



27. BÖLÜM

YAPAY ZEKANIN ROMATOLOJİK GÖRÜNTÜLEMEDE KULLANIMI

Seher ŞENER¹

GİRİŞ

Yapay zeka, insan zekasına özgü olan, algılama, öğrenme, çoğul kavramları bağlama, düşünme, fikir yürütme, sorun çözme, iletişim kurma, çıkarım yapma ve karar verme gibi yüksek bilişsel fonksiyonları veya otonom davranışları sergilemesi beklenen yapay bir işletim sistemidir (1). Yapay zekanın amacı insanın zekasını bilgisayar aracılığı ile taklit etmek ve bu anlamda belli bir ölçüde bilgisayarlara öğrenme yeteneği kazandırabilmektir. Bu durum, bazen toplumu zor şekilde etkileyebilecek belirsiz bir teknoloji olarak algılanabiliyor olsa da, yapay zekanın tıbbi görüntüleme ile tıbbi bakım ve araştırmada, etkinliği ve verimliliği artırmada kullanılabileceği de oldukça aşikardır. Son zamanlarda özellikle romatoid artrit (RA) ve sistemik skleroz (SSc) gibi önemli romatolojik hastalıklarda görüntüleme yapay zeka kullanılmaya başlanmıştır (1).

Günümüzde yapay zeka yöntemi, “makine öğrenimi” ve onun alt dalı olan “derin öğrenme” olmak üzere esasen iki temel alanda kullanılmaktadır (2) Bu kavramlar yapay zekayı oluşturan kapsayıcı terimlerdir. Makine öğrenimi, bir makinenin elde edilen verilerle mantıklı ve rasyonel sonuçlar türetmesini sağlayan algoritmalarıdır. Derin öğrenme ise, herhangi bir insan müdahalesi gerektirmeden; algoritmalar ve büyük veri kümeleri kullanarak kalıplar bulan ve çıktılar oluşturup yanıtlar veren bir makine öğrenme tekniğidir. Makine öğrenimi tek katmanda işlem yaparken derin öğrenme birçok katmanda aynı anda işlem yapabilmektedir.

¹ Uzm. Dr., Hacettepe Üniversitesi Tıp Fakültesi, Çocuk Romatoloji BD, kzl_seher@hotmail.com

KAYNAKLAR

1. Stoel, B., Use of artificial intelligence in imaging in rheumatology - current status and future perspectives. *RMD Open*, 2020. 6(1).
2. Thrall, J.H., et al., Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *J Am Coll Radiol*, 2018. 15(3 Pt B): p. 504-508.
3. Carano, R.A., et al., Multispectral analysis of bone lesions in the hands of patients with rheumatoid arthritis. *Magn Reson Imaging*, 2004. 22(4): p. 505-14.
4. Tripoliti, E.E., D.I. Fotiadis, and M. Argyropoulou, Automated segmentation and quantification of inflammatory tissue of the hand in rheumatoid arthritis patients using magnetic resonance imaging data. *Artif Intell Med*, 2007. 40(2): p. 65-85.
5. Boesen, M., et al., Correlation between computer-aided dynamic gadolinium-enhanced MRI assessment of inflammation and semi-quantitative synovitis and bone marrow oedema scores of the wrist in patients with rheumatoid arthritis--a cohort study. *Rheumatology (Oxford)*, 2012. 51(1): p. 134-43.
6. Aizenberg, E., et al., Automatic quantification of bone marrow edema on MRI of the wrist in patients with early arthritis: A feasibility study. *Magn Reson Med*, 2018. 79(2): p. 1127-1134.
7. Disini, L., et al., Cancellous bone changes in the radius of patients with rheumatoid arthritis: a cross-sectional quantitative macroradiographic study. *Rheumatology (Oxford)*, 2004. 43(9): p. 1150-7.
8. Langs, G., et al., Automatic quantification of joint space narrowing and erosions in rheumatoid arthritis. *IEEE Trans Med Imaging*, 2009. 28(1): p. 151-64.
9. Rohrbach, J., et al., Bone erosion scoring for rheumatoid arthritis with deep convolutional neural networks. *Computers & Electrical Engineering*, 2019. 78: p. 472-481.
10. Töpfer, D., et al., Segmentation and quantification of bone erosions in high-resolution peripheral quantitative computed tomography datasets of the metacarpophalangeal joints of patients with rheumatoid arthritis. *Rheumatology (Oxford)*, 2014. 53(1): p. 65-71.
11. Allander, E., et al., Computerized assessment of radiological changes of the hand in rheumatic diseases. *Scand J Rheumatol*, 1989. 18(5): p. 291-6.
12. Eckstein, F. and C. Peterfy, A 20 years of progress and future of quantitative magnetic resonance imaging (qMRI) of cartilage and articular tissues--personal perspective. *Semin Arthritis Rheum*, 2016. 45(6): p. 639-47.
13. Liu, F., et al., Deep Learning Approach for Evaluating Knee MR Images: Achieving High Diagnostic Performance for Cartilage Lesion Detection. *Radiology*, 2018. 289(1): p. 160-169.
14. Anderson, M.E., et al., Computerized nailfold video capillaroscopy--a new tool for assessment of Raynaud's phenomenon. *J Rheumatol*, 2005. 32(5): p. 841-8.
15. Scheja, A., et al., Computer based quantitative analysis of capillary abnormalities in systemic sclerosis and its relation to plasma concentration of von Willebrand factor. *Ann Rheum Dis*, 1996. 55(1): p. 52-6.
16. Jones, B.F., et al., A proposed taxonomy for nailfold capillaries based on their morphology. *IEEE Trans Med Imaging*, 2001. 20(4): p. 333-41.
17. Zhai, Z., et al., Pulmonary Vascular Morphology Associated With Gas Exchange in Systemic Sclerosis Without Lung Fibrosis. *J Thorac Imaging*, 2019. 34(6): p. 373-379.
18. Genovese, D., et al., Machine Learning-Based Three-Dimensional Echocardiographic Quantification of Right Ventricular Size and Function: Validation Against Cardiac Magnetic Resonance. *J Am Soc Echocardiogr*, 2019. 32(8): p. 969-977.
19. Abignano, G., et al., Virtual skin biopsy by optical coherence tomography: the first quantitative imaging biomarker for scleroderma. *Ann Rheum Dis*, 2013. 72(11): p. 1845-51.
20. Lagarde, J.M., et al., Automatic measurement of dermal thickness from B-scan ultrasound images using active contours. *Skin Res Technol*, 2005. 11(2): p. 79-90.

21. Ognard, J., et al., Edge detector-based automatic segmentation of the skin layers and application to moisturization in high-resolution 3 Tesla magnetic resonance imaging. *Skin Res Technol*, 2019. 25(3): p. 339-346.
22. Sciolla, B., et al., Joint segmentation and characterization of the dermis in 50 MHz ultrasound 2D and 3D images of the skin. *Comput Biol Med*, 2018. 103: p. 277-286.
23. Ninaber, M.K., et al., Lung structure and function relation in systemic sclerosis: application of lung densitometry. *Eur J Radiol*, 2015. 84(5): p. 975-9.