DERLEME
DOI:10.4274/nts.galenos.2026.86158
Nucl Med Semin 2026;12:226-233

Nörobilimin Yapay Zekaya Katkıları

Contributions of Neuroscience to Artificial Intelligence

Ümit Özgür Akdemir, Lütfiye Özlem Atay
Gazi Üniversitesi Tıp Fakültesi, Nükleer Tıp Anabilim Dalı, Ankara, Türkiye

Öz

Nörobilim ile yapay zeka (YZ), birbirini besleyen iki disiplin olarak derin bir etkileşim içindedir. Yapay sinir ağları, derin öğrenme ve pekiştirmeli öğrenme gibi temel YZ kavramlarının kökenleri nörobilimsel temellere dayanır ve nörobilim, YZ'nin gelişiminde en önemli esin kaynağı olmuştur. Bu gözden geçirmede, görsel korteks hiyerarşisinden evrişimli sinir ağlarına, dopaminerjik ödül tahmin hatası sinyallerinden pekiştirmeli öğrenmeye, hipokampal ve neokortikal tamamlayıcı bellek sistemlerinden sürekli öğrenme çözümlerine ve seçici dikkat mekanizmalarından Transformer mimarisine nörobilimin YZ'ye katkıları ele alınmaktadır. Veri verimliliği ve öngörücü hesaplama gibi güncel YZ konuları için de nörobilimin etkin bir kavramsal rehber olmayı sürdürmektedir.

Anahtar Kelimeler: Nörobilim, yapay zeka, derin öğrenme, sinir ağları, pekiştirmeli öğrenme

Abstract

Neuroscience and artificial intelligence (AI) share a deep synergy, functioning as disciplines that continuously enrich each other. Fundamental AI concepts—such as artificial neural networks, deep learning, and reinforcement learning—are rooted in neuroscience, which has served as a primary source of inspiration for AI's development. This review examines neuroscience's contributions across a range of areas: from the visual cortex hierarchy to convolutional neural networks; from dopaminergic reward prediction error signals to reinforcement learning; from the complementary learning systems of the hippocampus and neocortex to continual learning solutions; and from selective attention mechanisms to the Transformer architecture. Neuroscience continues to serve as a valuable conceptual guide for addressing current topics in AI, such as data efficiency and predictive computation.

Keywords: Neurosciences, artificial intelligence, deep learning, neural networks, reinforcement learning

Giriş

Yapay zeka (YZ); bir bilgisayar sisteminin görüntü tanıma, dil anlama ve karar verme gibi insan zekası gerektiren görevleri yerine getirme kapasitesine verilen genel addır. Bu gözden geçirmede, bilgiyi büyük veri kümelerinden öğrenilmiş örüntüler (sayısal ağ yapıları) aracılığıyla temsil eden ve "derin öğrenme" olarak da adlandırılan bağlantıcı YZ yaklaşımı ele alınmaktadır. Görüntü tanımada, doğal dil işlemede ve tıbbi görüntü analizinde çığır açan başarıların büyük bölümünden sorumlu olan bu yaklaşımın kavramsal çerçevesi, köklerini ve en büyük ilham kaynağını bilişsel nörobilim alanında 1940'lı yıllardan itibaren yürütülen araştırmalardan almıştır (1,2).

Günümüzde derin öğrenme tabanlı YZ araçları nükleer tıp pratiğine hızla dahil olmaktadır. Pozitron emisyon tomografi (PET) görüntülerinde gürültünün azaltılmasında, lezyonların saptanmasında, parametrik haritalamada ve radyomiks analizlerinde YZ algoritmalarından yararlanılmaktadır (3). Özellikle F-18 florodeoksiglukoz (FDG) PET ile nörodejeneratif hastalıkların tanısı, biyobelirteç temelli tanı ve dozimetri çalışmaları YZ destekli yöntemlerin nükleer tıpta en çok araştırıldığı alanlardır (4). YZ araçlarının hangi nörobilimsel temellerden beslendiğini ve nasıl çalıştığını anlamak nükleer tıp hekimlerine bu uygulamalarla ilgili eleştirel bir bakış kazandıracaktır.

Sorumlu Yazar/Corresponding Author
Prof. Dr. Ümit Özgür Akdemir, Gazi Üniversitesi Tıp Fakültesi, Nükleer Tıp Anabilim Dalı, Ankara, Türkiye
E-posta: uoakdemir@gazi.edu.tr **ORCID ID:** orcid.org/0000-0002-5401-9853
Geliş Tarihi/Received: 25.09.2026 **Kabul Tarihi/Accepted:** 04.11.2026 **Yayınlanma Tarihi/Publication Date:** 26.11.2026
Cite this article as/Atıf: Akdemir ÜÖ, Atay LÖ. Contributions of neuroscience to artificial intelligence. Nucl Med Semin. 2026;12:226-233

Copyright© 2026 Yazar(lar). Türkiye Nükleer Tıp Derneği adına Galenos Yayınevi tarafından yayımlanmıştır.
Creative Commons Atıf-GayriTicari 4.0 (CC BY-NC 4.0) Uluslararası Lisansı ile lisanslanmış, açık erişimli bir makaledir.
Copyright© 2026 The Author(s). Published by Galenos Publishing House on behalf of Turkish Society of Nuclear Medicine.
This is an open access article under the Creative Commons Attribution Non-Commercial 4.0 International (CC BY-NC 4.0) License.

Erken Dönem Nörobilimsel Temeller

İlk yapay nöron, nörolog Warren McCulloch ve matematikçi Walter Pitts'in 1943'te biyolojik bir sinir hücresini matematiksel olarak modellemesiyle ortaya konmuştur (1,5). Bu modelde yapay nöron, birden fazla iki durumlu (0 veya 1) girdi alır; bu girdilerin ağırlıklı toplamı belirli bir eşiği aşarsa nöron "ateşler" (1 üretir), aşmazsa sessiz kalır. Bu model, yapay nöronların mantıksal ve hesaplamalı işlemler gerçekleştirebileceğini göstermiştir.

Ancak McCulloch ve Pitts (5) modelinde bağlantı ağırlıkları sabit olduğundan öğrenme yeteneği yoktu. Bu kısıtlılık 1949'da nörobilimci Hebb (6) tarafından kavramsal düzeyde çözüldü. Hebb (6), bir nörona gelen presinaptik girdinin, diğer eşzamanlı girdilerle birlikte o nöronda bir aksiyon potansiyeli oluşturduğunda, bu sinapsların güçleneceğini öne sürmüştür (7,8). Bu ilkeye göre sinaps gücü, bağlı nöronların eşzamanlı aktivitesiyle değişir ve öğrenmenin temelini oluşturur. Hebbian öğrenme adı verilen bu tanımlama yapay sinir ağlarındaki ağırlık güncelleme kurallarının da kavramsal atası olarak kabul görür (1,9).

Hebbian öğrenmenin hücresel ve moleküler düzeydeki karşılığı, beyindeki uyarıcı glutamaterjik sinapslarda tanımlanan uzun süreli güçlenme (*long-term potentiation*, LTP) ve uzun süreli baskılanma (*long-term depression*, LTD) mekanizmalarıdır (7,8). Glutamaterjik NMDA reseptörlerinin uyarılması için hem presinaptik glutamat salınımının hem de postsinaptik depolarizasyonun eşzamanlı olması gerektiğinden, bu sistem bir "koinsidans detektörü" gibi işlev görür: güçlü ve eşzamanlı aktivasyon hücre içine yoğun kalsiyum girişine ve hücre zarına yeni AMPA reseptörlerinin eklenmesine yol açarak sinapsı kalıcı biçimde güçlendirirken (LTP), zayıf ve düşük korelasyonlu aktivasyon AMPA reseptörlerinin hücre zarından uzaklaştırılmasına ve postsinaptik etkinin zayıflamasına yol açar (LTD). Bu mekanizmalar, nöronların birbirine nasıl bağlandığıyla, yani devre mimarisiyle birleştiğinde işlevsel bir anlam kazanır; nitekim beyindeki bilgi işleme büyük ölçüde nöronlar arasındaki ileri beslemeli (*feedforward*), geri beslemeli (*feedback*), yakınsak (*convergent*), ıraksak (*divergent*) ve yinelenen (*recurrent*) bağlantı motifleriyle yapılanan devreler üzerinden gerçekleşir (7,10). Yapay sinir ağı mimarilerinin katmanlı yapısı bu biyolojik bağlantısallık motiflerinin basitleştirilmiş bir yansıması olarak düşünülebilir.

Perseptrondan Derin Öğrenmeye

Yapay sinir ağları, birbirine bağlı yapay nöron (düğüm) katmanlarından oluşan matematiksel modellerdir. Her yapay nöron, biyolojik bir sinir hücresinden esinlenmiştir: bir veya birden fazla girdi alır, bunları ağırlıklı toplama ve bir "etkinleşme fonksiyonu" ile işleyerek çıktı üretir. Bu çıktı, sonraki katmandaki bağlı nöronlara iletilir. Nöronlar arasındaki bağlantıların gücüne "ağırlık" denir; öğrenme süreci bu ağırlıkların veriye göre ayarlanmasıyla gerçekleşir (1). Rosenblatt (11), 1958'de bu fikri "Perseptron" adlı işlevsel bir makineye dönüştürdü. Doğru sınıflandırmada ağırlıkları koruyan, hatada düzelten Perseptron öğrenen makinelerin ilk somut örneği ve nörobilimden esinlenen sınıflandırıcıların atasıdır. Ancak tek katmanlı bir perseptron, girdilerini yalnızca bir ağırlıklı toplama ve eşikleme işleminden geçirebildiği için doğrusal olarak ayrılamayan karmaşık örüntüleri ayırt edemez. Bu sınırlılık, tıpkı beyindeki görsel işlemede bilginin ardışık katmanlar boyunca giderek karmaşıklaşan temsillere dönüştürülmesi gibi, yapay sinir ağlarının da çok katmanlı hale getirilmesini gerekli kılmıştır. Nitekim retinadan talamusun lateral genikulat çekirdeğine, oradan birincil görme korteksine ve daha ileri görsel kortikal alanlara uzanan hiyerarşik işleme dizisinde, her katmandaki nöronlar giderek daha karmaşık ve soyut görsel özelliklere seçici hale gelir (12). Bu biyolojik hiyerarşi, modern derin öğrenme ağlarının katmanlı mimarisine ilham veren en somut örnektir (7,13).

Rumelhart ve ark.'nın (14) 1986'da geri yayılım algoritmasını bu çok katmanlı ağlara uygulaması yapay sinir ağlarının başarısını belirgin olarak iyileştirmiştir. Bu algoritmada ağın ürettiği tahmin doğru yanıtla karşılaştırılarak çıktıdaki hata hesaplanır. Geri yayılım, bu hatanın büyüklüğüne ve bağlantı ağırlıklarının sorumluluk derecesine göre ağırlıkları geriye doğru günceller (9,14). Bu mekanizma, beynin çalışma şekline tam uymasa da nörobilimsel yaklaşımın mühendislik çözümüne dönüştürülmesinin erken bir örneğidir. Beyinde bu işlevin daha yerel ve bağlantısallık tabanlı süreçlerle gerçekleştiği hipotezi güncel bir nörobilim araştırma konusudur (9).

Çok sayıda katmana sahip yapay sinir ağlarının eğitilmesi ile "derin öğrenme" kavramı ortaya çıkmıştır. Buradaki "derin" kelimesi, giriş ve çıkış katmanları arasındaki birden fazla gizli katmanın varlığını işaret eder. Her katman, bir önceki katmanın öğrendiklerinin üzerine daha karmaşık örüntüler inşa eder. İki-üç katmandan

oluşan geleneksel sinir ağlarından farklı olarak, modern derin ağlar onlarca ila yüzlerce katman içerebilir (1). Derin öğrenme; görüntü ve konuşma tanıma ile dil çevirisi gibi görevlerde önceki yöntemlere kıyasla büyük ilerlemeler sağlamış, tıbbi görüntülemede ise seçilmiş görevlerde uzmanlara eşdeğer veya daha yüksek performans sergilemiştir (15,16).

Görsel Korteks Hiyerarşisi ve Evrişimli Sinir Ağları

Hubel ve Wiesel (17), 1962'de kedi görsel korteksinde yaptıkları tek-birim kayıt çalışmalarıyla 1981'de Nobel Ödülü'nü kazandılar. Bulgularına göre "basit hücreler" görsel alanın küçük bir bölgesine duyarlı olup yalnızca belirli bir yönde uzanan çizgilere yanıt verirken, "kompleks hücreler" aynı yön seçiciliğini korumakla birlikte çizginin konumundan bağımsız yanıt verebilmektedir. Daha sonra Mishkin ve ark.'nın (18) çalışmalarıyla, primer görme (V1) korteksinden başlayan görsel bilginin iki paralel akıma ayrılarak ilerlediği gösterilmiştir: nesne kimliğinin ve renginin işlendiği ventral ("ne") akım (V1 → V2 → V3 → V4 → inferotemporal korteks) ile nesnenin konumunun ve hareketinin işlendiği dorsal ("nerede") akım (V1 → V2 → V3 → orta temporal korteks → pariyetal korteks). V1'in bir diğer özelliği de yön-seçici nöronlarının düzenli dağılımıdır: Korteks yüzeyine dik ilerleyen bir elektrot aynı yönelimi paylaşan nöronlara rastlarken, yüzeye paralel ilerleyen elektrotta yönelim düzenli biçimde kayar - bu "yönelim kolonu" organizasyonu, komşu kolonlar arasındaki yatay bağlantılarla birleşerek kısa çizgi parçalarının tek bir nesne sınırına bütünleştirilmesini sağlar (19,20). Sonuç olarak, gözdeki yaklaşık bir milyon retinal gangliyon hücresinin çıktısı, oksipital, pariyetal ve temporal loblara yayılan bir milyardan fazla korteks nöronunun etkinliğini harekete geçirebilmektedir (19).

Bu paralel devre mimarisi, görüntü işlemenin beyinde tek bir merkezi süreçte değil, dağıtık bir hiyerarşide gerçekleştiğini ortaya koymuş; bu ilke modern YZ mimarilerinde de karşılık bulmuştur. Fukushima (21), 1980'de Hubel ve Wiesel (17) modelini doğrudan uygulayan Neocognitron adlı yapay sinir ağını geliştirdi: bu ağda basit hücre katmanları (S-katmanları) belirli görsel örüntüleri tespit ederken, kompleks hücre katmanları (C-katmanları) bu tespitleri konumdan bağımsız hale getirir. Bu mimari, bugün evrişimli sinir ağı (*convolutional neural network*, CNN) olarak bilinen, görüntü işleme için özelleşmiş derin öğrenme mimarisinin doğrudan öncülüdür. CNN'in temel yapı taşı "evrişim" (*convolution*) işlemidir: küçük bir filtre (*kernel*), görüntü üzerinde kaydırılarak her konumda bir kenar, doku veya şeklin varlığını ölçer; ardından "havuzlama" (*pooling*) katmanları bu bilgiyi sıkıştırarak ölçek, dönme ve öteleme gibi mekansal dönüşümlere karşı dayanıklılık kazandırır. Fukushima'nın (21) S- ve C-katmanlarının matematiksel karşılığı budur (1). 1989'da LeCun ve ark. (22,23) geri yayılımı CNN'ye uygulayarak el yazısı posta kodlarını tanımada önemli bir başarı gösterdi; bu yaklaşım 1998'de LeNet-5 ile olgunlaştı (24). Modern derin öğrenme atılımı ise 2012'de Krizhevsky ve ark.'nın (25) grafik işlemci birimleri ve geniş ImageNet veri kümesini kullanarak AlexNet'i eğitmesi ile gerçekleşti (24).

Görsel ventral akımın son durağı olan inferotemporal kortekste, nöronların bir kısmı yüz gibi davranışsal açıdan anlamlı, karmaşık uyaranlara seçici biçimde yanıt verir; görüntüde belirli özelliklerin (örneğin; gözlerin veya ağzın) örtülmesi bu nöronların yanıtını belirgin biçimde azaltırken, aynı özelliklerin yerlerinin karıştırılması yanıtı neredeyse tamamen ortadan kaldırır, yani inferotemporal korteksteki temsil tek tek özelliklerin değil, bunların bütüncül konfigürasyonunun bir kodlamasıdır; bu ilke, CNN'in son katmanlarındaki nesne-düzeyi sınıflandırma birimleriyle doğrudan paraleldir (12). Bugün nükleer tıpta kullanılan otomatik lezyon tespiti, segmentasyon ve sınıflandırma algoritmalarının çoğu, kökleri Hubel ve Wiesel'le (17) uzanan bu CNN mimarilerini temel almaktadır. CNN tabanlı modeller, ventral görsel akımdaki hiyerarşik bilgi işleme düzenine benzer biçimde, düşük düzeyli görüntü özelliklerinden daha karmaşık ve anlamsal temsillere ilerleyen özellikleri öğrenebilir (26,27). FDG PET çalışmalarında bu yaklaşım, mediastinal lenf nodu metastazlarının saptanmasında hekim performansına yakın sonuçlar vermiştir (28,29). Benzer biçimde, FDG PET tabanlı glioma sınıflandırmasında da makine öğrenmesi tabanlı radyomiks modellerinin yüksek tanısal doğruluk gösterdiği bildirilmiştir (30).

Dopaminerjik Ödül Sistemi ve Pekiştirmeli Öğrenme (*Reinforcement Learning*, RL)

RL, bir YZ ajanının (*agent*) bir ortamda deneme-yanılma yoluyla en iyi kararları nasıl alacağını öğrenmesini inceleyen YZ dalıdır: ajana doğru kararlar için "ödül", yanlış kararlar için "ceza" verilir ve ajanın amacı bu ödülleri uzun vadede en üst düzeye çıkarmaktır. Pekiştirmeli öğrenmenin oyun oynamaktan otonom araç sürüşüne, ilaç dozu optimizasyonundan radyoterapi planlamasına kadar geniş uygulama alanları vardır (1). Bu yaklaşımın nörobilimsel kökü, dopaminerjik sistemin ödül öngörüsündeki rolünün keşfine uzanır. Canlılar ödül içeren

deneyimler aracılığıyla öğrenir: olumlu sonuç doğuran davranışlar tekrarlanırken olumsuz sonuç doğuranlar bastırılır; bu sürecin nörobiyolojik temelini beyin sapındaki ventral tegmental alan (VTA) ve substansiya nigranın dopaminerjik nöronları oluşturur (31). Bu ödül devresinin varlığı deneysel olarak ilk kez 1954'te Olds ve Milner'in (32) sıçanlarda tanımladığı "beyin stimülasyon ödülü" (*brain stimulation reward*) fenomeniyle ortaya konmuştur: VTA'dan nükleus akumbense (ventral striatumun temel bileşeni), dorsal striatuma, bazal ön beyne ve prefrontal kortekse uzanan dopaminerjik projeksiyonların elektriksel uyarımı için hayvanlar bir kolu saatlerce, hatta yemeyi ve içmeyi ihmal edecek kadar ısrarla çekmeye devam etmiş, bu da söz konusu devrenin güçlü ve doğrudan bir "istek" (motivasyon) sinyali ürettiğini göstermiştir (31,32). Schultz ve ark.'nın (33) 1990'lı yıllarda maymunlarda gerçekleştirdiği klasik elektrofizyoloji deneyleri şunu gösterdi: ödül beklenmedik biçimde geldiğinde dopamin nöronları güçlü biçimde ateşler; ödül önceden bir sinyalle (koşullu uyaran) haber verilmişse ateşleme ödül anında değil sinyalin verildiği anda gerçekleşir; sinyal verilip ödül gelmezse dopamin aktivitesi beklenen zamanda normalin altına düşer. Bu bulgular, dopamin nöronlarının ödülün kendisini değil, ödül hakkındaki tahminin ne kadar doğru olduğunu kodladığını göstermektedir: "ödül tahmin hatası" = gerçekleşen ödül - beklenen ödül. Pekiştirmeli öğrenmede kullanılan zamansal fark öğrenmesi de yapısal olarak aynı ilkeye dayanır: bir YZ ajanı, bir durumun değerine ilişkin önceki tahminini, bir adım sonra elde ettiği daha güncel tahminle karşılaştırır ve aradaki farkı ("zamansal fark hatası") kullanarak değer tahminini bu farkla orantılı biçimde günceller (34). Bir YZ ajanının yalnızca anlık ödüle değil gelecekteki beklenen ödüllerin tahmin edilen değerine göre güncellenmesini sağlayan bu ilke, bugün AlphaGo'dan otonom araçlara kadar birçok pekiştirmeli öğrenme sisteminin temelini oluşturur (1,33,35).

Tamamlayıcı Bellek Sistemleri ve Sürekli Öğrenme

İnsan belleğinin nöral temeli tek bir beyin bölgesine indirgenemez; bunun yerine, hipokampal devrelerden kortikal ağlara uzanan, birbirini tamamlayan ve karşılıklı etkileşim içinde çalışan çok sayıda yapıya dayanır (36,37). McClelland ve ark.'nın (38) 1995'te önerdiği tamamlayıcı öğrenme sistemleri (*complementary learning systems*) hipotezine göre hipokampüs tek bir deneyimi hızlı, seyrek ve özgün biçimde kodlarken, neokorteks birçok deneyimden ortak örüntüleri yavaşça, dağıtık biçimde öğrenir (1). Bu iki sistem birbirini tamamlar: hipokampüs her yeni deneyimi ayrı ve örtüşmesi az bir temsil olarak hızla kaydettiği için yeni öğrenmenin önceki anılar üzerindeki girişimini büyük ölçüde sınırlar; neokorteks ise yeni bilgilerle eski örüntüleri yavaşça bütünleştirerek genel bilgiyi korur (36). Hipokampusun epizodik belleğin (belirli bir olay/yaşantıya dair bellek) konsolidasyonundaki (kalıcılaştırma) bu ayrıcalıklı rolünün en klasik kanıtı, ilaca dirençli epilepsi nedeniyle iki medial temporal lobu cerrahi olarak çıkarılan hasta H.M.'nin durumudur. Ameliyat sonrası H.M. yeni epizodik anılar oluşturamaz hale gelirken, ameliyat öncesine ait uzak anıları, çalışma belleği ve motor beceri öğrenme kapasitesi (prosedürel bellek) büyük ölçüde korunmuştur (36,39). Bu ayrışma, hipokampusun bilgiyi kalıcı olarak "depolamadığını" ama konsolidasyon için gerekli olduğunu ve bildirimsel ile prosedürel bellek sistemlerinin birbirinden bağımsız beyin devrelerine dayandığını göstermiştir.

Hipokampal kodlamanın neokortekse aktarılması büyük ölçüde uyku sırasında gerçekleşir: hipokampüs, gün içinde edinilen deneyimleri defalarca tekrar eder ve bu tekrarlar aracılığıyla neokorteks kademeli olarak güncellenir. Bu olgunun elektrofizyolojik karşılığı, intrakraniyal kayıtlarda yavaş dalga uykusu sırasında hipokampüste görülen keskin dalga-dalgacık kompleksleridir (*sharp-wave ripples*) (7). Hücresel düzeyde ise kısa süreli bir belleğin kalıcı hale gelmesi yeni gen ifadesi ve protein sentezi gerektirir; CREB adlı transkripsiyon faktörünün aktivasyonu bu sürecin kritik bir adımıdır ve deneyimin "geçici sinaptik değişiklikten kalıcı depolamaya" dönüşmesini sağlar (40). Bu biyolojik bulgular, YZ'deki "deneyim tekrarı" (*experience replay*) yöntemi için önemli bir kavramsal ilham kaynağı olarak kabul edilmektedir (1). Yapay sinir ağlarının bilinen zayıflıklarından biri, görevler ardışık olarak öğrenildiğinde yeni öğrenmenin önceden öğrenilmiş bilgiyi hızla ve büyük ölçüde bozmasıdır; bu olgu "yıkıcı unutma" (*catastrophic forgetting*) olarak adlandırılır (41). Biyolojik bellek sistemleri de unutmadan muaf değildir: zamanla bozulma, anılar arası girişim ve geri getirme başarısızlıkları biyolojik belleğin olağan özellikleridir. Ancak beyinde unutma genellikle kademeli ve seçici biçimde gerçekleşir; yeni öğrenme, pekişmiş bilgiyi yapay ağlardaki ölçüde toptan silmez ve tamamlayıcı öğrenme sistemleri bu dengenin olası mekanizmalarından biri olarak önerilmiştir (38). Deneyim tekrarı ilk kez 1992'de Lin (42) tarafından pekiştirmeli öğrenme ajanları için önerilmiş, DeepMind'ın

2015'te geliştirdiği derin Q-ağı (*deep Q-network*, DQN) ile geniş ölçekte başarıyla uygulanmıştır (43). DQN, ajanın geçmiş deneyimlerini (durum, eylem, ödül, sonraki durum) bir "tekrar belleği"nde (*replay buffer*) saklar ve eğitim sırasında bu deneyimlerden rastgele örnekler seçerek ağı günceller. Bu rastgele örnekleme, ardışık deneyimler arasındaki güçlü zamansal korelasyonu azaltır, her deneyimin birden çok kez kullanılmasını sağlayarak veri verimliliğini artırır ve ağın yalnızca en son deneyimlere göre biçimlenmesini önleyerek öğrenme sürecini daha kararlı hale getirir (43). Bu yönüyle deneyim tekrarı, hipokampal tekrarın hesapsal bir benzeri olarak değerlendirilebilir (1). Tekrar temelli yaklaşımlar daha sonra, birden fazla görevin ardışık öğrenildiği sürekli öğrenme (continual learning) alanında yıkıcı unutmayı azaltmak amacıyla da uyarlanmıştır (44).

Seçici Dikkat Mekanizmaları ve Transformer Mimarisi

Gözümüz her an milyonlarca foton bombardımanına maruz kalır, ancak görsel sistemimize giren bu bilginin yalnızca küçük bir bölümü bilinçli algı tarafından işlenir. Seçici dikkat, prefrontal ve pariyetal korteksin ortak yönetiminde yukarıdan aşağıya (*top-down*) bir filtre işlevi görür: hedef nesneyi temsil eden korteks bölgeleri güçlendirilirken alakasız bilgiyi temsil edenler baskılanır. Bu mekanizma mekansal dikkatin (nereye bakılacağı) ve özellik tabanlı dikkatin (neyin arandığı) temelini oluşturur (1,45). Dikkat edilen konumdaki bir uyaran daha hassas algılanır ve daha hızlı tepki doğurur; bunun nöral karşılığı, o konumu temsil eden nöronların yanıt kazancının artmasıdır. Örneğin; pariyetal kortekste bir nöron, bir uyarana dikkat edildiğinde, edilmediği duruma göre çok daha güçlü yanıt verir. Bu "dikkat spot ışığı" (*spotlight of attention*) çerçevesi, ilgili konuma orantılı bir kazanç uygulanması olarak özetlenebilir (46).

Vaswani ve ark.'nın (47) 2017'de yayımladığı "Attention is All You Need" makalesiyle tanıtılan Transformer, bugün büyük dil modellerinin (ChatGPT, Gemini vb.) temelini oluşturan sinir ağı mimarisidir. Transformer'ın özünde, beynin seçici dikkat mekanizmalarından ilham alan "öz-dikkat" katmanı yatar: model, bir girdi dizisinin (örneğin; bir cümlenin veya görüntü yama dizisinin) her öğesini işlerken diğer öğelerle ilişkisini dinamik biçimde değerlendirir ve en ilgili olanlara daha fazla ağırlık verir. Bu "küresel bağlam değerlendirmesi" özelliği Transformer'ı önceki mimarilerden köklü biçimde ayırır (47). Görüntü alanında *Vision Transformer* (48), tıbbi görüntü analizinde CNN'in yerini giderek almaktadır (49,50,51). Transformer mimarisinin klinik potansiyeli, farklı veri modalitelerini entegre etme yeteneğinde yatar: bir nükleer tıp uzmanının PET görüntüsünü değerlendirirken aynı anda hastanın öyküsünü, biyokimyasal bulgularını, patoloji raporlarını ve geçmiş görüntüleme verilerini de göz önünde bulundurması gibi, Transformer tabanlı çok modlu modeller de görüntü ve klinik metin verilerini birlikte işleyerek bu bütünleşik değerlendirmeyi taklit etmeye çalışır; rapor otomasyonu, klinik karar desteği ve prognostik tahmin bu yaklaşımın aktif uygulama alanlarıdır (3,50,51).

Verimli Kodlama, Öngörücü Hesaplama ve Olay-Güdümlü Hesaplama

İnsan beyninin enerji tüketimi, vücut ağırlığının yalnızca %2'sine karşılık gelmesine rağmen toplam enerji tüketiminin %20'sini oluşturur (52). Nörobilim araştırmaları, beynin bu verimliliği büyük ölçüde "seyrek kodlama" (*sparse coding*) ile sağladığını göstermiştir: herhangi bir anda milyarlarca nörondan yalnızca küçük bir kısmı aktiftir ve bunlar mevcut girdiyi en az enerjiyle temsil eden minimal bir küme oluşturur (1). Bu ilke YZ'de denetimsiz ve öz-denetimli öğrenme yöntemlerini etkilemiştir; "seyrek otoenkoder" (*sparse autoencoder*) modelleri veriyi seyrek bir gizli temsile sıkıştırarak en yüksek bilgi içeriğine sahip öznitelikleri otomatik keşfeder ve bu yaklaşım tıbbi görüntülemede (röntgen, mamografi, dijital patoloji, ekokardiyografi, anjiyografi ve bilgisayarlı tomografi dahil) klinik açıdan anlamlı özniteliklerin yorumlanabilir biçimde otomatik çıkarılması için araştırılmaktadır (53).

Günümüzde geniş kabul gören bir başka nörobilim teorisine göre beyin, pasif bir alıcı değil aktif bir tahmin makinesidir: her an bir sonraki duyusal girdiyi tahmin eder ve üst merkezlere yalnızca tahmin ile gerçek girdi arasındaki farkı (tahmin hatası) iletir. Friston'un (54) "serbest enerji ilkesi"yle ilişkili bu "öngörücü kodlama" çerçevesi, beklenmedik bulguların neden dikkat çekici göründüğünü açıklar ve YZ açısından geri yayılımın daha yerel, biyolojik olarak daha gerçekçi alternatiflerine kavramsal bir zemin sunar (1). Tahmin hatasına dayalı öğrenme kuralları, büyük merkezi hata sinyallerine ihtiyaç duymadan ağırlıkları güncelleyerek daha az veriyle daha verimli öğrenmeyi mümkün kılabilir (9). Nitekim Mathis (55), öngörü hatası tabanlı iç modeller kullanan "adaptif YZ" kavramının hem daha az veriyle öğrendiğini hem de değişen ortamlara daha iyi uyum sağladığını öne sürmüştür.

Enerji verimliliğinin bir başka yansıması, sinir hücrelerinin bilgiyi sürekli bir sinyalle değil, kısa elektriksel atımların (aksiyon potansiyeli) zamanlaması ve sıklığı üzerinden taşımasıdır (56). Bu iletişimi taklit eden spiking sinir ağları da enerji tüketimini düşürmeyi ve modelin beyne benzerliğini artırmayı hedefler (2).

YZ'den Nörobilime: Karşılıklı Etkileşim

Nörobilimden YZ'ye uzanan akış tek yönlü değildir; son on yılda YZ araçları nörobilim araştırmalarında güçlü bir "hipotez test ortamı" işlevi görmeye başlamıştır. Biyolojik ödül öğrenmesi teorisinden ilham alan zamansal fark öğrenmesi, YZ'de büyük başarılar kazandıktan sonra geri dönüp nörobilime yeni hipotezler kazandırmıştır: DeepMind araştırmacıları, dağıtımsal pekiştirmeli öğrenme modellerinin dopaminerjik nöronların alt tiplerinin farklı ödül bağlamlarında farklı tepkiler vermesini olağanüstü doğrulukla öngördüğünü göstermiş, bu model önceden bilinmeyen bir biyolojik mekanizmayı keşfettirmiş ve araştırmacılar bu tahmini sonradan hayvan deneyleriyle doğrulamıştır (4,57). Bu örnek, YZ'nin salt bir araç değil, gerçek hayatta uzun zaman sürecek, maliyetli ve etik açıdan zorlu olacak deneyleri saatler içinde simüle edebilen bir *in silico* laboratuvar işlevi de gördüğünü ortaya koymaktadır.

Bununla birlikte, nörobilim ile YZ arasında bir metodolojik uçurum da bulunmaktadır: Chance ve ark.'nın (13) 2020 tarihli çalışmasına göre nörobilim "bu hangi bileşenden oluşuyor?" sorusunu (form/yapı odaklı) öncelikli görürken, YZ "bu ne işe yarıyor?" sorusunu (işlev odaklı) öncelikli görür ve bu farklı perspektifler bir alanın bulgusunun diğerine doğrudan aktarılmasını güçleştirir. Dopaminerjik sistemin devre anatomisini bilen bir nörobilimci bu bilgiyi bir pekiştirmeli öğrenme algoritmasında kullanılabilir bir "işlevsel açıklama"ya dönüştürmekte zorlanabilirken, bir pekiştirmeli öğrenme araştırmacısı da biyolojik ayrıntının algoritmaya ne ekleyeceğini sormak için nörobilimciye ihtiyaç duyar; bu köprüyü kurmak, NeuroAI adıyla şekillenen disiplinlerarası alanın gündemine girmiştir (58).

Sonuç

Bu makalede, nörobilim ile YZ arasındaki çift yönlü ilişki ele alınmıştır. YZ'nin tarihçesi, McCulloch ve Pitts (5) nöronundan Hubel ve Wiesel'in (17) görsel korteks keşfine, oradan dopaminerjik ödül sinyaline ve seçici dikkat mekanizmalarına uzanan biyolojik bulguların yapay sinir ağlarını, evrişimli ağları, pekiştirmeli öğrenmeyi ve Transformer mimarisini doğrudan biçimlendirdiğini göstermektedir. Birçok YZ atılımının temelinde bir nörobilimsel ilkenin hesapsal dile çevrilmesi yatmaktadır. Nörobilimin biyolojik gerçekçiliği YZ için katı bir kural değil bir pusuladır; bunu doğru okumak iki alana hakim araştırmacılara, disiplinlerarası çalışma gruplarına ve ortak bir dile ihtiyaç duyar.

Nükleer tıp hekimi için bu gelişmelerin pratik önemi iki katmanlıdır: birincisi, klinik pratikte kullanılan veya kullanılması değerlendirilen YZ araçları bu kavramsal çerçeveyle daha bilinçli ve eleştirel biçimde değerlendirilebilir; ikincisi, nörobilim-YZ kesişiminin klinik uygulama alanlarından biri nükleer tıp pratiğidir. Bu nedenle bu etkileşimi takip etmek yalnızca akademik bir merak değil, klinik bir gerekliliktir.

Dipnotlar

Çıkar Çatışması: Yazarlar tarafından çıkar çatışması bildirilmemiştir.

Finansal Destek: Yazarlar tarafından finansal destek almadıkları bildirilmiştir.

Yapay Zeka (AI) Kullanım Beyanı: Bu çalışmanın hazırlanması sırasında yazarlar Anthropic Claude aracını, metnin dil ve anlatım açısından düzenlenmesi ve ek kaynakların belirlenmesi amacıyla kullanmıştır; araç tarafından önerilen tüm içerik ve kaynaklar, orijinal kaynak metinleriyle karşılaştırılarak yazarlar tarafından doğrulanmıştır. İçerik dikkatlice gözden geçirilip gerekli düzenlemeler yapıldıktan sonra yazarlar yayın içeriğinin sorumluluğunu tamamen üstlenmektedir. Yapay zeka aracı kullanımı, esas olarak çalışmanın dil, anlatım kalitesi ve kaynakça oluşturulmasında etkili olmuştur.

Kaynaklar

1. Hassabis D, Kumaran D, Summerfield C, Botvinick M. Neuroscience-inspired artificial intelligence. Neuron. 2017;95:245-258.
2. Marblestone AH, Wayne G, Kording KP. Toward an integration of deep learning and neuroscience. Front Comput Neurosci. 2016;10:94.
3. Kirienko M, Biroli M, Gelardi F, Seregni E, Chiti A, Sollini M. Deep learning in nuclear medicine—focus on CNN-based approaches for PET/CT and PET/MR: where do we stand? Clin Transl Imaging. 2021;9:37-55.
4. Macpherson T, Churchland A, Sejnowski T, et al. Natural and artificial intelligence: a brief introduction to the interplay between AI and neuroscience research. Neural Netw. 2021;144:603-613.

5. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. 1943. Bull Math Biol. 1990;52:99-115; discussion 73-97.
6. Hebb DO. The organization of behavior: a neuropsychological theory. New York: John Wiley & Sons; 1949.
7. Abbott LF, Losonczy A, Sawtell NB. The computational basis of neural circuits that mediate behavior. In: Kandel ER, Koester JD, Mack SH, Siegelbaum SA, editors. Principles of Neural Science. 6th ed. New York: McGraw Hill; 2021. p. 97-110.
8. Bear MF, Connors BW, Paradiso MA. Wiring the brain. In: Neuroscience: exploring the brain. 4th ed. Philadelphia: Wolters Kluwer; 2016. p. 783-821.
9. Lillicrap TP, Santoro A, Marris L, Akerman CJ, Hinton G. Backpropagation and the brain. Nat Rev Neurosci. 2020;21:335-346.
10. Luo L. Architectures of neuronal circuits. Science. 2021;373:eabg7285.
11. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychol Rev. 1958;65:386-408.
12. Albright TD, Freiwald WA. High-level visual processing: from vision to cognition. In: Kandel ER, Koester JD, Mack SH, Siegelbaum SA, editors. Principles of neural science. 6th ed. New York: McGraw Hill; 2021. p. 564-581.
13. Chance FS, Aimone JB, Musuvathy SS, Smith MR, Vineyard CM, Wang F. Crossing the cleft: communication challenges between neuroscience and artificial intelligence. Front Comput Neurosci. 2020;14:39.
14. Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. Nature. 1986;323:533-536.
15. Ching T, Himmelstein DS, Beaulieu-Jones BK, et al. Opportunities and obstacles for deep learning in biology and medicine. J R Soc Interface. 2018;15:20170387.
16. Liu X, Faes L, Kale AU, et al. A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. Lancet Digit Health. 2019;1:e271-e297. Erratum in: Lancet Digit Health. 2019;1:e334.
17. Hubel DH, Wiesel TN. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. J Physiol. 1962;160:106-154.
18. Mishkin M, Ungerleider LG, Macko KA. Object vision and spatial vision: two cortical pathways. Trends Neurosci. 1983;6:414-417.
19. Bear MF, Connors BW, Paradiso MA. The central visual system. In: Neuroscience: exploring the brain. 4th ed. Philadelphia: Wolters Kluwer; 2016. p. 331-366.
20. Gilbert CD. Intermediate-level visual processing and visual primitives. In: Kandel ER, Koester JD, Mack SH, Siegelbaum SA, editors. Principles of neural science. 6th ed. New York: McGraw Hill; 2021. p. 545-563.
21. Fukushima K. Neocognitron: a self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biol Cybern. 1980;36:193-202.
22. LeCun Y, Boser B, Denker JS, et al. Backpropagation applied to handwritten zip code recognition. Neural Comput. 1989;1:541-551.
23. LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. Proc IEEE. 1998;86:2278-2324.
24. Schmidhuber J. Deep learning in neural networks: an overview. Neural Netw. 2015;61:85-117.
25. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. Adv Neural Inf Process Syst. 2012;25:1097-1105.
26. Zhuang C, Yan S, Nayebi A, et al. Unsupervised neural network models of the ventral visual stream. Proc Natl Acad Sci U S A. 2021;118:e2014196118.
27. Lindsay GW. Convolutional neural networks as a model of the visual system: past, present, and future. J Cogn Neurosci. 2021;33:2017-2031.
28. Wang H, Zhou Z, Li Y, et al. Comparison of machine learning methods for classifying mediastinal lymph node metastasis of non-small cell lung cancer from ^{18}F-FDG PET/CT images. EJNMMI Res. 2017;7:11.
29. Wallis D, Soussan M, Lacroix M, Akl P, Duboucher C, Buvat I. An [^{18}F]FDG-PET/CT deep learning method for fully automated detection of pathological mediastinal lymph nodes in lung cancer patients. Eur J Nucl Med Mol Imaging. 2022;49:881-888. Erratum in: Eur J Nucl Med Mol Imaging. 2022;49:3598.
30. Shahriari A, Ghazanafar Ahari S, Mousavi A, et al. Machine learning-driven radiomics on 18 F-FDG PET for glioma diagnosis: a systematic review and meta-analysis. Cancer Imaging. 2025;25:106.
31. Nestler EJ, Salzman CD. Motivation, reward, and addictive states. In: Kandel ER, Koester JD, Mack SH, Siegelbaum SA, editors. Principles of neural science. 6th ed. New York: McGraw Hill; 2021. p. 1065-1079. Chapter 43.
32. Olds J, Milner P. Positive reinforcement produced by electrical stimulation of septal area and other regions of rat brain. J Comp Physiol Psychol. 1954;47:419-427.
33. Schultz W, Dayan P, Montague PR. A neural substrate of prediction and reward. Science. 1997;275:1593-1599.
34. Sutton RS. Learning to predict by the methods of temporal differences. Mach Learn. 1988;3:9-44.
35. Silver D, Huang A, Maddison CJ, et al. Mastering the game of go with deep neural networks and tree search. Nature. 2016;529:484-489.
36. Bear MF, Connors BW, Paradiso MA. Memory systems. In: Neuroscience: exploring the brain. 4th ed. Philadelphia: Wolters Kluwer; 2016. p. 823-864.

37. Moser EI, Moser MB, Siegelbaum SA. The hippocampus and the neural basis of explicit memory storage. In: Kandel ER, Koester JD, Mack SH, Siegelbaum SA, editors. Principles of neural science. 6th ed. New York: McGraw Hill; 2021. p. 1339-1369.
38. McClelland JL, McNaughton BL, O'Reilly RC. Why there are complementary learning systems in the hippocampus and neocortex: insights from the successes and failures of connectionist models of learning and memory. Psychol Rev. 1995;102:419-457.
39. Scoville WB, Milner B. Loss of recent memory after bilateral hippocampal lesions. J Neurol Neurosurg Psychiatry. 1957;20:11-21.
40. Bear MF, Connors BW, Paradiso MA. Molecular mechanisms of learning and memory. In: Neuroscience: exploring the brain. 4th ed. Philadelphia: Wolters Kluwer; 2016. p. 865-899.
41. McCloskey M, Cohen NJ. Catastrophic interference in connectionist networks: the sequential learning problem. Psychol Learn Motiv. 1989;24:109-165.
42. Lin LJ. Self-improving reactive agents based on reinforcement learning, planning and teaching. Mach Learn. 1992;8:293-321.
43. Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning. Nature. 2015;518:529-533.
44. van de Ven GM, Siegelmann HT, Tolias AS. Brain-inspired replay for continual learning with artificial neural networks. Nat Commun. 2020;11:4069.
45. Goldberg ME, Wurtz RH. Visual processing for attention and action. In: Kandel ER, Koester JD, Mack SH, Siegelbaum SA, editors. Principles of neural science. 6th ed. New York: McGraw Hill; 2021. p. 582-597.
46. Bear MF, Connors BW, Paradiso MA. The resting brain, attention, and consciousness. In: Neuroscience: exploring the brain. 4th ed. Philadelphia: Wolters Kluwer; 2016. p. 719-850.
47. Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. Adv Neural Inf Process Syst. 2017;30:5998-6008.
48. Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: transformers for image recognition at scale. In: International Conference on Learning Representations (ICLR); 2021.
49. Ansari S, Faraji N, Topham L, et al. A survey of transformer-based architectures in medical image analysis: models, applications, and challenges. Front Artif Intell. 2026;9:1873938.
50. Bradshaw TJ, Tie X, Warner J, Hu J, Li Q, Li X. Large language models and large multimodal models in medical imaging: a primer for physicians. J Nucl Med. 2025;66:173-182.
51. Shamshad F, Khan S, Zamir SW, et al. Transformers in medical imaging: a survey. Med Image Anal. 2023;88:102802.
52. Raichle ME, Gusnard DA. Appraising the brain's energy budget. Proc Natl Acad Sci U S A. 2002;99:10237-10239.
53. Metzger A, Patil S, Sugarmann LR, Karabacak M, Margetis K. Application of sparse autoencoders to enhance mechanistic interpretability of large language models in medicine. JMIR AI. 2026;5:e81134.
54. Friston K. The free-energy principle: a unified brain theory? Nat Rev Neurosci. 2010;11:127-138.
55. Mathis MW. Leveraging insights from neuroscience to build adaptive artificial intelligence. Nat Neurosci. 2026;29:13-24.
56. Attwell D, Laughlin SB. An energy budget for signaling in the grey matter of the brain. J Cereb Blood Flow Metab. 2001;21:1133-1145.
57. Dabney W, Kurth-Nelson Z, Uchida N, et al. A distributional code for value in dopamine-based reinforcement learning. Nature. 2020;577:671-675.
58. Zador A, Escola S, Richards B, et al. Catalyzing next-generation artificial intelligence through NeuroAI. Nat Commun. 2023;14:1597.