



Bölüm 1

KARDİYOLOJİDE YAPAY ZEKANIN YERİ



Ahmet BALUN¹

GİRİŞ

Gelişen teknoloji ile birlikte bilgisayarlar ve makinalarda gelişmiş ve kendilerince zekaya sahip olmaya başlamışlardır. Yapay zeka, makinaların insan gibi düşünüp insan benzeri görevleri yerine getirmesi, deneyimlerinden öğrenmesini ve yeni girdilere uyum sağlama olarak tanımlanabilir. Yapay zeka, normalde insan zekasının özelliği olan tanıma ve tanımlama, planlama yapma, nesneleri ve sesleri tanıma ve problem çözme gibi örnekleri gerçekleştirebilen bir teknoloji olarak tanımlanabilir. Bir bakıma yapay zeka, bir makinenin topladığı verilere dayanarak otonom kararlar verme yeteneği olarak düşünülebilir (1). Yapay zeka insanlar için temel varoluşsal bir tehdit, iş gücü kaybı ve ahlaki sorunlara yol açacağı korkusu olsa da insanlara yaşamın her anında verdiği kolaylıklarla onlara özgürlüğü ve rahatlığı sağlamıştır.

Gelişen teknolojiden en çok fayda gören Tıp bilimi yapay zeka sayesinde tanı ve tedavi aşamasında yine teknolojiden faydalananmaya başlamıştır. Tipta, bu tipik olarak olası bir tanrı tahmin etmek, yeni bir hastalığı tanımlamak veya en iyi tedavi seçenekini seçmek için kullanılan verileri içerir (2). Yapay zeka, bir tanrı koymak veya sonucu tahmin

etmek veya en iyi tedaviyi seçmek için kullanılmıştır. Giyilebilir teknolojilerin son yıllarda artışı, görüntüleme yöntemlerinde olan artış gibi konular nedeniyle tıp alanında da yapay zeka kullanımı bir ihtiyaç haline gelmiştir. Yapay zeka tıbbın pek çok alanında olduğu gibi kardiyolojide de kullanılmaya başlanmış ve gelecekte umut vadeden gelişmeler yaşanmaktadır. Bu bölümde kardiyolojide yapay zekanın günümüzdeki hali ve geleceğinden bahsedeceğiz.

KARDİYAK GÖRÜNTÜLEMEDE

Kardiyovasküler alanda görüntüleme yönteminin kullanılmasının artması önemli bir finansal maliyet getirmektedir. Yapay zeka, görüntü elde etme, ölçüm, raporlama ve sonraki klinik değerlendirmeleri kolaylaştırarak maliyetleri azaltabilir ve görüntüleme tekniklerinin değerini artırabilir. Mevcut görüntü elde etme, yorumlama ve karar verme modeli ile zaman kaybı, verimlilik düşmesi, gözden kaçan tanılar ve yanlış pozitif tanılar ile ilgili sorunlar yaşanmaktadır. Yapay zeka açısından gelişen algoritma ve metodolojilerdeki son gelişmeler, nicel otomatik görüntüleme teknolojisini hastalıkların teşhisine ve kişiselleştirilmiş

¹ Dr. Öğr. Üyesi, Bandırma Onyedi Eylül Üniversitesi Kardiyoloji AD. abalun@bandirma.edu.tr

büyük olasılıkla, yakın gelecekte, yapay zekanın katkısı hastalıklarında tanısı konusunda, görüntüleme uzmanları ve klinisyenler için akıllı yardımcı araçlar olacaktır

KAYNAKLAR

1. Russell, S., & Norvig, P. (2002). Artificial intelligence: a modern approach.
2. Darcy AM, Louie AK, Roberts LW. Machine Learning and the Profession of Medicine. *JAMA*. 2016 Feb 9;315(6):551-2. doi: 10.1001/jama.2015.18421. PMID: 26864406.
3. Dawes, T. J., de Marvao, A., Shi, W., Fletcher, T., Watson, G. M., Wharton, J., ... & O'Regan, D. P. (2017). Machine learning of three-dimensional right ventricular motion enables outcome prediction in pulmonary hypertension: a cardiac MR imaging study. *Radiology*, 283(2), 381-390.
4. Yeboah, J., McClelland, R. L., Polonsky, T. S., Burke, G. L., Sibley, C. T., O'Leary, D., ... & Herrington, D. M. (2012). Comparison of novel risk markers for improvement in cardiovascular risk assessment in intermediate-risk individuals. *Jama*, 308(8), 788-795.
5. Wolterink, J. M., Leiner, T., de Vos, B. D., van Hammersveld, R. W., Viergever, M. A., & Isgum, I. (2016). Automatic coronary artery calcium scoring in cardiac CT angiography using paired convolutional neural networks. *Medical image analysis*, 34, 123-136.
6. Lessmann, N., Isgum, I., Setio, A. A., de Vos, B. D., Ciompi, F., de Jong, P. A., ... & van Ginneken, B. (2016, March). Deep convolutional neural networks for automatic coronary calcium scoring in a screening study with low-dose chest CT. In *Medical Imaging 2016: Computer-Aided Diagnosis* (Vol. 9785, p. 978511). International Society for Optics and Photonics
7. Feuchtnner, G., Kerber, J., Burghard, P., Dichtl, W., Friedrich, G., Bonaros, N., & Plank, F. (2017). The high-risk criteria low-attenuation plaque< 60 HU and the napkin-ring sign are the most powerful predictors of MACE: a long-term follow-up study. *European Heart Journal-Cardiovascular Imaging*, 18(7), 772-779.
8. Conte, E., Annoni, A., Pontone, G., Mushtaq, S., Guglielmo, M., Baggiano, A., ... & Andreini, D. (2017). Evaluation of coronary plaque characteristics with coronary computed tomography angiography in patients with non-obstructive coronary artery disease: a long-term follow-up study. *European Heart Journal-Cardiovascular Imaging*, 18(10), 1170-1178.
9. Zreik, M., Van Hammersveld, R. W., Wolterink, J. M., Leiner, T., Viergever, M. A., & Isgum, I. (2018). A recurrent CNN for automatic detection and classification of coronary artery plaque and stenosis in coronary CT angiography. *IEEE transactions on medical imaging*, 38(7), 1588-1598.
10. Toth, G., Hamilos, M., Pyxaras, S., Mangiacapra, F., Neillis, O., De Vroey, F., ... & De Bruyne, B. (2014). Evolving concepts of angiogram: fractional flow reserve discor-
- dances in 4000 coronary stenoses. *European heart journal*, 35(40), 2831-2838.
11. Nagel, E., Greenwood, J. P., McCann, G. P., Bettencourt, N., Shah, A. M., Hussain, S. T., ... & Berry, C. (2019). Magnetic resonance perfusion or fractional flow reserve in coronary disease. *New England Journal of Medicine*, 380(25), 2418-2428
12. Taylor, C. A., Fonte, T. A., & Min, J. K. (2013). Computational fluid dynamics applied to cardiac computed tomography for noninvasive quantification of fractional flow reserve: scientific basis. *Journal of the American College of Cardiology*, 61(22), 2233-2241
13. Itu, L., Rapaka, S., Passerini, T., Georgescu, B., Schwemmer, C., Schoebinger, M., ... & Comaniciu, D. (2016). A machine-learning approach for computation of fractional flow reserve from coronary computed tomography. *Journal of applied physiology*, 121(1), 42-52.
14. Coenen, A., Kim, Y. H., Kruk, M., Tesche, C., De Geer, J., Kurata, A., ... & Nieman, K. (2018). Diagnostic accuracy of a machine-learning approach to coronary computed tomographic angiography-based fractional flow reserve: result from the MACHINE consortium. *Circulation: Cardiovascular Imaging*, 11(6), e007217.
15. Dey, D., Gaur, S., Ovrehus, K. A., Slomka, P. J., Betancur, J., Goeller, M., ... & Norgaard, B. L. (2018). Integrated prediction of lesion-specific ischaemia from quantitative coronary CT angiography using machine learning: a multicentre study. *European radiology*, 28(6), 2655-2664
16. Tao, Q., Yan, W., Wang, Y., Paiman, E. H., Shamonin, D. P., Garg, P., ... & van der Geest, R. J. (2019). Deep learning-based method for fully automatic quantification of left ventricle function from cine MR images: a multivendor, multicenter study. *Radiology*, 290(1), 81-88.
17. Ruijsink, B., Puyol-Antón, E., Oksuz, I., Sinclair, M., Bai, W., Schnabel, J. A., ... & King, A. P. (2020). Fully automated, quality-controlled cardiac analysis from CMR: validation and large-scale application to characterize cardiac function. *Cardiovascular Imaging*, 13(3), 684-695.
18. Zhang, J., Gajjala, S., Agrawal, P., Tison, G. H., Hallock, L. A., Beussink-Nelson, L., ... & Deo, R. C. (2018). Fully automated echocardiogram interpretation in clinical practice: feasibility and diagnostic accuracy. *Circulation*, 138(16), 1623-1635
19. Moghaddasi H, Nourian S. Automatic assessment of mitral regurgitation severity based on extensive textural features on 2D echocardiography videos. *Comput Biol Med*. 2016 Jun 1;73:47-55. doi: 10.1016/j.combiomed.2016.03.026. Epub 2016 Apr 2. PMID: 27082766
20. Tabassian, M., Alessandrini, M., Herbots, L., Mirea, O., Pagourelas, E. D., Jasaityte, R., ... & D'hooge, J. (2017). Machine learning of the spatio-temporal characteristics of echocardiographic deformation curves for infarct classification. *The international journal of cardiovascular imaging*, 33(8), 1159-1167
21. Narula, S., Shameer, K., Salem Omar, A. M., Dudley, J. T., & Sengupta, P. P. (2016). Machine-learning algorithms to automate morphological and functional assessments in 2D echocardiography. *Journal of the American College of Cardiology*, 68(21), 2287-2295.

22. Sengupta, P. P., Huang, Y. M., Bansal, M., Ashrafi, A., Fisher, M., Shameer, K., ... & Dudley, J. T. (2016). Cognitive machine-learning algorithm for cardiac imaging: a pilot study for differentiating constrictive pericarditis from restrictive cardiomyopathy. *Circulation: Cardiovascular Imaging*, 9(6), e004330.
23. Choi, E., Schuetz, A., Stewart, W. F., & Sun, J. (2017). Using recurrent neural network models for early detection of heart failure onset. *Journal of the American Medical Informatics Association*, 24(2), 361-370.
24. Ten Eyck, L., MacLeod, S., Hawkins, K., Guimont, R., & Hartley, S. (2019). The impact of a heart failure management program in a Medicare advantage population. *Population health management*, 22(2), 153-161.
25. Conraads, V. M., Spruit, M. A., Braunschweig, F., Cowie, M. R., Tavazzi, L., Borggrefe, M., ... & van Veldhuisen, D. J. (2014). Physical activity measured with implanted devices predicts patient outcome in chronic heart failure. *Circulation: Heart Failure*, 7(2), 279-287.
26. Corder, K., Brage, S., & Ekelund, U. (2007). Accelerometers and pedometers: methodology and clinical application. *Current Opinion in Clinical Nutrition & Metabolic Care*, 10(5), 597-603.
27. Lindholm, D., & Holzmann, M. (2018). Machine learning for improved detection of myocardial infarction in patients presenting with chest pain in the emergency department. *Journal of the American College of Cardiology*, 71(11S), A225-A225.
28. Shameer, K., Johnson, K. W., Glicksberg, B. S., Dudley, J. T., & Sengupta, P. P. (2018). Machine learning in cardiovascular medicine: are we there yet?. *Heart*, 104(14), 1156-1164.
29. Krittanawong, C., Zhang, H., Wang, Z., Aydar, M., & Kitai, T. (2017). Artificial intelligence in precision cardiovascular medicine. *Journal of the American College of Cardiology*, 69(21), 2657-2664.)
30. Sardar, P., Abbott, J. D., Kundu, A., Aronow, H. D., Granda, J. F., & Giri, J. (2019). Impact of artificial intelligence on interventional cardiology: from decision-making aid to advanced interventional procedure assistance. *Cardiovascular Interventions*, 12(14), 1293-1303.
31. Shah, A. P., & Rubin, S. A. (2007). Errors in the computerized electrocardiogram interpretation of cardiac rhythm. *Journal of electrocardiology*, 40(5), 385-390.
32. Poon, K., Okin, P. M., & Kligfield, P. (2005). Diagnostic performance of a computer-based ECG rhythm algorithm. *Journal of electrocardiology*, 38(3), 235-238.
33. Tison GH, Sanchez JM, Ballinger B, Singh A, Olglin JE, Pletcher MJ, Vittinghoff E, Lee ES, Fan SM, Gladstone RA, Mikell C, Sohoni N, Hsieh J, Marcus GM. Passive Detection of Atrial Fibrillation Using a Commercially Available Smartwatch. *JAMA Cardiol*. 2018 May 1;3(5):409-416. doi: 10.1001/jamacardio.2018.0136. PMID: 29562087; PMCID: PMC5875390.
34. Bumgarner, J. M., Lambert, C. T., Hussein, A. A., Cantillon, D. J., Baranowski, B., Wolski, K., ... & Tarakji, K. G. (2018). Smartwatch algorithm for automated detection of atrial fibrillation. *Journal of the American College of Cardiology*, 71(21), 2381-2388.
35. Shcherbina, A., Mattsson, C. M., Waggott, D., Salisbury, H., Christle, J. W., Hastie, T., ... & Ashley, E. A. (2017). Accuracy in wrist-worn, sensor-based measurements of heart rate and energy expenditure in a diverse cohort. *Journal of personalized medicine*, 7(2), 3.
36. Perez MV, Mahaffey KW, Hedlin H, Rumsfeld JS, Garcia A, Ferris T, Balasubramanian V, Russo AM, Rajmane A, Cheung L, Hung G, Lee J, Kowey P, Talati N, Nag D, Gummidi Pundi SE, Beatty A, Hills MT, Desai S, Granger CB, Desai M, Turakhia MP; Apple Heart Study Investigators. Large-Scale Assessment of a Smartwatch to Identify Atrial Fibrillation. *N Engl J Med*. 2019 Nov 14;381(20):1909-1917. doi: 10.1056/NEJMoa1901183. PMID: 31722151; PMCID: PMC8112605.
37. Guo Y, Wang H, Zhang H, Liu T, Liang Z, Xia Y, Yan L, Xing Y, Shi H, Li S, Liu Y, Liu F, Feng M, Chen Y, Lip GYH; MAFA II Investigators. Mobile Photoplethysmographic Technology to Detect Atrial Fibrillation. *J Am Coll Cardiol*. 2019 Nov 12;74(19):2365-2375. doi: 10.1016/j.jacc.2019.08.019. Epub 2019 Sep 2. PMID: 31487545
38. Galloway CD, Valys AV, Shreibati JB, Treiman DL, Petterson FL, Gundotra VP, Albert DE, Attia ZI, Carter RE, Asirvatham SJ, Ackerman MJ, Noseworthy PA, Dillon JJ, Friedman PA. Development and Validation of a Deep-Learning Model to Screen for Hyperkalemia From the Electrocardiogram. *JAMA Cardiol*. 2019 May 1;4(5):428-436. doi: 10.1001/jamacardio.2019.0640. PMID: 30942845; PMCID: PMC6537816.)
39. Kolossvary, M., Kellermayer, M., Merkely, B., & Maurovich-Horvat, P. (2018). Cardiac computed tomography radiomics. *Journal of thoracic imaging*, 33(1), 26-34.
40. Kotu, L. P., Engan, K., Skretting, K., Måløy, F., Ørn, S., Woie, L., & Eftestøl, T. (2013). Probability mapping of scarred myocardium using texture and intensity features in CMR images. *Biomedical engineering online*, 12(1), 1-19.
41. Larroza, A., Materka, A., López-Lereu, M. P., Monmenneu, J. V., Bodí, V., & Moratal, D. (2017). Differentiation between acute and chronic myocardial infarction by means of texture analysis of late gadolinium enhancement and cine cardiac magnetic resonance imaging. *European journal of radiology*, 92, 78-83.