



28.

BÖLÜM

RADYOLOĞUN YAPAY ZEKA HAKKINDA BİLMESİ GEREKENLER

İnci ALTIOK¹

GİRİŞ

Yapay zeka, bilişim ve bilgi-işlem dünyasının en hızlı büyüyen alanlarından biri olup, radyolojiyi çok yakından ilgilendirmektedir. Pubmed’de yakın bir zamanda “yapay zeka” ile ilgili bir tarama yapıldığında bu konu ile ilgili 110.855 yayın vardır ve buna “radyoloji” de eklendiğinde 8358 yayın bulunmaktadır. Bunların çoğu 2005 yılından beri yayınlanmıştır. Radyologlar, stajyerler ve geleceğin radyologlarının ilerleyen yıllarda mesleklerini nasıl değiştirebileceği konusunda fikir sahibi olabilmeleri için, yapay zekanın radyolojiyi ilgilendiren konularını anlamaya ihtiyaçları vardır (1).

TANIMLAMALAR

Yapay zeka insan gibi davranışlar sergileme, sayısal mantık yürütme, hareket, konuşma, ses algılama gibi birçok yeteneğe sahip bilgisayar tabanlı çalışan algoritmaları ifade eder ve makinelerin insanın öğrenme ve problem çözme gibi bilişsel fonksiyonlarını taklit edebilme becerisi olarak tanımlanabilir. Temelde istatistiksel tahmin yöntemlerini kapsamakta olup, bilinen verileri kullanarak yeni karşılaşılan durumlar hakkında öngöründe bulunan ve sınıflandırma yapan algoritmaları kapsamaktadır. Yapay zeka tek bir görevi yerine getirmek için programlanan “yapay sınırlı zeka” ve akıl yürütme, sorunları çözme, planlama gibi bir insanın yapabileceği herhangi bir entelektüel görevi başarıyla gerçekleştirebilen “yapay genel zeka” olarak iki alt kategoriye ayrılabilir (2,3).

1956 yılında Alan Turing, bilgisayara yazılı sorular gönderen bir insan sorulayıcının cevapların bilgisayardan mı yoksa bir insandan mı geldiğini ayırt

¹ Dr. Öğr. Üyesi, Medipol Üniversitesi Koşuyolu Hastanesi Radyoloji Kliniği, ibaltepe@yahoo.com

de yeterli yorumlama becerisi kazanamayabilirler. Madalyonun diğer yüzüne göre, stajyerler yapay zekadan yardım aldıklarında daha iyi yorumlar da yapabilirler; her şeye rağmen, geleceğin radyologlarının yapay zeka yazılımının yardımına fazla bağımlı olmaları bir risktir. Bu risk potansiyel olarak zararlı sonuçlar doğurabilir. Yapay zekanın radyolojiye uygulanması, stajyerlerin yapay zekayı radyoloji pratiğinde en iyi şekilde nasıl kullanabileceklerini öğrenmelerini gerektirir (1). Bu nedenle geleceğin radyoloji eğitimi müfredatında özel bir yapay zeka ve bilişim modülünün yer alması önemlidir.

SONUÇ

Yapay zeka radyologların yerine geçecek mi sorusunun basit cevabı “HA-YIR”dır. Bununla birlikte, radyologların iş yaşantıları bu yapay zeka çağında hiç şüphesiz değişecektir. Radyoloji iş akışındaki rutin basit işlerin birçoğu yapay zeka tarafından daha hızlı ve iyi bir şekilde yapılabilecektir. Fakat radyoloğun rolü daha karmaşık klinik problemleri çözmek üzerine odaklanmak olacaktır (66). Gerçek meydan okuma, yapay zekanın profesyonel yaşantıların içine dahil edilmesine karşı gelmek değil (bu boş bir çabadır), yapay zekayı radyoloji iş akışına dahil ederek radyoloji pratiğindeki kaçınılmaz değişikliği kucaklamaktır (1,13). Radyologlar yapa zekanın yararlı, güvenli ve anlamlı bir şekilde uygulanmasını sağlamak için araştırmacılarla iş birliği yapmalıdır. Yapay zekanın kullanımının her zaman öncelikle hasta yararına yönlendirilmesini sağlayarak kendilerini ve geleceğin radyologlarını eğitmelidirler (67, 68).

KAYNAKLAR

1. European Society of Radiology(ESR). What the radiologist should know about artificial intelligence: an ESR white paper. Insights Imaging 2019;10(1):44.
2. Güven M, Hardalaç F. Yapay Zeka Teknikleri: Çalışma ve araştırma alanları. Hardalaç F, Serhatlıoğlu S, editörler. Yapay Zeka Teknikleri ve Radyolojide Uygulanması. 1. Baskı. Ankara: Türkiye Klinikleri ; 2020. p.1-5.
3. Brink JA, Arenson RL, Grist TM, Lewin JS, Enzman D (2017)Bits and bytes: the future of radiology lies in informatics and information technology. Eur Radiol 27:3647-3651 <https://doi.org/10.1007/s00330-016-4688-5>
4. Nilsson NJ(1998) Artificial Intelligence: A New Synthesis. Morgan Kaufmann Publishers, Inc
5. Turing A(1936) On computable numbers, with an application to the Entscheidungsproblem. Proc Lond Math Soc 2nd Ser42:230-265
6. Uysal F, Güven M, Paç M. Yapay zekanın dünü, bugünü ve geleceği. Hardalaç F, Serhatlıoğlu S, editörler. Yapay Zeka Teknikleri ve Radyolojide Uygulanması. 1. Baskı. Ankara: Türkiye Klinikleri ; 2020. p.6-10.
7. Lighthill J. Artificial Intelligence Report, Science Research Council, 1973.
8. Nagar Y, Malone TW, Combining Human and Machine Intelligence for Making Predictions, MIT Cent. Collect. Intell. Work Pap. 2011;2:1-6

9. McCarthy J, Minsky ML, Rochester N, Shannon CE(1955) Proposal for the Dartmouth summer research project on artificial intelligence. Tech rep, Dartmouth College. Original document available at <http://www-formal.stanford.edu/jnrc/history/Dartmouth.html>. Accessed 13 Oct 2018
10. Russel S, Norvig P (2010) Artificial Intelligence. A modern approach. Pearson Education. Inc. Upper Saddle River, New Jersey. p 07458
11. Samuel AI. (1959) Some studies in machine learning using the game of checkers. IBM Journal 3:211-229
12. Zhou N, Siegel ZD, Zarecor Z et al(2018) Crowdsourcing image analysis for plant phenomics to generate ground truth data for machine learning. PloS Comput Biol 14(7):e1006337. <https://doi.org/10.1371/journal.pcbi.1006337>
13. Fry H(2018) Hello World: How to be human in the age of machine. Doubleday
14. Yamashita R, Nishio M, Do RKG, Togashi K (2018) Convolutional neural networks: an overview and application in radiology. Insights Imaging 9(4):611-629
15. Ravi D, Wong C, Deligianni F, Berthelot M, Andreu-Perez J, Lo B, et al. Deep Learning for Health Informatics. IEEE Journal of Biomedical Health Informatics. 2017; 21(1):4-21
16. Cho J, Lee K, Shin E, Choy G, Do S. How much data is needed to train a medical image deep learning system to achieve necessary high accuracy? arxiv preprint arxiv: 151106348. 2015
17. Doi K(2007) Computer-Aided Diagnosis in Medical Imaging: Historical Review, Current Status and Future Potential. Comput Med Imaging Graph 31(4-5):198-211
18. Lodwick GS, Haun CL, Smith WE, Keller RF, Robertson ED(1963) Computer diagnosis of primary bone tumor. Radiology 80:273-275
19. Meyers PH, Nice CM Jr, Becker HC, Nettleton JW Jr, Sweeney JW, Meckstroth GR(1964) Automated computer analysis of radiographic images. Radiology 83:1029-1034
20. Winsberg F, Elkin M, Macy J Jr, Bordaz V, Weymouth W (1967) Detection of radiographic abnormalities in mammograms by means of optical scanning and computer analysis. Radiology 89: 211-215
21. Kruger RP, Towns JR, Hall DL, Dwyer SJ 3rd, Lodwick GS(1972)Automated radiographic diagnosis via feature extraction and classification of cardiac size and shape descriptors. IEEE Trans Biomed Eng 19(3):174-186
22. Kruger RP, Thompson WB, Turner AF (1974) Computer diagnosis of pneumoconiosis. IEEE Trans Syst Man, Cybern SMC-4:44-47 31
23. Regge D, Halligan S(2013) CAD: how it works, how to use it, performance. Eur J Radiol. 82(8): 1171-1176
24. Al Mohammed B, Brennan PC, Mello Thoms C (2017) A review of lung cancer screening and the role of computer-aided detection. Clin Radiol. 72(6):433-442
25. Katzen J, Dodelzon K(2018) A review of computer aided detection in mammography. Clin Imaging 52:305-309
26. Halabi SS, Prevedello LM, Kalpathy-Cramer J et al (2018) The RSNA Pediatric Bone Age Machine Learning Challenge. Radiology 290:498-503
27. Sadoughi F, Kazemy Z, Hamedan F, et al. (2018) Artificial intelligence methods for the diagnosis of breast cancer by image processing: a review. Breast Cancer(Dove Med Press) 10: 219-230 <https://doi.org/10.2147/BCTT.S175311>
28. Ayer T, Chen Q, Burnside ES (2013) Artificial neural networks in mammography interpretation and diagnostic decision making. Comput Math Methods Med. 2013:832509.<https://doi.org/10.1155/2013/832509>
29. Houssami N, Lee CI, Buist DSM, Tao D (2017) Artificial intelligence for breast cancer screening: Opportunity or hype? Breast 36:31-33. <https://doi.org/10.1016/j.breast.2017.09.003>
30. Codari M, Schiaffino S, Sardanelli F, Trimboli RM (2019) Artificial intelligence for breast MRI in 2008-2018: A Systematic Mapping Review. AJR Am J Roentgenol 212:280-292 <https://doi.org/10.2214/AJR.18.20389>

31. Dalmış MU, Gubern-Merida A, Vreeman S et al (2019) Artificial Intelligence Based- Classification of Breast Lesions Imaged With a Multiparametric Breast MRI Protocol With Ultrafast DCE-MRI, T2 and DWI. *Invest Radiol.* <https://doi.org/10.1097/RLI.0000000000000544>
32. Ha R, Chin C, Karcich J et al (2018) Prior to Initiation of Chemotherapy, Can We Predict Breast Tumor Response? Deep Learning Convolutional Neural Networks Approach Using a Breast MRI Tumor Dataset. *J Digit Imaging* <https://doi.org/10.1007/s10278-018-0144-1>.
33. Rajpurkar P, Irvin J, Ball RI et al (2018) Deep learning for chest radiograph diagnosis: A retrospective comparison of ChexNext to practicing radiologists. *PLoS Med* 15(11):e1002686 <https://doi.org/10.1371/journal.pmed.1002686>
34. Taylor AG, Mielke C, Mongan J (2018) Automated detection of clinically-significant pneumothorax on frontal chest X-rays using deep convolutional neural networks. *PLoS Med.* 15(11):e1002697 <https://doi.org/10.1371/journal.pmed.1002697>
35. Zech JR, Badgeley MA, Liu M et al (2018) Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study. *PLoS Med.* 15(11):e1002683 <https://doi.org/10.1371/journal.pmed.1002683>
36. Setio AAA, Traverso A, de Bel T et al (2017) Validation, comparison and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: The LUNA 16 challenge. *Med Image Anal* 42:1-13
37. Yasaka K, Akai H, Kunimatsu A et al (2018) Liver fibrosis: Deep Convolutional Neural Network for Staging by Using Gadoteric Acid-enhanced Hepatobiliary Phase MR images. *Radiology* 287(1):146-155 <https://doi.org/10.1148/radiol.2017171928>
38. Yasaka K, Akai H, Abe O et al (2018) Deep Learning with Convolutional Neural Network for Differentiation of Liver Masses at Dynamic Contrast-enhanced CT: A Preliminary Study. *Radiology* 286(3):887-896 <http://doi.org/10.1148/radiol.2017170706>
39. Streba CT, Ionescu M, Gheonea DI et al (2012) Contrast-enhanced ultrasonography parameters in neural network diagnosis of liver tumors. *World Journal Gastroenterol* 18(32):4427-4434
40. Lotan E, Jain R, Razavian N et al (2019) State of the Art: Machine Learning Applications in Glioma Imaging. *AJR Am J Roentgenol* 212(1):26-37
41. Naceur MB, Saouli R, Akil M et al (2018) Fully Automatic Brain Tumor Segmentation using End-To-End Incremental Deep Neural Networks in MRI images. *Comput Methods Programs Biomed.* 166:39-49. <http://doi.org/10.1016/j.cmpb.2018.09.007>
42. Yuan Y, Qin W, Buyyounouski M et al (2018) Prostate Cancer Classification with Multi-parametric MRI Transfer Learning Model. *Med Phys.* <http://doi.org/10.1002/mp.13367>
43. Wang J, Wu CJ, Bao ML et al (2017) Machine learning-based analysis of MR radiomics can help to improve the diagnostic performance of PI-RADS v2 in clinically relevant prostate cancer. *Eur Radiol* 27(10):4082-4090
44. Smyser CD, Dosenbach NU, Smyser TA et al (2016) Prediction of brain maturity in infants using machine-learning algorithms. *Neuroimage* 136:1-9.
45. Fartaria MJ, Bonnier G, Roche A et al (2016) Automated detection of white matter and cortical lesions in early stages of multiple sclerosis. *J Magn Reson Imaging* 43(6):1445-1454. <http://doi.org/10.1002/jmri.25095>
46. Zhang X, Yan LF, Hu YC et al (2017) Optimizing a machine learning based glioma grading system using multi-parametric MRI histogram and texture features. *Oncotarget* 8(29):47816-47830.
47. Avendi MR, Kheradvar A, Jafarkhani H (2016) A combined deep-learning and deformable-model approach to fully automatic segmentation of the left ventricle in cardiac MRI. *Med Image Anal* 30:108-119. <http://doi.org/10.1016/j.media.2016.01.005>
48. Cheng R, Roth HR, Lay N et al (2017) Automatic magnetic resonance prostate segmentation by deep learning with holistically nested networks. *J Med Imaging (Bellingham)* 4(4):041302. <https://doi.org/10.1117/1.JMI.4.4.041302>

49. Roth HR, Lu L, Lay N et al (2018) Spatial aggregation of holistically-nested convolutional neural networks for automated pancreas localization and segmentation. *Med Image Anal* 45:94-107. <https://doi.org/10.1016/j.media.2018.01.006>
50. Weston AD, Korfiatis P, Kline TL et al (2018) Automated Abdominal Segmentation of CT Scans for Body Composition Analysis Using Deep Learning. *Radiology* 290:669-679.
51. Gibson E, Giganti F, Hu Y et al (2018) Automatic Multi-Organ Segmentation on Abdominal CT with Dense V-Networks. *IEEE Trans Med Imaging* 37(8): 1822-1834. <https://doi.org/10.1109/TMI.2018.2806309>
52. Liu Y, Stojadinovic S, Hryciushko B et al (2017) A deep convolutional neural network-based automatic delineation strategy for multiple brain metastases stereotactic radiosurgery. *PLoS One* 12(10):0185844. <https://doi.org/10.1371/journal.pone.0185844>
53. Gillies RJ, Kinahan PE, Hricak H (2016) Radiomics: Images Are More Than Pictures, They Are Data. *Radiology* 278:563-577
54. Neri E, Del Re M, Paiar F et al (2018) Radiomics and liquid biopsy in oncology: the holons of systems medicine. *Insights Imaging* 9(6):915-924. <https://doi.org/10.1007/s13244-018-0657-7>
55. Neri E, Regge D (2017) Imaging biobanks in oncology: European perspective. *Future Oncol.* 13(5):433-441. <https://doi.org/10.2217/fon-2016-0239>
56. European Society of Radiology (ESR) (2015) ESR Position Paper on Imaging Biobanks. *Insights Imaging* 6(4):403-410. <https://doi.org/10.1007/s13244-015-0409-x>
57. Hong Y, Kahn CE Jr (2013) Content analysis of reporting templates and free text radiology reports. *J Digit Imaging* 26(5):843-849 <https://doi.org/10.1007/s10278-013-9597-4>
58. Rubin DL, Kahn CE Jr (2017) Common Data Elements in Radiology. *Radiology* 283(3):837-844. <https://doi.org/10.1148/radiol.2016161553>
59. Choy G, Khalilzadeh O, Michalski M et al (2018) Current Applications and Future Impact of Machine Learning in Radiology. *Radiology* 288(2):318-328. <https://doi.org/10.1148/radiol.2018171820>
60. Hosny A, Parmar C, Quackenbush J et al (2018) Artificial intelligence in radiology. *Nat Rev Cancer* 18(8):500-510.
61. Asimov I(1950) "Runaround". I, Robot. The Isaac Asimov Collection ed. Doubleday, New York City, p 40 ISBN 0-385-42304-7
62. Practice and Research. *AJR Am J Roentgenol* 208(4):754-760. <https://doi.org/10.2214/AJR.16.17224>
63. Smith G (2018) *The AI Delusion*. Oxford University Press
64. Şahin Ş, Şirik M, Baykan AH. Yapay zeka uygulamalarında güçlükler ve tuzaklar. Hirdalaç F, Serhatlıoğlu S, editörler. *Yapay Zeka Teknikleri ve Radyolojide Uygulanması*. 1. Baskı, Ankara: Türkiye Klinikleri; 2020. P.64-67.
65. Saba L, Biswas M, Kuppili V et al. The present and future of deep learning in radiology. *European journal of Radiology*. 2019.
66. Kohli M, Geis R (2018) Ethics, Artificial Intelligence and Radiology. *J Am Coll Radiol* 15: 1317-1319. <https://doi.org/10.1016/j.jacr.2018.05.020>
67. Hricak H (2018) 2016. New Horizons Lecture: Beyond Imaging – Radiology of tomorrow. *Radiology* 286:764-775
68. Pesapane F, Codan M, Sardanelli F (2018) Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *Eur Radiol Exp* 2(1):35