

GİRİŞİMSEL RADYOLOJİDE YAPAY ZEKA GELİŞMELERİ VE UYGULAMALARI

Mehmet Akif SARICA¹

GİRİŞ

Yapay zeka (YZ), mantığını ve karar verme sürecini sürekli olarak geliştirirken, verileri işlemek ve yorumlamanın yanı sıra görevleri kısmi veya tam özerklikle gerçekleştirmek için bilgisayar algoritmalarının geliştirilmesidir. Yapay zeka alanı, ancak büyük miktarda veriyi toplama, saklama ve işleme kapasitesine sahip güçlü hesaplama donanımının daha yakın zamanda geliştirilmesiyle radyolojiyle alakalı hale geldi. Spesifik olarak, girişimsel radyoloji (GR) alanı, yalnızca görüntü işlemeyi geliştirmek için değil aynı zamanda minimal invazif prosedürlerin sonuçlarını yönlendirmek ve tahmin etmek için yapay zekadaki ilerlemelerden faydalanma konusunda benzersiz bir konumdadır.

İlk kez 1950'lerde resmi olarak tanıtılan yapay zekanın büyümesi, bilgi geçişinin bitişik nöronlardan gelen girdiler ve çıktılar yoluyla gerçekleştiği biyolojik sinir ağlarından ilham alan bir fikir olan yapay sinir ağlarının (YSA) tanıtılmasıyla başladı. Tanıtılmasından bu yana, makine öğrenimi (MÖ) ve derin öğrenmeyi (DÖ) içeren hesaplamalı öğrenme modellerinde daha fazla ilerleme kaydedilmiştir (Şekil 1) [1].

MÖ, eğitiminin belirli, etiketli verilere maruz bırakılması yoluyla gerçekleştiği “tersine eğitime” dayanmaktadır [1,2]. DÖ, daha karmaşık, daha yüksek seviyeli görevlerde kullanılmak üzere çok katmanlı yapay sinir ağlarından (YSA) oluşturulmuş özel bir makine öğrenimi alt kümesidir [1,2]. YSA, birden fazla düzeyde öğrenme algoritması içeren veya bir çıkış ‘nöronları’ giriş ve çıkışını içeren bir hesaplama modelidir ve bu katmanlardan biri evrişimli bir filtre içeriyorsa, o zaman evrişimli sinir ağı (ESA) olarak sınıflandırılır.

Sinir ağlarının dahil edilmesiyle DÖ, bir ESA'yı girdi ve çıktı arasında, DÖ'nün esnekliğine katkıda bulunan çok sayıda sinir katmanıyla eğiterek, büyük etiketlenmemiş veri kümelerinden bilgileri otomatik olarak ayırt edebilir [1]. Bu, DÖ'nün insan zekasını, akıl yürütmeyi ve öğrenmeyi daha iyi taklit etmesine olanak tanır [1]. Bu algoritmalar, patolojinin insanın fark edemeyeceği spesifik özelliklerini bile tanımlayabiliyor. Bununla birlikte, sinir ağlarını eğitime ihtiyacı nedeniyle DÖ'nün şu anda vaka verilerinin sınırlı olduğu ve genellikle oldukça değişken olduğu girişimsel radyoloji gibi alanlarda sınırlı uygulamaları vardır.

¹ Uzm. Dr., NCR Hastanesi, Radyoloji Kliniği, drakifs@hotmail.com, ORCID iD: 0000-0001-8472-3174

kanın kullanıma sunulmasıyla karışabilir. Yapay zeka programlarının hasta planlamasını, görüntü analizini ve işlem sonrası takip ve prognozu otomatikleştirmesine izin verilirse ilgili radyoloğun sorumluluğu belirsiz hale gelir [36].

6. SONUÇLAR

GR'nin çok sayıda etkili alanı, yapay zekanın dahil edilmesinden büyük ölçüde faydalanmaya hazır. Bu tekniklerin entegrasyonu yalnızca prosedür planlaması ve performansın yanı sıra tedavi takibine de fayda sağlamakla kalmayacak, aynı zamanda hasta deneyimini iyileştirecek, hem hastanın hem de operatörlerin radyasyona maruz kalmasını azaltacak ve potansiyel olarak hastane maliyetlerini ve olumsuz olayları azaltacaktır. GR'de yapay zekanın faydaları geniş kapsamlıdır ve planlamayı ve minimal invaziv prosedürlerin etkinliğini iyileştirerek bireysel hasta düzeyinde ve aynı zamanda küresel radyoloji eğitimini optimize ederek uluslararası düzeyde yardımcı olabilir. Çok sayıda çalışma, yapay zeka entegrasyonunun GR ortamındaki olumlu etkisini zaten göstermiştir ve gelişen tıbbi görüntüleme teknolojisi ve daha kapsamlı prognostik modellerle birlikte yetenekler daha da genişliyor. Yapay zeka uygulamalarının geniş kapsamının günlük pratikte ortaya çıkmasından önce aşılması gereken belirli sınırlamalar ve dikkate alınması gereken etik hususlar vardır. Ancak devam eden heyecanın yanı sıra araştırma ve veri toplama, GR'deki potansiyel yapay zeka uygulamalarının kilidini açmanın anahtarıdır.

KAYNAKÇA

1. Gurgitano, M.; Angileri, S.A.; Rodà, G.M.; Liguori, A.; Pandolfi, M.; Ierardi, A.M.; Wood, B.J.; Carrafiello, G. Interventional Radiology ex-machina: Impact of Artificial Intelligence on practice. *Radiol. Med.* 2021, 126, 998–1006.
2. Meek, R.D.; Lungren, M.P.; Gichoya, J.W. Machine Learning for the Interventional Radiologist. *AJR Am. J. Roentgenol.* 2019, 213, 782–784.
3. Moussa, A.M.; Ziv, E. Radiogenomics in Interventional Oncology. *Curr. Oncol. Rep.* 2021, 23, 9.
4. Morshid, A.; Elsayes, K.M.; Khalaf, A.M.; Elmohr, M.M.; Yu, J.; Kaseb, A.O.; Hassan, M.; Mahvash, A.; Wang, Z.; Hazle, J.D.; et al. A machine learning model to predict hepatocellular carcinoma response to transcatheter arterial chemoembolization. *Radiol. Artif. Intell.* 2019, 1, e180021.
5. Iezzi, R.; Goldberg, S.N.; Merlino, B.; Posa, A.; Valentini, V.; Manfredi, R. Artificial Intelligence in Interventional Radiology: A Literature Review and Future Perspectives. *J. Oncol.* 2019, 2019, 6153041.
6. D'Amore, B.; Smolinski-Zhao, S.; Daye, D.; Uppot, R.N. Role of Machine Learning and Artificial Intelligence in Interventional Oncology. *Curr. Oncol. Rep.* 2021, 23, 70.
7. Bang, J.Y.; Hough, M.; Hawes, R.H.; Varadarajulu, S. Use of Artificial Intelligence to Reduce Radiation Exposure at Fluoroscopy-Guided Endoscopic Procedures. *Am. J. Gastroenterol.* 2020, 115, 555–561.
8. Zimmermann, J.M.; Vicentini, L.; Van Story, D.; Pozzoli, A.; Taramasso, M.; Lohmeyer, Q.; Maisano, F.; Meboldt, M. Quantification of Avoidable Radiation Exposure in Interventional Fluoroscopy With Eye Tracking Technology. *Investig. Radiol.* 2020, 55, 457–462.
9. Kidd, A.C.; Anderson, O.; Cowell, G.W.; Weir, A.J.; Voisey, J.P.; Evison, M.; Tsim, S.; Goatman, K.A.; Blyth, K.G. Fully automated volumetric measurement of malignant pleural mesothelioma by deep learning AI: Validation and comparison with modified RECIST response criteria. *Thorax* 2022, 77, 1251–1259.
10. Dohan, A.; Gallix, B.; Guiu, B.; Le Malicot, K.; Reinhold, C.; Soyer, P.; Bennouna, J.; Ghiringhelli, F.; Barbier, E.; Boige, V.; et al. Early evaluation using a radiomic signature of unresectable hepatic metastases to predict outcome in patients with colorectal cancer treated with FOLFIRI and bevacizumab. *Gut* 2020, 69, 531–539.
11. Seah, J.; Boeken, T.; Sapoval, M.; Goh, G.S. Prime Time for Artificial Intelligence in Interventional Radiology. *Cardiovasc. Intervent. Radiol.* 2022, 45, 283–289.
12. Daye, D.; Staziaki, P.V.; Furtado, V.F.; Tabari, A.; Fintelmann, F.J.; Frenk, N.E.; Shyn, P.; Tuncali, K.; Silverman, S.; Arellano, R.; et al. CT Texture Analysis and Machine Learning Improve Post-ablation Prognostication in Patients with Adrenal Metastases: A Proof of Concept. *Cardiovasc. Intervent. Radiol.* 2019, 42, 171–1776.
13. Waller, J.; O'Connor, A.; Rafaat, E.; Amireh, A.; Dempsey, J.; Martin, C.; Umair, M. Applications and challenges of artificial intelligence in diagnostic and interventional radiology. *Pol. J. Radiol.* 2022, 87, e113–e117.

14. Uppot, R.N.; Laguna, B.; McCarthy, C.J.; De Novi, G.; Phelps, A.; Siegel, E.; Courtier, J. Implementing virtual and augmented reality tools for radiology education and training, communication, and clinical care. *Radiology* 2019, 291, 570–580.
15. Gao, Y.; Song, Y.; Yin, X.; Wu, W.; Zhang, L.; Chen, Y.; Shi, W. Deep learning-based digital subtraction angiography image generation. *Int. J. Comput. Assist. Radiol. Surg.* 2019, 14, 1775–1784.
16. Molony, D.; Hosseini, H.; Samady, H. TCT-2 Deep IVUS: A machine learning framework for fully automatic IVUS segmentation. *J. Am. Coll. Cardiol.* 2018, 72, B1.
17. Cho, H.; Lee, J.G.; Kang, S.J.; Kim, W.J.; Choi, S.Y.; Ko, J.; Min, H.S.; Choi, G.H.; Kang, D.Y.; Lee, P.H.; et al. Angiography-based machine learning for predicting fractional flow reserve in intermediate coronary artery lesions. *J. Am. Heart Assoc.* 2019, 8, e011685.
18. El-Shallaly, G.E.H.; Mohammed, B.; Muhtaseb, M.S.; Hamouda, A.H.; Nassar, A.H.M. Voice recognition interfaces (VRI) optimize the utilization of theatre staff and time during laparoscopic cholecystectomy. *Minim. Invasive Ther. Allied Technol.* 2005, 14, 369–371.
19. Müller, M.; Rassweiler, M.C.; Klein, J.; Seitel, A.; Gondan, M.; Baumhauer, M.; Teber, D.; Rassweiler, J.J.; Meinzer, H.P.; Maier-Hein, L. Mobile augmented reality for computer-assisted percutaneous nephrolithotomy. *Int. J. Comput. Assist. Radiol. Surg.* 2013, 8, 663–675.
20. Solbiati, M.; Passera, K.M.; Rotilio, A.; Oliva, F.; Marre, I.; Goldberg, S.N.; Ierace, T.; Solbiati, L. Augmented reality for interventional oncology: Proof-of-concept study of a novel high-end guidance system platform. *Eur. Radiol. Exp.* 2018, 2, 18.
21. Letzen, B.; Wang, C.J.; Chapiro, J. The role of artificial intelligence in interventional oncology: A Primer. *J. Vasc. Interv. Radiol.* 2019, 30, 38–41.
22. Desai, S.B.; Pareek, A.; Lungren, M.P. Current and emerging artificial intelligence applications for pediatric interventional radiology. *Pediatr. Radiol.* 2022, 52, 2173–2177.
23. Malpani, R.; Petty, C.W.; Bhatt, N.; Staib, L.H.; Chapiro, J. Use of Artificial Intelligence in Non-Oncologic Interventional Radiology: Current State and Future Directions. *Dig. Dis. Interv.* 2021, 5, 331–337.
24. Sun, L.; Zhu, W.; Chen, X.; Jiang, J.; Ji, Y.; Liu, N.; Xu, Y.; Zhuang, Y.; Sun, Z.; Wang, Q.; et al. Machine Learning to Predict Contrast-Induced Acute Kidney Injury in Patients With Acute Myocardial Infarction. *Front. Med. (Lausanne)* 2020, 7, 592007.
25. Nielsen, M.; Waldmann, M.; Frölich, A.M.; Flottmann, F.; Hristova, E.; Bendszus, M.; Seker, F.; Fiehler, J.; Sentker, T.; Werner, R. Deep Learning-Based Automated Thrombolysis in Cerebral Infarction Scoring: A Timely Proof-of-Principle Study. *Stroke* 2021, 52, 3497–3504.
26. Saillard, C.; Schmauch, B.; Laifa, O.; Moarii, M.; Toldo, S.; Zaslavskiy, M.; Pronier, E.; Laurent, A.; Amaddeo, G.; Regnault, H.; et al. Predicting Survival After Hepatocellular Carcinoma Resection Using Deep Learning on Histological Slides. *Hepatology* 2020, 72, 2000–2013.
27. Gelmini, A.Y.P.; Duarte, M.L.; de Assis, A.M.; Guimarães Junior, J.B.; Carnevale, F.C. Virtual reality in interventional radiology education: A systematic review. *Radiol. Bras.* 2021, 54, 254–260.
28. Gould, D. Using simulation for interventional radiology training. *Br. J. Radiol.* 2010, 83, 546–553.
29. Thrall, J.H.; Li, X.; Li, Q.; Cruz, C.; Do, S.; Dreyer, K.; Brink, J. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *J. Am. Coll. Radiol.* 2018, 15, 504–508.
30. Tadavarthi, Y.; Vey, B.; Krupinski, E.; Prater, A.; Gichoya, J.; Safdar, N.; Trivedi, H. The State of Radiology AI: Considerations for Purchase Decisions and Current Market Offerings. *Radiol. Artif. Intell.* 2020, 2, e200004.
31. Fromherz, M.R.; Makary, M.S. Artificial intelligence: Advances and new frontiers in medical imaging. *Artif. Intell. Med. Imaging* 2022, 3, 33–41.
32. Aggarwal, R.; Sounderajah, V.; Martin, G.; Ting, D.S.W.; Karthikesalingam, A.; King, D.; Ashrafiyan, H.; Darzi, A. Diagnostic accuracy of deep learning in medical imaging: A systematic review and meta-analysis. *NPJ Digit. Med.* 2021, 4, 65.
33. Pesapane, F.; Tantrige, P.; Patella, F.; Biondetti, P.; Nicosia, L.; Ianniello, A.; Rossi, U.G.; Carrafiello, G.; Ierardi, A.M. Myths and facts about artificial intelligence: Why machine- and deep-learning will not replace interventional radiologists. *Med. Oncol.* 2020, 37, 40.
34. Futoma, J.; Simons, M.; Panch, T.; Doshi-Velez, F.; Celi, L.A. The myth of generalisability in clinical research and machine learning in health care. *Lancet Digit. Health* 2020, 2, e489–e492.
35. Geis, J.R.; Brady, A.P.; Wu, C.C.; Spencer, J.; Ranschaert, E.; Jaremko, J.L.; Langer, S.G.; Kitts, A.B.; Birch, J.; Shields, W.F.; et al. Ethics of Artificial Intelligence in Radiology: Summary of the Joint European and North American Multisociety Statement. *Insights Imaging* 2019, 10, 101.
36. Neri, E.; Coppola, F.; Miele, V.; Bibbolino, C.; Grassi, R. Artificial intelligence: Who is respon-

- sible for the diagnosis? *Radiol. Med.* 2020, 125, 517–521.
37. Nalepa, J.; Marcinkiewicz, M.; Kawulok, M. Data Augmentation for Brain-Tumor Segmentation: A Review. *Front. Comput. Neurosci.* 2019, 13, 83.
38. Peck, J.; Roels, J.; Goossens, B.; Saeys, Y. Lower bounds on the robustness to adversarial perturbations. In *Proceedings of the 31st International Conference on Neural Information Processing Systems, Long Beach, CA, USA, 4–9 December 2017*.
39. Mandal, I.; Ojha, U. Training in Interventional Radiology: A Simulation-Based Approach. *J. Med. Educ. Curric. Dev.* 2020, 13, 2382120520912744.