoka (7,11,14,15). Vis dėlto, po šio proveržio DI raida nebuvo sparti, nes tuo metu technologinės galimybės ribojė šių metodų platesnį taikymą (15). DI srityje reikšminga pažanga įvyko vėlesniu laikotarpiu. Ją lėmė naujų technologijų ir metodų, kurie ženkliai pagerino DI sistemų efektyvumą, atsiradimas ir plėtra (13,15). Per pastarąjį dešimtmetį DI tapo populiaria tema ne tik mokslo bendruomenėje, bet ir už jos ribų (14). Kai 2022 metais lapkričio mėnesį „OpenAI“ pristatė „ChatGPT“, DI technologijos tapo kasdienio gyvenimo dalimi – ši programa naudojama tiek kasdieniams klausimams spręsti, tiek ir sudėtingoms užduotims atlikti (13). „ChatGPT“ tapo sparčiausiai augančia internetine programėle, per du mėnesius pritraukusia 100 mln. vartotojų (13).

### 6.1.2. Dirbtinio intelekto tipai

Šiuolaikinės DI sistemos yra sudarytos iš kelių tarpusavyje susijusių metodų, kurie skiriasi savo sudėtingumu ir veikimo principais (13,15,16). DI apima tokius metodus kaip mašininis mokymasis (angl. machine learning), gilusis mokymasis (angl. deep learning) bei didieji kalbos modeliai (angl. large language models). Šiuos metodus iš esmės galima suskirstyti tam tikru hierarchiniu principu (1 pav.) (16).




**1 pav.** DI hierarchija.  $DI > \text{mašininis mokymasis} > \text{gilusis mokymasis} > \text{natūralios kalbos apdorojimas} > \text{didieji kalbos modeliai}$  (pagal Rojas-Carabali et al. (2024)) (16).

#### 6.1.2.1 Mašininis mokymasis (angl. machine learning)

Mašininis mokymasis yra DI šaka, orientuota į algoritmų, gebančių atpažinti dėsningumus duomenyse ir iš jų mokytis, kūrimą (14). Mašininio mokymosi tikslas – analizuoti įvairias situacijas ir atlikti prognozes, remiantis surinktais duomenimis. Tai yra nuolatinis ir kartotinis

procesas, kurio metu optimizuojamas algoritmo veikimas (10). Priešingai nei klasikinis programavimas, kuriame kompiuteriui iš anksto pateikiamas aiškiai užprogramuotas algoritmas, mašininis mokymasis pats savarankiškai kuria algoritmus (2 pav.) (14). Iš esmės, mašininiam mokymuisi yra pateikiamas duomenų rinkinys, kuriuo remdamasis kompiuteris sukuria tam tikrą savo logiką, kuria remiantis galės atsakyti į būsimus klausimus (17). Medicinoje mašininis mokymasis galėtų būti pritaikytas prognostinei analitikai, pavyzdžiui, pacientų išeičių ar pakartotinio hospitalizavimo tikimybės prognozavimui. Šis metodas taip pat turi didžiulį potencialą tokiose srityse kaip radiologija ir onkologija, kur jis ypač efektyviai taikomas diagnostinių sprendimų optimizavimui (18). Mašininis mokymasis yra skirstomas į keturis tipus: prižiūrimą, neprižiūrimą, pusiau prižiūrimą ir sustiprintą mokymąsi (14).



**2 pav.** Klasikinio programavimo ir mašininio mokymosi palyginimas. (A) Klasikiniame programavime kompiuteriui kartu pateikiamas ir duomenų rinkinys, ir jau sukurtas algoritmas. Algoritmas nurodo kompiuteriui, kaip apdoroti duomenų rinkinį, kad būtų gauti rezultatai. (B) Mašininio mokymosi atveju kompiuteriui pateikiamas duomenų rinkinys ir su juo susiję rezultatai. Kompiuteris pats mokosi ir sukuria algoritmą, kuris apibūdina ryšį tarp duomenų ir rezultatų. Šis algoritmas gali būti naudojamas būsimų duomenų rinkinių analizei (pagal Choi et al. (2020)) (14).

Prižiūrimo mokymosi metodai pasižymi ypač gerais rezultatais, todėl yra plačiausiai taikomi mašininio mokymosi srityje. Prižiūrimo mokymosi atveju algoritmas naudoja mokomuosius įvesties bei išvesties duomenis. Tai reiškia, jog iš anksto yra suvedamos įvestys bei išvestys ir algoritmas mokosi atpažinti, kaip tam tikros įvestys yra susijusios su atitinkamomis išvestimis (11,17,19). Prižiūrimas mokymasis yra ypač tinkamas klasifikavimo užduotims, kai pageidaujami rezultatai yra iš anksto apibrėžti. Taigi šis metodas ypač efektyvus situacijose, kai yra pateikiami tam tikri konkretūs duomenys, kuriais remiantis reikia pateikti teisingą prognozę (11). Išmokęs nustatyti ryšius tarp įvesties požymių ir dominančio rezultato, apmokytas modelis gali tiksliai prognozuoti rezultatą anksčiau nematytuose atvejuose. Pavyzdžiui, jei modelis buvo apmokytas pateikiant magnetinio rezonanso tomografijos (MRT) vaizdus, kuriuose įvairūs dariniai buvo pažymėti kaip gerybiniai arba piktybiniai, jis vėliau galėtų prognozuoti, ar konkretus darinys yra vėžinis susirgimas, ar ne (19).

Neprižiūravimo mokymosi atveju algoritmo kūrimui nėra pateikiami išvesties duomenys (17,20). Neprižiūravimas mokymasis siekia aptikti duomenų rinkinio dėsningumus ir priskirti atskirus objektus atitinkamoms kategorijoms. Šis metodas vadinamas neprižiūravimu, nes duomenų reikšmės nėra iš anksto nustatytos – sąsajas tarp duomenų turi nustatyti pats algoritmas (14). Šis mašininio mokymosi metodas yra ypač tinkamas kuriant grupavimo bei asociacines užduotis, kai rezultatai nėra iš anksto nustatyti, leidžiant modeliui savarankiškai identifikuoti duomenyse esančius ryšius ir grupes (11,14). Pavyzdžiui, grupavimo algoritmai gali būti panaudojami pacientų grupavimui pagal jų genų ekspresijos profilius, taip atskleidžiant ligų pogrupius, kurie tradiciniais diagnostikos būdais galėjo būti nepastebėti (20).


Pusiau prižiūravimas mokymasis gali būti laikomas „aukso viduriu“ tarp prižiūravimo ir neprižiūravimo mokymosi. Šis metodas naudojamas tuomet, kai viena dalis duomenų turi savo konkrečias pažymėtas išeitis, o kita dalis ne. Toks mokymasis gali būti taikomas radiologinių vaizdų analizei, kai gydytojas pilnai aprašo tik nedidelę vaizdų dalį ir ją naudoja modeliui apmokyti. Vėliau šis modelis pritaikomas likusiems, pilnai neaprašytiems vaizdams klasifikuoti (14).

Sustiprintas mokymasis – tai mašininio mokymosi rūšis, kuri yra pagrįsta apdovanojimo ir bausmės principu. Šio mašininio mokymosi autonominis agentas sąveikauja su aplinka. Kiekvienas agento veiksmas daro tam tikrą poveikį aplinkai, kuri savo ruožtu suteikia grįžtamąjį ryšį, pagal kurį agentas priima tolimesnius sprendimus. Priklausomai nuo atliktų veiksmų bei grįžtamojo ryšio agentas yra apdovanojamas arba baudžiamas. Kaupdamas patirtį agentas palaipsniui optimizuoja savo elgesį taip, kad gautų kuo didesnę atlygį (14,20). Pagrindiniai sustiprinto mokymosi sistemos komponentai yra šie: 1) agentas – mokinytis, kuris bendraudamas su aplinka priima sprendimus; 2) aplinka – pasaulis, kuriame agentas atlieka tam tikrus veiksmus; 3) būseną – dabartinės aplinkos būseną, sąlygas; 4) veiksmas – bet koks agento atliekamas veiksmas galintis pakeisti aplinkos būseną; 5) atlygis – grįžtamasis signalas iš aplinkos; 6) vertės funkcija, kuri įvertina tikėtiną apdovanojimą už tam tikrus veiksmus (11).

#### **6.1.2.2. Gilusis mokymasis (angl. deep learning)**


Gilusis mokymasis – tai mašininio mokymosi plėtinys. Gilusis mokymasis imituoja žmogaus mąstymą pasitelkdamas dirbtiniais neuroniniais tinklais (10). Iš esmės, šie neuroniniai tinklai yra kuriami siekiant atkartoti žmogaus smegenų veikimo principus (21,22). Taigi neuroniniai tinklai veikia tokiu pačiu principu kaip ir žmogaus neuronai – juos sudaro mazgai (atitinkantys neurono kūną), kurie perduoda informaciją kitiems mazgams per tam tikras jungtis (analogiška dendritų ir aksonų veikimo principui) (3 pav.). Šios jungtys tarpusavyje komunikuoja per sinapses.

Jungčių stiprumas nusako kiekvieno neuroninio mazgo įtaką galutiniam atsakymui – kuo jungtis stipresnė, tuo labiau atitinkamas mazgas lemia galutinį rezultatą (14).



**3 pav.** Žmogaus neuronų ir dirbtinių neuroninių tinklų palyginimas. Pavaizduota, kad neuroninių tinklų struktūra yra paremta žmogaus neuronų veikimo principais, lyginant žmogaus neuroną (A) su dirbtiniu neuronu (B) (pagal Muthukrishnan et al. (2020)) (15).

Giliojo mokymosi neuroniniai tinklai susideda iš daugybės sluoksnių, todėl yra vadinami giliaisiais neuroniniais tinklais (11,14). Tokie neuroniniai tinklai susideda iš įvesties sluoksnio, išvesties sluoksnio ir tarp jų esančių paslėptųjų sluoksnių, kurių skaičius gali siekti nuo dešimties iki kelių šimtų (4 pav.) (14,21,22). Pagrindinė duomenų analizė vyksta paslėptuosiuose sluoksniuose, kur neuronai ieško dėsningumų ir atlieka matematinius veiksmus (15,22).



**4 pav.** Giliojo mokymosi neuroninio tinklo struktūra. Įvesties sluoksnis (geltona spalva), paslėptieji sluoksniai (raudona ir šviesiai mėlyna spalvos), išvesties sluoksnis (tamsiai mėlyna spalva) (pagal Chakraborty et al. (2024)) (21).

Neuroniniai tinklai gali būti kelių skirtingų tipų: tiesioginio sklidimo neuroniniai tinklai (angl. feed-forward neural networks), pasikartojantys neuroniniai tinklai (angl. recurrent neural networks) ir konvoliuciniai neuroniniai tinklai (angl. convolutional neural networks) (21). Informacija tiesioginio sklidimo neuroniniais tinklais yra perduodama tik pirmyn – informacija sklinda nuo įvesties sluoksnio, per paslėptuosius sluoksnius, iki išvesties sluoksnio. Tuo tarpu pasikartojantys neuroniniai tinklai leidžia informacijai judėti ne tik pirmyn, bet ir grįžti atgal į buvusius sluoksnius. Tokiu būdu pasikartojantys neuroniniai tinklai gali atsiminti ankstesnę informaciją ir ją panaudoti vėlesniuose žingsniuose.

Konvoliuciniai neuroniniai tinklai dažniausiai yra pritaikomi vaizdų apdorojimo srityje. Šie neuroniniai tinklai analizuoja vaizdus ne manipuliuodami kiekvienu pikseliu atskirai, o apdorodami vaizdą mažais filtrų blokais (14). Konvoliuciniai neuroniniai tinklai apdoroję šiuos filtrus iš pradžių aptinka paprastas struktūras, pavyzdžiui, linijas ar kampus. Gilesniuose neuroniniuose sluoksniuose šie paprasti elementai sujungiami į sudėtingesnes formas, kol galiausiai yra atpažįstamas visas objektas (23). Dėl šios savybės konvoliuciniai neuroniniai tinklai yra plačiai naudojami radiologinių vaizdų analizei (17,18). Šio tipo DI išmoksta atpažinti ir interpretuoti tokius vaizdus, su kuriais buvo supažindintas anksčiau. Kuo platesnė duomenų bazė pateikiama šiai giliojo mokymosi sistemai, tuo daugiau ji išmoksta ir tuo efektyviau analizuoja vaizdus. Pateikus pakankamą duomenų kiekį konvoliuciniai neuroniniai tinklai gali išmokti atpažinti ir išanalizuoti tūkstančius ar net milijonus skirtingų radiologinių vaizdų – tokį informacijos kiekį, kurio net ir patyrusiam ekspertui būtų paprasčiausiai neįmanoma išmokti atpažinti bei išanalizuoti per visą savo medicininę karjerą (24).

#### **6.1.2.3. Didieji kalbos modeliai (angl. large language models)**


Didieji kalbos modeliai – tai DI sistemos, kurios geba apdoroti ir generuoti natūralią žmonių kalbą. Šios sistemos pasižymi itin didele apimti bei sudėtinga architektūra. Didieji kalbos modeliai yra kuriami naudojant giliojo mokymosi metodus ir treniruojami pasitelkiant milžiniškus tekstinius duomenų rinkinius. Pagrindinis jų veikimo principas yra sekos modeliavimas – kompiuteris mokosi prognozuoti, koks turėtų būti kitas naudojamas žodis pateiktoje žodžių sekoje. Vienas iš žinomiausių didžiųjų kalbos modelių pavyzdžių galėtų būti „ChatGPT“ programa. Medicinoje didieji kalbos modeliai galėtų būti pritaikomi klinikinių sprendimų palaikymui, medicininių tekstų kūrimui bei pacientų informavimo ir komunikacijos procesų tobulinimui (25).

#### **6.1.3. Dirbtinio intelekto pritaikymas radiologijoje**

Laiku atliekama ligų diagnostika ženkliai pagerina pacientų gydymo rezultatus, mažindama sergamumą ir mirtingumą. Viena svarbiausių diagnostikos priemonių yra radiologiniai

vaizdiniai tyrimai, kurie yra plačiai taikomi ligų nustatymui, gydymo planavimui ir gydymo rezultatų stebėsenai (26). Nuo to laiko, kai 1895 metais buvo atlikta pirmoji rentgenograma, įvyko didžiulė technologijų pažanga (27). Ši pažanga reikšmingai prisidėjo prie tikslesnės sudėtingų anatominių struktūrų ir fiziologinių procesų vizualizacijos bei interpretacijos, taip pagerindama diagnostikos ir gydymo rezultatus. Įvairūs vaizdinimo metodai, įskaitant rentgeno tyrimą, MRT, kompiuterinę tomografiją (KT) ir pozitronų emisijos tomografiją (PET), nors ir turi savitų trūkumų, atlieka svarbų vaidmenį nustatant, diagnozuojant ir valdant įvairias medicinines būkles. Tačiau greita technologijų pažanga atvėrė naujas galimybes radiologinių vaizdų analizėje – atsirado galimybė pasitelkti DI technologijas šių vaizdų interpretacijai ir apdorojimui (26).

2009 metais išleidus „ImageNet“ atsirado palankios sąlygos DI technologijų vystymuisi ir panaudojimui radiologijoje (13). „ImageNet“ – plataus masto vaizdinių duomenų rinkinys, kuris gali būti naudojamas DI modelių treniravimui, siekiant, kad DI gebėtų analizuoti radiologinius vaizdus. Būtent ši duomenų bazė paskatino DI sistemų kūrimą ir jų integravimą į klinikinę praktiką (13). 2019 metais Jungtinėse Amerikos Valstijose Maisto ir vaistų administracija (FDA) patvirtino 77 medicininius DI įrenginius, o Europoje CE (angl. European Conformity) ženklą buvo pažymėta apie 100 tokių įrenginių (8). Tuo tarpu radiologijos srityje 2024 metais Europoje iš viso buvo patvirtinta 213 DI programų (28). FDA 2025 metų duomenimis patvirtino 48 DI programas pilvo organų vaizdinimui, 46 DI programas krūtų vaizdinimui, 67 DI programas širdies vaizdinimui, 41 DI programą raumenų ir kaulų sistemos vaizdinimui ir 112 DI programų neuroradiologijai. Taigi DI technologijos gali būti taikomos įvairių patologijų diagnostikai (5 pav.) (13).



**5 pav.** FDA patvirtintų DI programų naudojimas radiologijoje. 29 % naudojama vėžio diagnostikoje, 8 % plaučių mazgų diagnostikoje, 13 % traumų, Alzheimerio ligos, pneumonijos, koronarinių arterijų ligos, insulto diagnostikoje, 50 % kitų ligų diagnostikoje (pagal Metin et al. (2025)) (13).

DI, ypač gilusis mokymasis, yra integruojamas ir į kompiuterinio aptikimo (angl. computer-aided detection) programas. Kompiuterinis aptikimas jau daugelį metų atlieka reikšmingą vaidmenį radiologijoje, suteikdamas pagalbą radiologams aptikti patologinius pakitimus radiologiniuose vaizduose. Kompiuterinio aptikimo metodai yra pritaikomi skirtinguose radiologiniuose tyrimuose – jie gali būti naudojami KT, MRT, atliekant mamografijas. Taigi kompiuterinis aptikimas gali padėti radiologui atpažinti įtartina radinį ir taip prisidėti prie tikslesnės diagnostikos (29).


Kompiuterinė rega (angl. computer vision) – tai dar viena DI sritis, kuri turi didžiulį potencialą radiologijoje. Ši technologija taip pat geba atlikti automatizuotą radiologinių vaizdų analizę ir padėti radiologams atpažinti anatomines struktūras bei šių struktūrų patologinius pakitimus (29).

Lietuvoje, kaip ir visame pasaulyje, yra kuriamos ir testuojamos DI programos, kurios galėtų būti panaudojamos medicinos srityje. Lietuvių įmonė „Oxipit“ sukūrė DI programinę įrangą „ChestLink“, kuri analizuoja krūtinės rentgenogramas ir nustato, ar rentgenograma yra normali ar patologinė. Ši DI sistema išvadą sugeneruoja per 10 sekundžių, taip suteikdama galimybę radiologui operatyviai identifikuoti radiogramas, kurioms yra būtina skubesnė peržiūra. Ši DI programinė įranga gavo patvirtinimą naudojimui Europos Sąjungoje (30). Kita neseniai lietuvių sukurta DI programinė įranga „Ligence Heart“ yra skirta širdies echoskopijos vaizdams analizuoti. Ši programinė įranga automatizuoja vaizdų analizę, todėl yra suteikiami tikslūs širdies matavimai, kuriais remiantis galima nustatyti tikslesnę diagnozę (31).

## **6.2. Dirbtinio intelekto privalumai radiologijoje**


### **6.2.1. Darbo efektyvumo didinimas**

DI atsiradimą ir plėtrą radiologijoje pirmiausia paskatino siekis padidinti darbo efektyvumą ir veiksmingumą (3). Kiekvienais metais yra atliekama ir išanalizuojama apie 3,6 mlrd. radiologinių vaizdų visame pasaulyje (32). Peng ir kiti bendraautoriai (2022) nustatė, jog per 15 metų (nuo 2005 metų iki 2020 metų) radiologinių vaizdų, išgautų naudojant rentgeno, KT ir MRT tyrimus, skaičius išaugo beveik 12 kartų (6 pav.) (33). Sparčiai augant radiologinių vaizdų skaičiui, vis labiau jaučiamas kvalifikuotų specialistų, galinčių šiuos vaizdus laiku ir tiksliai įvertinti, trūkumas. Siekdami kompensuoti šią problemą, radiologai privalo padidinti savo darbo našumą. Dėl to radiologams tenka vis didesnis darbo krūvis (3,33).



**6 pav.** *Augančių radiologinių tyrimų (rentgeno, KT ir MRT) skaičius nuo 2005 metų iki 2020 metų. Diagrama vaizduoja, kiek kartų padaugėjo radiologinių tyrimų lyginant su 2005 metais (pagal Peng et al. (2022)) (33).*

Tyrimai rodo, kad kai kuriais atvejais radiologas, siekdamas patenkinti darbo krūvio reikalavimus, per 8 valandų darbo dieną vienam vaizdui išanalizuoti galėtų paskirti tik apie 3–4 sekundes (3,33). Jau minėto Peng ir kitų bendraautorių (2022) tyrimo metu nustatyta, jog nuo 2005 metų iki 2020 metų vidutinis laikas, skirtas vaizdų interpretavimui, sumažėjo nuo 16 iki 2,9 sekundžių (vidutiniškai laikas vaizdų interpretavimui kasmet mažėjo po pusę sekundės) (7 pav.) (33). Taigi nenuostabu, jog esant tokioms sąlygoms didėja klaidų skaičius, nes paprasčiausiai yra skiriama per mažai laiko radiologinio vaizdo analizei (3,33). Tačiau radiologinį vaizdą reikia ne tik išanalizuoti, bet ir aprašyti. Taigi radiologai susiduria su keliais skirtingais iššūkiais: per limituotą laiką jie turi ne tik išlaikyti didelį diagnostinį tikslumą, bet ir užtikrinti laiku pateikiamas išvadas (34).



**7 pav.** *Vieno radiologinio vaizdo analizės trukmės (sekundėmis) kitimas 2005–2020 metų laikotarpiu (pagal Peng et al. (2022)) (33).*


Augantis radiologinių vaizdų skaičius kartu su mažėjančiu interpretavimo laiku skatina radiologų perdegimą. Manoma, jog nuo 61 % iki 92,5 % radiologų susiduria su perdegimo problema (33). Perdegimas prisideda prie didesnio klaidų skaičiaus ir mažesnio darbo efektyvumo. Iš radiologų tikimasi ne tik greito vaizdų interpretavimo, bet ir greitai pateikiamų išvadų apie patologiją. Didėjant darbo krūviui ilgėja darbo valandos, todėl radiologai jaučia nuovargį, nerimą ir sumažėjusį entuziazmą darbui (33).

DI galėtų padidinti radiologų darbo efektyvumą sumažindamas jų darbo krūvį. Užduotys, kurias galėtų atlikti DI – tai išvadų bei aprašymų generavimas (34). Šioms užduotims atlikti gali būti pasitelkiami didieji kalbos modeliai, kurie gali sukurti aprašomąjį tekstą ir paruošti išvadas (25,34). DI technologijų panaudojimas radiologinių vaizdų aprašymų ir išvadų rengimui sumažina rutininių radiologų atliekamų užduočių kiekį ir leidžia jiems susitelkti į sudėtingesnių atvejų analizę. Taip yra padidinamas ne tik darbo efektyvumas, bet ir kokybė. Neseniai atliktuose tyrimuose teigiama, jog naudojant DI radiologinės išvados yra pateikiamos žymiai greičiau. Pavyzdžiui, Rajmohamed ir kitų bendraautorių (2025) atliktame tyrime buvo nustatyta, jog DI gali sutrumpinti išvadų pateikimo laiką 45 % – nuo įprastų 6,10 min. iki 3,43 min. (34). Kitas Jorg ir kitų bendraautorių (2024) tyrimas nustatė, kad DI ne tik sutrumpino išvadų pateikimo laiką, bet ir pagerino jų kokybę (35). Kadangi radiologams nereikėjo patiems rankiniu būdu rašyti teksto, jų darbas tapo greitesnis ir sklandesnis (34,35). Taigi DI gali padėti radiologams greičiau ir tiksliau sukurti radiologinius aprašymus bei išvadas taip sumažindamas radiologų darbo krūvį ir padidindamas darbo efektyvumą (34).

### **6.2.2. Rūšiavimas**

Radiologiniai tyrimai yra viena iš svarbiausių skubiosios pagalbos skyriaus diagnostikos priemonių. Gydytojai privalo skubiai įvertinti pacientų būklę ir nustatyti, kuriems pacientams yra reikalinga neatidėliotina pagalba (13). Laiku nustatyta diagnozė ar atlikta intervencija gerina pacientų prognozes. Diagnozės nustatymo laikas yra ypač svarbus esant kritinėms būklėms, pavyzdžiui, diagnozuojant insultą, kur dažnai vartojama frazė „laikas – tai smegenys“ (angl. „time is brain“). DI analizuodamas KT vaizdus ir angiogramas gali nedelsiant perspėti radiologus bei intervencinę komandą esant didelių kraujagyslių užsikimšimui ar kraujavimui į smegenis (36). Taigi DI gali būti naudojamas kaip pacientų rūšiavimo priemonė. DI galėtų perspėti specialistus apie tokius įtartinus radinius kaip išeminis insultas (8 pav.), intrakranijinis kraujavimas ar plaučių embolija. Tokiu atveju radiologas galėtų iškart analizuoti vaizdus, kurie yra didesnės svarbos ir reikalauja neatidėliotino aprašymo bei išvadų pateikimo (13). DI tokius radiologinius vaizdus paprasčiausiai pažymėtų kaip patologinius, todėl specialistas galėtų juos nedelsiant peržiūrėti – jiems būtų

suteikiama pirmenybė. Vaizdus, kurie pažymėti kaip ne patologiniai, radiologas aprašytų vėliau. Tokiu atveju būtų greičiau diagnozuojamos ir gydomos įvairios kritinės būklės (18).



**8 pav.** Pademonstruota, kaip 11 skirtingų DI modelių aptinka išeminį insultą. (A) paciento KT vaizdas, (B) žmogaus ranka pažymėta išemijos zona („ground truth“), (C-F) KT perfuzijos vaizdai, (G-Q) skirtingų DI modelių pažymėtos išemijos zonos: (G) UNet3D, (H) ERFNet, (I) UShape, (J) USSNet, (K) TransBTS, (L) UNETR, (M) CLCI-Net, (N) X-Net, (O) SPiN, (P) nnUnet, (Q) HUT (pagal Soh et al. (2023)) (37).

### 6.2.3. Diagnostinis tikslumas


Pagrindinis radiologų darbo principas – vizualiai vertinti radiologinius vaizdus ir aprašyti patologinius radinius. Šis vertinimas gali būti gana subjektyvus, nes jis dažniausiai priklauso nuo specialisto sukauptos klinikinės patirties. Dėl šio subjektyvaus požiūrio didėja klaidų skaičius.

Tuo tarpu DI, sukaupęs visą informaciją apie tam tikras patologijas, radiologinius vaizdus galėtų įvertinti objektyviau (3). DI technologijų taikymas radiologijos srityje atvėrė naujas galimybes didesniai diagnostiniam tikslumui pasiekti. Kai kurie DI algoritmai gali pasiekti diagnostinį tikslumą, prilygstantį radiologų rezultatams arba juos net pranokstant (13,38). Pavyzdžiui, Cheikh ir kitų bendraautorių (2022) atliktame tyrime nustatyta, jog analizuojant KT vaizdus DI papildomai aptiko 19 plaučių embolijos atvejų, kurių radiologai analizuodami vaizdus nepastebėjo (38).

Plesner ir kiti bendraautoriai (2023) išbandė DI programą „ChestLink“, kuriai buvo pateikiamos plaučių rentgenogramos (30). DI turėjo nustatyti, kurios iš jų yra patologinės. „ChestLink“ programai pavyko pasiekti 99 % jautrumą – iš 1100 pacientų, kurie turėjo patologinių pakitimų, net 1090 atvejų buvo sėkmingai atpažinti (30). Taigi DI gali gana tiksliai nustatyti teisingą diagnozę (30). DI taip pat gali, remdamasis MRT vaizdais, gana tiksliai įvertinti širdies hemodinaminę funkciją apibūdinančius parametrus ir taip nustatyti tokias patologijas kaip hipertrofinė bei dilatacinė kardiomiopatija. Guo ir kitų bendraautorių (2022) tyrime DI, paremtas giliojo mokymosi konvoliuciniais neuroniniais tinklais, pasižymėjo dideliu jautrumu ir specifiškumu identifikuojant kairiojo skilvelio funkcinius ir tūrinius rodiklius, būdingus dilatacinei kardiomiopatijai (39). Dilatacinei kardiomiopatijai nustatyti DI apskaičiavo kairiojo skilvelio galinį diastolinį tūrį, galinį sistolinį tūrį, bendrą sistolinį tūrį bei išmetimo frakciją. Remiantis MRT vaizdų analize, galinio diastolinio tūrio nustatymo jautrumas siekė 90 %, o specifiškumas – 83,7 %, galinio sistolinio tūrio – atitinkamai 96,15 % ir 85,19 %, o išmetimo tūrio – 92,31 % ir 82,96 % (39). Taigi DI gali padėti radiologams tiksliau aprašyti širdies MRT vaizdus automatiškai apskaičiuodamas reikalingus širdies funkcinius ir tūrinius parametrus (39). DI taip pat gali tiksliai nustatyti tokią patologiją kaip insultas. Agripnidis ir kiti bendraautoriai (2025) atliko tyrimą, kuriame DI, paremtas konvoliuciniais neuroniniais tinklais, analizuodamas KT vaizdus turėjo diagnozuoti insultą (40). DI programai buvo pateikiami galvos smegenų KT vaizdai be kontrasto intracerebrinių hemoragijų nustatymui ir KT angiografijos vaizdai išeminio insulto nustatymui. Intracerebrinių hemoragijų nustatymo tikslumas siekė 94,6 %, o išeminio insulto – 86,4 % (40). Kitas tyrimas, kurį atliko Cohen ir kiti bendraautoriai (2023) parodė, jog DI gali gana tiksliai diagnozuoti kaulo lūžius iš rentgenogramų (41). Šiame tyrime buvo tiriama, ar neuroniniais tinklais paremtas DI gali tiksliau diagnozuoti riešo kaulų lūžius rentgenogramose nei radiologijos rezidentai bei bendrosios praktikos radiologai. DI pasiekė didesnę jautrumą – 83 %, palyginti su radiologijos rezidentų ir bendrosios praktikos radiologų pasiektais 76 %, o specifiškumas buvo vienodas – 96 % (41). Šiame tyrime DI pademonstravo didelį diagnostinį tikslumą (41). Taigi daugelis tyrimų rodo, jog DI gali gana tiksliai diagnozuoti įvairias patologijas atliekant skirtingus radiologinius tyrimus. Radiologai DI gali panaudoti kaip pagalbines priemones, kuri reikšmingai sumažina klaidų skaičių (42,43).

DI taip pat pasižymi dideliu tikslumu ankstyvoje navikų diagnostikoje ir jų klasifikacijoje, nes šiuolaikinės DI technologijos gali aptikti tokias struktūras, kurios kartais nėra pastebimos plika akimi (42,44). Ankstyvas vėžio nustatymas yra esminis veiksnys, užtikrinantis sėkmingą gydymą ir didesnę išgyvenamumo tikimybę. Hernström ir kitų bendraautorių (2025) atliktas tyrimas parodė, jog atliekant mamografijas dėl ankstyvo krūties vėžio aptikimo DI taikymas leido aptikti 29 % daugiau ankstyvųjų vėžio formų, palyginti su tradicine diagnostika be DI (45). Taigi DI taikymas klinikinėje praktikoje gali reikšmingai padidinti ankstyvųjų vėžio atvejų nustatymą (45). DI taip pat yra gana patikimas įrankis navikų klasifikacijai. Navikų piktybiškumas dažnai siejamas su tokiomis savybėmis kaip forma, dydis ir tekstūra. Šių požymių atpažinimas daugeliu atvejų priklauso nuo specialisto patirties, tačiau žmogui dažnai būna sudėtinga objektyviai įvertinti visus kiekybinius parametrus. Tuo tarpu DI geba šiuos požymius identifikuoti automatiškai (3). Shivwanshi ir kiti bendraautoriai (2025) pademonstravo, jog DI gali tiksliai atlikti plaučių navikų klasifikaciją (44). Šio tyrimo metu DI buvo pateikti plaučių KT vaizdai, ir DI turėjo suklasifikuoti matomus darinius į 5 grupes. DI pavyko tai atlikti 96,74 % tikslumu išlaikant 98,47 % specifiškumą (44). Akkus ir kiti bendraautoriai (2017) atliko tyrimą, kuriame pasitelkė konvoliucinius neuroninius tinklus siekdami nustatyti, ar gliomos turi 1p/19q kodeleciją (46). Gliomos su 1p/19q kodelecija teigiamai atsako į chemoterapiją ir radioterapiją, todėl yra svarbu suklasifikuoti šias gliomas, tačiau paprastai tai yra daroma atliekant biopsijas. Šio tyrimo metu buvo nustatyta, jog DI gali gana tiksliai suklasifikuoti gliomas pasitelkiant MRT vaizdus. DI gliomas suklasifikavo 87,7 % tikslumu išlaikydamas 93,3 % jautrumą ir 82,2 % specifiškumą (46). Taigi DI gali padėti radiologams tiksliau ir efektyviau diagnozuoti įvairius navikinius darinius bei taip prisidėti prie geresnių pacientų išiečių (42).

DI geba gana tiksliai identifikuoti įvairius darinius dėl segmentavimo funkcijos. Segmentavimo metu vaizdas yra padalijamas į atskiras sritis, atitinkančias dominančius objektus, remiantis jų savybėmis, tokiomis kaip intensyvumas, forma, tekstūra ar erdvinė padėtis. Šių objektų ribos apibrėžiamos pikselių tikslumu dvimačiuose vaizduose ir vokselių tikslumu trimatėse struktūrose, taip sudarant dominančių anatominių ar patologinių darinių kontūrus (3). Tie ir kiti bendraautoriai (2021) išbandė neuroniniais tinklais paremtą DI modelį, kuris, analizuodamas MRT vaizdus, segmentavo gliomas (47). Buvo vertinama, kiek DI atlikta segmentacija sutampa su žmogaus ranka atlikta segmentacija (angl. „ground truth“). Šiam tikslui buvo skaičiuojami koeficientai trims naviko sritims: visam navikui, naviko branduoliui ir kontrastą kaupiančiai naviko daliai; atitinkamai gautos koeficientų reikšmės buvo 0,901, 0,815 ir 0,766 (9 pav.), kai koeficiento reikšmė, lygi 1, rodo visišką segmentacijų sutapimą (47).




**9 pav.** Pademonstruota, kaip atrodo DI segmentavimas MRT tyrime. Geltona spalva žymi kontrastą kaupiantį naviko branduolį, žalia – edemą, raudona – nekrozinį ir kontrasto nekaupiantį naviko branduolį. (a) FLAIR seka, (b) T1 seka, (c) T1 seka su gadoliniu, (d) T2 seka, (e) žmogaus ranka sudaryta segmentacija („ground truth“), (f) ir (g) skirtingų DI programų segmentavimas (pagal Tie et al. (2021)) (47).

Taigi DI technologijos gali atlikti tokias svarbias funkcijas kaip radiologinių vaizdų klasifikavimas ir segmentavimas. Šios funkcijos gali būti atliekamos pasitelkiant įvairius radiologinius metodus, tokius kaip rentgeno tyrimas, KT, MRT ir ultragarsinis tyrimas. Galima sakyti, jog dar vienas DI privalumas – galimybė pritaikyti DI metodus atliekant skirtingo tipo radiologinius tyrimus (42). DI analizuodamas radiologinius vaizdus taip pat gali atpažinti didžiulį spektrą ligų. DI gali atpažinti tokias patologijas kaip Alzheimerio ligą, tuberkuliozę, pneumoniją, insultą, kepenų ligas bei įvairaus tipo navikus (42,43). Taigi DI gali padidinti diagnostinį tikslumą ieškant įvairių patologijų (42).

#### 6.2.4. Prognozavimas

DI gali būti naudojamas ne tik įvairių patologijų diagnostikai, bet ir klinikinių baigčių prognozavimui. Gilusis mokymasis analizuodamas radiologinius vaizdus gali prognozuoti pacientų išgyvenamumą, ligos progresavimą bei ligos atsinaujinimą (27). He ir kiti bendra autoriai (2019) atliko tyrimą, kuriame konvoliuciniai neuroniniai tinklai remdamiesi MRT vaizdais prognozavo kaulų gigantiųjų ląstelių navikų recidyvą po atlikto kiuretažo (48). Šiame tyrime dalyvavo 56 pacientai, kuriems histologiškai buvo patvirtinti kaulų gigantiųjų ląstelių navikai. Dėl šios patologijos

recidyvo pacientai buvo stebimi apie 5,8 metus. Buvo lyginama, kaip tiksliai navikų recidyvą gali prognozuoti konvoliuciniai neuroniniai tinklai, radiologai ir konvoliuciniai neuroniniai tinklai su integruotu logistiniu regresijos modeliu, kuriam buvo pateikta tokia klinikinė informacija kaip pacientų amžius ir naviko lokalizacija. Konvoliuciniais neuroniniais tinklais paremtas DI modelis navikų recidyvus prognozavo 75,5 % tikslumu išlaikydamas 85,7 % jautrumą. Tuo tarpu radiologų tikslumas siekė 64,3 %, o jautrumas – 58,3 % (48). Taigi DI pasiekė didesnę tikslumą ir jautrumą atliekant navikų recidyvo prognozavimą lyginant su radiologais. Tuo tarpu konvoliuciniai neuroniniai tinklai su integruotu logistiniu regresijos modeliu pasiekė dar geresnius rezultatus – tikslumas siekė 78,6 %, o jautrumas – 87,5 %. Konvoliucinių neuroninių tinklų su integruotu logistiniu regresijos modeliu ir radiologų gautas specifiškumas buvo vienodas – 75 % (48). DI gali prognozuoti ne tik navikų recidyvus, bet ir kitų patologijų išeitis, pavyzdžiui, analizuodamas širdies radiologinius vaizdus DI gali nustatyti kardiovaskulinių įvykių riziką (10 pav. **10 pav.**) (49). Taigi DI gali prognozuoti klinikines išeitis, taip palengvindamas gydymo planavimą ir pagerindamas pacientų išgyvenamumą (27).



**10 pav.** DI, remdamasis mašininio ir giliojo mokymosi, gali analizuoti radiologinius širdies vaizdus ir pagal juos nustatyti širdies patologiją bei įvertinti kardiovaskulinių įvykių riziką (pagal Slart et al. (2021)) (49).

### 6.2.5. Jonizuojančiosios spinduliuotės apšvitos mažinimas ir vaizdo kokybės gerinimas

Pagrindinis radiacinės saugos principas – ALARA principas (angl. As Low As Reasonably Achievable). Tai reiškia, jog kiekvieną radiologinį tyrimą reikia atlikti taip, kad pacientas patirtų kuo mažesnę jonizuojančiosios spinduliuotės apšvitos dozę, kartu išlaikant pakankamą diagnostinio vaizdo kokybę. Apšvitą galima sumažinti keliais būdais: sumažinant jonizuojančiųjų spindulių apšvitos dozę arba sutrumpinant skenavimo laiką (50). Tačiau šiais būdais sumažinus apšvitą, atsiranda papildomas triukšmas, kuris reikšmingai pablogina radiologinių vaizdų kokybę ir


taip apsunkina jų vertinimą (50,51). Radiologijoje aukšta vaizdų kokybė yra vienas pagrindinių veiksnių, lemiančių diagnostinio vertinimo patikimumą ir tikslumą. Radiologijoje susiduriama ir su kitais veiksniais, kurie blogina vaizdų kokybę. Tokie vaizdinimo metodai kaip KT, MRT ir ultragarsas dėl tam tikrų įrangos techninių apribojimų gali sukurti nepakankamos kokybės vaizdus. Branduolinės medicinos metodai, tokie kaip PET ir vieno fotono emisijos KT (SPECT), susiduria su panašiais iššūkiais dėl signalo svyravimų ir paciento judesių. Taigi radiologijoje svarbu taikyti vaizdo gerinimo metodus, kurie užtikrina aukštesnę vaizdų kokybę ir didesnę diagnostinį tikslumą. Tačiau tradiciniai metodai dažnai nepasiteisina (27). Pavyzdžiui, KT vaizdams pagerinti yra naudojama iteratyvi rekonstrukcija (angl. iterative reconstruction) – matematinis algoritmas, kuris gali pagerinti vaizdų kokybę esant mažesnei jonizuojančiosios spinduliuotės apšvitos dozei. Tačiau kai kurie tyrimai rodo, jog iteratyvios rekonstrukcijos algoritmų taikymas gali lemti susiliejusį, dėmėtą, su artefaktais ar tiesiog nenatūralų vaizdą, nes dauguma iteratyvios rekonstrukcijos algoritmų modifikuoja ne tik patį triukšmą, bet ir pakeičia vaizdo tekstūrą, todėl vaizdas praranda savo kokybę (51). Taigi nauji metodai, tokie kaip DI algoritmai, ypač gilusis mokymasis, pasižymi didžiule perspektyva vaizdų kokybės gerinime (27).

Cao ir kiti bendraautoriai (2021) tyrė, ar giliojo mokymosi pagrindu veikiantis vaizdų rekonstrukcijos algoritmas gali užtikrinti pakankamą KT vaizdų kokybę esant itin mažai jonizuojančiosios spinduliuotės apšvitos dozei, lyginant jį su iteratyvios rekonstrukcijos algoritmu (51). Tyrime dalyvavo pacientai, kuriems kepenyse buvo nustatyti įvairaus pobūdžio židiniai. Jiems buvo atlikta trijų fazių KT: arterinė, portinė veninė ir vėlyvoji fazė. Arterinė bei portinė veninė fazės buvo atliktos naudojant standartinį, iš anksto nustatytą triukšmo indeksą, kuris buvo lygus 11. Tuo tarpu vėlyvajai fazei panaudotas triukšmo indeksas, buvo lygus 24. Didėjant triukšmo indeksui, mažėja jonizuojančiosios spinduliuotės apšvitos dozė, tačiau didėja vaizdo triukšmas. Taigi padidinus triukšmo indeksą vėlyvojoje fazėje, jonizuojančiosios spinduliuotės dozė sumažėjo 76 % lyginant su arterine faze – nuo  $3,18 \pm 0,48$  mSv iki  $0,76 \pm 0,09$  mSv (51). Padidėjus triukšmo lygiui vėlyvojoje fazėje buvo lyginama, kuris metodas – gilusis mokymasis ar iteratyviosios rekonstrukcijos algoritmas – geriau rekonstruoja vaizdus ir išlaiko aukštesnę vaizdų kokybę. Kiekybinė analizė parodė, kad giliojo mokymosi metodai reikšmingai sumažino vaizdo triukšmą kepenų parenchimoje, blužnyje, aplinkiniuose raumenyse ir kepenų židiniuose, palyginti su iteratyviosios rekonstrukcijos algoritmu. Pavyzdžiui, kepenų parenchimoje triukšmas, matuojant Hounsfieldo vienetais (Hv), taikant gilųjį mokymąsi siekė  $14,77 \pm 2,61$  Hv, o naudojant iteratyviosios rekonstrukcijos algoritmą –  $24,95 \pm 4,32$  Hv (51). Galutiniai vaizdai taip pat buvo įvertinti radiologų specialistų, kurie giliojo mokymosi rekonstruotus vaizdus vertino kaip geros kokybės vaizdus. Taigi šis tyrimas parodė, jog gilusis mokymasis gali reikšmingai sumažinti vaizdo triukšmą ir taip pagerinti vaizdo kokybę. Šią funkciją DI gali atlikti net ir esant 76 % mažesnei jonizuojančiosios spinduliuotės dozei, nes vaizdo kokybė

išlieka tokia pati gera kaip ir naudojant standartinį jonizuojančiosios spinduliuotės apšvitos dozės protokolą (51).

Kitas apšvitos mažinimo metodas – skenavimo laiko trumpinimas. Pan ir bendraautoriai (2022) atliko tyrimą, kurio metu buvo sutrumpintas SPECT tyrimo laikas ir, taikant giliojo mokymosi metodus, pagerinta vaizdo kokybė (50). Pacientams, turintiems kaulų patologiją, buvo atliktas kaulų SPECT tyrimas. Tyrimo metu buvo taikomi du protokolai: standartinis skenavimas, skiriant 20 sekundžių vienai projekcijai, ir greitis skenavimas, skiriant 3 sekundes vienai projekcijai. Taigi greitojo skenavimo metu bendra skenavimo trukmė buvo beveik 7 kartus trumpesnė nei standartinio skenavimo (50). Sutrumpėjus skenavimo laikui vaizduose buvo matoma daugiau triukšmo, tačiau triukšmo panaikinimui buvo panaudotas gilusis mokymasis. Rezultatai parodė, jog taikant gilųjį mokymąsi vaizdų kokybė ženkliai pagerėja ir priartėja prie standartinių SPECT vaizdų kokybės. Taigi šio tyrimo metu, beveik 7 kartus sutrumpinus skenavimo laiką, buvo sumažinta jonizuojančiosios spinduliuotės apšvitos dozė, tačiau vaizdų kokybė nenukentėjo, nes jų rekonstrukcijai buvo panaudotas DI (50).

Šie tyrimai bei daugelis kitų demonstruoja, jog DI gali sumažinti pacientų patiriamą apšvitą, tuo pačiu išlaikydamas aukštą vaizdų kokybę (11 pav. **11 pav.**). DI reikšmingai sumažina triukšmą vaizduose ir taip pagerina įvairių būklių bei patologijų diagnostiką (27,50,51).




**11 pav.** DI metodais pašalintas triukšmas KT vaizduose. Matomi du KT vaizdų pjūviai: kairėje – KT vaizdai gauti taikant mažą jonizuojančiosios spinduliuotės apšvitos dozę, viduryje – DI pašalina mažų dozių KT vaizdų triukšmą, dešinėje – matoma, kaip tie patys KT vaizdai atrodo naudojant standartinę jonizuojančiosios spinduliuotės apšvitos dozės protokolą. Matoma, jog DI ženkliai pagerina triukšmingų KT vaizdų kokybę (pagal Su et al. (2025)) (52).

### 6.2.6. Radiologinių vaizdų sintezė

DI gali būti taikomas radiologinių vaizdų sintezei. Šiuo metu yra sukurta nemažai giliojo mokymosi algoritmų, kurie galėtų būti sėkmingai pritaikyti klinikinėje praktikoje pseudo-KT, sintetinės MRT ir sintetinės PET vaizdų sintezei (13).

Pseudo-KT – tai dirbtinai sugeneruotas KT vaizdas, gautas ne iš tikro KT tyrimo, o iš kito vaizdinimo metodo, dažniausiai – iš MRT (12 pav.). Šį sugeneruotą KT vaizdą gali išgauti DI technologijos (53). Pseudo-KT gali būti naudingas tyrimas labiau pažeidžiamoms pacientų grupėms, pavyzdžiui, vaikams arba vėžiu sergantiems pacientams (13,53,54). Liu ir kiti bendraautoriai (2019) pritaikė giliojo mokymosi metodus MRT vaizdams paversti į KT vaizdus radioterapijos planavimui (55). Sugeneruotų pseudo-KT vaizdų tikslumas buvo vertinamas lyginant juos su KT tyrimo metu gautais vaizdais, o panašumui nustatyti buvo taikytas Dice koeficientas. Dice koeficientas apibūdina struktūrų tarpusavio sutapimą, kai reikšmė, lygi 1, atitinka tobulą sutapimą. Tyrimo rezultatai parodė, kad Dice koeficientas oro turinčioms sritims siekė  $0,95 \pm 0,01$ , minkštiesiems audiniams –  $0,94 \pm 0,02$ , o kauliniam audiniui –  $0,85 \pm 0,02$  (55). Tai rodo aukštą pseudo-KT ir tikrojo KT tyrimo metu gautų vaizdų atitikimą (55). Taigi giliojo mokymosi sugeneruoti pseudo-KT vaizdai turi potencialą klinikiniam taikymui ir, palyginti su standartiniais KT tyrimais, pasižymi dideliu diagnostiniu tikslumu (54). Pseudo-KT vaizdų sukūrimas yra ypač naudingas radioterapijos planavime, nes MRT, skirtingai nei KT, leidžia išvengti papildomos jonizuojančiosios spinduliuotės apšvitos dozės pacientams, kurie jau serga onkologine liga (53).



**12 pav.** Galvos pseudo-KT vaizdai DI pagalba sugeneruoti iš MRT vaizdų. (a) MRT vaizdai, (b) palyginimui atlikti KT vaizdai, (c) pseudo-KT vaizdai, kurie buvo sugeneruoti iš MRT vaizdų naudojant deepMTP dirbtinio intelekto programą (pagal Liu et al. (2019)) (55).

DI taip pat gali sugeneruoti sintetinės MRT vaizdus (13). Pastaruoju metu stebimas didelis susidomėjimas kiekybinės informacijos išgavimu iš MRT be įprastinių kokybinių vaizdų. Kiekybinėje MRT audiniai yra įvertinami naudojant specialias kontrastines sekas, kurios registruoja MRT signalą keliuose skirtinguose taškuose. Po audinių kiekybinio įvertinimo yra sukuriami sintetinės MRT vaizdai (56). Sintetinė MRT – tai tyrimo metodas, kai vieno nuskenavimo metu yra sugeneruojami keli skirtingi MRT vaizdai ir kartu gaunami audinių kiekybiniai parametrai. Sintetinės MRT metu gali būti sugeneruojamos įvairios sekos: T1-weighted, T2-weighted, T2-FLAIR sekos. Sintetinė MRT yra jau gerai žinomas metodas, tačiau ši technologija dar turi nemažai trūkumų (56–58). Kadangi standartinis sintetinės MRT tyrimas trunka gana ilgai, padidėja judesio artefaktų atsiradimo tikimybė, ypač tiriant pediatriinius pacientus (57). Artefaktų gali atsirasti ne vien dėl judesių, bet ir dėl įvairių signalų pokyčių (56). Taigi siekiant sutrumpinti sintetinės MRT tyrimo trukmę ir pagerinti vaizdų kokybę, sintetinės MRT vaizdų generavimui buvo pasitelkti giliojo mokymosi metodai (56–58). Li ir kiti bendraautoriai (2022) panaudojo gilųjį mokymąsi krūtų sintetinės MRT vaizdų generavimui (58). Tyrimo metu nustatyta, kad, palyginus su standartine sintetine MRT, gilusis mokymasis sumažino tyrimo laiką nuo 5 minučių 12 sekundžių iki 1 minutės 52 sekundžių, tuo pačiu pagerindamas vaizdų kokybę (58). Kim ir kiti bendraautoriai (2022) atliko tyrimą, kurio metu gilusis mokymasis sugeneravo pediatriinių pacientų smegenų sintetinės MRT vaizdus (57). Nustatyta, kad gilusis mokymasis sutrumpino tyrimo laiką 42 %, kartu išlaikydamas gerą vaizdų kokybę, aukštą patologijų aptikimo tikslumą ir kiekybinių rodiklių patikimumą (57).

### **6.2.7. Mokymas**

Radiologijos rezidentų profesinis tobulėjimas – tai sudėtingas procesas, reikalaujantis ne tik teorinių žinių, bet ir gebėjimo greitai bei tiksliai interpretuoti radiologinius vaizdus, integruojant klinikinę informaciją. Šiuo metu radiologijos mokymas daugiausia grindžiamas tradiciniu modeliu, kai rezidentai mokosi analizuodami realius klinikinius atvejus darbo vietoje, padedami vyresniųjų gydytojų. Tačiau toks mokymasis labai priklauso nuo atvejų įvairovės konkrečioje gydymo įstaigoje bei vyresniųjų kolegų noro ir motyvacijos padėti rezidentams, todėl rezidentų patirtis ir žinių lygis gali smarkiai skirtis. Be to, didėjantis darbo krūvis riboja vyresniųjų gydytojų galimybes skirti pakankamai laiko grįžtamajam ryšiui ir nuosekliam rezidentų mokymui (59).

DI yra naudingas mokymo procese. Pastebėta, jog didieji kalbos modeliai gali būti naudojami atsakant į klausimus, kurie yra susiję su radiologija. Didieji kalbos modeliai gali paaiškinti apie tam tikrus patologinius radinius, radiologines procedūras ir skirtingus radiologinių tyrimų metodus. DI gali būti kaip virtualus dėstytojas, kuris radiologijos rezidentams padeda suprasti

sudėtingas sąvokas bei interpretuoti radiologinius vaizdus, suteikdamas galimybę nuosekliau įsisavinti žinias, gilinti teorinį supratimą ir geriau susieti jį su praktiniais klinikiniais pavyzdžiais (25).


DI taip pat gali būti vertingas įrankis atliekant praktines užduotis. DI rezidentams gali pateikti specialiai parinktus mokomuosius atvejus. Pavyzdžiui, DI gali automatiškai atrinkti ir pateikti retų ligų radiologinius vaizdus, su kuriais rezidentas rezidentūros metu greičiausiai nesusidurtų. Taip pat DI sistemos gali analizuoti rezidento sprendimus ir pasiūlyti papildomus panašius atvejus, jei pastebima, kad tam tikro tipo patologijos atpažinimas kelia sunkumų. Taigi iš esmės DI galėtų pateikti daugybę įvairiausių klinikinų atvejų, kuriuos rezidentas galėtų savarankiškai analizuoti ir pateikti išvadas. Tuomet DI galėtų įvertinti rezidentų sprendimus ir pateikti teisingus atsakymus. DI taip pat gali rezidentams padėti išmokyti, kaip reikia diferencijuoti įvairias patologijas, remiantis vaizdiniais radiniais. Patologijų diferencijavimas prisideda prie tikslesnio diagnostinio vertinimo bei mažesnio klaidų skaičiaus klinikinėje praktikoje. Taigi DI gali padėti rezidentams įgyti daugiau klinikinės patirties, užtikrinant, kad jie susidurtų su didesniu klinikinų atvejų skaičiumi ir įvairove bei mokėtų diferencijuoti įvairias patologijas (59).

### **6.3. Dirbtinio intelekto trūkumai radiologijoje**

#### **6.3.1. Neteisingai apibrėžiamos anatominių struktūrų bei patologinių darinių ribos**

Radiologijoje yra itin svarbu teisingai nustatyti anatominių struktūrų bei patologinių darinių ribas, kitaip tariant, atlikti tikslią jų segmentaciją, nes nuo jos priklauso diagnostiniai sprendimai. Nors DI pasiekė didelę pažangą radiologinių vaizdų segmentacijoje, segmentacijos rezultatai ne visuomet yra pakankamai patikimi. Dėl šios priežasties klinikinėje praktikoje specialistams tenka rankiniu būdu koreguoti DI atliktos segmentacijos rezultatus (60). Vilniaus universiteto ligoninėje Santaros klinikose Abramikas ir kiti bendraautoriai (2025) atliko tyrimą, kurio metu buvo nustatyta, jog DI ne visuomet tiksliai atlieka širdies kamerų segmentaciją (61). Šio tyrimo metu buvo vertinama, kaip tiksliai DI gali apskaičiuoti kairiojo skilvelio bendrąją išilginę miokardo įtampą remiantis MRT vaizdais. Kairiojo skilvelio bendroji išilginė miokardo įtampa atspindi kairiojo skilvelio funkciją, todėl šis rodiklis buvo pasitelktas kairiojo skilvelio disfunkcijos nustatymui pacientams, sergantiems aortos stenoze. Kairiojo skilvelio bendrajai išilginei miokardo įtampai apskaičiuoti buvo taikytas visiškai automatizuotas DI algoritmas, kuris segmentavo kairiojo skilvelio endokardo ir epikardo ribas bei apskaičiavo miokardo deformaciją širdies 2,3 ir 4 kamerų vaizduose. Tyrime dalyvavo pacientai, sergantys sunkia aortos stenoze, ir sveiki savanoriai (kontrolinė grupė). Tyrimo metu nustatyta, jog DI algoritmas 6 % atvejų netiksliai atliko kairiojo skilvelio segmentaciją (13 pav.) (61). Dėl nustatytų segmentacijos netikslumų 6 % atvejų reikėjo rankiniu būdu pakoreguoti

kairiojo skilvelio endokardo ir epikardo ribas. Segmentacijos klaidos dažniausiai pasireiškė 3 kamerų projekcijose. Pacientams, sergantiems aortos stenozė, segmentacijos klaidos buvo žymiai dažnesnės (18,6 % atvejų) nei sveikų asmenų grupėje (2,4 % atvejų) (61). Dažniausia klaidų priežastis buvo DI nesugebėjimas tiksliai atpažinti sustorėjusių skilvelio sienelių ir papiliarinių raumenų esant ryškiai kairiojo skilvelio hipertrofijai. Tai rodo, kad nors DI algoritmai daugeliu atvejų tiksliai atlieka segmentaciją, kai kuriais atvejais ji gali būti netiksli, ypač esant patologiniams pakitimams. Tokie atvejai kelia susirūpinimą, nes mažėja diagnostinis tikslumas, todėl ateityje būtina toliau tobulinti DI sistemas, siekiant užtikrinti patikimesnius rezultatus (61).



**13 pav.** Širdies struktūrų segmentacija, atlikta naudojant DI metodus. Matoma, jog yra neteisingai pažymėtos endokardo (raudona spalva) ir epikardo (žalia spalva) ribos širdies MRT 4,3 ir 2 kamerų vaizduose pacientui sergančiam aortos stenozė (pagal Abramikas et al. (2025)) (61).

### 6.3.2. Ribotas duomenų prieinamumas

DI mokosi atpažinti ir analizuoti radiologinius vaizdus, remdamasis jam anksčiau pateiktais pavyzdžiais, kurie yra sukaupti duomenų rinkiniuose (8,62). DI atliekamų užduočių tikslumas, įskaitant radiologinių vaizdų analizę, tiesiogiai priklauso nuo duomenų rinkinių apimties (62,63). Kuo daugiau duomenų yra pateikiama DI mokymuisi, tuo tiksliau yra sukuriami algoritmai, kurie patikimiau atlieka užduotis. Taigi DI modelių kūrimui yra reikalingi dideli duomenų rinkiniai, nes tik tokiu atveju galima tikėtis, jog šių modelių diagnostinis tikslumas bus pakankamas (63).

Šiuo metu medicininių duomenų prieinamumas išlieka ribotas, kadangi šie duomenys yra jautrūs ir jų rinkimas, saugojimas bei naudojimas yra griežtai reglamentuojamas, siekiant apsaugoti pacientų privatumą ir užtikrinti etikos principų laikymąsi. Nors šiuo metu duomenų rinkiniai turėtų būti lengviau prieinami dėl elektroninių sistemų įdiegimo medicininiams duomenims archyvuoti, dauguma gydymo įstaigų nesidalija medicininiams duomenimis, nes jie yra laikomi kiekvienos gydymo įstaigos nuosavybe, skirta individualiai pacientų priežiūrai ir gydymui (5,63). Be to, tam tikroms retoms ligoms, pasižyminčioms mažu paplitimu, būdingas labai ribotas sukaupytas

duomenų kiekis. Dėl riboto atvejų skaičiaus trūksta suarchyvuotų medicininių duomenų apie šias ligas. Toks duomenų trūkumas gali lemti mažesnį DI modelių tikslumą arba šališkumą šių retų ligų atžvilgiu. Taip pat reiktų turėti omenyje, jog ne visi gydytojų įrašai yra teisingi. Medicininuose dokumentuose, įskaitant radiologinius aprašymus, neretai pastebimos įvairios klaidos ir netikslumai (18). Taigi šiuo metu sukurti DI modeliai ne visada yra pakankamai tikslūs, o ribotas duomenų prieinamumas vis dar išlieka opia problema (5,62,63).

### **6.3.3. Duomenų apsauga**

DI pacientų radiologinius vaizdus naudoja ne tik mokymuisi, bet ir klinikinėje praktikoje jų analizei bei išvadų pateikimui. Dėl to iškyla daugybė su duomenų apsauga ir kibernetiniu saugumu susijusių problemų. Daugumą radiologinių vaizdų DI parsisiunčia iš elektroninių sistemų, kuriose yra elektroniniai medicininiai pacientų įrašai. Toks informacijos perdavimas didina pažeidžiamumo, duomenų nutekėjimo ir neautorizuotos prieigos riziką. Be to, įvairių kibernetinių atakų metu gali būti paviešinti ir DI mokymui skirti medicininiai duomenys, atskleidžiant pacientų informaciją ir pažeidžiant konfidencialumą. Šiuo metu yra sukurtų algoritmų, kurie gali identifikuoti net anoniminius duomenis ir priskirti juos konkrečiam žmogui (5). Todėl yra labai svarbu stengtis apsaugoti pacientų privatumą ir kurti tokias DI sistemas, kurios būtų kuo labiau apsaugotos (5,63).

Taip pat labai svarbu gauti pacientų sutikimą, kad jų medicininiai duomenys galėtų būti panaudoti DI mokymui. Tokiu būdu yra užtikrinama pacientų duomenų apsauga (63). 2016 metais DI programėlės „DeepMind“ mokymuisi buvo panaudoti 1,6 mln. pacientų medicininiai duomenys be jų sutikimo (5). Šis incidentas sukėlė didžiulį pacientų pasipiktinimą ir nepasitikėjimą, nes tokiu būdu buvo pažeistas duomenų apsaugos principas (5).

### **6.3.4. Duomenų šališkumas**


Kita opi DI problema – tinkamų duomenų pateikimas DI mokymuisi. Kaip ir buvo minėta, DI algoritmai mokosi analizuoti jiems iš anksto pateiktus radiologinius vaizdus. Tai reiškia, jog jei DI mokosi atpažinti kokius nors vienai gydymo įstaigai būdingas patologijas, jo gebėjimas tiksliai interpretuoti vaizdus kitai populiacijos daliai gali būti ribotas, todėl padidėja neteisingos analizės rizika. Tai rodo galimą duomenų šališkumą. Tokiu atveju būtų netikslinga naudoti tokią DI programą interpretuojant tam tikras patologijas, DI paprasčiausiai jų negebės diagnozuoti arba pakitimus interpretuos visiškai neteisingai (8). Taigi DI modeliams gali kilti sunkumų, kai jie susiduria su vaizdais, kurie skiriasi nuo apmokymo metu pateiktų radiologinių vaizdų. Be to, dauguma esamų algoritmų, analizuodami vaizdinius duomenis, neatsižvelgia į klinikinę paciento informaciją, tokią kaip paciento amžius, ligos anamnezė, rizikos veiksniai. Tai gali apsunkinti tikslios

diagnozės nustatymą įvairiose pacientų populiacijose esant skirtingiems klinikiniams kontekstams (12).

### 6.3.5. Neaiškus veikimo principas

Dauguma DI programų, ypač giliojo mokymosi metodais sukurtos programos, veikia vadinamosios „juodosios dėžės“ (angl. „black box“) principu – tai reiškia, kad yra naudojami algoritmai, kurių veikimo principai ir sprendimų priėmimo logika yra sunkiai suprantama ar paaiškinama (64,65). Nors šie modeliai dažnai labai tiksliai atlieka užduotis, pavyzdžiui, patikimai analizuoja radiologinius vaizdus bei nustato teisingas diagnozes, tačiau jie nesuteikia aiškių paaiškinimų, kodėl buvo priimtas vienas ar kitas sprendimas. Dėl to gali kilti etinės problemos – specialistai nežino, ar turėtų pasikliauti tokiais DI algoritmais (64).

Tobulėjant giliojo mokymosi algoritmams net patys DI kūrėjai nebesupranta, kaip DI priima tam tikrus sprendimus. Gilusis mokymasis remiasi sudėtingais neuroniniais tinklais, kurie turi daugybę paslėptųjų sluoksnių, kurių žmogus paprasčiausiai nebepajėgia suprasti. 14 pav. demonstruoja, kaip atskiri giliojo mokymosi neuroniniai sluoksniai analizuoja įvairius vaizdus. Iš pradžių pirmieji neuroniniai sluoksniai išskiria tokias detales kaip linijos ir apskritimai. Šie žingsniai žmonėms yra suprantami ir logiškai paaiškinami. Tačiau gilesniuose sluoksniuose vykstantis tam tikrų raštų rūšiavimas tampa vis sunkiau interpretuojamas. DI sprendimų priėmimai praranda žmogui suprantamą logiką (65).



**14 pav.** Giliojo mokymosi konvoliucinių neuroninių tinklų sluoksniai ir jų veikimo principas analizuojant vaizdus. Pirmajame neuroninių tinklų sluoksnyje (a) matomas logiškas įvairių raštų suskirstymas į tam tikras grupes pagal jų savybes (žaliai apibrėžtas langelis – linijos, mėlynai apibrėžtas langelis – apskritimai, raudonai apibrėžtas langelis – triukšmas, geltonai apibrėžtas langelis – spalvinis filtras). Antrajame sluoksnyje, kuris yra gilesnis sluoksnis (b), langeliai grupuojami pagal algoritmus, kurių žmogus nesupranta ir negali jų paaiškinti (pagal Gallée et al. (2023)) (65).

Medicinoje kiekvienas priimtas sprendimas yra itin svarbus, nes jis gali turėti tiek teigiamą, tiek neigiamą poveikį paciento sveikatai, tiesiogiai lemdamas diagnozės tikslumą, gydymo savalaikiškumą ir paciento išgyvenamumą. Esant šiam „juodosios dėžės“ fenomenui didėja rizika,

jog DI gali priimti neteisingus sprendimus, kurių specialistas negalės paaiškinti ir suprasti. Tuomet kyla klausimas, kas šiuo atveju yra kaltas dėl neteisingo sprendimo – gydytojas ar DI (63). Pavyzdžiui, tam tikri DI algoritmai, kurių logika žmogui yra sunkiai paaiškinama, judesio artefaktus širdies MRT vaizduose gali klaidingai palaikyti kaip patologiją. DI rezultatai turi būti vertinami kritiškai, nes dėl „juodosios dėžės“ fenomeno algoritmas negali atsakyti į klausimus „kodėl“ ar „kaip“ jis priėmė tam tikrą sprendimą. Taigi labai svarbu, jog DI išanalizuoti vaizdai būtų peržiūrimi radiologų, nes DI programos šiuo metu negali visiškai savarankiškai priimti tam tikrų sprendimų. (62).

### **6.3.6. Gydytojų nepasitikėjimas**

DI yra gana nauja technologija, kuri medicinos srityje pradėta taikyti palyginti neseniai. Dauguma gydytojų, įskaitant radiologus, dar nėra pilnai susipažinę su DI sistemomis, todėl jų žinios apie šias technologijas yra ribotos. Norint sėkmingai diegti DI technologijas radiologijos klinikinėje praktikoje svarbu, jog radiologai gebėtų suprasti, interpretuoti ir efektyviai taikyti DI priemones. Tačiau dauguma specialistų dar nėra tinkamai paruošti darbui su DI sistemomis. Mokomųjų programų apie DI stoka sukūrė reikšmingą žinių spragą, ribojančią gydytojų supratimą apie DI metodikas. Ši spraga skatina specialistų nepasitikėjimą DI, nes jie nepilnai supranta, kaip veikia šios technologijos ir jaučiasi nesaugiai jas naudodami. Be to, dėl tobulėjančių DI technologijų šiais laikais jau nebeįmanoma suvokti, kaip iš tikrųjų veikia DI algoritmai dėl jau minėto „juodosios dėžės“ fenomeno. Taigi ši nežinomybė kelia radiologų nepasitikėjimą DI technologijomis (5).

Kita problema, susijusi su DI integravimu į kasdienę klinikinę praktiką - tai gydytojų pasipriešinimas pokyčiams. Šis pasipriešinimas kyla dėl kelių tarpusavyje susijusių priežasčių. Kai kurie specialistai yra linkę abejoti DI, nes skeptiškai vertina DI metodų tikslumą, patikimumą ir gebėjimą priimti pagrįstus sprendimus. Toks skeptiškas požiūris dažnai siejamas su ribotu supratimu apie šias technologijas. Specialistų nepasitikėjimą stiprina ir baimė prisiimti atsakomybę už neigiamas pasekmes, kai sprendimai priimami remiantis DI rekomendacijomis. Be to, kai kurie radiologai baiminasi, kad DI gali apriboti jų profesinę autonomiją, sumažinti jų kompetenciją arba net užimti jų darbo vietas. DI įvedimas į klinikinę praktiką keičia nusistovėjusią darbo rutiną ir reikalauja prisitaikyti prie naujų darbo sąlygų, todėl šie procesai dažnai yra suvokiami kaip papildoma našta. Be to, gydytojai išreiškia susirūpinimą, kad DI naudojimas gali sumažinti empatijos lygį ir paveikti gydytojo bei paciento tarpusavio ryšį, kuris yra esminis medicinos principas lemiantis gydymo sėkmę (5).

## 6.4. Dirbtinio intelekto ateities perspektyvos radiologijoje

DI atsiradimas medicinoje tapo savotiška sensacija, kuri medicinos bendruomenėje sukėlė didelį susidomėjimą, tačiau kartu ir nerimą, ypač radiologijos srityje. 2016 metais DI pradininkas Geoffrey Hinton iškėlė iki šiol plačiai paplitusią mintį, jog ateityje DI pakeis radiologus. Jis teigė, jog „reikėtų stabdyti naujų radiologų rengimą“, nes „visiškai akivaizdu, kad po 5 metų gilusis mokymasis vaizdų analizę atliks žymiai geriau nei radiologai“ (62). Vis dėlto, šiuo metu DI nepakeitė gydytojo radiologo (9,62). Tačiau pastebima, jog DI radiologijoje populiarėja ir vis plačiau yra taikomas klinikinėje praktikoje (9,28).


Radiologija yra viena iš pirmųjų medicinos sričių, kuri pradėjo taikyti DI klinikinėje praktikoje. Radiologinių vaizdų analizei yra naudojama daug įvairių kompiuterinių programų, todėl nenuostabu, jog radiologija yra būtent ta sritis, kurioje greičiausiai pritaikomos naujausios technologijos. Be to, atsiradus „ImageNet“ duomenų rinkiniui, kuris buvo plačiai pritaikytas DI mokymuisi, DI tapo itin perspektyvia priemone radiologijos srityje (9).

DI paplitimą ir augantį populiarumą radiologijoje rodo didėjantis su šia sritimi susijusių publikacijų skaičius (15 pav.). Reikšmingas publikacijų apie DI technologijas radiologijoje skaičiaus augimas stebimas nuo 2017 metų (42). Tai parodo, jog buvo atliekami įvairūs tyrimai, siekiant sukurti tokias DI sistemas, kurias būtų galima pritaikyti klinikinėje praktikoje (42,66).



**15 pav.** Publikacijų skaičius nuo 2015 iki 2024 metų, kuriose buvo naudojami tokie raktažodžiai kaip „dirbtinis intelektas“, „gilusis mokymasis“ ir „vaizdinė diagnostika“ (pagal Sabri et al. (2025)) (42).

Spartų DI taikymo radiologijoje augimą patvirtina ne tik gausėjantis mokslinių publikacijų skaičius, bet ir didėjantis klinikinei praktikai pritaikytų DI programų skaičius. 16 pav. matoma, jog Europoje ženkliai išaugo radiologijoje naudojamų DI įrenginių skaičius. Nuo 2021 iki 2024 metų CE ženklu patvirtintų DI įrenginių skaičius išaugo net 150 %, o apskritai sukurtų DI įrenginių skaičius išaugo 122 % (28).



**16 pav.** Stulpelinė diagrama, vaizduojanti komercinių DI įrenginių ir sertifikuotų DI įrenginių skaičiaus augimą Europoje nuo 2021 metų iki 2024 metų spalio mėnesio. Matomas procentinis DI įrenginių skaičiaus padidėjimas, demonstruojantis spartų DI plitimą sveikatos priežiūros srityje (pagal Obuchowicz et al. (2025)) (28).

Šiuo metu DI jau yra taikomas ir plačiojoje visuomenėje, tačiau jo diegimas vis dar yra ankstyvoje stadijoje. Vis dėlto, vyrauja nuogastavimai, jog ateityje DI gali pakeisti dalį darbuotojų ir sumažinti darbo vietų skaičių (7,8,67). 2020 metais DI specialistai prognozavo, kad maždaug po 25 metų DI galės atlikti apie 90 % žmonių atliekamų užduočių, o po 50 metų – apie 99 % (67). Tai reiškia, kad DI savo funkcijomis beveik prilygs žmogui. Dėl to kyla klausimas, ar DI neperims žmonių darbo (67). Ši diskusija yra ypač aktuali medicinos bendruomenėje, o labiausiai – radiologijos srityje (7–9). Šiuo metu medicinoje yra paplitusios unimodalinės DI sistemos, kurios analizuoja tik vieno tipo duomenis, pavyzdžiui, tik tekstinę informaciją arba tik vaizdinę informaciją. Tai reiškia, kad radiologijoje naudojamos DI programos geba analizuoti tik radiologinius vaizdus, nevertindamos viso klinikinio paciento konteksto (9,68). Tačiau šiais laikais radiologams nebeužtenka vien tradicinių įgūdžių, skirtų tik radiologinių vaizdų analizavimui. Dabar, interpretuodami radiologinius vaizdus, radiologai turi atsižvelgti į visą paciento klinikinį kontekstą. Radiologai turi peržiūrėti

paciento laboratorinius tyrimus, genetinę informaciją, imunologinius rodiklius ir kitus duomenis. Kadangi unimodalinės DI sistemos nesugeba apdoroti skirtingo pobūdžio duomenų, analizuodamos radiologinius vaizdus, jos atlieka tik pagalbininko funkciją. Tačiau tobulėjant technologijoms atsirado galimybė kurti multimodalines DI sistemas. Šios multimodalinės DI sistemos geba analizuoti ne tik radiologinius vaizdus, bet ir kitą su paciento sveikata susijusią informaciją, pavyzdžiui, laboratorinius tyrimus, genetinę informaciją bei histopatologinius pakitimus. Šie multimodaliniai DI modeliai gali padidinti diagnostinį tikslumą ir klinikinę naudą. Kadangi šie modeliai geba apjungti ir analizuoti įvairius medicininius duomenis, tikimasi, kad ateityje būtent jie užims dominuojančią poziciją, skatindami tikslesnę diagnostiką bei efektyvesnę pacientų priežiūrą. Taigi kyla klausimas: jei DI sugebės atlikti tas pačias funkcijas ir mąstyti panašiai kaip radiologas, ar jis nepakeis radiologų? Šiuo metu multimodalinių DI sistemų funkcija apsiriboja pagalbine funkcija. Manoma, jog radiologai perims prižiūrėtojų vaidmenį. Jie koordinuos šias DI sistemas ir vertins jų atliktą darbą, peržiūrėdami, ar radiologiniai vaizdai buvo teisingai interpretuoti remiantis kita medicinine informacija (9). Taigi iš esmės prognozuojama, jog DI nepakeis radiologų, o taps jų pagalbininku, padedančiu pasiekti didesnę diagnostinį tikslumą (7,9).

## **7. REZULTATŲ APIBENDRINIMAS**

DI apima technologijas, kurios leidžia kompiuteriams „mąstyti“, mokytis ir atlikti sudėtingas užduotis. Kitaip tariant, DI gali imituoti žmogaus intelektui būdingus gebėjimus. Tai yra įmanoma, nes DI technologijų spektras yra labai platus ir apima kelis pagrindinius metodus: mašininių mokymąsi, gilųjį mokymąsi ir didžiuosius kalbos modelius. Mašininis mokymasis leidžia sistemoms analizuoti didelius duomenų kiekius ir atpažinti dėsningumus, kurie gali būti panaudoti prognozėms ar duomenų klasifikacijai. Gilusis mokymasis remiasi dirbtiniais neuroniniais tinklais, imituojančiais žmogaus smegenų veikimo principus, todėl geba apdoroti, analizuoti ir interpretuoti sudėtingus vaizdinius duomenis. Didieji kalbos modeliai, savo ruožtu, yra skirti natūralios kalbos apdorojimui ir gali būti naudojami tekstų analizei bei išvadų rengimui.

DI užima svarbią vietą šiuolaikinėje medicinoje. Spartus technologijų tobulėjimas paskatino DI įsitvirtinimą ir radiologijoje. DI gali būti taikomas radiologinių vaizdų analizei. Tokie tyrimai kaip rentgeno tyrimas, KT, MRT ar PET generuoja didelį kiekį sudėtingų vaizdinių duomenų, kuriuos reikia greitai ir tiksliai interpretuoti. DI algoritmai gali padėti radiologams efektyviau analizuoti šiuos duomenis ir išskirti svarbiausius radinius. Šiuo metu sukurta nemažai DI programų, kurios radiologijoje yra plačiai taikomos įvairių patologijų diagnostikai.

DI radiologijoje turi daug privalumų, vienas iš jų – darbo efektyvumo didinimas. Tai yra ypač svarbu, nes, sparčiai augant radiologinių vaizdų kiekiui, radiologai susiduria su vis didesniu darbo krūviu. DI gali automatizuoti tam tikras užduotis, pavyzdžiui, padėti rengti radiologines išvadas. Kai kurie tyrimai rodo, kad naudojant DI radiologinių išvadų parengimo laikas gali sutrumpėti 45 %. Tai leidžia radiologams daugiau dėmesio skirti sudėtingų klinikinių atvejų analizei ir mažina profesinio perdegimo riziką. Be to, DI gali būti naudojamas radiologinių tyrimų rūšiavimui. DI algoritmai gali automatiškai analizuoti radiologinius vaizdus ir identifikuoti galimai pavojingus patologinius pakitimus. Tokie vaizdai gali būti pažymimi kaip prioritetiniai ir perduodami radiologams skubiai peržiūrai. Tai ypač svarbu skubiojoje medicinoje, pavyzdžiui, esant insultui ar plaučių embolijai, kai greitas patologijos nustatymas gali turėti lemiamą reikšmę paciento išgyvenamumui bei gydymo rezultatams.

DI taip pat gali padidinti diagnostinį tikslumą. Radiologinių vaizdų vertinimas dažnai priklauso nuo gydytojo patirties, todėl gali būti subjektyvus, o kai kurie patologiniai pakitimai gali likti nepastebėti. Tačiau DI algoritmai yra apmokomi dideliais duomenų rinkiniais, todėl gali aptikti net subtiliausius patologinius pakitimus. Tyrimai rodo, kad tam tikrais atvejais DI diagnostinis tikslumas gali būti panašus į radiologų ar net juos pranokti. DI gali padėti diagnozuoti įvairiausias ligas, pavyzdžiui, insultą, plaučių emboliją, navikus, kaulų lūžius ir kitas patologijas. DI technologijos taip pat gali būti naudojamos ankstyvai vėžio diagnostikai, tai yra ypač svarbu siekiant pagerinti pacientų išgyvenamumą. Be to, analizuodamas radiologinius ir klinikinius duomenis, DI gali prognozuoti ligos progresavimą, atkryčio tikimybę ir paciento išgyvenamumą. Tokia informacija gali padėti gydytojams priimti pagrįstus sprendimus ir tiksliau sudaryti paciento gydymo planą.

Naudojant pažangius DI algoritmus diagnostinių tyrimų metu galima sumažinti jonizuojančiosios spinduliuotės apšvitos dozę arba sutrumpinti skenavimo laiką, tuo pačiu užtikrinant pakankamą vaizdų kokybę. DI pagerina radiologinių vaizdų kokybę sumažindamas papildomą triukšmą vaizduose, todėl radiologams tampa lengviau interpretuoti tyrimų rezultatus ir nustatyti patologinius pakitimus. Kita svarbi DI taikymo sritis radiologijoje yra radiologinių vaizdų sintezė. Naudojant giliojo mokymosi metodus galima generuoti tokius radiologinius vaizdus kaip pseudo-KT, sintetinius MRT ir PET vaizdus. Pavyzdžiui, pseudo-KT vaizdai yra generuojami iš MRT tyrimo duomenų. Tokiu būdu gaunami diagnostikai reikalingi vaizdai, kartu išvengiant jonizuojančiosios spinduliuotės apšvitos. Šios technologijos gali būti ypač naudingos pacientams, kuriems svarbu sumažinti papildomą jonizuojančiosios spinduliuotės apšvitą, pavyzdžiui, vaikams ar onkologija sergantiems pacientams.

Be klinikinio pritaikymo, DI gali būti naudojamas ir radiologijos rezidentų mokyme. DI technologijos gali veikti kaip virtualūs mokymo įrankiai, padedantys rezidentams analizuoti klinikinius atvejus, interpretuoti radiologinius vaizdus ir mokytis diferencijuoti įvairias patologijas.

Nepaisant daugybės privalumų, DI taikymas radiologijoje susiduria ir su tam tikrais iššūkiais. Viena iš svarbiausių problemų yra neteisingai apibrėžiamos anatominės struktūrų bei patologinių darinių ribos. Radiologinių vaizdų segmentacija yra labai svarbi diagnostikos dalis, tačiau DI algoritmai ne visada gali tiksliai nustatyti anatominės struktūrų ribas, ypač esant patologiniams pakitimams. Tokiais atvejais radiologams tenka rankiniu būdu koreguoti DI segmentavimo rezultatus, todėl visiškas automatizavimas dar nėra įmanomas.

Kitas svarbus iššūkis yra ribotas medicininių duomenų prieinamumas. DI modelių mokymui reikalingi dideli ir reprezentatyvūs duomenų rinkiniai, tačiau medicininių duomenų naudojimą riboja griežti privatumo ir etikos reikalavimai. Dėl šios priežasties dažnai trūksta duomenų patikimiams DI modeliams kurti. Radiologiniai vaizdai yra laikomi jautria informacija, todėl jų rinkimas, saugojimas ir naudojimas turi atitikti griežtus etinius ir teisinius reikalavimus. Užtikrinti šių duomenų saugumą yra vienas svarbiausių iššūkių diegiant DI technologijas sveikatos priežiūros sistemoje. Be to, naudojant duomenis iš ribotų populiacijų gali atsirasti algoritmų šališkumas. Jei DI modeliai yra apmokomi naudojant duomenis iš ribotos pacientų populiacijos arba iš vienos gydymo įstaigos, jie gali prarasti tikslumą kitose populiacijose. Tokiu atveju algoritmai gali neteisingai interpretuoti patologinius pakitimus. Tai rodo, jog kuriant DI sistemas yra būtina naudoti įvairius ir reprezentatyvius duomenų rinkinius.

Dar viena problema – neaiškus DI veikimo principas. Daugelis giliojo mokymosi algoritmų veikia vadinamuoju „juodosios dėžės“ principu, kai nėra aišku, kaip tiksliai sistema priima tam tikrus sprendimus. Nors tokie algoritmai gali pasiekti aukštą diagnostinį tikslumą, vis dar sunku paaiškinti jų pateikiamus rezultatus. Tai gali kelti etinių problemų, nes gydytojai turi suprasti diagnozės ar rekomendacijos pagrindimą, tačiau DI ne visada pateikia aiškų sprendimo paaiškinimą. Be to, kai kurie specialistai vis dar skeptiškai vertina DI naudojimą klinikinėje praktikoje. Gydytojų nepasitikėjimą dažnai lemia ribotas supratimas apie DI veikimo principus, taip pat baimė, kad ateityje technologijos gali pakeisti medicinos specialistus. Todėl labai svarbu skirti daugiau dėmesio specialistų mokymui ir supažindinti juos su DI galimybėmis bei apribojimais.

Atsižvelgiant į DI teikiamus privalumus ir esamus trūkumus tikėtina, jog ateityje DI taps neatsiejama radiologijos dalimi, tačiau jis greičiausiai nepakeis radiologo, o veiks kaip pagalbinė priemonė, padedanti gydytojams priimti tikslesnius ir greitesnius diagnostinius sprendimus.

## 8. IŠVADOS

1. Dirbtinis intelektas susideda iš tokių metodų kaip mašininis mokymasis, gilusis mokymasis ir didieji kalbos modeliai. Šių metodų pagrindu dirbtinis intelektas geba analizuoti radiologinius vaizdus bei automatizuoti diagnostikos procesus, todėl radiologijoje jis jau plačiai taikomas įvairių patologijų aptikimui.
2. Dirbtinio intelekto technologijos gali padidinti darbo efektyvumą, nes jos gali pateikti radiologinius aprašymus bei išvadas ir automatiškai analizuoti radiologinius vaizdus. Dirbtinis intelektas taip pat gali atlikti radiologinių vaizdų rūšiavimą, padidinti diagnostinį tikslumą, prognozuoti ligas bei jų išėitis, mažinti jonizuojančiosios spinduliuotės apšvitą, gerinti gaunamų vaizdų kokybę, atlikti radiologinių vaizdų sintezę bei prisidėti prie radiologijos rezidentų mokymo.
3. Vienas reikšmingiausių dirbtinio intelekto trūkumų – netikslus anatominių struktūrų bei patologinių darinių apibrėžimas. Dirbtinio intelekto taikymas taip pat kelia etinių ir teisinių problemų, susijusių su duomenų saugumo ir pacientų privatumo užtikrinimu, ribotu duomenų prieinamumu bei galimu algoritmų šališkumu. Radiologams taip pat nerimą kelia dirbtinio intelekto neaiškus veikimo principas.
4. Šiuo metu radiologijoje plačiai taikomos unimodalinės dirbtinio intelekto sistemos. Vis dėlto, tobulėjant technologijoms vis didesnis dėmesys skiriamas multimodalinių dirbtinio intelekto sistemų kūrimui. Nors dirbtinio intelekto raidą ir būsimas galimybes tiksliai prognozuoti sudėtinga, manoma, kad jis nepakeis radiologų, o bus naudojamas kaip pagalbinių diagnostikos priemonė.

## 9. REKOMENDACIJOS

Dirbtinis intelektas turėtų būti vis plačiau diegiamas ir nuolat tobulinamas radiologijos klinikinėje praktikoje, siekiant didinti diagnostikos efektyvumą ir mažinti specialistų darbo krūvį. Kuriant ir diegiant šias technologijas svarbu užtikrinti kokybiškų ir reprezentatyvių medicininių duomenų rinkinių naudojimą, nes tai padeda mažinti algoritmų šališkumo bei diagnostinių klaidų riziką. Siekiant užtikrinti veiksmingą dirbtinio intelekto taikymą, būtina sistemingai tobulinti specialistų žinias ir gebėjimus, įtraukiant dirbtinio intelekto veikimo principus ir pagrindus į profesinio tobulėjimo programas. Norint saugiai taikyti dirbtinį intelektą klinikinėje praktikoje, būtina apibrėžti teisinius ir etinius reikalavimus, susijusius su duomenų apsauga bei duomenų skaidrumu. Atsižvelgiant į šiuos aspektus, reikalingi tolesni moksliniai tyrimai, siekiant įvertinti dirbtinio intelekto klinikinį efektyvumą bei jo ilgalaikį poveikį diagnostikos kokybei.

## 10. LITERATŪROS ŠALTINIAI

1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019 Jan;25(1):44–56. doi:10.1038/s41591-018-0300-7 PubMed PMID: 30617339.
2. Thrall JH, Li X, Li Q, Cruz C, Do S, Dreyer K, et al. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *J Am Coll Radiol*. 2018 Mar;15(3 Pt B):504–8. doi:10.1016/j.jacr.2017.12.026 PubMed PMID: 29402533.
3. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nature reviews Cancer*. 2018 Aug;18(8):500. doi:10.1038/s41568-018-0016-5 PubMed PMID: 29777175.
4. Beger J. Not someone, but something: Rethinking trust in the age of medical AI. *European Journal of Radiology Artificial Intelligence*. 2025 Sep 1;3:100038. doi:10.1016/j.ejrai.2025.100038
5. Abd-Alrazaq A, Solaiman B, Mekki YM, Al-Thani D, Farooq F, Alkubeyyer M, et al. Hype vs Reality in the Integration of Artificial Intelligence in Clinical Workflows. *JMIR Form Res*. 2025 Dec 12;9:e70921. doi:10.2196/70921 PubMed PMID: 41385778; PubMed Central PMCID: PMC12700513.
6. Pallamala G, Jenkins J, Sherin PK, Nyathi A, George J. Healthcare professionals' perspectives on artificial intelligence in clinical practice: a systematic review of facilitators and challenges. *Oxf Open Digit Health*. 2026;4:oqag004. doi:10.1093/oodh/oqag004 PubMed PMID: 41756402; PubMed Central PMCID: PMC12935013.
7. Cronin T, Travers J. Dr AI will see you now: could artificial intelligence replace general practitioners? *Ir J Med Sci*. 2025 Aug;194(4):1353–8. doi:10.1007/s11845-025-04006-2 PubMed PMID: 40690151.
8. Cui S, Traverso A, Niraula D, Zou J, Luo Y, Owen D, et al. Interpretable artificial intelligence in radiology and radiation oncology. *Br J Radiol*. 2023 Oct;96(1150):20230142. doi:10.1259/bjr.20230142 PubMed PMID: 37493248; PubMed Central PMCID: PMC10546466.
9. Nensa F. The future of radiology: The path towards multimodal AI and superdiagnostics. *European Journal of Radiology Artificial Intelligence*. 2025 Jun 1;2:100014. doi:10.1016/j.ejrai.2025.100014
10. Katzman BD, van der Pol CB, Soyer P, Patlas MN. Artificial intelligence in emergency radiology: A review of applications and possibilities. *Diagn Interv Imaging*. 2023 Jan;104(1):6–10. doi:10.1016/j.diii.2022.07.005 PubMed PMID: 35933269.
11. Liu S, Russo C, Suero Molina E, Di Ieva A. Artificial Intelligence Methods. *Adv Exp Med Biol*. 2024;1462:21–38. doi:10.1007/978-3-031-64892-2\_3 PubMed PMID: 39523258.
12. Brancaccio G, Balato A, Malvey J, Puig S, Argenziano G, Kittler H. Artificial Intelligence in Skin Cancer Diagnosis: A Reality Check. *J Invest Dermatol*. 2024 Mar;144(3):492–9. doi:10.1016/j.jid.2023.10.004 PubMed PMID: 37978982.
13. Metin İ, Özdemir Ö. Artificial intelligence in medicine: Current applications in cardiology, oncology, and radiology. *World J Methodol*. 2025 Dec 20;15(4):106854. doi:10.5662/wjm.v15.i4.106854 PubMed PMID: 40900839; PubMed Central PMCID: PMC12400327.

14. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to Machine Learning, Neural Networks, and Deep Learning. *Transl Vis Sci Technol*. 2020 Feb 27;9(2):14. doi:10.1167/tvst.9.2.14 PubMed PMID: 32704420; PubMed Central PMCID: PMC7347027.
15. Muthukrishnan N, Maleki F, Ovens K, Reinhold C, Forghani B, Forghani R. Brief History of Artificial Intelligence. *Neuroimaging Clinics of North America*. 2020 Nov 1;Machine Learning and Other Artificial Intelligence Applications30(4):393–9. doi:10.1016/j.nic.2020.07.004
16. Rojas-Carabali W, Agrawal R, Gutierrez-Sinisterra L, Baxter SL, Cifuentes-González C, Wei YC, et al. Natural Language Processing in medicine and ophthalmology: A review for the 21st-century clinician. *Asia-Pacific Journal of Ophthalmology*. 2024 Jul 1;13(4):100084. doi:10.1016/j.apjo.2024.100084
17. Manco L, Maffei N, Strolin S, Vichi S, Bottazzi L, Strigari L. Basic of machine learning and deep learning in imaging for medical physicists. *Physica Medica*. 2021 Mar 1;83:194–205. doi:10.1016/j.ejmp.2021.03.026
18. Esmaeilzadeh P. Challenges and strategies for wide-scale artificial intelligence (AI) deployment in healthcare practices: A perspective for healthcare organizations. *Artificial Intelligence in Medicine*. 2024 May 1;151:102861. doi:10.1016/j.artmed.2024.102861
19. Murali N, Kucukkaya A, Petukhova A, Onofrey J, Chapiro J. Supervised Machine Learning in Oncology: A Clinician's Guide. *Dig Dis Interv*. 2020 Mar;4(1):73–81. doi:10.1055/s-0040-1705097 PubMed PMID: 32869010; PubMed Central PMCID: PMC7456427.
20. Rashidi HH, Pantanowitz J, Hanna MG, Tafti AP, Sanghani P, Buchinsky A, et al. Introduction to Artificial Intelligence and Machine Learning in Pathology and Medicine: Generative and Nongenerative Artificial Intelligence Basics. *Modern Pathology*. 2025 Apr 1;38(4):100688. doi:10.1016/j.modpat.2024.100688
21. Chakraborty C, Bhattacharya M, Pal S, Lee SS. From machine learning to deep learning: Advances of the recent data-driven paradigm shift in medicine and healthcare. *Current Research in Biotechnology*. 2024 Jan 1;7:100164. doi:10.1016/j.crbiot.2023.100164
22. Erickson BJ. Basic Artificial Intelligence Techniques: Machine Learning and Deep Learning. *Radiologic Clinics of North America*. 2021 Nov 1;Artificial Intelligence in Radiology59(6):933–40. doi:10.1016/j.rcl.2021.06.004
23. Richie RC. Basics of Artificial Intelligence (AI) Modeling. *Journal of Insurance Medicine*. 2024 Jul 1;51(1):35–40. doi:10.17849/in-sm-51-1-35-40.1
24. Chan HP, Samala RK, Hadjiiski LM, Zhou C. Deep Learning in Medical Image Analysis. *Adv Exp Med Biol*. 2020;1213:3–21. doi:10.1007/978-3-030-33128-3\_1 PubMed PMID: 32030660; PubMed Central PMCID: PMC7442218.
25. Akinci D'Antonoli T, Stanzione A, Bluethgen C, Vernuccio F, Ugga L, Klontzas ME, et al. Large language models in radiology: fundamentals, applications, ethical considerations, risks, and future directions. *Diagn Interv Radiol*. 2024 Mar 6;30(2):80–90. doi:10.4274/dir.2023.232417 PubMed PMID: 37789676; PubMed Central PMCID: PMC10916534.
26. Singhal V, R. S, Singhal S, Tiwari A, Mangal D. Healthcare and cutting-edge technology: Advancements, challenges, and future prospects. *Computers in Biology and Medicine*. 2025 Sep 1;196:110861. doi:10.1016/j.compbiomed.2025.110861

27. Wang L, Zhang S, Xu N, He Q, Zhu Y, Chang Z, et al. Role of artificial intelligence in medical image analysis. *Chin Med J (Engl)*. 2025 Nov 20;138(22):2879–94. doi:10.1097/CM9.0000000000003824 PubMed PMID: 41131954; PubMed Central PMCID: PMC12634253.
28. Obuchowicz R, Lasek J, Wodziński M, Piórkowski A, Strzelecki M, Nurzynska K. Artificial Intelligence-Empowered Radiology-Current Status and Critical Review. *Diagnostics (Basel)*. 2025 Jan 24;15(3):282. doi:10.3390/diagnostics15030282 PubMed PMID: 39941212; PubMed Central PMCID: PMC11816879.
29. Mohseni A, Ghotbi E, Kazemi F, Shababi A, Jahan SC, Mohseni A, et al. Artificial Intelligence in Radiology: What Is Its True Role at Present, and Where Is the Evidence? *Radiol Clin North Am*. 2024 Nov;62(6):935–47. doi:10.1016/j.rcl.2024.03.008 PubMed PMID: 39393852.
30. Plesner LL, Müller FC, Nybing JD, Laustrop LC, Rasmussen F, Nielsen OW, et al. Autonomous Chest Radiograph Reporting Using AI: Estimation of Clinical Impact. *Radiology*. 2023 May;307(3):e222268. doi:10.1148/radiol.222268 PubMed PMID: 36880947.
31. Karužas A, Miščikas L, Kiziela A, Šablauskas K, Kažukauskienė I, Verikas D, et al. Deep Learning-Driven Automated Assessment of Left Ventricular Diastolic Function in Echocardiography. *Echocardiography*. 2025 Sep;42(9):e70290. doi:10.1111/echo.70290 PubMed PMID: 40892533.
32. Kjelle E, Brandsæter IØ, Andersen ER, Hofmann B. Sustainability in healthcare by reducing low-value imaging - A narrative review. *Radiography (Lond)*. 2024 Jun;30 Suppl 1:30–4. doi:10.1016/j.radi.2024.05.014 PubMed PMID: 38870571.
33. Peng YC, Lee WJ, Chang YC, Chan WP, Chen SJ. Radiologist burnout: Trends in medical imaging utilization under the national health insurance system with the universal code bundling strategy in an academic tertiary medical centre. *Eur J Radiol*. 2022 Dec;157:110596. doi:10.1016/j.ejrad.2022.110596 PubMed PMID: 36379098.
34. Rajmohamed RF, Chapala S, Shazahan MA, Wali P, Botchu R. Evaluating the Accuracy and Efficiency of AI-Generated Radiology Reports Based on Positive Findings-A Qualitative Assessment of AI in Radiology. *Acad Radiol*. 2025 Dec;32(12):7035–40. doi:10.1016/j.acra.2025.09.012 PubMed PMID: 41015710.
35. Jorg T, Halfmann MC, Stoehr F, Arnhold G, Theobald A, Mildenerberger P, et al. A novel reporting workflow for automated integration of artificial intelligence results into structured radiology reports. *Insights Imaging*. 2024 Mar 19;15(1):80. doi:10.1186/s13244-024-01660-5 PubMed PMID: 38502298; PubMed Central PMCID: PMC10951179.
36. van Leeuwen KG, de Rooij M, Schalekamp S, van Ginneken B, Rutten MJCM. How does artificial intelligence in radiology improve efficiency and health outcomes? *Pediatr Radiol*. 2022 Oct;52(11):2087–93. doi:10.1007/s00247-021-05114-8 PubMed PMID: 34117522; PubMed Central PMCID: PMC9537124.
37. Soh WK, Rajapakse JC. Hybrid UNet transformer architecture for ischemic stroke segmentation with MRI and CT datasets. *Front Neurosci*. 2023;17:1298514. doi:10.3389/fnins.2023.1298514 PubMed PMID: 38105927; PubMed Central PMCID: PMC10723803.
38. Cheikh AB, Gorincour G, Nivet H, May J, Seux M, Calame P, et al. How artificial intelligence improves radiological interpretation in suspected pulmonary embolism. *Eur Radiol*. 2022;32(9):5831–42. doi:10.1007/s00330-022-08645-2 PubMed PMID: 35316363; PubMed Central PMCID: PMC8938594.

39. Guo J, Lu H, Chen Y, Zeng M, Jin H. Artificial intelligence study on left ventricular function among normal individuals, hypertrophic cardiomyopathy and dilated cardiomyopathy patients using 1.5T cardiac cine MR images obtained by SSFP sequence. *Br J Radiol.* 2022 May 1;95(1133):20201060. doi:10.1259/bjr.20201060 PubMed PMID: 35084208; PubMed Central PMCID: PMC10993976.
40. Agripnidis T, Ayobi A, Quenet S, Chaibi Y, Avare C, Jacquier A, et al. Performance of an artificial intelligence tool for multi-step acute stroke imaging: A multicenter diagnostic study. *Eur J Radiol Open.* 2025 Dec;15:100678. doi:10.1016/j.ejro.2025.100678 PubMed PMID: 40933241; PubMed Central PMCID: PMC12419105.
41. Cohen M, Puntonet J, Sanchez J, Kierszbaum E, Crema M, Soyer P, et al. Artificial intelligence vs. radiologist: accuracy of wrist fracture detection on radiographs. *Eur Radiol.* 2023 Jun;33(6):3974–83. doi:10.1007/s00330-022-09349-3 PubMed PMID: 36515712.
42. Sabri O, Al-Shargabi B, Abuarqoub A. The Role of Artificial Intelligence in Improving Diagnostic Accuracy in Medical Imaging: A Review. *Computers, Materials and Continua.* 2025 Sep 23;85(2):2443–86. doi:10.32604/cmc.2025.066987
43. Kumar Y, Koul A, Singla R, Ijaz MF. Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda. *J Ambient Intell Humaniz Comput.* 2023;14(7):8459–86. doi:10.1007/s12652-021-03612-z PubMed PMID: 35039756; PubMed Central PMCID: PMC8754556.
44. Shivwanshi RR, Nirala NS. A hybrid AI method for lung cancer classification using explainable AI techniques. *Physica Medica.* 2025 Jun 1;134:104985. doi:10.1016/j.ejmp.2025.104985
45. Hernström V, Josefsson V, Sartor H, Schmidt D, Larsson AM, Hofvind S, et al. Screening performance and characteristics of breast cancer detected in the Mammography Screening with Artificial Intelligence trial (MASAI): a randomised, controlled, parallel-group, non-inferiority, single-blinded, screening accuracy study. *The Lancet Digital Health.* 2025 Mar 1;7(3):e175–83. doi:10.1016/S2589-7500(24)00267-X
46. Akkus Z, Ali I, Sedlář J, Agrawal JP, Parney IF, Giannini C, et al. Predicting Deletion of Chromosomal Arms 1p/19q in Low-Grade Gliomas from MR Images Using Machine Intelligence. *J Digit Imaging.* 2017 Aug;30(4):469–76. doi:10.1007/s10278-017-9984-3 PubMed PMID: 28600641; PubMed Central PMCID: PMC5537096.
47. Tie J, Peng H, Zhou J. MRI Brain Tumor Segmentation Using 3D U-Net with Dense Encoder Blocks and Residual Decoder Blocks. *CMES.* 2021;128(2):427–45. doi:10.32604/cmes.2021.014107
48. He Y, Guo J, Ding X, van Ooijen PMA, Zhang Y, Chen A, et al. Convolutional neural network to predict the local recurrence of giant cell tumor of bone after curettage based on pre-surgery magnetic resonance images. *Eur Radiol.* 2019 Oct;29(10):5441–51. doi:10.1007/s00330-019-06082-2 PubMed PMID: 30859281.
49. Slart RHJA, Williams MC, Juarez-Orozco LE, Rischpler C, Dweck MR, Glaudemans AWJM, et al. Position paper of the EACVI and EANM on artificial intelligence applications in multimodality cardiovascular imaging using SPECT/CT, PET/CT, and cardiac CT. *Eur J Nucl Med Mol Imaging.* 2021 May;48(5):1399–413. doi:10.1007/s00259-021-05341-z PubMed PMID: 33864509; PubMed Central PMCID: PMC8113178.
50. Pan B, Qi N, Meng Q, Wang J, Peng S, Qi C, et al. Ultra high speed SPECT bone imaging enabled by a deep learning enhancement method: a proof of concept. *EJNMMI Phys.* 2022 Jun 13;9:43.

doi:10.1186/s40658-022-00472-0 PubMed PMID: 35698006; PubMed Central PMCID: PMC9192886.

51. Cao L, Liu X, Li J, Qu T, Chen L, Cheng Y, et al. A study of using a deep learning image reconstruction to improve the image quality of extremely low-dose contrast-enhanced abdominal CT for patients with hepatic lesions. *Br J Radiol.* 2021 Feb 1;94(1118):20201086. doi:10.1259/bjr.20201086 PubMed PMID: 33242256; PubMed Central PMCID: PMC7934287.

52. Su B, Dong P, Hu X, Wang B, Zha Y, Wu Z, et al. Fast and detail-preserving low-dose CT denoising with diffusion model. *Biomedical Signal Processing and Control.* 2025 Jul 1;105:107580. doi:10.1016/j.bspc.2025.107580

53. Jabbarpour A, Mahdavi SR, Vafaei Sadr A, Esmaili G, Shiri I, Zaidi H. Unsupervised pseudo CT generation using heterogenous multicentric CT/MR images and CycleGAN: Dosimetric assessment for 3D conformal radiotherapy. *Computers in Biology and Medicine.* 2022 Apr 1;143:105277. doi:10.1016/j.compbimed.2022.105277

54. Linkugel AD, Wang T, Boroojeni PE, Eldeniz C, Chen Y, Skolnick GB, et al. MR Cranial Bone Imaging: Evaluation of Both Motion-Corrected and Automated Deep Learning Pseudo-CT Estimated MR Images. *AJNR Am J Neuroradiol.* 2024 Sep 9;45(9):1284–90. doi:10.3174/ajnr.A8335 PubMed PMID: 38991771; PubMed Central PMCID: PMC11392357.

55. Liu F, Yadav P, Baschnagel AM, McMillan AB. MR-based treatment planning in radiation therapy using a deep learning approach. *J Appl Clin Med Phys.* 2019 Mar;20(3):105–14. doi:10.1002/acm2.12554 PubMed PMID: 30861275; PubMed Central PMCID: PMC6414148.

56. Kumar S, Saber H, Charron O, Freeman L, Tamir JJ. Correcting synthetic MRI contrast-weighted images using deep learning. *Magnetic Resonance Imaging.* 2024 Feb 1;106:43–54. doi:10.1016/j.mri.2023.11.015

57. Kim E, Cho HH, Cho SH, Park B, Hong J, Shin KM, et al. Accelerated Synthetic MRI with Deep Learning–Based Reconstruction for Pediatric Neuroimaging. *AJNR Am J Neuroradiol.* 2022 Nov;43(11):1653–9. doi:10.3174/ajnr.A7664 PubMed PMID: 36175085; PubMed Central PMCID: PMC9731246.

58. Li J, Wu LH, Xu MY, Ren JL, Li Z, Liu JR, et al. Improving Image Quality and Reducing Scan Time for Synthetic MRI of Breast by Using Deep Learning Reconstruction. *Biomed Res Int.* 2022 Aug 26;2022:3125426. doi:10.1155/2022/3125426 PubMed PMID: 36060133; PubMed Central PMCID: PMC9439918.

59. Duong MT, Rauschecker AM, Rudie JD, Chen PH, Cook TS, Bryan RN, et al. Artificial intelligence for precision education in radiology. *Br J Radiol.* 2019 Nov;92(1103):20190389. doi:10.1259/bjr.20190389 PubMed PMID: 31322909; PubMed Central PMCID: PMC6849670.

60. Yang B, Zhang X, Zhang H, Li S, Higashita R, Liu J. Structural uncertainty estimation for medical image segmentation. *Medical Image Analysis.* 2025 Jul 1;103:103602. doi:10.1016/j.media.2025.103602

61. Abramikas Ž, Jasiukevičiūtė I, Balčiūnaitė G, Glaveckaitė S, Palionis D, Valevičienė N. Artificial Intelligence Performance in Cardiac Magnetic Resonance Strain Analysis for Aortic Stenosis: Validation with Echocardiography and Healthy Controls. *Medicina (Kaunas).* 2025 May 22;61(6):950. doi:10.3390/medicina61060950 PubMed PMID: 40572638; PubMed Central PMCID: PMC12194916.

62. Kyrollos D, deKemp RA, Chow BJW. Artificial Intelligence Will Not Replace Imaging Specialists, For Now. *Canadian Journal of Cardiology*. 2025 Nov 22. doi:10.1016/j.cjca.2025.11.031
63. Aung YYM, Wong DCS, Ting DSW. The promise of artificial intelligence: a review of the opportunities and challenges of artificial intelligence in healthcare. *Br Med Bull*. 2021 Sep 10;139(1):4–15. doi:10.1093/bmb/ldab016 PubMed PMID: 34405854.
64. Majumder A, Sen D. Artificial intelligence in cancer diagnostics and therapy: current perspectives. *Indian J Cancer*. 2021;58(4):481–92. doi:10.4103/ijc.IJC\_399\_20 PubMed PMID: 34975094.
65. Gallée L, Kniesel H, Ropinski T, Götz M. Artificial intelligence in radiology - beyond the black box. *Rofo*. 2023 Sep;195(9):797–803. doi:10.1055/a-2076-6736 PubMed PMID: 37160147.
66. Kocak B, Baessler B, Cuocolo R, Mercaldo N, Pinto dos Santos D. Trends and statistics of artificial intelligence and radiomics research in Radiology, Nuclear Medicine, and Medical Imaging: bibliometric analysis. *Eur Radiol*. 2023 Nov 1;33(11):7542–55. doi:10.1007/s00330-023-09772-0
67. Gruetzemacher R, Paradice D, Lee KB. Forecasting extreme labor displacement: A survey of AI practitioners. *Technological Forecasting and Social Change*. 2020 Dec 1;161:120323. doi:10.1016/j.techfore.2020.120323
68. Ardic N, Dinc R. Emerging trends in multi-modal artificial intelligence for clinical decision support: A narrative review. *Health Informatics J*. 2025;31(3):14604582251366141. doi:10.1177/14604582251366141 PubMed PMID: 40808352.