

Bölüm 8

OFTALMOLOJİDE YAPAY ZEKANIN YERİ

Büşra ENGİN POTOĞLU¹

GİRİŞ

2020 yılı bilgi ve iletişim teknolojileri açısından bu yeni yüzyılda benzeri görülmemiş bir hızla ilerleyen birkaç önemli dijital yeniliğin eşzamanlı olgunlaşmasını getirdi. Teletıp yöntemlerinin yaygınlaşmaya başlaması, 5G kablosuz ağların geliştirilmesi, makine öğrenimi ve derin öğrenme gibi yapay zeka yaklaşımları endüstriyel alanların yanı sıra sağlık alanında da yeni fırsatlar için olağanüstü bir ekosistem yarattı (1). Bu gelişmeler hastalıkların tanı, tarama ve izlem süreçlerini temelden değiştirmekle birlikte tedavi süreçlerinin daha fazla hassaslaşması ve kişiselleşmesine yol açabilir. Bahsedilen gelişmeler, artan ve yaşlanan nüfusa yönelik adil, evrensel ve sürdürülebilir sağlık hizmetlerinin planlanması ve geliştirilmesi için sağlık hizmet sunucularına ve politika yapıcılara karşılaşılabilecek sorunlara yönelik bir çıkış noktası sunabilir.

YAPAY ZEKA, MAKİNE ÖĞRENİMİ VE DERİN ÖĞRENME

Yapay zeka kavramı ilk olarak 31 Ağustos 1955'te insan davranışını taklit etmeye yarayan teknolojiye atıfta bulunarak kullanılmıştır (2). Yapay zekanın bir alt alanı olarak, sistemlerin programlanmak yerine otomatik olarak deneyimlerden öğrenmesinin önemini vurgulayan makine öğrenimi 1959'da Arthur Samuel tarafından kavramsallaştırıldı (3). Makine öğreniminde temel amaç, bilgisayara girilen belirli miktarda veriye dayalı olarak bir algoritma oluşturmak ve sonrasında bu algoritmaya dayalı olarak tahminleri iyileştirmektir. Makine öğreniminde tahminleri iyileştirmek için denetimli ve denetimsiz öğrenme olmak üzere 2 tür öğrenme süreci vardır. Denetimli öğrenmede, verilere bilgisayara girildikçe etiketler atanırken, denetimsiz öğrenmede cihaz etiketlenmemiş verilerden kendi algoritmasını oluşturur. Makine öğreniminin bir alt alanı olan

¹ Uzm. Dr., Kırklareli Lüleburgaz Devlet Hastanesi, Göz Hastalıklar Kliniği, busrengin@hotmail.com

derin öğrenme makine öğreniminin aksine çıktı oluşturmak için birden çok katman kullanarak bilgi teknolojilerinde büyük atılımlar başlattı. Derin öğrenme, insan beynine benzer şekilde sinir ağlarını kullanarak çoklu işleme katmanlarından gelen verilerdeki temel özellikleri inceleyebilir ve kendi algoritmasını oluşturmak için her eğitim döngüsünde kendini geliştirebilir. (4). 2010'lardan günümüze derin öğrenme özellikle görüntü ve konuşma tanıma başta olmak üzere birçok alanda büyük ilgi topladı (5). Diğer birçok alanda olduğu gibi derin öğrenme tıp alanında da önemini arttırmaktadır. Tıbbi uygulamalarda derin öğrenme görüntü temelli alanlarda daha etkilidir. Akciğer grafilerinden tübrekülozu ve cilt fotoğraflarından malign melanomu saptayarak kendini kanıtlamıştır (6,7).

OFTALMOLOJİDE YAPAY ZEKA

Tıp alanında her geçen gün daha yaygınlaşan ve gelişen yapay zeka çalışmalarından oftalmoloji de payını almaktadır. Şimdiye kadar oftalmologlar çeşitli oküler hastalıkların klinik özelliklerine, alana özgü birçok cihazda yapılan testlere ve sağlıklı bir göz ile hastalıkların evrelerinde oluşan kayda değer farklara dayanarak teşhis izlem ve tedavi kararı almışlardır. Yapay zeka potansiyel olarak oftalmologları bu rutin görevlerden kurtaracak ve tanı, izlem ve tedavi kararlarında destek olabilecek gelişmekte olan bir disiplindir. Oftalmolojide, optik koherens tomografi (OKT), renkli fundus fotoğrafı ve görme alanı gibi görüntü temelli çok sayıda dijital tekniğin olması ve sağladıkları devasa veri tabanı düşünüldüğünde, oftalmoloji yapay zeka çalışmaları ve kullanımı için oldukça etkili bir disiplin olacaktır. Yapay zekanın günümüz oftalmoloji perspektifinde diyabetik retinopati (DR), yaşa bağlı maküla dejenerasyonu (YBMD), glokom, prematüre retinopatisi (ROP), nöro-oftalmoloji ve göz hareket çalışmaları ile ön plana çıktığı ancak gelecek dönemlerde günlük pratiğimizde daha çok yer alabileceği düşünülmektedir.

DR, diyabetli kişilerde retinanın küçük damarlarını etkileyen bir hastalıktır. Küresel olarak 2040 yılına kadar 600 milyon insanın diyabet hastası olacağı ve üçte birinin ise diyabetik retinopatiye sahip olacağı öngörülmektedir (8). Diyabetik retinopati için tarama ile zamanında tedavi oluşturulması körlüğün önlenmesi için evrensel olarak kabul edilen bir stratejidir. Etkilediği ve etkilemesi potansiyel nüfus ile klinik pratikte yaygın karşılaşılması ve tanı yöntemlerinin görsel temelli oluşu nedeni ile DR yapay zeka çalışmalarında önemli bir rol almıştır. Günümüzde yapay zeka ile oluşturulmuş DR taraması ve fundus görün-

tülerinde evreleme tıpta en umut verici yapay zeka araçlarından birisidir. Son yıllarda birçok çalışma bu tür sistemlerin klinisyenlerin performansı ile tutarlı bir şekilde eşleşebileceğini, bazen onlardan iyi performans gösterebileceğini ve mevcut tarama yöntemlerinden daha uygun maliyetli ve geniş kapsamlı olabileceğini belirtmişlerdir (9,10). Yapay zeka yazılımı kullanan ilk FDA onaylı cihaz olan IDx-DR bu alanda geliştirildi. Abramoff ve ark.(11) yaptıkları çalışmada DR hastalarını Amerikan Oftalmoloji Akademisi sınıflamasına göre hafif, ileri DR ve retinopatisi olmayanlar olarak gruplandırdı. Çalışma sonuçlarında cihazın duyarlılığı %96,8 ve özgüllüğü %87 olarak saptandı. Başka bir derin öğrenme sisteminde sevk edilebilir DR'yi tespit etmede duyarlılığın %90,5 özgüllüğün %91,6 olduğu bildirilmiştir (12). Bu iyi verilere rağmen yapay zeka sistemleri gerçek dünyada DR taramasında test edilmemiştir. Farklı etnisite ve farklı kameralar kullanarak çekilen retinal görüntülere genellenebilirliği hala belirsizliğini korumaktadır.

YBMD, küresel olarak yaşlı popülasyonda görme bozukluğunun önemli bir nedeni olmakla birlikte gelişmiş ülkelerde 50 yaş üzeri kişilerde geri dönüşümsüz görme kaybının ana sebebidir. Amerikan Oftalmoloji Akademisi orta dereceli YBMD hastalarının en az 2 yılda 1 görülmesini önermektedir. 2040 yılına kadar 288 milyon bireyin bazı YBMD formlarına sahip olabileceği öngörülmektedir (13). Yaşlanan nüfusla birlikte göz kliniklerinde daha fazla YBMD hastasına erken ulaşabilmek için yapay zeka temelli tarama sistemleri yüksek verim oluşturabilir. DR'den farklı olarak YBMD'de birçok makale girdi olarak fundus görüntüleri yerine OKT görüntülerini kullanmıştır. De Fauw ve ark.(14) çalışması hem metodoloji hem de sonuçlar açısından şimdiye kadar en iyi makalelerden birisidir ve yapay zekanın bir uzman doktorun sonuçlarına benzer sonuçları olduğu bildirilmiştir. Bazı yazarlar YBMD ilerlemesini öngörmeye çalıştılar. Örneğin Bhuiyan ve ark.(15) fundus görüntülerinde ileri YBMD insidansını tahmin etmeye çalıştılar ve %86,36 bir doğruluk elde ettiler. Yim ve ark. (16) ise OCT görüntülerini kullanarak ikinci gözde yaş tip YBMD ilerlemesini tahmin etmeye çalıştılar ve %80 duyarlılık, %55 özgüllük saptadılar.

Glokom gözde aköz hümor biriktikçe göz içi basıncın artması sonucu hasar gören optik sinirin bir hastalığıdır. 2040 yılında glokomlu insan sayısının 111,8 milyona yükseleceği öngörülmektedir (17). Glokomda erken tanı ve tedavinin önemi yapay zeka araştırmacılarının ilgisini çekmiştir. Bu bağlamda yapay zeka uygun ve maliyet etkin taramanın yaygınlaştırılmasına ve erken tedavinin optimize edilmesine yardımcı olabilir. 2018'de sevk edilebilir glokomatöz optik

nöropatiyi tanımlamak amacıyla yapılan bir çalışmada %95 hassasiyet, %92 özgüllük saptandığı bildirildi (18).

ROP, dünya çapında yıllık 32.000 ROP ilişkili körlük insidansı ile çocukluk çağının önemli körlük nedenlerinden birisidir (19). Doğrudan oftalmoskopik muayene veya dijital fundus fotoğrafı ile değerlendirme ROP'un erken belirtilerini saptayabilir ve ROP bağımlı körlük engellenebilir (20,21). ROP muayenesinin subjektif olması ve ROP muayenesi yapacak deneyimli oftalmologlarının sayısının azlığı neticesinde ROP tanısının erken evrede konulabilmesi güçleşmektedir ve bu durum yapay zeka temelli çalışmaların bu konuya yoğunlaşmasına yol açmıştır. Brown ve ark. (22) yapay zeka temelli sistem ile yaptıkları çalışmada sekiz ROP uzmanından altısını geride bırakacak sonuçlar aldıklarını bildirdiler.

Nöro-oftalmoloji alanında da yapay zeka çalışmaları artış göstermektedir. Örneğin papilödem tespit için kullanılan bir yapay zeka sisteminin, %84,7 doğruluk ile 25 yıldan uzun mesleki deneyimi olan 2 nöro-oftalmolog kadar iyi olduğu belirtilmiştir (23) Yapılan başka bir çalışmada optik disk solukluğunu fundus fotoğrafından tespit etmek için dizayn edilmiş yapay zeka temelli sistemin %95,3 hassasiyet ve %96,7 özgüllüğe sahip olduğu bildirilmiştir (24). Yang ve ark. yaptığı bir çalışmada glokomatöz optik nöropati ve glokomatöz olmayan optik nöropati duyarlılıkları yapay zeka temelli sistem ile %92,5 ve %86,4 olarak gösterilmiştir (25).

Tüm bunların yanı sıra yapay zeka ile göz hareket bozukluklarının tanısı üzerine de çalışmalar yapılmıştır. Almeida ve ark. (26) 40 yetişkin hastanın 5 bakış pozisyonunda klinik fotoğrafları ile şaşılık saptanması üzerine bir yapay zeka sistemi geliştirdiler. Yapılan bu çalışmanın oküler hiza bozukluğunu saptamada doğruluğu ekzotropyada %100, ezotropyada %88, hipertropyada %80, hipotropyada %83 olarak bildirilmiştir. Zheng ve ark.(27) birincil bakış fotoğraflarına dayalı olarak çocuklarda yatay şaşılığın taranması için bir yapay zeka sistemi geliştirdi. Algoritmanın %95 doğruluk oranı ile yerel oftalmologlardan daha iyi bir doğruluk oranı elde ettiği bildirildi.

SONUÇ

Özellikle derin öğrenme başta olmak üzere yapay zeka diğer alanlarda olduğu gibi tıp alanında da bir devrim yaratmaktadır. Oftalmoloji için DR ve ROP başta olmak üzere birçok retinal hastalığın tanısında kabul edilebilir sonuçlar

bildirilmiştir. Gelecekteki araştırmalar, farklı yapay zeka sistemlerinin hem klinik faydasını hem de maliyet etkinliğini ortaya koymalıdır. Yapay zeka sistemlerinin klinik pratikte kabulünü sağlamak için yapay zekanın gizemli doğasını çözmeye yönelik çalışmalar yapılmalıdır. Yapay zekanın klinik pratiğe girmesinde engeller mevcut olsa da önümüzdeki yıllarda tıp ve oftalmoloji pratiğini etkileyecektir. Yaşlanan dünya nüfusunun sağlık hizmetlerinin sürdürülmesi ve gelişmesinin cevabı yapay zeka teknolojilerinde saklı olabilir.

KAYNAKLAR

1. Ting DSW, Carin L, Dzau V, et al. Digital technology and COVID-19. *Nature Medicine*. 2020;26(4):459-461. doi:10.1038/s41591-020-0824-5.
2. McCarthy J, Minsky ML, Rochester N, et al. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. *AI Magazine*. 2006;27(4):12. doi:10.1609/aimag.v27i4.1904.
3. Samuel AL. Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*. 1959;3(3):210-229. doi:10.1147/rd.33.0210.
4. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436-444. doi:10.1038/nature14539.
5. Schmidhuber J. Deep learning in neural networks: An overview. *Neural Networks*. 2015;61:85-117. doi:10.1016/j.neunet.2014.09.003.
6. Lakhani P, Sundaram B. Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by Using Convolutional Neural Networks. *Radiology*. 2017;284(2):574-582. doi:10.1148/radiol.2017162326.
7. Esteva A, Kuprel B, Novoa RA, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542(7639):115-118. doi:10.1038/nature21056.
8. Yau JWY, Rogers SL, Kawasaki R, et al. Global Prevalence and Major Risk Factors of Diabetic Retinopathy. *Diabetes Care*. 2012;35(3):556-564. doi:10.2337/dc11-1909.
9. Arsalan M, Owais M, Mahmood T, et al. Aiding the diagnosis of diabetic and hypertensive retinopathy using artificial intelligence-based semantic segmentation. *Journal of Clinical Medicine*. 2019;8(9). doi:10.3390/jcm8091446.
10. Gunasekaran D v., Ting DSW, Tan GSW, et al. Artificial intelligence for diabetic retinopathy screening, prediction and management. *Current Opinion in Ophthalmology*. 2020;31(5):357-365. doi:10.1097/ICU.0000000000000693.
11. Abramoff MD, Lou Y, Erginay A, et al. Improved Automated Detection of Diabetic Retinopathy on a Publicly Available Dataset Through Integration of Deep Learning. *Investigative Ophthalmology & Visual Science*. 2016;57(13):5200. doi:10.1167/iovs.16-19964.
12. Ting DSW, Cheung CY-L, Lim G, et al. Development and Validation of a Deep Learning System for Diabetic Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic Populations With Diabetes. *JAMA*. 2017;318(22):2211. doi:10.1001/jama.2017.18152.

13. Wong WL, Su X, Li X, et al. Global prevalence of age-related macular degeneration and disease burden projection for 2020 and 2040: a systematic review and meta-analysis. *The Lancet Global Health*. 2014;2(2):e106-e116. doi:10.1016/S2214-109X(13)70145-1.
14. de Fauw J, Ledsam JR, Romera-Paredes B, et al. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nature Medicine*. 2018;24(9):1342-1350. doi:10.1038/s41591-018-0107-6.
15. Bhuiyan A, Wong TY, Ting DS, et al. Artificial Intelligence to Stratify Severity of Age-Related Macular Degeneration (AMD) and Predict Risk of Progression to Late AMD. *Translational Vision Science & Technology*. 2020;9(2):25. doi:10.1167/tvst.9.2.25.
16. Yim J, Chopra R, Spitz T, et al. Predicting conversion to wet age-related macular degeneration using deep learning. *Nature Medicine*. 2020;26(6):892-899. doi:10.1038/s41591-020-0867-7.
17. Tham Y-C, Li X, Wong TY, et al. Global Prevalence of Glaucoma and Projections of Glaucoma Burden through 2040. *Ophthalmology*. 2014;121(11):2081-2090. doi:10.1016/j.ophtha.2014.05.013.
18. Li Z, He Y, Keel S, et al. Efficacy of a Deep Learning System for Detecting Glaucomatous Optic Neuropathy Based on Color Fundus Photographs. *Ophthalmology*. 2018;125(8):1199-1206. doi:10.1016/j.ophtha.2018.01.023.
19. Blencowe H, Moxon S, Gilbert C. Update on Blindness Due to Retinopathy of Prematurity Globally and in India. *Indian Pediatrics*. 2016;53 Suppl 2:S89-S92. <http://www.ncbi.nlm.nih.gov/pubmed/27915313>.
20. Cryotherapy for Retinopathy of Prematurity Cooperative Group. Multicenter Trial of Cryotherapy for Retinopathy of Prematurity. *Archives of Ophthalmology*. 2001;119(8):1110. doi:10.1001/archophth.119.8.1110.
21. Good W v., Hardy RJ, Dobson V, et al. Final Visual Acuity Results in the Early Treatment for Retinopathy of Prematurity Study. *Archives of Ophthalmology*. 2010;128(6):663. doi:10.1001/archophthalmol.2010.72.
22. Brown JM, Campbell JP, Beers A, et al. Automated Diagnosis of Plus Disease in Retinopathy of Prematurity Using Deep Convolutional Neural Networks. *JAMA Ophthalmology*. 2018;136(7):803. doi:10.1001/jamaophthalmol.2018.1934.
23. Biousse V, Newman NJ, Najjar RP, et al. Optic Disc Classification by Deep Learning versus Expert Neuro-Ophthalmologists. *Annals of Neurology*. 2020;88(4):785-795. doi:10.1002/ana.25839.
24. Yang HK, Oh JE, Han SB, et al. Automatic computer-aided analysis of optic disc pallor in fundus photographs. *Acta Ophthalmologica*. 2019;97(4):e519-e525. doi:10.1111/aos.13970.
25. Yang HK, Kim YJ, Sung JY, et al. Efficacy for Differentiating Nonglaucomatous Versus Glaucomatous Optic Neuropathy Using Deep Learning Systems. *American Journal of Ophthalmology*. 2020;216:140-146. doi:10.1016/j.ajo.2020.03.035.
26. Sousa de Almeida JD, Silva AC, Teixeira JAM, et al. Computer-Aided Methodology for Syndromic Strabismus Diagnosis. *Journal of Digital Imaging*. 2015;28(4):462-473. doi:10.1007/s10278-014-9758-0.
27. Zheng C, Yao Q, Lu J, et al. Detection of Referable Horizontal Strabismus in Children's Primary Gaze Photographs Using Deep Learning. *Translational Vision Science & Technology*. 2021;10(1):33. doi:10.1167/tvst.10.1.33.