SVEIKATOS MOKSLAI /
HEALTH SCIENCES IN EASTERN EUROPE
ISSN 1392-6373 print / 2335-867X online
2026, 36 tomas, Nr.7, p. 165-166
DOI: https://doi.org/10.35988/sm-hs.2026.311

DIRBTINIS INTELEKTAS VĖŽIO DIAGNOSTIKOJE

Dominyka Naudužaitė, Patricija Juozaitytė
Vilniaus universitetas, Medicinos fakultetas

Raktažodžiai: dirbtinis intelektas medicinoje, radiomika, radiogenomika, diagnostinis tikslumas.

Santrauka

Tyrime analizuojamas dirbtinio intelekto panaudojimas medicininių vaizdų analizei vertinant jo diagnostinį tikslumą ir galimybes tobulinti radiologinę praktiką. Aptariami CNN, radiomikos ir radiogenomikos metodai, leidžiantys identifikuoti subtilius struktūrinius ir genetinius požymius, dažnai nepastebimus žmogaus akiai. Klinikiniai duomenys rodo, kad DI sistemos kai kuriais atvejais prilygsta arba net viršija radiologų jautrumą, vis dėlto išlieka iššūkių, susijusių su mažesniu specifiškumu ir „juodosios dėžės“ problema. Pabrėžiama paaiškinamojo DI reikšmė siekiant didesnio skaidrumo ir patikimumo klinikinėje praktikoje.

Įvadas

Dirbtinis intelektas dabar gali anksti identifikuoti navikus kompiuterinės tomografijos ir magnetinio rezonanso vaizdų analizės metu, kur kas greičiau nei žmogaus akis. Mašininio mokymosi algoritmai, ypač konvoliuciniai neuroniniai tinklai, geba atpažinti subtilias anomalijas, tokias kaip mikrokalcifikacijos, pikselių intensyvumo pokyčiai ir naviko masių kraštų netipiškumas [1]. Šiame straipsnyje nagrinėjamas dirbtinio intelekto (DI) vaizdų analizės procesas ir taikomi radiologinių tyrimų tipai, siekiant užtikrinti klinikinių studijų tikslumą, bei iššūkiai, su kuriais susiduriama diegiant šias technologijas sveikatos priežiūros įstaigose.

Tyrimo tikslas − įvertinti dirbtinio intelekto taikymo medicininių vaizdų analizėje diagnostinį tikslumą ir patikimumą, kartu analizuojant pagrindinius iššūkius, susijusius su modelių skaidrumu ir patikimumu.

Tyrimo medžiaga ir metodai

Literatūros analizė atlikta naudojant mokslinių publikacijų duomenų bazę. Į literatūros apžvalgą įtraukti straipsniai, kuriuose aprašomas DI naudojimas vėžio diagnostikoje.

Tyrimo rezultatai

Medicininių vaizdų analizė reikalauja sudėtingų algoritmų, kurie geba identifikuoti subtilias anomalijas tūkstančiuose pikselių. Konvoliuciniai neuroniniai tinklai (CNN) tapo pagrindiniais dirbtinio intelekto įrankiais diagnostikoje, kadangi jų architektūra idealiai tinka vaizdinių struktūrų atpažinimui [2, 3]. Radiomika, kaip radiologinių vaizdų struktūrinė analizė, suteikia galimybę identifikuoti kiekybinius požymius, kurių žmogaus akis nepajėgtų pastebėti. Radiogenomika, apimanti radiominius ir genominius požymius, teikia galimybę prognozuoti naviko elgseną. Jau identifikuoti vaizdiniai fenotipiniai biologiniai žymenys, kurie yra susiję su genetinėmis mutacijomis, ypač BRCA1 ir BRCA2 [4]. Klinikiniai tyrimai, atlikti su tūkstančiais pacientų, patvirtina, kad dirbtinio intelekto technologijos diagnostikoje gali pasiekti rezultatus, lyginamus su patyrusių radiologų rezultatais, o tam tikrais atvejais net juos pranokti [5]. Tyrimas, apimantis 11 studijų, susijusių su plaučių vėžio gydymo atsako prognozavimu, atskleidė, kad dirbtinio intelekto sistema pasiekė suvestinį jautrumo rodiklį 0,9, specifiškumo rodiklį 0,8, o tikslumas buvo 0,9 [6]. Limfmazgių metastazių nustatymo PET-CT vaizduose gilaus mokymosi sistemos pasiekė didesnius jautrumo rodiklius, bet mažesnius specifiškumo rodiklius, palyginti su radiologais. Toks rezultatų pasiskirstymas reiškia, kad DI labiau linkęs identifikuoti įtartinus pakitimus, bet kartu gali generuoti daugiau klaidingai teigiamų atvejų [7]. Metaanalizė, apėmusi 1,1 milijono krūties vėžio patikros tyrimų ir 497 000 moterų, atskleidė, jog autonomiškai veikiantis dirbtinis intelektas pasižymi 80,6 % jautrumu, palyginti su 73,6 % radiologų vertinimo rezultatu. Kalbant apie specifiškumo rodiklius, jie atitinkamai siekė 89,6 % radiologų atveju ir 85,7 % dirbtinio intelekto atveju [8]. Viena iš svarbiausių dirbtinio intelekto modelių problemų yra jų sudėtingumas ir veikimas „juodosios dėžės“ principu, todėl tampa sudėtinga išsiaiškinti sprendimų priėmimo logiką, duomenų interpretacijas bei galimą algoritmų šališkumą. Ši skaidrumo stoka kelia iššūkių pasitikėjimui, rezultatų interpretavimui ir klaidų taisymui, ypač medicinos srityje, kur tikslumas yra esminis. Todėl būtina užtikrinti kuo didesnį DI sistemų funkcionavimo skaidrumą, o paaiškinamojo DI (XAI) metodai turėtų padėti spręsti su „juodosiomis dėžėmis“ susijusias problemas [9].

Adresas susirašinėti: Dominyka Naudužaitė, el.p. dnauduzaite@gmail.com

Išvados

1. Dirbtinio intelekto naudojimas medicininių vaizdų analizei įrodo didelį diagnostinį potencialą: CNN modeliai, taip pat radiomikos ir radiogenomikos metodai leidžia atpažinti subtilius struktūrinius ir genetinius navikų požymius, kurių žmogaus akis dažnai nepajėgia pastebėti.

2. Klinikiniai tyrimai rodo, kad DI sistemos daugelyje sričių pasiekia radiologų lygio jautrumo rodiklius ar net juos pralenkia, nors kai kuriais atvejais specifiškumas gali būti mažesnis dėl didesnio klaidingai teigiamų rezultatų skaičiaus.

3. Vienas didžiausių iššūkių išlieka modelių skaidrumas, kadangi „juodosios dėžės“ principu veikiantys algoritmai sunkina sprendimų logikos supratimą ir riboja pasitikėjimą klinikinėje praktikoje. Todėl būtina plėtoti aiškinamojo DI metodus, kad būtų užtikrintas patikimas, interpretuojamas ir saugus dirbtinio intelekto taikymas medicinoje.

Literatūra

1. Ahmad I, Alqurashi F. Early cancer detection using deep learning and medical imaging: A survey. Crit Rev Oncol Hematol 2024;204(9):104528.

https://doi.org/10.1016/j.critrevonc.2024.104528

2. Mienye ID, Swart TG, Obaido G, Jordan M, Ilono P. Deep Convolutional Neural Networks in Medical Image Analysis: A Review. Inf 2025;16(3):195.

https://doi.org/10.3390/info16030195

3. Sarvamangala DR, Kulkarni R V. Convolutional neural networks in medical image understanding: a survey. Evol Intell 2021;15(1):1.

https://doi.org/10.1007/s12065-020-00540-3

4. McAuliffe D, Davey MG, Kerin MJ. Radiogenomic profiling to determine BRCA alteration status-a systematic review and meta-analysis. Br J Radiol 2025;98(1173):1383.

https://doi.org/10.1093/bjr/tqaf139

5. Chen H, Li E, Christos PJ, Zhu Y-S. Comparison of Artificial Intelligence and Radiologists in MRI-Based Prostate Cancer Diagnosis: A Meta-Analysis of Accuracy and Effectiveness. Biomed 2026;14(1):20.

https://doi.org/10.3390/biomedicines14010020

6. Rodriguez NG, Mercado NC, Panjiyar K, Kunwor R. Artificial intelligence versus radiologists in predicting lung cancer treatment response: a systematic review and meta-analysis. Front Oncol 2025;15:1634694.

https://doi.org/10.3389/fonc.2025.1634694

7. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. Nat Rev Cancer 2018;18(8):500.

https://doi.org/10.1038/s41568-018-0016-5

8. Yoon JH, Strand F, Baltzer PAT, Conant EF, Gilbert FJ, Lehman CD, et al. Standalone AI for Breast Cancer Detection at Screening Digital Mammography and Digital Breast Tomosynthesis: A Systematic Review and Meta-Analysis. Radiology 2023;307(5). https://doi.org/10.1148/radiol.222639

9. Lesley U, Kuratomi Hernández A. Improving XAI Explanations for Clinical Decision-Making - Physicians' Perspective on Local Explanations in Healthcare. Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics) 2024;14845 LNAI:296-312.

https://doi.org/10.1007/978-3-031-66535-6_32

ARTIFICIAL INTELLIGENCE IN CANCER DIAGNOSTICS

D. Naudužaitė, P. Juozaitytė

Keywords: artificial intelligence in medicine, radiomics, radiogenomics, diagnostic accuracy.

Summary

This study examines the use of artificial intelligence in medical image analysis, focusing on its diagnostic accuracy and potential to enhance radiological practice. It discusses CNN-based methods, radiomics, and radiogenomics, which enable the detection of subtle structural and genetic features often invisible to the human eye. Clinical evidence shows that AI systems can match or surpass radiologists in sensitivity, though challenges remain regarding lower specificity and the “black box” nature of AI models. The importance of explainable AI is highlighted as essential for improving transparency and reliability in clinical applications.

Correspondence to: dnauduzaite@gmail.com

Gauta 2026-03-08