

Bölüm 6

GİRİŞİMSEL RADYOLOJİ UYGULAMALARINDA YAPAY ZEKA



Hüseyin AKKAYA ¹
Sinan SÖZÜTOK ²

GİRİŞ

Yapay zeka (AI) terimi, belirli girdilerden yeni faydalı çıktılar üretmek için kısmi veya tam bağımsız şekilde insan zekasına özgü olduğu kabul edilen görevleri gerçekleştirebilen hesaplama algoritmalarını içerir (1). AI, girdileri yorulmadan işleyebilen, sonuçları anlayabilen ve mantığını öğrenmek ve geliştirmek için yapılandırılmış deneyimleri kullanabilen insan zihninin bir bilgisayar simülasyonudur (1,2). Yapay zeka, teşhis koyma sürecini kolaylaştırabilir, iyileştirebilir, tedavileri uyarlamaya yardımcı olabilir, kaynakları zamanında ve dinamik bir şekilde kullanmaya yardımcı olabilir. Radyolojik araştırmalara olan talebin radyologların sayısını aştığı ve yeni görüntüleme tekniklerinin hızlı bir şekilde geliştiği bir çağda, son dönemdeki radyoloji araştırmaları çoğunlukla yapay zekaya yönelmektedir (2).

Akıllı davranışı ve eleştirel düşünmeyi simüle etmek için bilgisayar kullanma fikri ilk olarak 1950'de Alan Turing tarafından ortaya atılmıştır (3,4). "Computers and Intelligence" kitabında Turing, bilgisayarların insan zekası yeteneğine sahip olduğunu belirtmiştir. Yaklaşık altı yıl sonrasında John McCarthy yapay zeka terimini "akıllı ma-

kineler yapma bilimi ve mühendisliği" olarak tanımlamıştır. Yapay zeka (AI), 1950'lerden bu yana ilgi konusu olmaya devam etmiştir ancak sağlık alanındaki uygulaması, hasta verilerinin (görüntüler ve kayıtlar) güçlü bilgisayar teknolojisi ve makine öğrenimine dayalı uç öğrenme algoritmaları sayesinde son on yılda teoriden pratiğe doğru ilerlemiştir (3,5). Yapay zekanın gelişimi yapay sinir ağlarının (YSA) tanımlanmasına dayanmakta olup daha sonraki gelişimi (tek katmanlıdan çok katmanlı YSA'ya), "hesaplamalı öğrenme modelleri", makine öğrenimi ve derin öğrenme kavramlarını oluşturmaktadır (6).

Makine öğrenimi, girişimsel radyoloji (GR) alanında hasta değerlendirmenin birçok yönünü geliştirme potansiyeline sahiptir. Makine öğrenimi algoritmaları, görüntü analiziyle ilgili görevlere yardımcı olmak için önemli bir potansiyele sahiptir (7). Anjiyografi işlemlerinde bu bilgisayarlı değerlendirme görevlerini gerçek zamanlı olarak gerçekleştirmek için makine öğrenimi algoritmalarını eğitmek ve uygulamak, operatöre prosedürel destek araçları sağlayabilir (8). Bununla birlikte, GR'de makine öğreniminin potansiyel uygulamaları; hasta seçim modellemesini, tedavi planlaması

¹ Uzm. Dr., Siverek Devlet Hastanesi Radyoloji Bölümü dr.hsynakkaya@gmail.com

² Öğr. Gör. Dr., Çukurova Üniversitesi Tıp Fakültesi Radyoloji AD. Sozutoks@yahoo.com

KAYNAKLAR

1. Chartrand G, Cheng PM, Vorontsov E, et al. Deep learning: a primer for radiologists. *Radiographics* 2017; 37(7), 2113–2131.
2. Asadi H., Dowling R., B. Yan, Mitchell P. Machine learning for outcome prediction of acute ischemic stroke post intra-arterial therapy. *PLoS One*, 9(2), Article ID e88225.
3. Asadi H., Kok K., Looby S. Et al. Outcomes and complications following endovascular treatment of brain arteriovenous malformations: a prognostication attempt using artificial intelligence. *World Neurosurgery*, 96(2019), 562–569.
4. Zhong BY, Ni CF, Ji JS, et al. Nomogram and artificial neural network for prognostic performance on the albumin-bilirubin grade for hepatocellular carcinoma undergoing transarterial chemoembolization. *J Vasc Interv Radiol*, 30(3), 330–338.
5. Hung AJ, Chen J, Che Z, et al. Utilizing machine learning and automated performance metrics to evaluate robot-assisted radical prostatectomy performance and predict outcomes. *J Endourol*, 32(5), 438–444.
6. Condino S, Turini G, Parchi PD, et al. How to build a patient-specific hybrid simulator for orthopaedic open surgery: benefits and limits of mixed reality using the Microsoft HoloLens. *J Healthc Eng*, 2018(1). doi: 10.1155/2018/5435097.
7. Pesapane F. How scientific mobility can help current and future radiology research: a radiology trainee's perspective. *Insights Imaging*, 10(1), 85.
8. Langlotz CP, Allen B, Erickson BJ, Kalpathy-Cramer J, Bigelow K, Cook TS, et al. A roadmap for foundational research on artificial intelligence in medical imaging: from the 2018 NIH/RSNA/ACR/The Academy Workshop. *Radiology*, 291(3), 781–91.
9. Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *Eur Radiol Exp*, 2(1), 35.
10. Ranschaert ER, Morozov S, Algra PR. Artificial intelligence in medical imaging. 2019 Springer. Berlin.
11. Tacher V, de Baere T. Robotic assistance in interventional radiology: dream or reality? *Eur Radiol*, 30(2), 925–926.
12. Krittanawong C. The rise of artificial intelligence and the uncertain future for physicians. *Eur J Intern Med*, 48, 13–14.
13. Kohli M, Prevedello LM, Filice RW et al. Implementing machine learning in radiology practice and research. *AJR*, 208(4):754–760.
14. Ho CWL, Soon D, Caals K, et al. Governance of automated image analysis and artificial intelligence analytics in healthcare. *Clin Radiol*, 74(5):329–337.
15. Sapkaroski D, Mundy M, Dimmock MR. Virtual reality versus conventional clinical role-play for radiographic positioning training: a students' perception study. *Radiography*, 26(1), 7–62.
16. Erdal BS, Prevedello LM, Qian S. Radiology and enterprise medical imaging extensions (REMIX). *J Digit Imaging*, 31(1):91–106.
17. Amisha MP, Pathania M, Rathaur VK. Overview of artificial intelligence in medicine. *J Family Med Prim Care*, 8(7):2328–2331.
18. Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis. *Med Image Anal*, 42, 60–88.
19. Obermeyer Z., Emanuel E.J., “Predicting the future—big data, machine learning and clinical medicine,” *New England Journal of Medicine*, 375(13), 1216–1219.
20. C. Mohan. “Artificial intelligence in radiology—are we treating the image or the patient? *Indian Journal of Radiology and Imaging*, 28(2), 137–139.
21. Liew C. The future of radiology augmented with artificial intelligence: a strategy for success. *Eur J Radiol*, 102, 152–156.
22. Padhani AR, Turkbey B. Detecting prostate cancer with deep learning for MRI: a small step forward. *Radiology*, 293(3), 618–619.
23. Cortes J, Tamura K, DeAngelo DJ. Phase I studies of AZD1208, a proviral integration Moloney virus kinase inhibitor in solid and haematological cancers. *Br J Cancer*, 118(11), 1425–1433.
24. Han X. MR-based synthetic CT generation using a deep convolutional neural network method. *Med Phys*, 44(4), 1408–1419.
25. Abajian A., N. Murali, L. J. Savic et al. “Predicting treatment response to intra-arterial therapies for hepatocellular carcinoma with the use of supervised machine learning—an artificial intelligence concept,” *Journal of Vascular and Interventional Radiology*, 29(6), 850–857.
26. Robert J. Gillies, Paul E. Kinahan Hedvig Hricak. *Radiology*, 278(2), 563–577.
27. Lakhani P, Sundaram B. Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural Networks. *Radiology*, 284(2), 574–582.
28. Stoianovici D. AcuBot: a robot for radiological interventions,” in *IEEE Transactions on Robotics and Automation*, 19(5), 927–930.
29. Hiraki T, Kamegawa T, Matsuno T. (2018) Zerobot*: a remote-controlled robot for needle insertion in CT-guided interventional radiology developed at Okayama University. *Acta Med Okayama*, 72(6), 539–546.
30. Cochenec F, Kobeiter H, Gohel M. et al. (2015) Feasibility and safety of renal and visceral target vessel cannulation using robotically steerable catheters during complex endovascular aortic procedures. *J Endovasc Ther*, 100(7), 187–193.
31. Fagogenis G, Mencattelli M, Machaidze Z et al., Autonomous robotic intracardiac catheter navigation using haptic vision. *Sci Robot*, 4(29), eaaw1977.
32. American Heart Association. “Surgeons successfully treat brain aneurysms using a robot.” ScienceDaily. ScienceDaily, 21 February 2020.