



Nöroşirürjide Yapay Zekâ ve Gelecek

Artificial Intelligence in Neurosurgery and the Future

Çağhan TÖNGE¹, Muhammed Erkan EMRAHOĞLU¹, Esra OĞUZ², Onur İNAM³, Elçin ÖZGÜR BÜYÜKATALAY³

¹Sağlık Bilimleri Üniversitesi Gülhane Tıp Fakültesi, Dışkapı Yıldırım Beyazıt Eğitim ve Araştırma Hastanesi, Beyin ve Sinir Cerrahisi Kliniği, Ankara, Türkiye

²Gazi Üniversitesi Sağlık Bilimleri Enstitüsü, Biyofizik Doktora Programı, Ankara, Türkiye

³Gazi Üniversitesi Tıp Fakültesi, Biyofizik Anabilim Dalı, Ankara, Türkiye

Yazışma adresi: Çağhan TÖNGE ✉ caghantonge@gmail.com

ÖZ

20. yüzyıl bilgi çağı olarak geçmektedir. Dijital bilginin artışıyla bilginin işlenmesi için de çok sayıda araştırma yapılmaya başlanmıştır. Yapay zekâ destekli bilişim sistemleri cerraha tarama, cerrahi karar verme, takip, tedavi, intraoperatif komplikasyon yönetimi ve postoperatif takip açısından destek verebilmektedir. Yapay zekâ, yüklenen veri tabanı aracılığıyla çevresini tanımaya çalışır ve kendini geliştirir. Makine öğreniminde eğitim ve test aşamaları ile başarı oranı hesaplanır. Derin öğrenmede katmanlar aracılığı ile derin öğrenme meydana gelir. Konvolusyonel sinir ağlarında katmanlar filtrelenerek girdilerin arasındaki ilişki ortaya konulmuş olur. Beyin Cerrahisinde tümör evreleme, radyoterapi kararı, nüks varlığı, vasküler patolojilerin tayini, travmatik beyin hasarının takip ve prognozunun belirlenmesi, derin beyin stimülasyonu, spondilolistezis, instabilite varlığının tespiti, yoğun bakım hastalarının ihtiyaçlarının belirlenmesi ve tedavisinin düzenlenmesi, kafa içi basınç sendromunun tespiti gibi pek çok alanda yapay zekâ kendine bir yer edinmeye başladı. Her ne kadar veri setlerinin oluşturulması uzun bir süreç olsa da yapay zekâ ucuz, ulaşılabilir ve güvenilir bir yöntem olarak uzun vadede beyin cerrahlarının yanında yer alabilir.

ANAHTAR SÖZCÜKLER: Derin öğrenme, Konvolusyonel sinir ağları, Nöroşirürjide yapay zekâ, Makine öğrenimi

ABSTRACT

The 20th century is known as the information age. In parallel with technological developments, patient follow-up, imaging techniques, surgical decision-making and intraoperative methods continued to develop. Artificial intelligence-supported information systems can support the surgeon in terms of screening, surgical decision-making, follow-up, treatment, intraoperative complication management, and postoperative follow-up. Artificial intelligence tries to recognize its environment through the uploaded database and improves itself. In machine learning, the success rate is calculated with the training and test stages. In deep learning, this occurs through layers. In convolutional neural networks, the layers are filtered to reveal the relationship between the inputs. In this way, the relationship between the inputs is revealed. In neurosurgery, artificial intelligence has started to gain a place in many fields through tumor staging, radiotherapy decisions, presence of recurrence, determination of vascular pathologies, determination of the follow-up and prognosis of traumatic brain injury, deep brain stimulation, detection of spondylolisthesis, instability, determination of the needs of intensive care patients and regulation of treatment, and detection of intracranial pressure syndrome. Although the creation of data sets is a long process, artificial intelligence can stand by neurosurgeons in the long run as a cheap, accessible, and reliable method.

KEYWORDS: Deep learning, Convolutional neural networks, Artificial intelligence in neurosurgery, Machine learning

■ GİRİŞ

İçerisinde bulunduğumuz yüzyıl, bilgi çağı olarak geçmektedir. Bilginin önemi her geçen gün daha fazla anlaşılmakta ve üretimi ve geliştirilmesi için daha fazla zaman, sermaye ve işgücü harcanmaktadır. Analog depo sistemlerinden dijital depo sistemlerine geçişin yoğun olarak yaşandığı 21. yüzyıl başlarından bu zamana, insanlığın ürettiği bilginin ikiye katlanma süresi de giderek azalmaktadır. Schilling tarafından insanlık tarihi boyunca üretilen bütün bilginin ikiye katlanma hızının 2020 yılı itibarıyla her 12 saatte bir olacağı ileri sürülmüştür (23). Bu yoğun bilgi akışının her alanda olduğu gibi sağlık sektöründe de ciddi etkileri olmuştur.

Her gün dünyanın dört bir yanında hastaneler ve hastalar hakkında farklı sistemler üzerinden düzenli olarak veri toplanmaktadır. Üretilen çok miktardaki bu verilerin heterojenliği, hamlığı ve standartize edilmemiş olmaları büyük verinin önemli sorunlarından birini oluşturmaktadır. Bunların başında bu verinin saklanması, depolanması, fonksiyonel hâle getirilebilmesi için işlenmesi, güvenliği gibi faktörler yer almaktadır. Bu kadar çok miktardaki klinik verinin işlenmesi ve anlamlandırılabilmesi noktasında yapay zekâ (artificial intelligence, AI) ve konvolusyonel sinir ağları bize yardımcı olabilir.

Her bilim dalı gibi tıp ve beyin cerrahisi de bilgi çağında önemli oranda çeşitlenmiştir ve bu bilgi artışı, kalifiye bir cerrahın yetişmesinin gün geçtikçe daha uzun, daha çok sermaye ve emek isteyen bir sürece dönüşmesine neden olmaktadır. Dünyanın her yerindeki beyin cerrahisi eğitiminin standart olmadığı ve güncel prosedürleri takip imkân ve zamanının tüm beyin cerrahlarının ortak paydası olamadığı gerçeği de göz önünde bulundurulduğunda, bilgisayar destekli yapay zekâ programları sağlık sistemine ulaşım, araştırma, cerrahi karar verme, preoperatif hazırlık, postoperatif takip gibi konularda beyin cerrahına yol gösterici olabilir. Yapay zekâ temelli programlar dünyanın her yerinden ulaşılabilir pratik, hızlı, otomatik ve düşük maliyetli bir yapı sunabilmektedir (12,21).

Daha fazla veri işleme gücünün ve veri birikiminin gelmesiyle birlikte yapay zekâ, son dekat içerisinde cerrahi araştırmalarda daha başarılı hâle gelmiştir. Günümüzde teknoloji, “zihnin kontrolü” kavramını aydınlatmaya çalışmaktadır. Beyin-bilgisayar arayüzü (BCI) ve yapay zekâ, felçli hastaların bazı duyuşsal ve motor işlevlerini eski hâline getirmek, sağlıklı insanların motor yeteneklerini genişletmek ve yeni nesil robotların gelişimini kolaylaştırmak için birleştirilmeye çalışılmaktadır (16,17,29).

Yapılan bir sistematik derlemede bugüne kadar beyin cerrahisinde yapay zekâ teknolojilerinin kullanımına ilişkin araştırmalar nöro-onkoloji, fonksiyonel, vasküler, spinal nöroşirürji ve travmatik beyin hasarı olmak üzere beş ana alana ayrılmıştır (10).

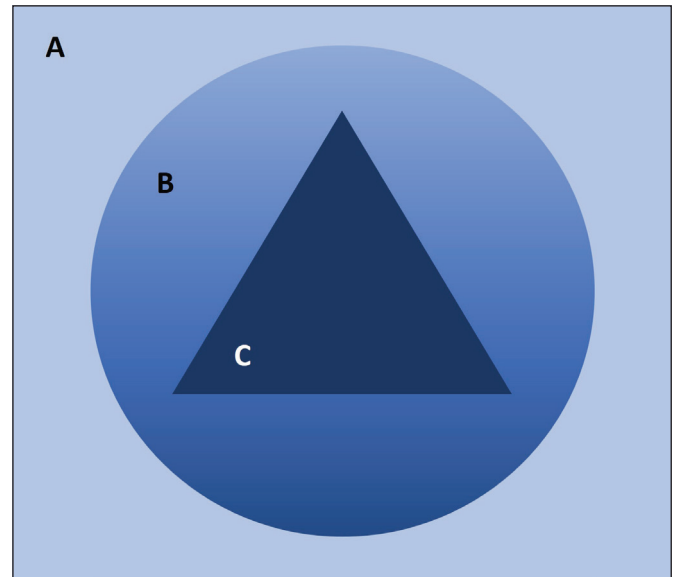
Bu makalede yapay zekânın beyin cerrahisinde kullanım alanları hakkında genel bir bakış açısı sağlanması amaçlanmıştır.

■ MAKİNE ÖĞRENİMİ ve DERİN ÖĞRENME

Yapay zekâ, makine öğrenimi ve derin öğrenme, beyin cer-

rahisini baştan sona değiştirme potansiyeline sahiptir. Yapay zekâ, bilgisayarlarda biyolojik varlıkların zekâsını ve davranışını taklit etmeyi amaçlarken, yapay zekâ algoritmalarının yapabildikleri içerisinden makine öğrenimi, bilgisayar bilimi ve istatistiklerini birleştirerek bilgisayarların, harici programlamadan bağımsız olarak, deneyim yoluyla verileri doğrudan inceleyerek kalıpları öğrenmesini sağlar (7). Beynimizin bizim yeni bilgileri öğrendiğimizde oluşturduğu sinaptik bağlantılar gibi makine öğrenimi de üzerine çalıştığı konu üzerine pratik yaptıkça kendi sonuçlarını mükemmelleştirir. Makine öğrenimi tüm sürecini algoritmalar ve istatistik üzerinden yürütür. Bunun için de elinde büyük bir veri havuzu bulundurur. Elindeki veri havuzunun oluşturduğu örneklem eğer evreni temsil edebiliyorsa, makine öğrenimi bu veri tabanını kullanıp analiz ederek karşısına çıkan problemler hakkında kararlar verebilir (19). Her karşılaştığı ve çözdüğü problemi ise kendi veri setine dahil ederek daha iyi sonuçlara ulaşmasını sağlayacak veri havuzu genişletme işlemini sürdürebilir. Makine öğreniminin tıpta temel olarak kullandığı algoritmalar lojistik regresyon, destek vektör makinesi ve rastgele ormanlar gibi eğitim algoritmalarıdır ve bu algoritmalar aracılığıyla denetimli öğrenmeyi kullanır (8,9,11).

Sadece istatistiksel analiz ve ikili korelasyon ile çalışmak daha sofistike ve ilişkili problemlerin çözümü için yeterli kalmayabilir. Makine öğrenimi belli bir konuda belli bir problemi çözmek için elindeki veri havuzunu kullanarak analiz ile sonuca ulaşır. Her veri setinin birbiri ile çapraz ilişkilerine bakarak çoklu girdi ve çoklu çıktı sistemlerinin beraber değerlendirilmesini sağlayan sistemlerin algoritması ise derin öğrenme aracılığı ile gerçekleştirilir (14,25,30). Burada çoklu sinir ağları işin içine girmektedir. Yapay zekâ hem makine öğrenimini hem de derin öğrenmeyi sağlayan algoritmaları içerir. Derin öğrenmenin ise makine öğreniminin daha karmaşık bir versiyonu olduğu söylenebilir (Şekil 1).



Şekil 1: Yapay zekâ komponentlerinin birbiri ile ilişkileri. **A:** Yapay zekâ. Makinenin insan davranışını taklit etmesi. **B:** Makine öğrenimi. İstatistiksel yöntemler aracılığı ile makine deneyimini artırma. **C:** Derin öğrenme: Çok katlı sinir ağlarının kullanımı.

Radyografik tarama ve erken tanı programları için makine öğreniminde görüntü işleme devreye girmektedir. Belli bir hastalığa ait MR, BT gibi görüntüleme yöntemlerinden alınan ince kesit yüksek rezolüsyonlu görüntülerde normal beyin ve patoloji, görüntü işleme ile düzenlendikten sonra yapay zekâyâ hangi alanların patolojik, hangi alanların normal dokuyu temsil ettiği öğretilmektedir. Genellikle veri tabanında bulunan toplam verinin %70'i yapay zekânın konu hakkında eğitilmesi (training), %30'u ise aldığı eğitimin testi (testing) için değerlendirilerek veri tabanındaki sağlam ve hastalıklı beyin bölgelerinin ne kadar iyi ayırt edilebildiği ile ilgili testin sensitivite ve spesifite değerlerini sunabilmektedir (27). Makine öğreniminin belli başlı kısıtlılıkları vardır, bunlardan en önemlisi homojen veri tabanının elde edilmesinin zor oluşudur. Veri kaynağı bir MR cihazı ise farklı merkezlerde çekim kalitesi, kesit sayısı, hastanın başının pozisyonu, çekim protokolü gibi farklı sonuçlara sebebiyet verebilecek durumlar vardır. Yazılımsal olarak ortak paydada buluşulmaya çalışılsa da yapay zekâda en iyi sonuçlar homojen veri tabanı üzerinden yapılan makine öğrenimi sonucu elde edilebilmektedir.

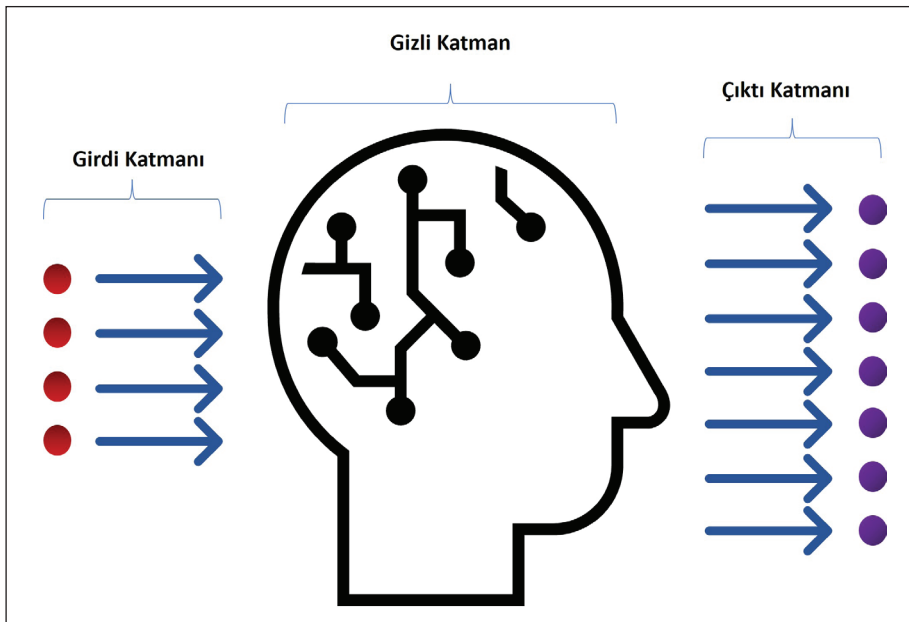
Derin öğrenme, makine öğreniminde tariflenen görüntü işleme ve eğitimden daha kompleks bir yapıya sahiptir. Bilginin nodlar hâlinde bölünerek her nodun birbiri ile ilişkisine çoklu ilişkisel analiz ile yaklaşım birden çok girdiyi eş zamanlı değerlendirerek birden çok çıktıyı ortaya çıkarabilme kapasitesine sahiptir. Bünyesinde birden çok katman bulunduran yapay zekâ programları, gizli katmanlarda veri analizi sonucunda farklı temalar arasında ilişkisel analiz gösterebilmektedir (26) (Şekil 2). Yapay zekâ, bu güçlü analiz kapasitesi ile insanın fark edemeyeceği detayları yakalayarak ilişkilendirebilir (24). Bu noktada da ilişkilendirmenin test edilebilir olması önemlidir. Elde edilen sonuçların cihaza tekrar sunulması ya da farklı zaman dilimlerinde yapılan testlerin farklı sonuçlar vermesi ihtimali vardır. Bu da makine öğreniminin zeminde getirdiği mükemmelliğe ulaşma için veri seti genişletmesinden kaynaklanır.

■ KONVOLUSYONEL SİNİR AĞLARI

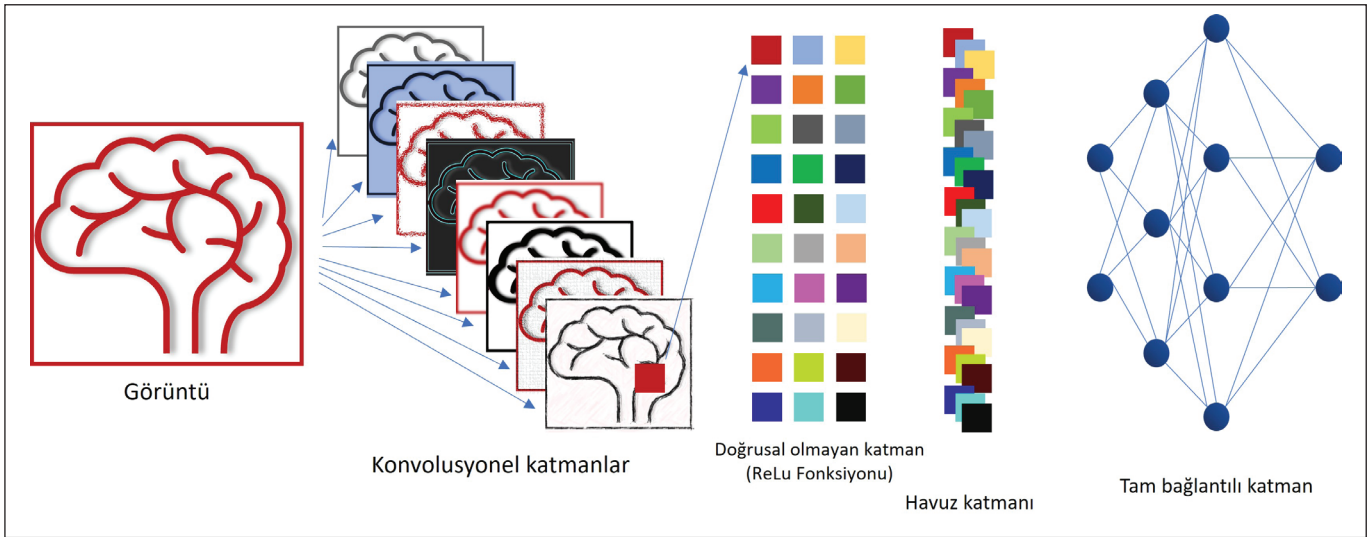
Makine öğrenimi ve derin öğrenme için büyük veri setlerine ihtiyaç duyulmaktadır. Daha düşük veri setleri ile anlamlı sonuçlar doğurmak için geliştirilen ilişkisel analiz yöntemi konvolusyonel sinir ağlarıdır. Bu sayede daha kısa sürede, çok güçlü bir bilgisayara sahip olmadan da yapay zekâ aracılı analizler gerçekleştirilebilmektedir (28). Konvolusyonel sinir ağları (convolutional neural network) insan beyninin çalışma prensibini baz alarak geliştirilmiş bir yapay zekâ algoritmasıdır. Herhangi bir nesneye ya da kişiye baktığımızda beynimizde meydana gelen sinaptik bağlantılar ve bu bağlantılar sonucunda nesneyi ya da kişiyi tanıma fonksiyonu, bilgisayara taşınmıştır. Günümüzde de birçok sosyal medya platformunda, şirketlerde, endüstride ve hatta savaş sanayisinde aktif olarak kullanılan bir yöntemi, nesne tanımlamayı içerir (3,6). Derin öğrenme gibi katman katman çalışan bir yapıya sahiptir. Konvolusyonel katman resmin (MR görüntüsü, hastanın yüzündeki anomali, faset hipertrofisi, vb.) özelliklerini saptar, resmi küçük parçalara bölerek farklı katmanlar üretir ve işlem sonunda çok sayıda konvolusyonel katman elde edilmiş olur. Doğrusal olmayan katman oluşturulacak veri havuzuna bilgi sunar, bunu yaparken verilerin doğrusal olmamasına dikkat eder. Doğrusal veriler tek tip sonuç sunarlar. Algoritmaların her açıdan değerlendirilmesi için sistem doğrusallıktan uzak bir yapı kullanır. Bunun için günümüzde en sık kullanılan fonksiyon Rectifier (ReLU) fonksiyonudur. ReLu Fonksiyonu (6):

$$F(x) = \max(0, x)$$

Havuz katmanı verileri tasnif eder ve veri yükünü azaltır, düzleştirme katmanı sinir ağı için verileri düzenler ve tam bağlantılı katman ise standartize ederek analizi sonuçlandırır (Şekil 3).



Şekil 2: Derin öğrenmenin şematizasyonu. Girdi katmanına gelen veriler gizli katmanda her bir veri diğer tüm veriler ile çapraz yapacak şekilde işlenir. Çıktı katmanında da çoklu sistem sonucu ortaya konulur.



Şekil 3: Konvolusyonel sinir ağı sempatisasyonu. Ham görüntü matrisler şeklinde alınarak farklı filtrelerden geçirilmesi (konvolusyonel katman). Doğrusal sonuçlardan kaçınmak için doğrusal olmayan katman oluşturulması. Veri sadeleştirme ve iş yükünü azaltma için havuz katmanı oluşturulup tam bağlantılı katmanda hücrelerin birbiri ile çapraz karşılaştırılması.

■ BEYİN CERRAHİSİ, YAPAY ZEKÂ ve GELECEK

Beyin cerrahisi her zaman en son teknoloji ile içli dışlı olmuştur. İleri radyolojik modalitelerin geçtiğimiz yüzyıl içerisinde geliştirilmesinden sonra beyin patolojileri noninvaziv olarak gösterilebilmeye başlanmıştır. Ultrasonografi, bilgisayarlı tomografi ve manyetik rezonans görüntüleme teknikleri geliştikçe entegre ameliyathaneler, intraoperatif görüntüleme yöntemleri gibi yenilikler üretilmiştir. Günümüzde beyin cerrahisi ile ilgili yapay zekâ çalışmaları daha çok tanısal süreçler ve klinik karar verme süreçleri üzerinden ilerlemektedir. Bunun dışında yapay zekâ temelli algoritmalar tarama, erken tanı, ilişkisel analiz, araştırma gibi süreçleri daha homojen, objektif bakış açısı ile yürütebilmektedir.

Martin Kocher ve ark. tarafından yapılan bir çalışmada radyomiklerin malign beyin tümörlerinin radyoterapi kararında makine öğrenimi aracılı diyagnostik doğruluk oranlarının %80-90 aralığında olabileceğini söylemişlerdir (20). Yine başka bir derlemede malign beyin tümörlerinin derin öğrenme aracılı patofizyolojik değerlendirmelerinin, görüntüleme modalitelerinin ve kanser karakteristiklerinin tayini için kullanılabileceğinden bahsedilmiştir (25). Bu çalışmalar beyin tümörlerinin cerrahisinde ve sonrasında yapay zekânın cerrahlara yol gösterici olabileceğine dair ışık tutmaktadır. Tümör cerrahisinin yanı sıra, fonksiyonel nöroşirürjide de yapay zekâ çalışmalarının izlerini görmek mümkündür. Peralta ve ark. tarafından derin beyin nörostimülasyonunda makine öğrenimi hakkında yazılan derlemede, makine öğreniminin derin beyin stimülasyonunda elektriksel sinyal ve MR görüntüleri üzerinden giderek yaygınlaştığına, fakat henüz tam anlamıyla veri tabanındaki heterojenitenin ve farklı ölçüm araçlarının ve tekniklerinin standartizasyonunun oturmadığına dikkat çekmişlerdir (22).

Tarama ve tanı anlamında yapay zekânın sıklıkla araştırıldığı alanlardan biri de inme ve serebral vasküler patolojilerin belirlenmesidir. Serebral inmenin erken tanısı ile ilgili makine öğrenmesi ve test edilmesi konusunda yapılan çalışmalarda

beyin damarsal hastalıklarında hastanın klinik çıktılarını tahmin oranlarının makine öğrenmesinde insan ile anlamlı bir fark yaratmadığı, bazı durumlarda ise insandan gelen hata paylarını ortadan kaldırdığı gösterilmiştir (5). Bunun dışında yapay zekânın vasküler patolojilerin tespitinde de kullanılabileceğine dair çalışmalar vardır (4). Beyin vasküler anatomisinin çok fazla varyantı olduğu için heterojeniteyi içerisinde barındıran bir veri seti oluşturup bu veri setine uygun bir şekilde eğitim ve test uygulamak radyografik görüntülerin makine öğrenmesini yönetmeye kıyasla daha kompleks bir süreçtir.

Yapay zekâ ve derin öğrenmenin bir diğer kullanım alanı ise travmatik beyin hasarıdır. Travmatik beyin hasarında epileptik aktivitenin otomatik tespiti ile ilgili yapılan bir derin öğrenme çalışmasında yapay zekânın %80,78 oranla posttravmatik epilepsiyi tespit edebildiği gösterilmiştir (13). Adil ve ark.nın yürüttüğü prospektif bir çalışmada ise derin öğrenme aracılı yapay zekânın ilk kez travmatik beyin hasarında prognozunu değerlendirilmesinde kullanımı görülmektedir. Beş yıllık takip süresince derin sinir ağı, yüzeysel sinir ağı ve elastik-net düzenleyici lojistik regresyon modellerinin klinik çıktıları izlemedeki üstünlükleri incelenmiştir. Yoğun bakım açısından kısıtlı imkânlarla sahip bölgeler için düşük oranda kurtulma şansı olan hastaların ayrımı açısından belirlenen 13 klinik değişkenin değerlendirilmesi üzerinden karar verme aşamasında derin öğrenme modellerinin ve lojistik regresyon modelinin birbirlerine üstünlüklerinin olmadığı gösterilmiştir (1). Bir diğer çalışma da nörolojik yoğun bakım hastalarının bakımında makine öğrenimi ve yapay zekâ kullanımı ile ilgili Al-Mufti ve ark. tarafından yapılmış olup yapay zekânın klinisyenin intrakraniyal basınç artışı, nöbet, hemodinamik instabilite ve ventilasyona yaklaşımı konusunda yardımcı olabileceğini ileri sürmektedir (2).

Yapay zekâyı spinal cerrahide de kullanmak mümkündür. Lomber spondilolistezisi olan hastalarda tek başına dekompresyon ya da dekompresyon ve stabilizasyon kombine yaklaşımının karar verme sürecinde füzyon varlığının ayrımını yapmak için

yapay zekâ kullanımı olan örnekler bulunmaktadır (15). Erişkin spinal deformitede de karar verme sürecinde yapay zekâdan yararlanılabilir (18).

Bu çalışmalardan da görülebileceği üzere, travmatik beyin hasarının erken tanısı, tespiti, zemininde gelişen posttravmatik epilepsi gibi prognozu olumsuz etkileyen faktörlerin tayini gibi ölçümler yapay zekâ aracılı programlar tarafından yürütülebilme potansiyeline sahiptir.

Yapay zekâ, algoritmalarından ve veri setlerinden oluşan karmaşık bir yapıdır. Günümüzde gitgide daha çok alan tarafından kabul görüp uygulamaya yer bulabilen makine öğrenmesi, derin öğrenme modelleri, konvolusyonel sinir ağları, ileride ciddi meslek gruplarının bile yerini alma potansiyeli taşımaktadır. Algoritma ve yapay zekâ bir kez oturtulduğunda dünyanın her yerinden kolayca ulaşılabilir bir hizmet noktasına dönüşebilmektedir. Bu da konvansiyonel olarak meslek sahibi olmanın getirdiği maddi, manevi ve zamansal zorlukların üstesinden gelebilmemizi sağlayabilir. Yeterince iyi bir algoritma ile yapay zekânın insanın yapabildiği her yetiyi yerine getirebilmesi mümkün olabilir.

■ SONUÇ

Beyin ve sinir cerrahisinde yapay zekâ araştırmaları son 10 yıl içerisinde ciddi oranda artış göstermiştir. Algoritmaların geliştirilmesi ve yeni sinir ağı sistemlerinin keşfi sayesinde günümüzde teknolojik imkânların profesyonel hayatımıza dahil ettiği MR, BT ve intraoperatif nöronavigasyon teknikleri gibi katkıların pratikte yaygın olarak kullanımı, yakın gelecekte yapay zekâ temelli sistemler için de geçerli olabilir.

■ KAYNAKLAR

1. Adil SM, Elahi C, Patel DN, Seas A, Warman P, Fuller AT, Haglund MM, Dunn TW: Deep Learning to Predict Traumatic Brain Injury Outcomes in the Low-Resource Setting. *World Neurosurg* 2022 (Online ahead of print)
2. Al-Mufti F, Kim M, Dodson V, Sursal T, Bowers C, Cole C, Scurlock C, Becker C, Gandhi C, Mayer SA: Machine learning and artificial intelligence in neurocritical care: A specialty-wide disruptive transformation or a strategy for success. *Curr Neurol Neurosci Rep* 19(11):89, 2019
3. Anwar SM, Majid M, Qayyum A, Awais M, Alnowami M, Khan MK: Medical image analysis using convolutional neural networks: A review. *J Med Syst* 42(11):226, 2018
4. Boyd C, Brown G, Kleinig T, Dawson J, McDonnell MD, Jenkinson M, Bezak E: Machine learning quantitation of cardiovascular and cerebrovascular disease: A systematic review of clinical applications. *Diagnostics (Basel)* 11(3):551, 2021
5. Bravo J, Wali AR, Hirshman BR, Gopesh T, Steinberg JA, Yan B, Pannell JS, Norbash A, Friend J, Khalessi AA, Santiago-Dieppa D: Robotics and artificial intelligence in endovascular neurosurgery. *Cureus* 14(3):e23662, 2022
6. Brownlee J: How Do Convolutional Layers Work in Deep Learning Neural Networks? *Deep Learning for Computer Vision*, 2019. Retrieved April 17; Available from <https://machinelearningmastery.com/convolutional-layers-for-deep-learning-neural-networks/>
7. Celtikci E: A systematic review on machine learning in neurosurgery: The future of decision-making in patient care. *Turk Neurosurg* 28(2):167-173, 2018
8. Chan HP, Samala RK, Hadjiiski LM, Zhou C: Deep learning in medical image analysis. *Adv Exp Med Biol* 1213:3-21, 2020
9. Currie G, Hawk KE, Rohren E, Vial A, Klein R: Machine learning and deep learning in medical imaging: Intelligent imaging. *J Med Imaging Radiat Sci* 50(4):477-487, 2019
10. Danilov GV, Shifrin MA, Kotik KV, Ishankulov TA, Orlov YN, Kulikov AS, Potapov AA: Artificial intelligence in neurosurgery: A systematic review using topic modeling. Part I: Major research areas. *Sovrem Tekhnologii Med* 12(5):106-112, 2021
11. Deo RC: Machine learning in medicine. *Circulation* 132(20):1920-1930, 2015
12. Dlamini Z, Francies FZ, Hull R, Marima R: Artificial intelligence (AI) and big data in cancer and precision oncology. *Comput Struct Biotechnol J* 18:2300-2311, 2020
13. Faghihpirayesh R, Ruf S, Rocca M, Garner R, Vespa P, Erdogmus D, Duncan D: Automatic detection of EEG epileptiform abnormalities in traumatic brain injury using deep learning. *Annu Int Conf IEEE Eng Med Biol Soc* 2021: 302-305, 2021
14. Feng R, Badgeley M, Mocco J, Oermann EK: Deep learning guided stroke management: A review of clinical applications. *J Neurointerv Surg* 10(4):358-362, 2018
15. Ghogawala Z, Dunbar M, Essa I: Artificial intelligence for the treatment of lumbar spondylolisthesis. *Neurosurg Clin N Am* 30(3):383-389, 2019
16. Gibson RM, Owen AM, Cruse D: Brain-computer interfaces for patients with disorders of consciousness. *Prog Brain Res* 228:241-291, 2016
17. Green AM, Kalaska JF: Learning to move machines with the mind. *Trends Neurosci* 34(2):61-75, 2011
18. Joshi RS, Lau D, Ames CP: Artificial intelligence for adult spinal deformity: Current state and future directions. *Spine J* 21(10):1626-1634, 2021
19. Jumah F, Raju B, Nagaraj A, Shinde R, Lescott C, Sun H, Gupta G, Nanda A: Uncharted waters of machine and deep learning for surgical phase recognition in neurosurgery. *World Neurosurg* 160:4-12, 2022
20. Kocher M, Ruge MI, Galldiks N, Lohmann P: Applications of radiomics and machine learning for radiotherapy of malignant brain tumors. *Strahlenther Onkol* 196(10):856-867, 2020
21. Lohmann P, Galldiks N, Kocher M, Heinzl A, Filss CP, Stegmayr C, Mottaghy FM, Fink GR, Jon Shah N, Langen KJ: Radiomics in neuro-oncology: Basics, workflow, and applications. *Methods* 188:112-121, 2021
22. Peralta M, Jannin P, Baxter JSH: Machine learning in deep brain stimulation: A systematic review. *Artif Intell Med* 122: 102198, 2021

23. Schilling DR: Knowledge Doubling Every 12 Months, Soon to be Every 12 Hours, 2013. Retrieved April 19, Available from: <https://www.industrytap.com/knowledge-doubling-every-12-months-soon-to-be-every-12-hours/3950>
24. Tan MS, Cheah PL, Chin AV, Looi LM, Chang SW: A review on omics-based biomarkers discovery for Alzheimer's disease from the bioinformatics perspectives: Statistical approach vs machine learning approach. *Comput Biol Med* 139:104947, 2021
25. Tandel GS, Biswas M, Kakde OG, Tiwari A, Suri HS, Turk M, Laird JR, Asare CK, Ankrah AA, Khanna NN, Madhusudhan BK, Saba L, Suri JS: A review on a deep learning perspective in brain cancer classification. *Cancers (Basel)* 11(1):111, 2019
26. Ting DSW, Pasquale LR, Peng L, Campbell JP, Lee AY, Raman R, Tan GSW, Schmetterer L, Keane PA, Wong TY: Artificial intelligence and deep learning in ophthalmology. *Br J Ophthalmol* 103(2):167-175, 2019
27. Xu Y, Goodacre R: On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning. *J Anal Test* 2(3):249-262, 2018
28. Yang R, Yu Y: Artificial Convolutional neural network in object detection and semantic segmentation for medical imaging analysis. *Front Oncol* 11:638182, 2021
29. Zhang J, Xu K, Zhang S, Wang Y, Zheng N, Pan G, Chen W, Wu Z, Zheng X: Brain-machine interface-based rat-robot behavior control. *Adv Exp Med Biol* 1101:123-147, 2019
30. Zlochower A, Chow DS, Chang P, Khatri D, Boockvar JA, Filippi CG: Deep learning AI applications in the imaging of glioma. *Top Magn Reson Imaging* 29(2):115-110, 2020