

# Psikiyatri Hizmetlerinin Yapay Zekâ ile Geliştirilmesi: Fırsatlar ve Zorluklar



Muhammed BALLI<sup>1</sup>, Aslı ERCAN DOĞAN<sup>2</sup>, Hale YAPICI ESER<sup>3</sup>

## ÖZET

Ruhsal bozukluklar, artan yaygınlık, yükselen maliyet ve önemli ekonomik yükleri nedeniyle kritik bir küresel halk sağlığı sorunudur. Türkiye'de, ruh sağlığı iş gücünü artırma çabalarına rağmen, psikiyatri uzmanı eksiği önemli düzeyde devam etmekte, bu durum ruh sağlığı hizmet kalitesini ve erişilebilirliğini sınırlamaktadır. Bu derleme yapay zekâ (YZ), özellikle de büyük dil modellerinin, dünyada ve Türkiye'de psikiyatrik bakımı dönüştürme potansiyelini incelemektedir. Makine öğrenmesi ve derin öğrenme dahil olmak üzere YZ teknolojileri, konuşma kalıpları, nörogörüntüleme ve davranışsal ölçümler gibi çeşitli veri kaynaklarını kullanarak ruhsal bozuklukların tanısı, tedavinin kişiselleştirilmesi ve izlenmesinde yenilikçi çözümler sunmaktadır. YZ, tanı doğruluğunu ve ruh sağlığı hizmetlerine erişimi artırma konusunda umut verici yetenekler gösterse de, algoritmik yanlılıklar, veri gizliliği endişeleri, etik sonuçlar ve büyük dil modellerinin konfabulasyonu fenomeni gibi zorluklar, YZ'nin pratikte tam olarak uygulanmasını engellemektedir. Derleme, özellikle Türkiye bağlamında kültürel ve dilsel olarak uyarlanmış YZ araçları geliştirmek üzere disiplinler arası işbirliğinin gerekliliğini vurgulamakta ve YZ güvenilirliğini artırmak için ince ayar, geri alım destekli üretim ve insan geri bildiriminden pekiştirmeli öğrenme gibi stratejileri önermektedir. İlerlemeler, YZ'nin tıbbi bakımın temel insanı unsurlarını korurken tanı hassasiyetini ve erişilebilirliği artırarak ruh sağlığı hizmetlerini geliştirebileceğini göstermektedir. YZ'nin ruh sağlığı hizmetlerine etkili ve adil entegrasyonu için mevcut sınırlamaların titiz araştırmalar ve etik çerçeveler aracılığıyla ele alınması gerekmektedir.

**Anahtar Sözcükler:** Büyük Dil Modelleri, Makine Öğrenmesi, Psikiyatri, Sağlık, Yapay Zeka

## ABSTRACT

### Improving Psychiatry Services with Artificial Intelligence: Opportunities and Challenges

Mental disorders are a critical global public health problem due to their increasing prevalence, rising costs, and significant economic burden. Despite efforts to increase the mental health workforce in Türkiye, there is a significant shortage of psychiatrists, limiting the quality and accessibility of mental health services. This review examines the potential of artificial intelligence (AI), especially large language models, to transform psychiatric care in the world and in Türkiye. AI technologies, including machine learning and deep learning, offer innovative solutions for the diagnosis, personalization of treatment, and monitoring of mental disorders using a variety of data sources, such as speech patterns, neuroimaging, and behavioral measures. Although AI has shown promising capabilities in improving diagnostic accuracy and access to mental health services, challenges such as algorithmic biases, data privacy concerns, ethical implications, and the confabulation phenomenon of large language models prevent the full implementation of AI in practice. The review highlights the need for interdisciplinary collaboration to develop culturally and linguistically adapted AI tools, particularly in the Turkish context, and suggests strategies such as fine-tuning, retrieval-augmented generation, and reinforcement learning from human feedback to increase AI reliability. Advances suggest that AI can improve mental health care by increasing diagnostic accuracy and accessibility while preserving the essential human elements of medical care. Current limitations need to be addressed through rigorous research and ethical frameworks for effective and equitable integration of AI into mental health care.

**Keywords:** Artificial Intelligence, Health, Large Language Model, Machine Learning, Psychiatry

## Ekonomik Yük ve Psikiyatride İş Gücü Kısıtlılıkları: Küresel ve Türkiye Perspektiflerinden İlgörüler

Ruh sağlığı bozuklukları, yaygınlıkları ve ekonomik maliyetleri nedeniyle halk sağlığı açısından küresel kritik bir öneme sahiptir. 2022 yılında yayınlanan, 204 ülkeden, 12 ruhsal bozukluğa

ilişkin, 1990-2019 yılları arasındaki verileri analiz eden bir çalışma, ruhsal bozukluklara bağlı küresel engelliliğe ayarlanmış yaşam yıllarının (Disability Adjusted Life Years, DALY) 80,8 milyondan 125,3 milyona yükseldiğini, ruhsal bozukluklara atfedilen DALY'lerin payının % 3,1'den % 4,9'a çıktığını bulmuştur. (GBD 2019 Mental Disorders Collaborators 2022).

**Geliş Tarihi:** 07.10.2024, **Kabul Tarihi:** 27.11.2024, **Çevrim İçi Yayın Tarihi:** 06.12.2024

<sup>1</sup>PhD Adayı, Koç Üniv., Sağlık Bilimleri Enstitüsü, İstanbul; <sup>2</sup>Uzm., <sup>3</sup>Doç., Koç Üniv., Tıp Fak., Psikiyatri Bl., İstanbul.

**Dr. Hale Yapıcı Eser, e-posta:** [hyapici@ku.edu.tr](mailto:hyapici@ku.edu.tr)

Bu bulgu, küresel bağlamda ruhsal bozuklukların yükünün arttığını göstermektedir. Ruhsal bozukluklarla ilişkili ekonomik dezavantajlar, sosyal dışlanma gibi risk etkenlerinde artış ve eğitim gibi koruyucu etkenlere erişimin sınırlı olması, ruhsal bozuklukların yaygınlığının daha da artmasına katkıda bulunmaktadır (Niemeyer ve ark. 2019, Heinz ve ark. 2020). Ruh sağlığı bozukluklarının ekonomik etkisi, hem üretkenlik kayıpları hem de tedavi maliyetleri nedeniyle önemlidir (Knapp ve ark. 2020). Amerika Birleşik Devletleri'nde majör depresif bozukluğun (MDB) ekonomik yükü üzerine yapılan 2021 tarihli bir çalışmaya göre, MDB ile ilişkili maliyet 2010'dan 2018'e kadar % 37,9 artarak 236,6 milyar dolardan 326,2 milyar dolara yükselmiştir. Bu dönemde, MDB teşhisi konulan yetişkinlerin sayısı 15,5 milyondan 17,5 milyona çıkmış, bununla birlikte, tedavi gören hastaların oranı 2018'de 2010'a kıyasla azalmıştır (Greenberg ve ark. 2021). Bu durum, MDB gibi tanılarının sıklığı artsa da etkin tedaviye erişimin aynı oranda artmadığını göstermektedir. Ruh sağlığı bozuklukları, engellilik ve ölüm gibi ciddi sonuçlarla ilişkili olduğundan, önleyici tedbirler ve erişilebilir hizmetler çok önemlidir (Martin-Carrasco ve ark. 2016).

2021'de yayınlanan Ulusal Ruh Sağlığı Eylem Planı'na göre, 2011 yılında Türkiye'de 100.000 kişiye 2,2 psikiyatri uzmanı düşerken, bu sayı 2020 yılında 3,43'e yükselmiştir; çocuk ve ergen ruh sağlığı ve hastalıkları uzmanı sayısı ise 100.000 kişiye 1,63'tür (Ulusal Ruh Sağlığı Eylem Planı 2021). Ruh sağlığı profesyonellerinin artırılmasına yönelik çabalara rağmen, sayıca yetersizlik devam etmekte ve bu durum ruh sağlığı hizmeti kalitesini ve hizmete erişilebilirliği olumsuz etkilemektedir. Türkiye Psikiyatri Derneği'nin 2016 yılı raporuna göre, ruh sağlığı merkezleri güncel teknolojik imkanlardan yoksundur ve devlet hastanelerindeki psikiyatri uzmanları günde 80 hastaya kadar muayene etmekte, randevu süreleri 1-2 dakika gibi sürelerle Dünya Sağlık Örgütü'nün tavsiye ettiği minimum süre olan 20 dakikanın çok altında kalmakta ve bu durumda akut ve yüksek riskli hastalara her zaman öncelik verilememektedir (Türkiye Psikiyatri Derneği 2016). Ayrıca toplumsal ve bireysel düzeyde artan damgalanma, ruh sağlığı desteği aramanın önünde önemli bir engel olup (Zweifel 2021) Türkiye Psikiyatri Derneği'nin aynı raporuna göre, hastaları psikiyatri alanında uzman olmayan kişilerden yardım almaya iterek mevcut sağlık durumlarının daha da kötüleşmesine neden olmakta ve böylece ruh sağlığı sistemi üzerindeki yükü daha da ağırlaştırmaktadır (Türkiye Psikiyatri Derneği 2016). Devlet hastanelerindeki sınırlı uzman hekim sayısı ve zaman yetersizliği nedeniyle hastaların psikiyatri hizmetlerine erişimi zaten kısıtlıdır. Buna ek olarak, birçok özel sigorta planının psikiyatri hizmetlerini kapsamaması, bu erişimi daha da zorlaştırmaktadır.

Ruh sağlığı profesyonellerinin sayısını artırmak için çaba sarf edilmesine rağmen, bir psikiyatri uzmanının eğitimi ve süpervizyonu genellikle 4 ila 5 yıl sürmektedir. Bu süreç, süpervizörlerden/ öğretim üyelerinden bilgi ve becerilerin eğitim alan

kişilere aktarılmasını içerir ve hasta görüşmelerinin ve vaka dosyalarının doğrudan gözlemlenmesi, değerlendirilmesi ve takibini kapsar. Şu anda bu eğitim büyük ölçüde insan girdisine bağımlıdır, bu da eğitimi hem zaman alıcı hale getirmekte hem de eğitimin kurumlar arasında standardize olmasını zorlaştırmaktadır. Klinik uygulama ve eğitimin yanı sıra, araştırma alanında da daha geniş veri setlerinin oluşturulabilmesi için psikopatolojik belirtilerin ve bulguların daha hassas bir şekilde standardize edilerek sınıflandırılması ve belgelenmesi gerekmektedir. Bu standardize değerlendirmeler için de merkezler arasında ortak danışman ve değerlendiricilere ihtiyaç vardır. Tüm bu değerlendirmelerin yapılması ve standardizasyonu da emek ve zaman gerektirir.

## Yapay Zekânın Evrimi ve Ruh Sağlığı Hizmetleriyle Bütünleştirilmesi

Yapay zekâ (YZ), insan zekâsının gerekli olduğu görevleri yerine getirmeye odaklanan çok disiplinli bir bilgisayar bilimi alanıdır. Makinelere, sağlıklı insanların kolayca yapabildiği algılama, akıl yürütme, öğrenme ve karar verme gibi görevleri gerçekleştirme yeteneği kazandırmaya çalışmak, YZ ve alt disiplinlerinin kapsamındadır. Modern anlamda YZ çalışmalarının başlangıcı, Alan Turing'in *Computing Machinery and Intelligence* makalesini yayınladığı 1950 yılına dayanmaktadır (Turing 2009). YZ terimi ise bu alanda çalışan araştırmacıları bir araya getiren Dartmouth konferansında 1956 yılında ortaya atılmıştır. Başlangıçtaki iyimser havaya rağmen, YZ 1970 ve 1980'lerde bilgisayarların yeterli hesaplama gücünün olmaması nedeniyle beklenen gelişmeye ulaşamamıştır (Delipetrev 2020). Üstel olarak artan veri ve işlem kaynakları, yapay sinir ağları ve derin öğrenme gibi makine öğrenmesi teknikleriyle birlikte, 1990'ların sonlarında YZ alanını yeniden canlandırmıştır (Pastur-Romay ve ark. 2016). IBM tarafından geliştirilen Deep Blue'nun 1996'da satranç ustası Garry Kasparov'u yenmesi, bu yeniden ortaya çıkışın sembolik anlarından biridir (Delipetrev 2020). 2020'den sonraki yıllarda, YZ'nin üstel bir şekilde büyümesi YZ güvenliği ve yararlılığı hakkındaki tartışmaların da artmasına sebep olmuştur. Makine öğrenmesi algoritmaları ve yapay sinir ağları kullanan YZ sistemlerinin, tıbbi görüntülemeler ve genetik bilgiler gibi karmaşık verileri analiz ederek kanser, kalp hastalığı ve nörolojik bozukluklar gibi hastalıkları yüksek hassasiyetle tespit edebileceği öne sürülmüştür (Jiang ve ark. 2017). Ayrıca, YZ'nin moleküler etkileşimleri tahmin ederek ve potansiyel ilaç adaylarını belirleyerek ilaç keşfini hızlandırabileceği önerilmiştir (Gupta ve ark. 2021). YZ, hastalık seyri süresince tedavi yanıtı ile ilgili bilgileri kullanarak oluşturacağı algoritmalarla tedavi planını tekil kişi bazında gerçek zamanlı olarak ayarlamaya yardımcı olabilir. Bu dinamik yöntem, halen deneme yanılma aşaması içeren konvansiyonel tedavi yaklaşımlarına kıyasla daha etkin bir tedavi olasılığını artırmayı amaçlamaktadır (Espejo ve ark. 2023).

Ruh sağlığı hizmetlerinde YZ'nin uygulanması, 20. yüzyılın ortalarında insan düşünce süreçlerini taklit etmek üzere tasarlanmış robotlar üzerine yapılan ön çalışmalarla başlamıştır (Olawade ve ark. 2024). Bu teknolojinin ruh sağlığı alanındaki potansiyeli ilk olarak 1960'larda Joseph Weizenbaum tarafından, terapötik konuşmaları taklit eden bir sohbet robotu geliştirmesiyle gösterilmiştir (Basset 2019). Ayhan'ın (2023) yazısında bizzat YZ üretimi metinde belirtildiği gibi, ruh sağlığında YZ'nin, etik kullanım ve güvenilirlik konusundaki endişelere rağmen, daha iyi teşhis, takip, risk değerlendirmesi ve önleme sağlamak amacıyla genetik veriler, manyetik rezonans görüntüleme sonuçları, günlük deneyimler, fiziksel değişiklikleri takip eden giyilebilir cihazların verileri ve davranışsal fenotipler gibi büyük miktarda veriyi bütünleştirmesi beklenmektedir. (Ayhan 2023). Bu YZ destekli araçlar, damgalamadan uzak, erişilebilir ve ölçülebilir ruh sağlığı hizmetleri sunabilir ve hastaların geleneksel terapi ve psikiyatrik muayene seanslarının dışında da destek alabilmelerine olanak tanıyan bir çözüm sağlayabilir. Bu değişim sadece görüşmelerin etkinliğini artırmakla kalmayıp, aynı zamanda ruh sağlığı kaynaklarının ihtiyacı olanlara daha geniş çapta ulaşmasını sağlayabilir (Omarov ve ark. 2023). YZ'nin etkisi, tedavi sonrası aşamaya da uzanabilir; burada ruh sağlığı boyutlarındaki iyileşme, kötüleşme yada sabit kalma şeklindeki dalgalanmaların sürekli izlenmesi hasta davranışlarını ve sonuçlarını izlemede kritik bir rol oynayabilir. Ruh sağlığı boyutlarının (işlevsellik, uyku, iştah, psikomotor hareket vb) düzenli izlenmesi ve işlenmesi, nökslerin erken tespitine olanak sağlayabilir ve hastaların ruh sağlığı durumlarının kapsamlı bir şekilde değerlendirilmesiyle tedavi etkinliği ve sonuçlarını önemli ölçüde iyileştirebilecek zamanında müdahalelere imkan tanıyabilir (Hickey ve ark. 2021, Zlatinsti ve ark. 2022, Krysta ve ark. 2024).

### **YZ Süreçlerini Anlamak: Veri Yönetimi, Makine Öğrenmesi ve Derin Öğrenme**

YZ, makinelerin görevleri yerine getirmesini sağlayan bir dizi süreç aracılığıyla çalışır. Bu süreç, görüntüler, metinler veya sensör girişleri gibi çeşitli kaynaklardan büyük miktarda bilginin toplandığı 'veri toplama' ile başlar. Ardından, bu veriler YZ sisteminin etkili bir şekilde anlamlı örüntüler ve ilişkiler çıkarabilmesi için temizlenir ve düzenlenir (Roh ve ark. 2019). YZ daha sonra, verileri analiz etmek ve kalıpları veya ilişkileri tanımlamak için bir dizi matematiksel talimat olan algoritmaları kullanır (Basu ve ark. 2010). Örneğin, görüntü tanımadaki bir YZ modeli, binlerce etiketli görüntüyü inceleyerek kedileri köpeklerden ayırtma kabiliyeti kazanabilir. (Elgandy 2020). Genellikle eğitim olarak adlandırılan bu öğrenme aşaması, doğruluğu artırmak için algoritmanın değişkenlerinin ayarlanmasını içerir. Eğitildikten sonra, YZ sistemi, önceki verilerden oluşturduğu modeli temel alarak,

daha önce karşılaşmadığı yeni veriler hakkında tahminlerde bulunabilir veya kararlar alabilir. (Baduge ve ark. 2022).

Bu noktada, YZ'nin dalları olan Makine Öğrenmesi (MÖ) ve Derin Öğrenme (DÖ) kavramlarını açıklamak da faydalı olacaktır. MÖ, bilgisayar sistemlerinin açıkça programlanmadan, deneyim yoluyla belirli bir görevdeki performanslarını iyileştirmelerini sağlayan algoritma ve istatistiksel modellerin geliştirilmesine odaklanır. Minimal insan müdahalesiyle tahminlerde bulunabilen, kalıpları tanıyabilen veya kararlar alabilen modelleri eğitmek için büyük miktarda veri kullanmak gereklidir (Jordan ve Mitchell 2015). Otonom sürüş özelliğine sahip araçların kırmızı ışıktaki durması bu kararla alma durumuna bir örnek olarak verilebilir. MÖ'DE tahmin ile ilgili yaygın bir yaklaşım, girdi özellikleri (ev büyüklüğü, yatak odası sayısı, konum gibi) ile hedef değişken (ev fiyatı) arasındaki ilişkiyi modellemeye çalışan doğrusal regresyonu kullanmaktır. Algoritma, bir eğitim veri setindeki tahminleri ile gerçek ev fiyatları arasındaki farkı en aza indirerek öğrenir. En iyi uyum çizgisini bulmak için her özelliğe atanan ağırlıkları ayarlar. Eğitildikten sonra, yeni bir evin özelliklerini göz önüne alarak model fiyatını tahmin edebilir (Ghosalkar ve ark. 2018). MÖ alanında, hem doğrusal hem de doğrusal olmayan algoritmalar çeşitli tahmin görevlerini ele almada çok önemli roller oynar. Doğrusal regresyon, doğrusal ilişkileri olan problemler için basit bir yaklaşım sunarken, birçok gerçek dünya senaryosu daha karmaşık, doğrusal olmayan modeller gerektirir. Rastgele ormanlar ve sinir ağları, verilerdeki karmaşık ilişkileri yakalayabilen doğrusal olmayan MÖ algoritmalarıdır (Greener ve ark. 2022). Bunun dışında, sık kullanılan bir başka doğrusal olmayan teknik de destek vektör makineleridir (DVM). DVM, verileri sınıflandırma veya regresyon için daha yüksek boyutlu bir uzaya taşıyarak ayırıcı hiperdüzlemler bulabilir. Doğrusal ve doğrusal olmayan algoritmalar arasında seçim yapmak ise genellikle veri yapısına ve çözülmesi gereken probleme bağlıdır (Suthaharan ve ark. 2016). DÖ, çok katmanlı yapay sinir ağlarını kullanan bir MÖ alt dalıdır. Geleneksel MÖ algoritmaları genellikle elle belirlenen özelliklere ihtiyaç duyarken, DÖ modelleri bu temsilleri verilerden otomatik olarak çıkarabilir. Bu özellik, derin öğrenmenin görüntü, ses ve metin gibi yapılandırılmamış verilerle çalışabilmesini sağlar. Derin öğrenmenin en önemli farkı, ham girdi verilerini çok katmanlı bir yapı aracılığıyla işleyebilmesidir. Bu katmanlar, her bir adımda giderek daha soyut özellikler çıkarır. Örneğin, bir görüntü tanıma sisteminde ilk katmanlar kenarları algılamak, daha derin katmanlar nesnelere ve daha karmaşık şekilleri tanıyabilir (LeCun ve ark. 2015).

Bu hiyerarşik öğrenme, DÖ'nün daha karmaşık kalıpları ele almasını ve konuşma tanıma ve bilgisayarlı görü gibi görevlerde üstün performans elde etmesini sağlar (Mikolov ve ark. 2011, Krizhevsky ve ark. 2012). Ancak DÖ, daha basit MÖ algoritmalarına kıyasla genellikle daha büyük veri kümeleri



**Şekil 1.** Makine öğrenmesi ve derin öğrenme karşılaştırması.

RAM (Rastgele Erişimli Bellek), bir bilgisayarın geçici verileri saklamak için kullandığı hızlı erişimli bir bellek türüdür. Makine öğrenimi ve derin öğrenme gibi veri yoğunluğu yüksek işlemlerde RAM, özellikle eğitim sırasında ve veri işleme süreçlerinde kritik bir rol oynar. Merkezi işlem birimi, CPU (Central Processing Unit, Genel amaçlı hesaplama işlemleri için tasarlanmış işlemci birimi); Grafik İşlem Birimi, GPU (Graphics Processing Unit, Paralel işlem yapabilme yeteneğine sahip, özellikle matris çarpımları gibi derin öğrenme işlemleri için optimize edilmiş işlemci birimi); Tensör İşlem Birimi, TPU (Tensor Processing Unit, Google tarafından özel olarak derin öğrenme uygulamaları için geliştirilmiş, matris işlemlerinde yüksek performans sağlayan işlemci birimi) kavramlarını ifade etmektedir.

ve daha fazla hesaplama kaynağı gerektirir ve karmaşık ağ yapısı nedeniyle karar verme süreci daha az yorumlanabilir (Hestness vd. 2019, Lipton 2018). Bu zorluklara rağmen DÖ'nün karmaşık kalıpları öğrenme kapasitesi, çeşitli alanlardaki YZ uygulamalarında ilerlemelere yol açmıştır. MÖ ve DÖ ile ilgili özellikler Şekil 1'de özetlenmiştir.

## Psikiyatride Makine Öğrenmesi: Tanısal Potansiyel, Sınırlamalar ve Tanılar Arası Çerçevesel

İnsanlarda doğal duygu, davranış ve düşünce süreçleri ve bunların bozukluklarını anlamaya odaklanan psikiyatri, karmaşık örüntüleri ortaya çıkarmak için, YZ'nin, konuşma içeriği (Joshi ve ark. 2022), ölçekler, beyin görüntüleme, kan ve dijital biyobelirteçler, ses verileri (Huang ve ark. 2021), duygudurum (Barzilay ve ark. 2019), sosyal medya verileri, okülo-metrik sistem dinamikleri, dikkat değerlendirmesi için göz hareketleri ve periferik fizyolojik sinyaller (Saxena ve ark. 2021, Morar ve ark. 2020, Kalmady 2019, Giorgi 2021) gibi geniş ve çok yönlü veri setlerini analiz etme yeteneğinden faydalanabilir. Bu yöntemler toplu olarak, hem beyin hem beden aktivitelerinin hem de bunların karşılıklı etkileşimlerinin değerlendirilmesi ve anlaşılmasına katkıda bulunur. Örneğin, YZ destekli araçlar, depresyon, anksiyete ve bipolar bozukluk gibi ruhsal bozuklukların erken belirtilerini tespit etmek için konuşma kalıplarını, yüz ifadelerini ve sosyal medya aktivitesini değerlendirebilir (Smerke ve ark. 2021, Su ve ark. 2020). Genetik verilerden psikiyatrik bozukluk tanılarını öngörmek için kullanılan MÖ modellerini derleyen bir sistematik inceleme, model performanslarının hastalıklar arasında değiştiğini

ortaya koymuştur. Şizofreni (ŞZ) modelleri en geniş doğruluk aralığını (Eğri altında kalan alan (EAKA): Area under curve – AUC) gösterirken (EAKA 0.541-0.95), bipolar bozukluk tahminleri ise daha az doğru olmuş (EAKA 0.482-0.65), anoreksiya nervoza modelleri orta düzeyde doğruluk göstermiştir (EAKA 0.623-0.693). MÖ'nin Otizm Spektrum Bozukluğu (OSB) tanı öngörücülüğünün ise değişkenlik gösterdiği görülmüştür (EAKA 0.516-0.806). Kullanılan algoritmalar arasında DVM'ler, sinir ağları ve rastgele ormanların yer aldığı bildirilmiştir. Yazarlar, örneklem örtüşmesi ve popülasyon yapısı sorunları nedeniyle sonuçların yüksek yanlılık ve potansiyel doğruluk aşırı uyumu (overfit) riski taşıdığı konusunda uyarılmaktadır (Bracher-Smith ve ark. 2021).

Zhang ve ark.'nın 2020 incelemesi, dört beyin bozukluğu için derin öğrenme uygulamalarını incelemiştir: Alzheimer Hastalığı (AH), Parkinson Hastalığı (PH), Otizm Spektrum Bozukluğu (OSB) ve Şizofreni (ŞZ). Çalışma etkileyici sonuçlar bildirmiştir. Derin öğrenme modelleri, sağlıklı kontrollere kıyasla AH için %90-99.3, PH için %85-98.8, OSB için %70-91 ve ŞZ için %70-98.09 aralığında değişen doğruluk oranlarıyla hastalıkları tahmin edebilmiştir. Bu tanı algoritmaları, manyetik rezonans görüntüleme ve fonksiyonel manyetik rezonans görüntüleme dahil olmak üzere nörogörüntüleme verilerine uygulanan 3 Boyutlu-Konvolüsyonel Sinir Ağları (Convolutional Neural Networks, CNN'ler) ve yığılmış öz kodlayıcılar gibi çeşitli derin öğrenme mimarileri kullanılarak geliştirilmiştir (Zhang ve ark. 2020).

Squarcina ve ark. (2021)'a göre, DÖ yöntemleri depresyon tedavisine yanıtı tahmin etmede umut vaat etmektedir. Sekiz çalışmanın incelemesi, derin öğrenme modellerinin çeşitli veri türlerini (klinik, genetik, nörogörüntüleme ve

elektroensefalogram) analiz ettiğinde DÖ ile tedavi yanıtı öngörme gücünün geleneksel yöntemlerden daha iyi olduğunu ortaya koymuştur. Bazı çalışmalarda bulunan 0,80'in üzerinde EAKA değerleri modellerin çeşitli verileri bütünleştirme ve tedavi sonuçlarını öngören karmaşık kalıpları tanımlamadaki umut vaad edici performanslarını göstermektedir.

Makine öğrenmesi ile intihar riski belirleme üzerine de çalışmalar vardır. Ancak, yakın zamanda yapılan bir sistematik incelemeye göre, bu alandaki etkinliği şu anda anket tabanlı verilerle ortalama % 80 doğruluk civarında kalmaktadır (Some ve ark. 2024). Mevcut çalışmaların çoğu, farklı ölçüm ve tanı araçları kullanarak farklı psikiyatrik bozukluklar için benzer doğruluk seviyelerine ulaşmıştır. Araştırma grubumuzun Koç Üniversitesi lisans ve lisansüstü öğrencilerinden oluşan bir örnekleme yaptığı hakem değerlendirmesi aşamasındaki çalışması, üniversitenin psikolojik danışmanlık ve terapi merkezine başvuran kişilerin yanıtladığı rutin psikometrik ölçek ve envanterler ile, çeşitli MÖ algoritmaları kullanarak intihar/kendine zarar verme düşüncesini tespit etmede %80 doğruluk oranını aşamamıştır (Ballı ve ark. 2024, yayın aşamasında olan çalışma).

Yukarıda da bahsedildiği gibi araştırmalar halihazırda YZ teknolojilerinin ruhsal bozukluklara güvenilir bir şekilde tanı koyma ve intihar gibi karmaşık davranışları öngörme kapasitelerinin sınırlı kaldığını göstermektedir. Bu eksiklik, insan bilişinin ve davranışının doğasında var olan karmaşıklık ve eğitim veri setlerinin tasarımı ve düzenlenmesi sırasında ortaya çıkabilecek insan kaynaklı potansiyel yanlışlıklar dahil olmak üzere çeşitli etkenlerin ortak etkisine atfedilebilir. Kullanılan MÖ modellerinin bazı yönetsel kısıtlılıkları olabilir. Bunlar düşük örneklem büyüklüğü, birini dışarıda bırakma (leave-one-out) veya iç içe çapraz doğrulama (nested cross-validation) eksikliği, eğitim, test ve doğrulama veri setlerinin tasarımında sorunlar, MÖ yönteminin ve kullanılan değişkenlerin seçiminde uygunsuzluklar vb şeklindedir. (Cearns ve ark. 2019). Gelecekteki çalışmalar, daha yüksek doğruluk oranlarına ulaşmak için yöntemlerini bu doğrultuda iyileştirmelidir.

Öte yandan, psikiyatrik tanımlar şu anda Uluslararası Hastalık Sınıflandırması-11 (ICD-11) veya Mental Bozuklukların Tanısal ve Sayımsal El Kitabı-5 (DSM-5) gibi sistemlerde belirtildiği gibi belirti kümeleri, işlevsellik ve süre açısından belirlenen tanı ölçütlerine göre sınıflandırılmaktadır (World Health Organization 2018, American Psychiatric Association 2013, Di Vincenzo 2023). Ancak bu tanımlar aslında insanlar tarafından geliştirilen yapılar ve psikiyatrik bozukluklar çok yüksek oranda birlikte görülür (Yapıcı Eser ve ark. 2018). Bu birlikte görülme durumu, MÖ yöntemleri için zorluklar oluşturur ve saf tanı grupları oluşturmayı ve bunlar arasında ayırım yapmayı zorlaştırır. Ayrıca, psikiyatrik bozukluklar arasında birçok ortak çevresel, genetik, hücresel ve nöroanatomik yol vardır (Scangos ve ark. 2023). Dahası, bireye yaşamı

boyunca birden fazla psikiyatrik tanı konulabilir, bu da MÖ yaklaşımlarına sınırlamalar getirebilir. Psikiyatride tanımlar arası (transdiagnostic) yaklaşım her tanıyı ayrı ayrı ele almak yerine, farklı ruhsal bozuklukların altında yatan ortak süreçlere odaklanır. Bu yaklaşım, ortak mekanizmaları tanımlar, belirtileri bir süreklilik olarak görür ve temel psikolojik süreçleri hedefleyen esnek müdahalelere olanak tanımlar (Fusar-Poli ve ark. 2019). Ulusal Ruh Sağlığı Enstitüsü (NIMH) tarafından tanımlanan Araştırma Alan Ölçütleri (RDoC) bu tanımlar arası yaklaşıma odaklıdır. RDoC, gözlemlenebilir davranış ve nörobiyolojik ölçümlerin boyutlarına dayalı olarak ruhsal bozuklukları araştırmak için yeni bir çerçeve oluşturmayı amaçlamaktadır. (Cuthbert, 2014). YZ'nin, görüntüleme, biyokimya, öz bildirim ve klinisyen gözlemi ile sağlanan davranışsal ölçümler gibi farklı veri türlerini bir arada kullanılabilmesi ve bu veriler arasındaki doğrusal olmayan ilişkileri yakalayabilmesi, tanımlar arası yaklaşımı mümkün ve uygulanabilir hale getirebilir ve böylece psikiyatrik bozuklukların daha doğru sınıflandırmasını sağlayabilir.

Bzdok ve ark.'nın 2018'deki derleme çalışmasına göre, MÖ özellikle tedavi optimizasyonu ve psikopatolojiye boyutsal yaklaşımlar konusunda, geleneksel sınıflandırma sistemlerinden ziyade, kişiselleştirilmiş tıp ve yüksek doğruluklu (precision) psikiyatridi ilerletmede önemli bir potansiyele sahiptir. Yazarlar, geleneksel deneme-yanılma yöntemlerinin ötesine geçerek, bireyselleştirilmiş ilaç düzenlenmesi için öngörücü modellerin kullanılabilmesini belirtmişlerdir. . Temsil öğrenme algoritmaları ham verilerden otomatik olarak anlamlı ve faydalı temsiller (özellikler) öğrenmeyi sağlayan MÖ yöntemleridir. Çok modlu veri analizi ise birden fazla veri türünün örneğin, metin, görüntü, ses, genetik veya nörogörüntülemenin aynı anda işlenmesini ifade eder. Temsil öğrenme tabanlı MÖ algoritmaları çok modlu verilerle birlikte çalışarak RDoC çerçevesine uyum sağlar. Örneğin, bir bireyin genetik verilerini, beyin görüntülerini ve davranışsal ölçümlerini bir arada değerlendirerek, psikopatolojinin gizli boyutlarını keşfedebilir. Bu yaklaşım, geleneksel tanı sınırlarının ötesine geçerek, biyolojik temelli ve klinik olarak öngörülebilir hastalık süreçlerini anlamamıza yardımcı olabilir. Aynı zamanda, mevcut tanı kategorilerindeki heterojenliği ve bozukluklar arasındaki ortak özellikleri dikkate alarak, biyolojik olarak daha doğru ve bütüncül bir psikiyatrik sınıflandırma sistemine (nozoloji) ulaşmayı mümkün kılabilir.

### **Psikiyatri Hizmetlerini İyileştirmek için Doğal Dil İşleme ve Büyük Dil Modellerinden Yararlanma**

Doğal Dil İşleme (DDİ), insan dilini işleyen ve analiz eden bir YZ dalıdır. Tıp alanında, teşhis koyma, klinik araştırmaları destekleme, ilaç etkileşimlerini tespit etme ve hasta verilerini anlamlandırma gibi birçok kritik uygulama için

kullanılmaktadır (Luo ve ark. 2017, Savova ve ark. 2019, Juhn ve Liu 2020, Bhatnagar ve ark. 2022) DDİ, konuşma ve metinlerden semantik ve duygusal içerik dahil olmak üzere zengin bilgiler çıkarabilir, psikiyatride kullanılan standart ölçeklerin kısıtlılıklarını aşır, bireylerin dil kullanımındaki örüntüleri analiz ederek daha derinlemesine ve kişiselleştirilmiş bir değerlendirme yapabilir (Kjell ve ark. 2023) ve bu sayede tıbbi karar destek sistemlerinin geliştirilmesine önemli katkılar sağlayabilir (Yang ve ark. 2022).

İleri DDİ tabanlı YZ sistemleri olan ve insana benzer şekilde bir dili anlama, üretme ve etkileşimde bulunmak üzere tasarlanmış büyük dil modelleri (BDM), OpenAI'nin ChatGPT'yi piyasaya sürdüğü Kasım 2022'de geniş kitlelerin hayatına girmiştir. Başta dönüştürücü mimariler olmak üzere derin öğrenme teknikleri ile geliştirilen BDM'ler, büyük ve çeşitli metinsel veri setleri üzerinde eğitilebilir, bu da onların karmaşık dilbilimsel kalıpları ve bağlamsal ilişkileri kavramasına olanak tanır. Dönüştürücü mimari, kendi kendine dikkat mekanizmasını (self-attention) kullanarak uzun metinlerdeki bağlamları ve karmaşık ilişkileri etkili bir şekilde modelleyen ve paralel işlemeye olanak tanıyan özellikleri ile BDM'lerin başarısının temelini oluşturan bir derin öğrenme mimarisidir. (Vaswani ve ark. 2017). BDM'leri geliştirme süreci, modelin büyük miktarda metin verisi ile eğitilerek bir dizideki bir sonraki kelimeyi tahmin edebilmesini sağlamayı, bu sayede modelin dilbilgisi, genel geçer bilgiler ve çeşitli yazım stillerini öğrenmesini içermektedir. Bu eğitim, BDM'lerin metin tamamlama, çeviri, özetleme ve konuşma etkileşimleri gibi çok çeşitli görevleri gerçekleştirmesine olanak tanır (Radford ve ark. 2019). Çok modlu BDM'ler, metin, görüntü ve ses gibi birden fazla veri türünü tek bir çerçeve içinde bütünleştirip işleyerek geleneksel BDM'lerin yeteneklerini genişletir (Wu ve ark. 2023). Bu gelişme, bu modellerin farklı modaliteleri birleştiren içeriği anlamasını ve üretmesini sağlar, görsel bilgileri içeren görüntü altyazısı oluşturma, video analizi ve interaktif konuşmalar gibi görevleri gerçekleştirme yeteneklerini artırır. Örneğin, çok modlu bir BDM, bir fotoğrafı analiz edebilir, açıklayıcı bir paragraf oluşturabilir veya görüntü hakkındaki sorulara yanıt verebilir, böylece daha kapsamlı ve sezgisel bir kullanıcı deneyimi sağlar.

Büyük Dil Modelleri (BDM'ler) psikiyatride kullanılabilir ve dil yoluyla ifade edilen karmaşık insan duygu, düşünce ve davranışlarını analiz etmek için gelişmiş araçlar sunarak alanın betimleyici doğasını zenginleştirebilir. BDM'ler, klinisyenlere, hastaların konuşmalarında veya yazılarında depresyon, anksiyete ya da şizofreni gibi ruhsal bozukluklarla ilgili ipuçlarını fark etmelerinde yardımcı olabilir. Bu modeller, metinlerde sık tekrarlanan ifadeler, duygusal tonlar ya da belirli temalar gibi dikkat çekici dil kalıplarını analiz ederek bireyin ruh sağlığı hakkında bilgi sağlayabilir. (Kjell ve ark. 2023). Örneğin, bir BDM, terapi oturumu transkriptlerini analiz ederek geleneksel değerlendirmeler sırasında gözden

kaçabilecek dilsel işaretleri ve tematik içeriği saptayabilir (Volkmer ve ark. 2024). Çok modlu BDM'ler ayrıca duygu-durum değerlendirmesinin kritik olduğu psikiyatri hastalarının görüntü verilerine dayalı analizler de yapabilir (AlSaad ve ark. 2024). Ek olarak, bu modeller kapsamlı psikiyatri alanının sentezleyerek araştırmacıların ve uygulayıcıların en son gelişmelerden haberdar olmalarına yardımcı olabilir.

Dil modellerinin bir diğer avantajı, eğitim yöntemleri ve tasarım özelliklerinden dolayı, kullanıcı komutlarındaki yazım veya dilbilgisi hatalarına rağmen doğru yanıtlar üretebilmeleleridir. Hatalı ve formel olmayan dil kullanımı örnekleri de dahil olmak üzere geniş ve çeşitli metin korpusları üzerinde gerçekleşen bu YZ eğitimi, modellerin katı dilbilgisi kurallarının ötesine geçen incelikli ve bağlama duyarlı bir dil anlayışı geliştirmelerini sağlar (Gao ve ark. 2020). Bu modeller, yüzeysel özellikler yerine anlam bütünlüğünü önceliklendirir ve dikkat mekanizmaları kullanarak farklı girdi unsurlarının önemini değerlendirir, böylece hatalar bulunsu bile genellikle amaçlanan anlamları doğru bir şekilde çıkarabilir. (Zhao ve ark. 2023). Ayrıca, bazı modeller hata toleransını artırmak için özellikle 'gürültülü' girdilerle eğitilir (Karpukhin ve ark. 2019). Bu çok yönlü yaklaşım, psikiyatride başvuran ve sorunlarını ifade etmekte bazı zorluklar yaşayan kişilerin bildirimlerini anlamada da yararlı olabilir. Ancak bu durum, özellikle dil öğrenme sürecinde olan kişiler için bazı olumsuz sonuçlar doğurabilir; hatalarına rağmen doğru cevaplar almaları kişilerin öğrenme sürecini zorlaştırabilir ve dil modellerinin gösterdiği anlayış günlük hayatta bulunabilecek türden olmadığı için günlük dilin bozulmasına neden olabilir (Adeshola ve ark. 2023). Bu modellerin girdi aynı olmasına rağmen her seferinde farklı yanıtlar üretebilmesi ve bu yanıtların bazı durumlarda birbiriyle çelişkili olabilmesi ise kısıtlılıklarıdır (de Leon 2023).

### **Psikiyatride Yapay Zekânın Kısıtlılıkları: Yanlılık, Doğruluk ve Etik Zorluklar**

Etkileyici yeteneklerine rağmen, BDM'lerin bir takım kısıtlılıkları vardır. Birincisi, bir BDM oluşturmak, büyük veriye ulaşım ve bu veriyi analiz edebilecek kaynakları kullanabilecek olanaklar gerektirir (Hoffman ve ark. 2022). İkincisi, eğitim verilerinde çeşitli yanlılıklar mevcut olabilir ve BDM eğitimi esnasında bu yanlılıklar 'miras alınıp' büyütülebilir, bu da potansiyel olarak eşitliğe aykırı çıktılara yol açabilir (Acerbi ve ark. 2023). Ayrıca, BDM'lerin sabit bir bilgi kesme tarihi vardır, bu nedenle eğitim dönemlerinden sonra meydana gelen bilgi veya olaylara erişimleri yoktur, bu da güncel olmayan veya yanlış yanıtlara neden olabilir (Wang ve ark. 2023). İnsanlar, dünyayı anlamak ve yönlendirmek için fiziksel çevreden elde edilen duygusal bilgilere güvenirlir. Buna ek olarak, zihin-beden etkileşimlerini bütünleştirerek bilişsel süreçleri

geliştiren ‘bedenlenmiş biliş’ kullanıcılar, bu da çevrelerini daha kapsamlı bir şekilde anlamalarına yol açar (Dove 2023). BDM modellerinin de daha iyi hedef odaklı karar verebilmesi için bedenlenmiş ajanlar olması üzerinde çalışılmaktadır. Ancak, bugünkü ilerleme düzeyinde, Özer (2024) tarafından detaylıca tartışıldığı gibi, BDM’ler için kritik bir sorun halüsinasyon olarak da adlandırılan BDM’lerin tutarlı ve makul görünen ancak gerçekte yanlış, yanıltıcı veya tamamen uydurulmuş olan çıktılarıdır (Banerjee ve ark. 2024, Maynez ve ark. 2020). Bunun nedeni, BDM’lerin gerçek dünya hakkında insan zihninin çalıştığı anlamda bir anlayış veya akıl yürütme yeteneğine sahip olmak yerine, eğitim verilerindeki kalıplara dayalı olarak olası kelime dizilerini tahmin etmeye eğitilmiş olmalarıdır. Bu da bazı bağlamlarda yaratıcı sonuçlar verse de, gerçeğe örtüşme anlamında ‘doğruluk’ gerektiren uygulamalarda önemli zorluklar oluşturabilir (Woodland 2023). Aslında, bu uydurulmuş çıktı terim olarak halüsinasyonun (varsanı) klinik kullanımı ile uyumsuzdur, çünkü varsanılar işitme, görme, dokunma ve koku duyularıyla ilgili algı bozukluklarıdır (Sterzer ve ark. 2018, Russo ve ark. 2019). Varsanı terimi birçok insanın aklında var olmayan bir şeyi uydurma (yaratma) sürecini çağırırsa da, konfabulasyon bu bağlamda daha uygun bir terim olabilir. Çünkü konfabulasyon, uydurulmuş, çarpıtılmış veya yanlış yorumlanmış anıların bilinçsiz üretimi ile karakterize edilen bir tür bellek hatasıdır. Özer’in (2024) de savunduğu gibi, son zamanlarda yapılan bir dizi bilimsel makale varsanı yerine konfabulasyon terimini tercih etmektedir (Smith ve ark. 2023). Varsanıların aksine, konfabulasyonlar algılanan deneyimler değil, bilgilerin, geçmiş yaşantılar, beklentiler ve bağlamın etkisiyle hatalı olarak yeniden yapılandırılmasıdır. Soruları yanıtlarken, BDM’ler çok büyük veri setlerinden öğrenilen kalıplara dayalı yanıtlar üretir. Hem insanlarda hem de BDM’lerde konfabulasyon fenomeni, dış gerçekliğe tam olarak dayanmayan çıktılar üreten iç süreçleri içerir, bu da beynin öngörücü işlemi ile BDM’lerdeki istatistiksel tahmin mekanizmaları arasında bir paralellik olduğunu vurgular (Wang ve ark. 2023).

Yapay Zekâ modellerinde ‘yanlılık’ başka kritik bir konudur; örneğin eğitim verilerinde belirli demografik gruplar yetersiz temsil edilmişse, YZ’nin ürettiği sonuçlar uygulanacağı topluluk nezdinde adil olmayabilir ve sağlık eşitsizliklerini artırabilir (Rajkomar ve ark. 2018). Ayrıca ruh sağlığı patolojilerinin karmaşıklığı ve öznelliği, doğru değerlendirmeler için çok önemli olan nüanslı insan duygularını, kültürel bağlamları ve bireysel deneyimleri yorumlamakta zorlanan YZ sistemleri için bir zorluk oluşturur. Veri setlerindeki ülkeler ve kültürler arasındaki dile dayalı farklılıklar bağlamında fenomenlerin kültürel temsilleri yeterince yer almalıdır. Ayrıca, bazı YZ algoritmalarında şeffaflık ve açıklanabilirliğin eksik olması, klinisyenlerin YZ tarafından üretilen önerilerin arkasındaki mantığı anlamalarını zorlaştırabilir, bilgiye dayalı kararlar

alma yeteneklerini engelleyebilir ve teknolojiye olan güveni zayıflatır (Antoniadi ve ark. 2021).

Psikiyatri uzmanlarının işlerinin YZ’ya tevdi edilmesi etik kaygılar ortaya çıkarmaktadır; YZ, hasta-hekim ilişkisindeki temel unsurlardan empati ve terapötik ittifakı beklenen şekilde sağlayamayabilir (Morrow ve ark. 2023). Ayrıca eğitimden sağlık hizmetlerine kadar çeşitli alanlarda giderek daha fazla YZ’ye güvenildikçe, YZ ile ilişkili olabilecek herhangi bir yanlış bilginin yaygın kullanılma riski ciddi bir tehdit haline gelecektir. Kullanıcıları bu modellerin doğruluğu konusunda gerçek zamanlı olarak uyarıcı sistemler geliştirmek, örneğin kullanıcı etkileşimlerinin model yanıtlarını iyileştirmeye yardımcı olduğu geri bildirim döngülerinin kullanıma entegre edilmesi, konfabulasyonlarla ilişkili riskleri azaltabilir (Nahar ve ark. 2024). Ayrıca, hassas alanlarda BDM’leri kullanırken, bu modellerin içeriğinin nasıl oluşturulduğuna dair şeffaflık, kullanıcıların kendilerine sunulan bilgileri eleştirel olarak değerlendirmelerini sağlayacaktır (Reddy ve ark. 2024).

BDM’lerin psikiyatrik uygulamadaki eksikliklerini gidermek çok yönlü bir yaklaşım gerektirir. Örneğin, ince ayar, önceden eğitilmiş bir dil modelinin bilgisini ve performansını belirli bir alana veya göreve uyarlamak için daha küçük, özelleştirilmiş bir veri seti üzerinde daha fazla eğitildiği bir süreçtir. Bu teknik, modelin alana özgü kelime dağarcığını, bağlamları ve nüansları öğrenmesine olanak tanır ve potansiyel olarak daha doğru ve güvenilir çıktılara yol açar (Gu ve ark. 2021). Modelleri yüksek kaliteli, alana özgü psikiyatrik veriler üzerinde ince ayarlamak, doğruluğu önemli ölçüde artırabilir ve konfabulasyonları azaltabilir. Bir diğer yaklaşım, Geri Alım Destekli Üretim (RAG), BDM çıktılarını doğrulanmış psikiyatrik bilgilerle temellendirerek, olgusal doğruluğu artırır. Bu yöntem, BDM’lerin üretken yeteneklerini düzenlenmiş bir bilgi tabanından bilgi geri alımı ile birleştirir (Lewis ve ark. 2020). Yanıtlar üretirken model, önce güvenilir bir psikiyatrik veritabanından ilgili bilgileri alır, ardından bu bilgileri çıktısını doğrulamak ve sınırlandırmak için kullanır. Bu yaklaşım, sadece olgusal doğruluğu artırmakla kalmaz, aynı zamanda bilgi kaynaklarının izlenebilir ve alıntılanabilir olması nedeniyle şeffaflığı da artırır. Ayrıca, Bai ve ark. tarafından 2022’de önerilen İnsan Geri Bildiriminden Pekiştirmeli Öğrenme (İGBPÖ), YZ modellerini ruh sağlığında en iyi klinik uygulamalarla uyumlu hale getirmek için kullanılabilir bir yöntemdir. Ruh sağlığı profesyonelleri modelin yanıtlarını değerlendirir, doğruluk, empati ve etik açısından puanlar. Model daha sonra bu uzman derecelendirmelerini ödül olarak kullanarak ince ayar yapar. Bu insan geri bildirimini içeren döngüsel yaklaşım, YZ çıktılarının güvenilirliğini artırır, yanıtların klinik olarak uygun ve etik ilkelerle uyumlu olmasını sağlar. İGBPÖ, uzman bilgisini dahil etmek suretiyle ruh sağlığı uygulamaları için daha güvenilir YZ asistanları oluşturur. Bu güvenli ve kontrollü yapı sayesinde, YZ’nin örüntü tanıma konusundaki olağanüstü yeteneklerinden yararlanılarak klinik standartlar iyileştirilebilir.

Sürekli öğrenme yöntemi, yeni bilgilerin kademeli olarak modele dahil edilmesini sağlayarak bilgi kesme tarihi sorununun aşılmasına ve YZ modellerinin son psikiyatrik bulgular, tedavi yaklaşımları ve etik yönergelerle güncel kalmasına olanak tanır (Parisi ve ark. 2019).

## **YZ Destekli Psikiyatri Hizmetlerinde Gizlilik ve Etik Bütünlüğü Sağlama**

Büyük dil modellerinin (BDM'lerin) eğitimi ve kullanımı sırasında hasta mahremiyetinin sağlanması önemli bir zorluk teşkil etmekte ve devam eden bir tartışma konusudur. BDM'lerin performansı genellikle akıl yürütme, kıyaslama, veri setlerindeki doğruluk, ve kodlama veya dili anlama gibi belirli görevlerdeki etkinliklere dair metrikler kullanılarak ölçülür. Özel şirketlerin sahip olduğu bazı gelişmiş BDM'lerin çalışabilmesi için verilerin geçici bir süreyle de olsa şirket sunucularında toplanması gereklidir; bu da yetkisiz kişi veya kurumların verilere erişimi riski nedeniyle hasta mahremiyetinin ihlaline ve şirketlerin veri korumaya yönelik düzenlemelere uyumu konusunda sorunlara neden olabilir (Nazi ve ark. 2024). Ameika Birleşik Devletleri'nde kullanılması hedeflenen uygulamaların Sağlık Sigortası Taşınabilirliği ve Hesap Verebilirliği Yasası (HIPAA) tarafından belirtilen düzenlemelere uyması gerekmektedir (U.S. Department of Health & Human Services 2023). Günümüzde aktif olarak kullanılan YZ dil modeli sunucusu şirketlerin önerilerine göre veri koruma ve güvenlik standartlarına uyumu sağlamak için YZ şirketi ile bir İş Ortağı Anlaşması yapılması gerekmektedir (OpenAI 2023). Ayrıca, etik alanında çalışan uzmanların önerilerine göre ürün tasarımının UNESCO'nun nöroteknoloji konusundaki etik kılavuzlarını ve Türkiye için Kişisel Verileri Koruma Kurumu'nun YZ ile ilgili tavsiyelerini dikkate alması gerekmektedir (International Bioethics Committee 2022, Kişisel Verileri Koruma Kurumu 2023). Bu yaklaşım, kişisel veri gizliliğinin hem ulusal hem de uluslararası düzenlemelerle uyumlu olmasını sağlayabilir. Temel hak ve özgürlükleri korumak için risk önlemeye ve azaltmaya odaklanan ihtiyatlı bir duruş benimsenmelidir. Veri toplama ve işleme süreçlerinin tüm aşamalarında, ayrımcılığı önlemek ve bireyler için olumsuz sonuçlar doğurabilecek etkileri engellemek amacıyla gerekli önlemler alınmalı ve temel hakların korunmasına sürekli olarak öncelik verilmelidir. Kullanılan veriler kalitesine, kaynağına ve kategorisine göre değerlendirilmeli ve yalnızca gerekli minimum veri toplanmalıdır. Psikiyatride, gerekli minimum verinin ne olması gerektiği her zaman net değildir ve bu konuda sınırlı rehberlik vardır. Hangi bilgilerin gerekli olduğunun belirlenmesi, devam eden önemli bir araştırma alanıdır.

Bazı açık erişimli BDM'ler, verilerin kendi sunucularına gönderilme gerekliliği olmadan yerel sunucularda çalıştırılması imkanı sunarak, kuruluşlara YZ sistemlerini bağımsız bir şekilde entegre etme ve yönetme olanağı sağlamaktadır. (Jiyang ve ark. 2023, Touvron ve ark. 2023). Bu yaklaşım,

veri gizliliği ve güvenliği üzerinde daha fazla kontrol sağlar, sıkı sağlık hizmeti gerekliliklerine uyar ve şeffaflık ve özelleştirmeye olanak tanır. Sağlık hizmeti sağlayıcıları kodu denetleyebilir, ek güvenlik önlemleri uygulayabilir ve modellere, psikiyatrik bakımdaki belirli ihtiyaçları karşılayacak şekilde ince ayar yapabilir, böylece yanlılığı azaltabilir, doğruluğu artırabilir ve ruh sağlığı bakımında gerekli olan yüksek etik standartları koruyabilir. Konuşmadan metne yerleştirilmiş ortamlarda çalışan modeller, veri ve hasta gizliliğinin bir diğer önemli bileşenidir. Bu uygulamalar, konuşulan dili gerçek zamanlı olarak işleyip analiz ederek transkripsiyon veya belirli ruh sağlığı koşullarıyla ilişkili konuşma kalıplarının tespiti gibi görevleri kolaylaştırabilir. Collobert ve arkadaşları tarafından önerilen sistemlerle örneklenen bu yaklaşım, sağlık hizmeti gizliliğindeki katı düzenlemelere uygundur ve gizli bilgilerin sağlayıcının kontrollü ortamında kalmasını sağlayabilir (Collobert ve ark. 2016). Bu uygulamalar, klinisyenlerin hasta gizliliğinden ödün vermeden terapi seansları sırasında değerli içgörüler elde etmelerine olanak tanıyarak psikiyatrik bakımın etkinliğini artırabilir.

Psikiyatride YZ uygulamalarının yaygınlaşmasının önündeki bir diğer zorluk kabul edilebilirliğinin düşük olmasıdır. (McCradden 2023). Hastalar ve ruh sağlığı profesyonelleri, terapötik ilişkiyi zayıflatabileceği veya psikiyatrik bakımda gerekli olan empatiyi eksik bırakabileceği endişesiyle ruh sağlığı değerlendirmeleri ve müdahaleleri için YZ'ye güvenme konusunda endişe duyabilirler. Bu engelin üstesinden gelmek için, YZ'yi insanların yerine geçen değil, onlara yardımcı bir araç olarak sunmak önemlidir. YZ araçlarının klinisyenler nezdindeki kabulü, onlara hastaları hakkında değerli içgörüler sağlama, tanı doğruluğunu artırma ve hasta etkileşimi için onlara daha fazla zaman tanıma gibi destekler vurgulanarak sağlanabilir. Bu yaklaşım, sonuçları ve verimliliği artırmak için YZ'den yararlanırken insan bağlantısının ruh sağlığı bakımının ön planında kalmasını sağlar.

Yukarıda sıralanan kısıtlılıklar yanısıra YZ'nin dahil edildiği psikiyatri uygulamaları ile olan kanıta dayalı verilerin hala yetersiz olduğunu vurgulamak gereklidir. Aşağıdaki bölümlerde çözüm önerileri sıralanmıştır.

## **Türkiye'de YZ Hizmetlerini İyileştirmek için Türkçe BDM'ler ve Psikiyatrik Korpuse Duyulan İhtiyaç**

Türkiye'de psikiyatride YZ kullanımı henüz başlangıç aşamasındadır. Diğer branşlarda olduğu gibi genetik, biyokimya, görüntüleme gibi büyük veri setlerinin kullanımı dışında konuşma analizi yöntemiyle de psikiyatrik bozuklukların tespit edilmesi üzerine çalışmalar yapılmaya başlanmıştır. Örneğin Bilkent Üniversitesi'nde bir araştırma grubu konuşma içeriği, ses tonu, yüz ifadesi ve duruş verilerini kullanarak depresyon tespiti yapan YZ tabanlı bir yazılım üzerine



çalışmalarını sürdürmekte olup çalışmanın ilk verileri yayınlanmıştır (Kaynak ve Dibeklioglu, 2024). Ayrıca, Çabuk ve arkadaşlarının (2024) şizofreni hastalarında DDİ üzerine gerçekleştirdiği çalışma ile Arslan ve arkadaşlarının (2024) bipolar bozukluk ve psikoz tanısı alan hastalarda yürüttüğü çalışma bu alanda önemli katkılar sunmaktadır. Ancak, her iki çalışma da düşük örneklem büyüklüğüne sahiptir ve yöntemleri farklı örneklemeler üzerinde henüz tekrarlanmamıştır. . Çeşitli üniversiteler ve sağlık kurumları bünyesinde araştırmalar yapılsa da, henüz bu çalışmaların klinik pratiğe entegrasyonu ve yaygın kullanımı sınırlıdır. Özellikle dijital sağlık alanında kamu ve özel sektör iş birliklerinin kurulması, klinik verilerin toplanması ve analizine yönelik teknolojik altyapının kurulması gibi adımların atılmaya başlanması gereklidir. Türkiye’de özellikle klinik kullanıma yansiyabilecek uygulamalar geliştirme noktasında Sağlık Bakanlığı ve Türkiye Psikiyatri Derneği ile üniversiteler ve diğer özel kuruluşların işbirliği önem arz etmektedir.

Türkiye’ye özgü Büyük Dil Modellerinin (BDM’ler) ve psikiyatrik derlemelerin geliştirilmesi, Türkiye’de YZ hizmetlerinin ilerlemesi için çok önemlidir. Küresel BDM’ler önemli ilerlemeler kaydetmiş olsa da, genellikle yerel bağlamlarda optimal performans için gerekli olan diğer dillerin ve kültürlerin nüanslı anlayışından yoksundurlar (Tenzer ve ark. 2024). Özellikle, tek bir dilde eğitilmiş büyük bir dil modelinin, mevcut çok dilli bir modelin ince ayarlanmasıyla oluşturulan bir modele göre o dilin deyimlerini, nüanslarını, atasözlerini ve diğer kültürel ve yerel bağlamlarını daha iyi anlaması muhtemeldir (Pires ve ark. 2023). Bunu destekler nitelikte, Türkçe’nin de dahil olduğu birkaç dil ChatGPT ile farklı görevler için kullanıldığında, İngilizce tüm görevlerde tutarlı bir şekilde diğer dillerdeki görevlerden daha iyi performans göstermiştir (Lai ve ark. 2023). Bu, kültürel duyarlılığın ve dilin anlamsal doğruluğunun çok önemli olduğu psikiyatri alanındaki uygulamalarda özellikle önemlidir (Ratana ve ark. 2019).

Ancak, Türkçe gibi eklemeli yapıdaki diller için BDM’ler geliştirmenin kendine has zorlukları mevcuttur. Eklemeli yapıdaki diller, bir köke ekler getirerek kelimeler oluşturur ve bu da karmaşık, bilgisel yoğunluğu fazla kelimeler yaratır (Chimalamarri ve ark. 2021). Bu morfolojik zenginlik, BDM’lerde kullanılan geleneksel belirteçleme yöntemleri için zorluklar oluşturur (Petrov ve ark. 2024). Belirteçleme (tokenizasyon), metni kelimeler, kökler veya ekler gibi daha küçük birimlere ayırarak dil modellerinin bu birimleri işlemesini ve anlamlandırmasını sağlayan bir ön işleme yöntemidir. Olası kelime formlarının yüksek sayısı, kelime dağarcığı boyutunu üstel olarak artırır, bu da modellerin etkili bir şekilde öğrenmesini ve genellemesini zorlaştırır (Li ve ark. 2020). Ayrıca, bu dillerdeki eklerin bağlama duyarlı doğası, modellerin uzak ilişkili ifadeleri ve morfemler arasındaki nüanslı etkileşimi anlamasını gerektirir. Bu zorlukları aşmak ve Türkçe’nin dilsel inceliklerini BDM’lerde etkili bir şekilde yakalamak için veri

ön işleme, model mimarisi ve eğitim stratejilerinde özelleştirilmiş yaklaşımlara ihtiyaç vardır.

Günümüzde Türkçe’yi anlayan ve sorulara cevap veren açık kaynak dil modellerinin sayısı her geçen gün artmaktadır. Bu modeller, genellikle çok dilli özgün sürümlerin Türkçe derlem ile ince ayar yapılmasıyla geliştirilmiştir. Bu yöntemle bir alternatif, yalnızca Türkçe derlem kullanarak sıfırdan yeni bir dil modeli oluşturmaktır.

## Psikiyatri Hizmetlerinde Yapay Zekâ için Olası Gelecek Yönelimler

Yapay zekâ, sanal terapist ve psikiyatristlerin ötesinde, ruh sağlığı profesyonellerine tanı, tedavi ve takip aşamalarında yardımcı olabilir, ruh sağlığı hizmetlerinin kalitesini ve erişilebilirliğini artırabilir ve bireyin ihtiyaçlarına odaklanabilir, ayrıca psikoeğitim sürecinin bir parçası olarak da kullanılabilir. Her bireyin 7/24 kişisel sanal psikoterapistinin olması ve gerçek terapistlerin sadece sanal terapistlere süpervizyon hizmeti vermesi ya da kişinin günlük konuşmaları ve yazışmalarından yola çıkarak psikiyatrik muayene ihtiyacının değerlendirilmesi ve hatta belirli bir psikiyatriste yönlendirilmesi gibi sistemler günümüzden çok da uzakta olmayabilir. Gelişmiş YZ sistemleri bireyin konuşmalarını ve tüm yazışmalarını analiz edebilir, anlık geri bildirim sağlayabilir, duygusal ve zihinsel ihtiyaçlarına göre özelleştirilmiş etkili terapi seansları sunmasına yardımcı olabilir (Olawade ve ark. 2024). Giyilebilir teknolojiler ve mobil uygulamalar aracılığıyla sürekli veri toplayan akıllı sistemler, fiziksel sağlık verilerini de analiz ederek ruh ve beden sağlığı arasındaki bağlantıları daha iyi anlamaya ve bütünlük tedavi planları oluşturmaya yardımcı olabilir. Sanal gerçeklik ve artırılmış gerçeklik teknolojileri ile bir araya gelen YZ, farkındalık uygulamaları, travma terapisi ve fobilerin tedavisi gibi alanlarda yenilikçi ve etkili terapi yöntemleri sunabilir.

Günümüz koşullarında YZ uygulamalarının doğrudan profesyonel olmayan bireylerin kullanımına açılması risk oluşturacak, aynı zamanda kişilerin özerkliğine de engel oluşturabilecektir. YZ’nin klinik alanda daha güvenilir ve etkin bir biçimde kullanılabilmesi için, bu uygulamaların alanda tecrübe sahibi profesyonellere yardımcı olacak şekilde tasarlanması ve klinik süreçler içinde deneyimli sağlık uzmanlarının yönlendirmesi ile hastalara sunulması ilk planda uygun olabilir. YZ tabanlı test ve uygulamaların hata payı içermesi olasılığı göz önünde bulundurularak, karar verici mekanizmanın nihai olarak klinisyene ait olması gerektiği düşünülmelidir. Ayrıca, sosyal medya gibi geniş kitlelere ulaşan platformlar, yanlış ya da eksik bilgilere dayalı paylaşımlar içerme potansiyeline sahiptir. Bu nedenle, YZ’nin geliştirilmesi ve güvenilirliği için, öncelikli olarak kanıt dayalı klinik veriler ve geçerliliği yüksek ölçüm araçları kullanılarak daha kontrollü bir ilerleme sağlanmalıdır. Şu an için YZ algoritmalarının sunduğu

verilerin doğrudan “gerçek” olarak değil, klinik anlamda “gösterge” niteliğinde olduğu (örneğin, troponin yüksekliği bir kalp krizi göstergesidir ancak tek başına kalp krizinin kendisi değildir) ve güçlü istatistiksel tahminlerden oluştuğu konusunda farkındalık oluşturulmalıdır. Bu nedenle, YZ'nin klinik süreçlerde kullanıldığı her durumda klinik tecrübe ile de desteklenmesi günümüzde hala önemli olacaktır.

## Sonuç

Ruh sağlığı hizmetleriyle bütünleştirilmiş yapay zekâ uygulamaları psikiyatrinin küresel ekonomik yükü ve iş gücü kaybına çözüm sunmak için önemli bir potansiyel sunmaktadır. Makine öğrenmesi ve doğal dil işleme gibi YZ teknikleri tanı, tedavi ve hasta takibini daha nitelikli hale getirebilir. Bununla birlikte, tanı doğruluğu, etik kaygılar, veri gizliliği sorunları ve terapötik işbirliğinin sürdürülmesi gibi zorluklar bulunmaktadır. Türkiye gibi ülkeler için, dilsel ve kültürel nüansları yansıtan YZ modelleri geliştirmek çok önemlidir. Bu engellerin aşılması için şeffaflık, etik stratejiler ve ruh sağlığı uzmanlarıyla işbirliği yapılması gerekmektedir. YZ'nin profesyonellerin yerini almaktansa onları destekleyici bir araç olma potansiyeli, ruh sağlığı hizmetlerinin erişilebilirliğini ve sonuçlarını iyileştirebilir.

Türkçe BDM'ler hâlen geliştirilme aşamasındadır ve Türkiye'deki psikiyatristler tarafından kullanılacak bir YZ aracı psikiyatri için çok faydalı olacaktır. Psikiyatride kullanılacak YZ araçlarının geliştirilmesi aşamasında hasta temsilcileri, psikiyatristler, dilbilimciler, YZ geliştiricileri ve araştırmacıları, etik ve hukuk uzmanları arasında işbirliğine ihtiyaç vardır. Bu disiplinler arası işbirliği, YZ sistemlerinin kültürel ve dilsel olarak uygun olmasını sağlayabilir ve nihayetinde toplumumuzdaki psikiyatrik bakımı daha iyi bir hale getirebilir. Psikiyatri alanındaki uzmanların YZ araçlarının geliştirilmesindeki öncü rolü, hem ruh sağlığı camiasının hem de hasta gruplarının bu teknolojiye olan güveninin artmasında rol oynayacaktır.

## KAYNAKLAR

- Acerbi A, Stubbersfield JM (2023) Large language models show human-like content biases in transmission chain experiments. *Proc Natl Acad Sci U S A* 120: e2313790120.
- Adeshola I, Adepoju AP (2023) The opportunities and challenges of ChatGPT in education. *Interact Learn Environ*: 1-14.
- AlSaad R, Abd-Alrazaq A, Boughorbel S ve ark. (2024) Multimodal large language models in health care: applications, challenges, and future outlook. *J Med Internet Res* 26: e59505.
- American Psychiatric Association (2013) *Diagnostic and Statistical Manual of Mental Disorders: DSM-5*. 5th ed. Washington DC, American Psychiatric Association.
- Anderson SW, Rizzo M (1994) Hallucinations following occipital lobe damage: the pathological activation of visual representations. *J Clin Exp Neuropsychol* 16: 651-63.
- Antoniadi A M, Du Y, Guendouz Y ve ark. (2021) Current challenges and future opportunities for XAI in machine learning-based clinical decision support systems: a systematic review. *Appl Sci* 11: 5088.
- Arslan B, Kizilay E, Verim B ve ark. (2024) Computational analysis of linguistic features in speech samples of first-episode bipolar disorder and psychosis. *J Affect Disord* 15;363:340-7.
- Ayhan Y (2023) The Impact of Artificial Intelligence on Psychiatry: Benefits and Concerns—An essay from a disputed 'author'. *Turk Psikiyatri Derg* 34: 65.
- Baduge SK, Thilakarathna S, Perera JS ve ark. (2022) Artificial intelligence and smart vision for building and construction 4.0: machine and deep learning methods and applications. *Autom Constr* 141: 104440.
- Bai Y, Jones A, Ndousse K ve ark. (2022) Training a helpful and harmless assistant with reinforcement learning from human feedback. *arXiv:2204.05862*.
- Ballı M, Ercan Doğan A, Hun Şenol Ş ve ark. (2024) Uncovering psychiatric predictors of suicidal ideation using non-suicidal predictors: machine learning insights from a university mental health clinic. (Yayın aşamasında).
- Banerjee S, Agarwal A, Singla S (2024) LLMs will always hallucinate, and we need to live with this. *arXiv:2409.05746*.
- Barzilay R, Israel N, Krivoy A ve ark. (2019) Predicting affect classification in mental status examination using machine learning face action recognition system: a pilot study in schizophrenia patients. *Front Psychiatry* 10: 446117.
- Basu JK, Bhattacharyya D, Kim TH (2010) Use of artificial neural network in pattern recognition. *Int J Softw Eng Its Appl* 4: 23-34.
- Bhatnagar R, Sardar S, Beheshti M ve ark. (2022) How can natural language processing help model informed drug development?: a review. *JAMIA Open* 5: oaac043.
- Bracher-Smith M, Crawford K, Escott-Price V (2021) Machine learning for genetic prediction of psychiatric disorders: a systematic review. *Mol Psychiatry* 26: 70-9.
- Bzdok D, Meyer-Lindenberg A (2018) Machine learning for precision psychiatry: opportunities and challenges. *Biol Psychiatry Cogn Neurosci Neuroimaging* 3: 223-30.
- Cearns M, Hahn T, Baune B T (2019) Recommendations and future directions for supervised machine learning in psychiatry. *Transl Psychiatry* 9: 271.
- Chimalamarri S, Sitaram D (2021) Linguistically enhanced word segmentation for better neural machine translation of low-resource agglutinative languages. *Int J Speech Technol* 24: 1047-53.
- Collobert R, Puhersch C, Synnaeve G (2016) Wav2letter: an end-to-end convnet-based speech recognition system. *arXiv:1609.03193*.
- Cuthbert BN (2014) The RDoC framework: facilitating transition from ICD/DSM to dimensional approaches that integrate neuroscience and psychopathology. *World Psychiatry* 13: 28-35.
- Çabuk T, Sevim N, Mutlu E ve ark. (2024) Natural language processing for defining linguistic features in schizophrenia: A sample from Turkish speakers. *Schizophr Res* 266:183-9.
- Delipetrev B, Tsinaraki C, Kostic U (2020) Historical evolution of artificial intelligence.
- Di Vincenzo M (2023) New research on validity and clinical utility of ICD-11 vs. ICD-10 and DSM-5 diagnostic categories. *World Psychiatry* 22: 171.
- Dove GO (2023) Rethinking the role of language in embodied cognition. *Philos Trans R Soc Lond B Biol Sci* 378: 20210375.
- de Leon J, De Las Cuevas C (2023) Will ChatGPT3 substitute for us as clozapine experts? *J Clin Psychopharmacol* 43: 400-2.
- Ebden P, Sproat R (2015) The Kestrel TTS text normalization system. *Nat Lang Eng* 21: 333-53.
- Elgendy M (2020) *Deep learning for vision systems*. New York, Simon and Schuster, p. 1-350.
- Espejo G, Reiner W, Wenzinger M (2023) Exploring the role of artificial intelligence in mental healthcare: progress, pitfalls, and promises. *Cureus* 15: e37176.
- Fusar-Poli P, Solmi M, Brondino N ve ark. (2019) Transdiagnostic psychiatry: a systematic review. *World Psychiatry* 18: 192-207.
- GBD 2019 Mental Disorders Collaborators (2022) Global, regional, and national burden of 12 mental disorders in 204 countries and territories, 1990–2019: a systematic analysis. *Lancet Psychiatry* 9: 137-50.

- Gao L, Biderman S, Black S ve ark. (2020) The pile: an 800GB dataset of diverse text for language modeling. arXiv:2101.00027.
- Ghosalkar NN, Dhage SN (2018) Real estate value prediction using linear regression. In: 2018 Fourth International Conference on Computing Communication Control and Automation (IC3UBEA). IEEE, pp. 1-5.
- Giorgi A, Ronca V, Vozzi A ve ark. (2021) Wearable technologies for mental workload, stress, and emotional state assessment during working-like tasks: a comparison with laboratory technologies. *Sensors* 21: 2332.
- Greener JG, Kandathil SM, Moffat L ve ark. (2022) A guide to machine learning for biologists. *Nat Rev Mol Cell Biol* 23: 40-55.
- Greenberg PE, Fournier AA, Sisitsky T ve ark. (2021) The economic burden of adults with major depressive disorder in the United States (2010 and 2018). *Pharmacoeconomics* 39: 653-65.
- Gu Y, Tinn R, Cheng H ve ark. (2021) Domain-specific language model pretraining for biomedical natural language processing. *ACM Trans Comput Healthc* 3: 1-23.
- Gupta R, Srivastava D, Sahu M ve ark. (2021) Artificial intelligence to deep learning: machine intelligence approach for drug discovery. *Mol Divers* 25: 1315-60.
- Hestness J, Ardalani N, Damos G (2019) Beyond human-level accuracy: computational challenges in deep learning. In: Proceedings of the 24th Symposium on Principles and Practice of Parallel Programming, ACM, pp. 1-14.
- Heinz A, Zhao X, Liu S (2020) Implications of the association of social exclusion with mental health. *JAMA Psychiatry* 77: 113-4.
- Hickey B A, Chalmers T, Newton P ve ark. (2021) Smart devices and wearable technologies to detect and monitor mental health conditions and stress: a systematic review. *Sensors* 21: 3461.
- Hoffmann J, Borgeaud S, Mensch A ve ark. (2022) Training compute-optimal large language models. arXiv:2203.15556.
- Huang KL, Duan SF (2021) Affective voice interaction and artificial intelligence: acoustic features of gender and emotional states. *Front Psychol* 12: 664925.
- International Bioethics Committee (2022) Ethical Issues of Neurotechnology: Report, Adopted in December 2021. UNESCO Publishing. 24 Kasım 2024 tarihinde <https://unesdoc.unesco.org/ark:/48223/pf0000383559> adresinden indirildi.
- Jiang AQ, Sablayrolles A, Mensch A ve ark. (2023) Mistral 7B. arXiv:2310.06825.
- Jiang F, Jiang Y, Zhi H ve ark. (2017) Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol* 2: 230-43.
- Johnson KB, Wei WQ, Weeraratne D ve ark. (2021) Precision medicine, AI, and the future of personalized health care. *Clin Transl Sci* 14: 86-93.
- Jordan MI, Mitchell TM (2015) Machine learning: trends, perspectives, and prospects. *Science* 349: 255-60.
- Joshi ML, Kanoongo N (2022) Depression detection using emotional artificial intelligence and machine learning: a closer review. *Mater Today Proc* 58: 217-26.
- Juhn Y, Liu H (2020) Artificial intelligence approaches using natural language processing to advance EHR-based clinical research. *J Allergy Clin Immunol* 145: 463-9.
- Kalmady SV, Greiner R, Agrawal R ve ark. (2019) Towards artificial intelligence in mental health by improving schizophrenia prediction. *NPJ Schizophr* 5: 2.
- Karpukhin V, Levy O, Eisenstein J, Ghazvininejad M (2019) Training on synthetic noise improves robustness to natural noise in machine translation. In: Proceedings of the 5th Workshop on Noisy User-generated Text (W-NUT 2019). ACL, pp. 42-7.
- Kaynak AB, Dibeklioglu H (2024) Systematic analysis of speech transcription modeling for reliable assessment of depression severity. *Sakarya University Journal of Computer and Information Sciences*, 7: 77-91.
- Kişisel Verileri Koruma Kurumu (2023). Yapay Zekâ Alanında Kişisel Verilerin Korunmasına Dair Tavsiyeler. Ankara. 24 Kasım 2024 tarihinde <https://www.kvkk.gov.tr/Icerik/7048/Yapay-Zekâ-Alanında-Kişisel-Verilerin-Korunmasına-Dair-Tavsiyeler> adresinden indirildi.
- Kjell ON, Kjell K, Schwartz HA (2023) Beyond rating scales: with targeted evaluation, language models are poised for psychological assessment. *Psychiatry Res* 115667.
- Knapp M, Wong G (2020) Economics and mental health: the current scenario. *World Psychiatry* 19: 3-14.
- Krysta K, Cullivan R, Brittlebank A ve ark. (2024) Artificial intelligence in healthcare and psychiatry. *Acad Psychiatr* 19: 1-3.
- Krizhevsky A, Sutskever I, Hinton GE (2012) Imagenet classification with deep convolutional neural networks. *Adv Neural Inf Process Syst* 25: 1097-105.
- Lai VD, Ngo NT, Veyseh APB ve ark. (2023) ChatGPT beyond English: towards a comprehensive evaluation of large language models in multilingual learning. arXiv:2304.05613.
- LeCun Y, Bengio Y, Hinton G (2015) Deep learning. *Nature* 521: 436-44.
- Lewis P, Perez E, Piktus A ve ark. (2020) Retrieval-augmented generation for knowledge-intensive NLP tasks. *Adv Neural Inf Process Syst* 33: 9459-74.
- Li Z, Li X, Sheng J ve ark. (2020) AgglutiFiT: efficient low-resource agglutinative language model fine-tuning. *IEEE Access* 8: 148489-99.
- Lipton ZC (2018) The myths of model interpretability. *Queue* 16: 31-57.
- Luo Y, Thompson WK, Herr TM ve ark. (2017) Natural language processing for EHR-based pharmacovigilance: a structured review. *Drug Saf* 40: 1075-89.
- Martin-Carrasco M, Evans-Lacko S, Dom G ve ark. (2016) EPA guidance on mental health and economic crises in Europe. *Eur Arch Psychiatry Clin Neurosci* 266: 89-124.
- Maynez J, Narayan S, Bohnet B, McDonald R (2020) On faithfulness and factuality in abstractive summarization. arXiv:2005.00661.
- McCadden M, Hui K, Buchman DZ (2023) Evidence, ethics and the promise of artificial intelligence in psychiatry. *J Med Ethics* 49: 573-9.
- Meltzer HY, Lowy MT (1986) Neuroendocrine function in psychiatric disorders. In: American Handbook of Psychiatry, 2nd ed., vol. 8, Berger PA, Brodie HKH (Eds), New York. Basic Books Inc, pp. 110-7.
- Mikolov T, Deoras A, Povey D ve ark. (2011) Strategies for training large scale neural network language models. In: 2011 IEEE Workshop on Automatic Speech Recognition & Understanding, IEEE, pp. 196-201.
- Minerva F, Giubilini A (2023) Is AI the future of mental healthcare? *Topoi* 42: 809-17.
- Morar U, Martin H, Izquierdo W ve ark. (2020) A deep-learning approach for the prediction of mini-mental state examination scores. In: 2020 International Conference on Computational Science and Computational Intelligence (CSCI). IEEE, pp. 761-6.
- Morrow E, Zidaru T, Ross F ve ark. (2023) Artificial intelligence technologies and compassion in healthcare: a systematic scoping review. *Front Psychol* 13: 971044.
- Nahar M, Seo H, Lee EJ ve ark. (2024) Fakes of varying shades: how warning affects human perception regarding LLM hallucinations. arXiv:2404.03745.
- Nazi Z A, Peng W (2024) Large language models in healthcare and medical domain: a review. *Informatics* 11: 57.
- Nazimek JM, Hunter MD, Woodruff PW (2012) Auditory hallucinations: expectation-perception model. *Med Hypotheses* 78: 802-10.
- Niemeyer H, Bieda A, Michalak J ve ark. (2019) Education and mental health: do psychosocial resources matter? *SSM Popul Health* 7: 100392.
- Olawade DB, Wada OZ, Odetayo A ve ark. (2024) Enhancing mental health with artificial intelligence: current trends and future prospects. *J Med Surg Public Health* 100099.
- Omarov B, Zhumanov Z, Gumar A ve ark. (2023) Artificial intelligence enabled mobile chatbot psychologist using AIML and cognitive behavioral therapy. *Int J Adv Comput Sci Appl* 14: 87-94.
- OpenAI (2023) How can I get a Business Associate Agreement (BAA) with OpenAI? 24 Kasım 2024 tarihinde <https://help.openai.com/en/articles/86660679-how-can-i-get-a-business-associate-agreement-baa-with-openai> adresinden erişilmiştir.
- Özer M (2024, Eylül). Yapay Zekânın Varsanıları mı Oluyor? *Türk Psikiyatri Dergisi*, Makale 27587. 31 Ekim 2024'de <https://www.turkpsikiyatri.com/yayinlanmamis?type=c> adresinden indirildi.
- Parisi GI, Kemker R, Part JL ve ark. (2019) Continual lifelong learning with neural networks: a review. *Neural Netw* 113: 54-71.
- Pastur-Romay LA, Cedrón F, Pazos A ve ark. (2016) Deep artificial neural networks and neuromorphic chips for big data analysis. *Int J Mol Sci* 17: 1313.

- Pires R, Abonizio H, Almeida TS ve ark. (2023) Sabiá: Portuguese large language models. In: Brazilian Conference on Intelligent Systems. Cham, Springer Nature Switzerland, pp. 226-40.
- Radford A, Wu J, Child R ve ark. (2019) Language models are unsupervised multitask learners. OpenAI Blog 1: 9.
- Rajkumar A, Hardt M, Howell MD ve ark. (2018) Ensuring fairness in machine learning to advance health equity. *Ann Intern Med* 169: 866-72.
- Ratana R, Sharifzadeh H, Krishnan J ve ark. (2019) A comprehensive review of computational methods for automatic prediction of schizophrenia with insight into indigenous populations. *Front Psychiatry* 10: 659.
- Petrov A, La Malfa E, Torr P ve ark. (2024) Language model tokenizers introduce unfairness between languages. *Adv Neural Inf Process Syst* 36.
- Reddy GP, Kumar YP, Prakash KP (2024) Hallucinations in large language models (LLMs). In: 2024 IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream). IEEE, pp. 1-6.
- Roh Y, Heo G, Whang SE (2019) A survey on data collection for machine learning. *IEEE Trans Knowl Data Eng* 33: 1328-47.
- Russo M, Carrarini C, Dono F ve ark. (2019) The pharmacology of visual hallucinations in synucleinopathies. *Front Pharmacol* 10: 1379.
- Saxena A (2021) Artificial intelligence and machine learning in healthcare. Singapore, Springer, pp. 1-200.
- Savova GK, Danciu I, Alamudun F ve ark. (2019) Use of natural language processing to extract clinical cancer phenotypes from electronic medical records. *Cancer Res* 79: 5463-70.
- Scangos KW, State MW, Miller AH ve ark. (2023) New and emerging approaches to treat psychiatric disorders. *Nat Med* 29: 317-33.
- Squarcina L, Villa FM, Nobile M ve ark. (2021) Deep learning for the prediction of treatment response in depression. *J Affect Disord* 281: 618-22.
- Simons JS, Garrison JR, Johnson MK (2017) Brain mechanisms of reality monitoring. *Trends Cogn Sci* 21: 462-73.
- Smith AL, Greaves F, Panch T (2023) Hallucination or confabulation? Neuroanatomy as metaphor in large language models. *PLoS Digit Health* 2: e0000388.
- Smrke U, Mlakar I, Lin S ve ark. (2021) Language, speech, and facial expression features for AI-based detection of depression. *JMIR Ment Health* 8: e30439.
- Somé NH, Noormohammadpour P, Lange S (2024) The use of machine learning on administrative and survey data to predict suicidal thoughts and behaviors: a systematic review. *Front Psychiatry* 15: 1291362.
- Sterzer P, Adams RA, Fletcher P ve ark. (2018) The predictive coding account of psychosis. *Biol Psychiatry* 84: 634-43.
- Subramaniam K, Luks TL, Fisher M ve ark. (2012) Computerized cognitive training restores neural activity within the reality monitoring network in schizophrenia. *Neuron* 73: 842-53.
- Su C, Xu Z, Pathak J ve ark. (2020) Deep learning in mental health outcome research: a scoping review. *Transl Psychiatry* 10: 116.
- Sun H, Lin Z, Zheng C ve ark. (2021) PsyQA: a Chinese dataset for generating long counseling text for mental health support. *arXiv:2106.01702*.
- Suthaharan S (2016) Support vector machine. In: *Machine Learning Models and Algorithms for Big Data Classification*. Springer, pp. 207-35.
- Tenzer H, Feuerriegel S, Piekkari R (2024) AI machine translation tools must be taught cultural differences too. *Nature* 630: 820.
- T.C. Sağlık Bakanlığı (2021) Ulusal Ruh Sağlığı Eylem Planı 2021-2023. Available from: [https://hsgm.saglik.gov.tr/depo/Yayinlarimiz/Eylem\\_Planlari/Ulusal\\_Ruh\\_Sagligi\\_Eylem\\_Plani\\_2021-2023.pdf](https://hsgm.saglik.gov.tr/depo/Yayinlarimiz/Eylem_Planlari/Ulusal_Ruh_Sagligi_Eylem_Plani_2021-2023.pdf).
- Türkiye Psikiyatri Derneği (2016) Devlet Hastanelerinde Psikiyatri Uygulamaları: Sorunlar ve Çözüm Önerileri. Available from: <https://psikiyatri.org.tr/uploadFiles/2872016201037-DEVLET-HASTANELERINDE-PSIKIYATRI-UYGULAMALARI-SORUNLAR-VE-COZUM-ONERILERI-ozet-.pdf>.
- Touvron H, Lavril T, Izacard G ve ark. (2023) Llama: open and efficient foundation language models. *arXiv:2302.13971*.
- Turing AM (2009) Computing machinery and intelligence. In: Epstein R, Roberts G, Beber G (Eds), *Parsing the Turing Test*. Springer, pp. 23-65.
- U.S. Department of Health & Human Services (2023) Health Insurance Portability and Accountability Act (HIPAA). 24 Kasım 2024 tarihinde <https://www.hhs.gov/hipaa/index.html> adresinden erişilmiştir.
- Vaswani A ve ark. (2017) Attention is all you need. *Adv Neural Inf Process Syst* 30: 5998-6008.
- Volkmer S, Meyer-Lindenberg A, Schwarz E (2024) Large language models in psychiatry: opportunities and challenges. *Psychiatry Res* 116: 026.
- Wang P, Zhang N, Tian B ve ark. (2023) EasyEdit: an easy-to-use knowledge editing framework for large language models. *arXiv:2308.07269*.
- Wang S, Ding N, Lin N ve ark. (2023) Language cognition and language computation—human and machine language understanding. *arXiv:2301.04788*.
- Woodland T (2023) ChatGPT for improving medical education: proceed with caution. *Mayo Clin Proc Digit Health* 1: 294-5.
- World Health Organization (2018) *The ICD-11 Classification of Mental and Behavioural Disorders: Diagnostic Criteria for Research*. Geneva, World Health Organization.
- Wu J, Gan W, Chen Z ve ark. (2023) Multimodal large language models: a survey. In: 2023 IEEE International Conference on Big Data (BigData). IEEE, pp. 2247-56.
- Yang X, Joukova A, Ayanso A ve ark. (2022) Social influence-based contrast language analysis framework for clinical decision support systems. *Decis Support Syst* 159: 113813.
- Yapici Eser H, Kacar AS, Kilciksiz CM ve ark. (2018) Prevalence and associated features of anxiety disorder comorbidity in bipolar disorder: a meta-analysis and meta-regression study. *Front Psychiatry* 9: 229.
- Zhang L, Wang M, Liu M ve ark. (2020) A survey on deep learning for neuroimaging-based brain disorder analysis. *Front Neurosci* 14: 779.
- Zhao WX, Zhou K, Li J ve ark. (2023) A survey of large language models. *arXiv:2303.18223*.
- Zlatintsi A, Filntisis P, Garoufis C ve ark. (2022) E-prevention: advanced support system for monitoring and relapse prevention in patients with psychotic disorders. *Sensors* 22: 7544.
- Zweifel P (2021) Mental health: the burden of social stigma. *Int J Health Plann Manage* 36: 813-25.