

PLASTİK, REKONSTRÜKTİF VE ESTETİK CERRAHİDE YAPAY ZEKANIN KULLANIMI

Alper URAL¹

GİRİŞ

Yapay zeka, basitçe makinelere akıl yürütme, nesne ve kelime bilgisi gibi bilişsel işlevler kazandırarak problem çözme, karar verme yeteneği veren algoritmalar ile ilgili çalışmalar olarak tanımlanabilir. Bazen “makine zekası” olarak da adlandırılan yapay zeka özetleme yapabilen, simüle edebilen, yaratıcı ve tümdengelimli bir düşünce kapasitesine sahip bir makine gibi düşünülebilir. Birkaç anahtar terimin anlaşılması yapay zekayı tam kavrayabilmek için çok önemlidir. Makine öğrenmesi, temsil öğrenme, derin öğrenme, denetimli öğrenme ve denetimsiz öğrenme dahil olmak üzere çeşitli öğrenme türleri vardır(1). Makine öğrenme genellikle yapay zeka teriminin yerine kullanılıyor olsa da, bunun yapay zekanın bir bileşeni olarak ele almak daha doğrudur. Makine öğreniminin temeli yapılması istenen her şeyi adım adım öğretmek ihtiyacından ziyade, makineler eğer bizim gibi düşünmek üzere programlanabilir ise, gözlemleyerek, sınıflandırarak ve hatalarından da öğrenerek çalışmayı öğrenebilir. Tahmini makine öğrenme modelleri, algoritmanın hem girdilerin hem de istenen çıktılarının örneklerini kullanarak eğitildiği, gelecekteki girdilerin çıktılara eşlenmesini sağlayan denetimli öğrenme alanına girer(2). Bu sürecin amacı, yeni verilerden istenen hedef değerleri tahmin edebilen benzersiz bir model olmasıdır. Buna bir örnek olarak 2005’ten 2009’a kadar olan verileri kullanarak, cerrahi prosedürlere risk puanları üretebilen bir algoritma geliştirmek amacıyla mevcut prosedür terminolojisi, mortalite, morbidite, Clavien tip 4 komplikasyonlar ve cerrahi saha enfeksiyonları arasındaki ilişkiler belirlenerek bir destek vektör makinesi eğitilmiştir. Destek vektörü makine yaklaşımı, diğer yöntemlerle karşılaştırıldığında cerrahi komplikasyonları daha yüksek oranda bilmeyi ve ayrımını yapmayı başarmıştır(3). Önceden bilim kurgudan ibaret olduğu düşünülen yapay zeka giderek

¹ Öğretim Üyesi, Kahramanmaraş Sütçü İmam Üniversitesi, Tıp Fakültesi Plastik, Rekonstrüktif ve Estetik Cerrahi AD, Dr.

için ve beklentilerini belirlemek için bir tahmin aracı olarak hizmet edebilmesinin yanında marjinal bir değişim bekleyen hastaların da ayrıca ameliyat olmasını engellemek için nicel ve rasyonel bir önlem sağlayabilir(27). Dorfman ve arkadaşları en sık uygulanan estetik ameliyatlardan olan rinoplasti ameliyatının hastanın görünür yaşı üzerindeki etkisini araştırmak için rinoplasti ameliyatı yaptıkları toplamda 100 hastalarının ameliyat öncesi ve sonrası fotoğrafları üzerinden 96x96 piksellik görüntülerde 68 adet tanımlanmış nirengi noktası baz alınarak önceden eğitilmiş yüzün görünen yaşını tahmin edebilen bir konvolusyonel nöral ağ algoritması (Microsoft Azure Face API, Redmond, WA) kullanarak analiz etmişler ve bunun sonucunda bu algoritma sayesinde estetik rinoplasti ameliyatının hastaların görünen yaşını ortalama 3,10 yaş azalttığını bulmuşlardır(28) . Böylece, makine öğrenme algoritmaları konvolusyonel nöral ağlar sayesinde hastaların rinoplasti öncesi ve sonrası yaşlarını tahmin etmede hassas ve doğru sonuçlar elde edilmesiyle gerçekten de rinoplastinin yaşlanma karşıtı etkisinin objektif olarak ölçülebilir olduğu gösterilmiştir.

SONUÇ

Plastik cerrahide klinik pratikte, araştırmada ve eğitimde bir çok avantajlar sunan yapay zeka, karmaşık klinik muayene ve araştırma üzerine problemleri çözmek için yüksek hacimli sayısal ve görsel klinik verilerden etkili bir şekilde öğrenip analiz ederek çok sayıda imkan sunmaktadır. Yapay zekanın kullanımı ve güncel klinik kullanıma entegre edilebilmesine ilişkin bir takım kısıtlamaların aşılmasıyla birlikte yapay zeka plastik cerrahların eğitiminde, ameliyat planlamalarında ve ameliyat sonuçlarının değerlendirilmesi gibi alanlarda hayatlarına daha da fazla girerek büyük kolaylıklar sağlayacaktır.

KAYNAKLAR

1. Mayo RC, and Leung J. Artificial intelligence and deep learning - Radiology's next frontier? Clin Imaging 2018;49: 87-88.
2. Meyfroidt G, Güiza F, Ramon J, Bruynooghe M. Machine learning techniques to examine large patient databases. Best Pract Res Clin Anaesthesiol. 2009;23:127-143.
3. Van Esbroeck A, Rubinfeld I, Hall B, Syed Z. Quantifying surgical complexity with machine learning: Looking beyond patient factors to improve surgical models. Surgery 2014;156:1097-1105.
4. Kim YJ, Kelley BP, Nasser JS, Chung KC. Implementing precision medicine and artificial intelligence in plastic surgery: concepts and future prospects. Plast Reconstr Surg Glob Open 2019;7(3):e2113
5. Kanevsky J, Corban J, Gaster R, Kanevsky A, Lin S, Gilardino M. Big data and machine learning in plastic surgery: a new frontier in surgical innovation. Plast Reconstr Surg 2016;137(5):890e-897e

6. Yeong EK, Hsiao TC, Chiang HK, Lin CW. Prediction of burn healing time using artificial neural networks and reflectance spectrometer. *Burns* 2005;31:415–420.
7. Cirillo MD, Mirdell R, Sjöberg F, Pham TD. Time-Independent Prediction of Burn Depth Using Deep Convolutional Neural Networks. *J Burn Care Res.* 2019 Oct 16;40(6):857-863. doi: 10.1093/jbcr/irz103.
8. Kiranantawat K, Sitpahul N, Taepasartsit P, et al. The first Smartphone application for micro-surgery monitoring: SilpaRamanitor. *Plast Reconstr Surg.* 2014;134:130–139.
9. Mendoza CS, Safdar N, Okada K, Myers E, Rogers GF, Linguraru MG. Personalized assessment of craniosynostosis via statistical shape modeling. *Med Image Anal.* 2014;18:635–646.
10. Dixon MJ, Marazita ML, Beaty TH, Murray JC. Cleft lip and palate: Understanding genetic and environmental influences. *Nat Rev Genet.* 2011;12:167–178.
11. Patcas R, Bernini DAJ, Volokitin A, Agustsson E, Rothe R, Timofte R. Applying artificial intelligence to assess the impact of orthognathic treatment on facial attractiveness and estimated age. *Int J Oral Maxillofac Surg.* 2019 Jan;48(1):77-83. doi: 10.1016/j.ijom.2018.07.010.
12. Nishimoto S, Sotsuka Y, Kawai K, Ishise H, Kakibuchi M. Personal computerbased cephalometric landmark detection with deep learning using cephalograms on the Internet. *J Craniofac Surg* 2019;30(1):91–5.
13. Choi HI, Jung SK, Baek SH, Lim WH, Ahn SJ, Yang IH, Kim TW. Artificial Intelligent Model With Neural Network Machine Learning for the Diagnosis of Orthognathic Surgery. *J Craniofac Surg.* 2019 Oct;30(7):1986-1989. doi: 10.1097/SCS.0000000000005650.
14. Li L, Song X, Guo Y, et al. Deep Convolutional Neural Networks for Automatic Detection of Orbital Blowout Fractures (published online ahead of print, 2019 Dec 13). *J Craniofac Surg.* 2019; 10.1097/SCS.0000000000006069. doi:10.1097/SCS.0000000000006069
15. Conforth M, Meng Y, Valmikinathan C, Xiaojun Y. Nerve graft selection for peripheral nerve regeneration using neural networks trained by a hybrid ACO/PSO method. Paper presented at: 6th Annual IEEE Symposium on Computational Intelligence in Bioinformatics and Computational Biology; March 30–April 2, 2009; Nashville, Tenn.
16. Hincapie JG, Kirsch RF. Feasibility of EMG-based neural network controller for an upper extremity neuroprosthesis. *IEEE Trans Neural Syst Rehabil Eng.* 2009;17:80–90.
17. Luján JL, Crago PE. Computer-based test-bed for clinical assessment of hand/wrist feed-forward neuroprosthetic controllers using artificial neural networks. *Med Biol Eng Comput.* 2004;42:754–761.
18. Totty JP, Harwood AE, Wallace T et al. Use of photograph-based telemedicine in postoperative wound assessment to diagnose or exclude surgical site infection. *J Wound Care* 2018; 27(3):128–135. <https://doi.org/10.12968/jowc.2018.27.3.128>
19. Li F, Wang C, Liu X, Peng Y, Jin S. A Composite Model of Wound Segmentation Based on Traditional Methods and Deep Neural Networks (published correction appears in *Comput Intell Neurosci.* 2018 Sep 12;2018:4967290). *Comput Intell Neurosci.* 2018;2018:4149103. Published 2018 May 31. doi:10.1155/2018/4149103
20. Wang L, Pedersen PC, Agu E, Strong DM, Tulu B. Area Determination of Diabetic Foot Ulcer Images Using a Cascaded Two-Stage SVM-Based Classification. *IEEE Trans Biomed Eng.* 2017;64(9):2098–2109. doi:10.1109/TBME.2016.2632522
21. Goyal M, Yap MH, Reeves ND et al. Fully convolutional networks for diabetic foot ulcer segmentation. *IEEE* 2017. <https://doi.org/10.1109/SMC.2017.8122675>
22. Ohura N, Mitsuno R, Sakisaka M, et al. Convolutional neural networks for wound detection: the role of artificial intelligence in wound care. *J Wound Care.* 2019;28(Sup10):S13–S24. doi:10.12968/jowc.2019.28.Sup10.S13

23. Conner-Simons A. Using artificial intelligence to improve early breast cancer detection. 2017. Available at <http://news.mit.edu/2017/artificial-intelligence-early-breast-cancer-detection-1017>. Accessed July 17, 2018.
24. Ehteshami Bejnordi B, Veta M, Johannes van Diest P, et al; The CAMELYON16 Consortium. Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. *JAMA*. 2017;318:2199–2210.
25. de Boer M, van Leeuwen FE, Hauptmann M, et al. Breast implants and the risk of anaplastic large-cell lymphoma in the breast. *JAMA Oncol*. 2018;4:335–341.
26. Bilgen F, Ural A, Bekerecioğlu M. Preoperative Estimation of Breast Resection Weight in Patients Undergoing Inferior Pedicle Reduction Mammoplasty: Bilgen Formula (published online ahead of print, 2020 Mar 31). *Turk J Med Sci*. 2020;10.3906/sag-1905-7.
27. Gunes H, Piccardi M. Assessing facial beauty through proportion analysis by image processing and supervised learning. *Int J Hum-Comput St*. 2006;64:1184–1199.
28. Dorfman R, Chang I, Saadat S, Roostaeian J. Making the Subjective Objective: Machine Learning and Rhinoplasty (published online ahead of print, 2019 Nov 30). *Aesthet Surg J*. 2019;sjz259. doi:10.1093/asj/sjz259