

Dikkat Eksikliği Hiperaktivite Bozukluğu Tanısının Makine Öğrenimi Yöntemleri ile Konulması: Sistemik Bir Derleme

Diagnosis of Attention Deficit Hyperactivity Disorder with Machine Learning Methods: A Systemic Review

Enes Sarigedik¹, Çiğdem Yektaş², Ali Evren Tufan³

¹Sakarya Üniversitesi Tıp Fakültesi, Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları Anabilim Dalı, Sakarya, Türkiye

²Serbest Hekim, Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları, İstanbul, Türkiye

³Bolu Abant İzzet Baysal Üniversitesi, Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları Anabilim Dalı, Bolu, Türkiye

ÖZ

Dikkat eksikliği hiperaktivite bozukluğu (DEHB), toplum içerisinde oldukça sık görülen nörogelişimsel bir bozukluktur. Tanı koyma sürecinde altın standart yöntem klinisyen değerlendirmesidir. Öte yandan gelişen teknoloji ile sağlık alanında kullanımı artan makine öğreniminin (ML) bu bozukluğun tanısında kullanımı ile ilgili çalışmaların sayısı artmaktadır. Çalışmalar özellikle elektroensefalogram ve görüntüleme yöntemleri üzerine yoğunlaşmış ancak bu konudaki farklı yöntemler ve bunlarla ilgili çalışmalar daha önce bütüncül bir biçimde değerlendirilmemiştir. Bu derlemenin amacı, çocuk ve ergenlerde yapılan DEHB ve ML ile ilgili artan literatür ve güncel çalışmalar hakkında bilgi vermek, önemli çalışmalarını özetlemek, ML ile ilgili gelecek çalışmalar için öneri sunmaktır.

Anahtar Kelimeler: Dikkat eksikliği, hiperaktivite, makine öğrenimi, derleme

ABSTRACT

Attention deficit hyperactivity disorder (ADHD) is a common neuro-developmental disorder in the community. The gold standard for diagnosis is clinician evaluation. In contrast, with the increase in technological developments, the number of studies on the use of machine learning (ML) in the diagnosis of this disorder is increasing. Studies have mainly focused on electroencephalogram and imaging methods. However, to our knowledge, no studies up to now integrated studies using various methods related to this issue. The purpose of this review was to provide information about the increasing body of literature and current studies on ADHD and ML in children and adolescents, summarize important studies, and offer suggestions for future studies on ML.

Keywords: Attention deficit, hyperactivity, machine learning, review

Giriş

Dikkat eksikliği hiperaktivite bozukluğu (DEHB) çocukluk çağında başlayıp yaşam boyu devam eden nörogelişimsel bir bozukluktur.¹ DEHB için dünya çapında yaygınlık çocukluk çağında %5,0-12,0 arasında bildirilmiştir.² Ülkemizde ilköğretim 2-4. sınıf çocuklarının dahil edildiği çok merkezli bir çalışmada ise DEHB yaygınlığının %12,4 olduğu bildirilmektedir.³ Bu bozukluk ergenlikte %34,0-67,0, erişkinlikte ise eşik altı ancak işlevi bozan semptomlar da dahil edildiğinde %50,0-66,0 oranında devam edebilmektedir.^{4,5} DEHB tanısı alan bireylerin önemli bir kısmı psiko-farmakolojik tedavilere yanıt verse bile, sosyal iletişim ve duygu düzenleme sorunları devam edebilmekte ve semptomlar düzelse dahi işlevselliğin düzelmediği görülmektedir.⁶ Bu gözlemler, bozukluğun süregelen doğası; birey, aile ve toplum üzerine olumsuz etkileri nedeniyle

bu nörogelişimsel bozukluğun değerlendirilmesi ve takibi üzerine çalışmalar halen devam etmektedir.

DEHB tanısı koymak için altın standart klinisyen tarafından olabildiğince farklı kaynaktan bilgi toplanarak gelişimsel öykünün aydınlatılması ve ruhsal durum muayenesinin gerçekleştirilmesidir.⁷ Günümüzde henüz DEHB tanısını doğrulamak ya da dışlamak için kullanılacak yeterli öngörü gücüne sahip yardımcı testler, araştırmalar veya biyobelirteçler bulunmamaktadır.⁷ Nörogörüntüleme yöntemleri [manyetik rezonans (MR), pozitron emisyon tomografisi, tek foton yayımlı bilgisayarlı tomografi gibi] ve elektroensefalogram (EEG) nadiren olguların ayırıcı tanısında faydalı olabilmelerine karşın rutin klinik değerlendirmede kullanımları önerilmemektedir.^{7,8} Nöropsikolojik testler ve zeka testleri ise DEHB'ye eşlik eden entelektüel bozulmayı, yürütücü işlev eksikliklerini belirleyebilir

Yazışma Adresi/Address for Correspondence: Enes Sarigedik, Sakarya Üniversitesi Tıp Fakültesi, Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları Anabilim Dalı, Sakarya, Türkiye

E-posta: enesarig@outlook.com **ORCID:** orcid.org/0000-0002-9294-1152

Geliş Tarihi/Received: 23.05.2022 **Kabul Tarihi/Accepted:** 29.07.2022

Copyright © 2024 Yazar. Türkiye Çocuk ve Gençlik Psikiyatrisi Derneği adına Galenos Yayınevi tarafından yayımlanmıştır. Creative Commons Atıf-GayriTicari-Türetilemez 4.0 (CC BY-NC-ND) Uluslararası Lisansı ile lisanslanmış, açık erişimli bir makaledir.



ve öğrenme bozukluğu gibi durumların yönetiminde ve tanısında yardımcı olabilir.^{7,8} Semptom tarama ve derecelendirme ölçekleri de yakınmaların ve bulguların şiddetini ölçmek ve tedaviye yanıtı izlemek için kullanılabilir.^{7,8} Dolayısıyla yaygın olarak görülen ve süregelen olabilen bu bozukluğun değerlendirilmesinde klinik izlem ve uzman görüşü en önemli yöntemler olmayı sürdürmektedir. Ancak klinisyenlerin vakit ve emeklerinin daha verimli kullanılarak tanı koymanın kolaylaştırılabilmesi için de çalışmalar devam etmektedir. Bu bozukluk ile ilgili çalışılan dikkat çekici konulardan biri ise makine öğrenmesi (ML) ve yapay zeka uygulamalarıdır.⁹ Bilişim ve görüntüleme teknolojilerindeki hızlı ilerleme, sağlık verilerinin elektronik ortamlarda depolanması, artan veri paylaşım imkanları ile sağlığın diğer alanlarında olduğu gibi ruh sağlığı alanında da çok büyük veri setlerinin oluşturulması sağlamıştır. Bu gelişim sayesinde tanı, değerlendirme ve tedavi gibi alanlarda ML'nin kullanımını artırmıştır.^{10,11} DEHB'nin tanısal olarak değerlendirilmesinde ML yöntemlerinin kullanımı ile ilgili henüz sınırlı sayıda çalışma bulunsa da elde edilen veriler bu alanda hızlı bir ilerlemenin gerçekleşebileceğini düşündürmektedir.^{9,12} Bu çalışmada DEHB ve ML ile ilgili güncel çalışmaları gözden geçirerek olası klinik uygulamalar hakkında ruh sağlığı çalışanlarını bilgilendirmek ve ileri çalışma önerilerini belirtmek amaçlanmıştır.

Makine Öğrenimi

ML, öncelikle örüntü tanıma tekniklerini belirlemeye çalışan yapay zeka çalışmalarından ortaya çıkmıştır.¹³ ML'nin ana amacı girilen verileri bilgisayara analizi ile değerlendirerek, verideki kalıp ve eğilimleri belirleyen, bu veriler ile kabul edilebilir bir güvenilirlik aralığında çıktı değerini tahmin edebilen ve geçmiş deneyimlerinden öğrenebilen algoritma yapıları oluşturmaktır.^{13,14} ML yaklaşımları içerisinde algoritma yapılarının geçmiş deneyimlerine göre kendilerini geliştirebilmesi bu sistemi daha da ilginç kılmaktadır.^{13,14}

ML, denetimli öğrenme, denetimsiz öğrenme ve yarı-denetimli öğrenme gibi farklı yöntemleri kullanabilir.^{13,14} Denetimli öğrenmede algoritmaya öğrenme hedefi (hasta demografisi ve risk faktörleri gibi) ve ulaşılmaya istenen sonuç ölçütleri (tanılar veya klinik olaylar gibi) ile ilgili özellikler tanımlanarak bu ikisi arasındaki bağlantıları belirlemek amacıyla kullanılacak bir veri seti sağlanır. Yaygın olarak kullanılan bir örnekte "elma", "portakal" ve "limon" arasında ayırım yapmak için model eğitilir. Her bir meyve türünün "etiketi" başlangıçta algoritmaya renk, boyut, ağırlık ve şekil gibi özelliklerle birlikte verilir ve algoritma meyveleri farklılaştıran özelliklerin bileşkesini öğrenir. Ardından, yeni "etiketlenmemiş" bir meyve kendisine sunulduğunda, model bunun hangi tür bir meyve olduğunu tahmin edebilmelidir.^{13,14} Dolayısıyla bu tür bir model ruh sağlığı alanında kullanıldığında, bir kere oluşturulduktan ve parametreleri optimize edildikten sonra, dış geçerliliğini ve dolayısıyla diğer hastalara uygulanabilirliğini belirlemek için eğitim verilerine dahil olmayan yeni hastalar üzerinde test edilmelidir. Denetimli öğrenme modelleri tıpta en çok tanı ve prognozla ilgili klinik problemlere uygulanmaktadır. Tanı amaçlı modellerde algoritmanın eğitimi, bir eğitim veri seti

kullanılarak yapılır ve bu set içerisinde bozukluk varlığı ya da yokluğu iki değerli bir değişken olarak tanımlanır. Model bir kere eğitildikten sonra ayrı bir test veri setinde doğrulanmalıdır. Prognoz veya sonucun belirlenmesi amacı ile geliştirilen bir modelde ise benzer şekilde bir eğitim veri seti kullanılır. Ancak bu sette örneğin; "5 yıllık sağkalım veya hastalısız sağkalım" istenen sonuç ölçütleri olarak ayarlanır ve iki değerli olarak tanımlanır. Bu şekilde eğitilen bir model yine ayrı bir veri setinde doğrulanarak sonuç veya prognozu tahmin edebilmelidir.^{13,14}

Denetimsiz öğrenmede algoritmaya sınıflandırılmamış bir veri tabanı sağlanır ve bu sayede var olan veri yapısı içerisinde gizli örüntülerin tanımlanması gerçekleştirilir. Bu sayede bazen araştırmacıların önceden düşünmediği cevap ve sorular elde edilebilir.^{13,14} Teknik açıdan bakıldığında, denetimli öğrenmenin öncelikle sınıflandırma ve regresyon problemleriyle ilgilendiği, denetimsiz öğrenmenin ise daha çok kümeleme ve bileşenlerin azaltılması ile ilgilendiği söylenebilir.^{13,14}


Yarı denetimli öğrenme ise küçük miktarda etiketlenmiş (yani önceden sınıflandırılmış) veri ile algoritmanın örüntü tanıma yeteneklerini artırırken büyük miktarda etiketlenmemiş (sınıflandırılmamış) veriyi analiz edebilen denetimli ve denetimsiz ML'nin bir karışımıdır. Tıp uygulamaları çerçevesinde değerlendirildiğinde bu yaklaşımın daha değerli olduğu söylenebilir çünkü bu tür veriler bazen çok büyük boyutlara ulaşabilmekte ve karmaşık ölçümler içerebilmektedir. Belirtilen özelliklere sahip veri tabanlarında istenen her bilgiye ayrı ayrı etiket atanması zaman ve ekonomi açısından verimli olmayabilir.¹⁵ ML geleneksel analiz yöntemlerine kıyasla önceden belirlenmiş seçimler gerektirmemesi, belli bir veri kümesi için en etkin modeli belirleyebilmesi ve çok sayıda karmaşık veri kombinasyonlarını işleyebilmesi açısından avantajlı olabilir.¹⁵

Dikkat Eksikliği Hiperaktivite Bozukluğu ve Makine Öğrenmesi

"DEHB" ve "makine öğrenmesi" terimleri ile ilgili 13.05.2022 tarihi itibarı ile Web of Science dizininde yayınlanan çalışmalar incelendiğinde 257, PubMed aramasında ise 233 çalışma bulunmaktadır. Bu çalışmalardan örtüşen çalışmalar, yetişkin çalışmaları, istatistiksel yöntemlerin belirtilmediği çalışmalar çıkarıldığında 119 tanesinin çocuk ve ergenlerde DEHB ile ilişkili olduğu belirtilmiştir. Bunların 99 tanesi teşhise yönelik iken, 10 tanesi ayrıcı tanı, 4 tanesi alt kümeler, 4 tanesi tedavi ile ilgilidir. Kullanılan yöntemlerin ise nörogörüntüleme (n=61), EEG (n=23), bilişsel test (n=13), anket yöntemi (n=13), biyokimya (n=5), sağlık kayıtları (n=5), genetik (n=2), bilgisayar oyunları (n=3), sanal gerçekliği (n=1) kapsadığı gözlenmiştir (Şekil 1).

Dikkat Eksikliği Hiperaktivite Bozukluğu ve Makine Öğrenmesi Hakkındaki Çalışmalar

Bu konudaki çalışmaların büyük kısmının EEG ve çeşitli nörogörüntüleme yöntemlerini içerdiği görülmüştür.¹⁶⁻¹⁸ Bu makalede, okuyucunun bu konudaki yazın hakkında bilgi sahibi olmasına yönelik seçilmiş yazılar yer almaktadır. Yazıdaki makalelerin genel özeti Tablo 1'de verilmektedir.



Şekil 1. Akış şeması

DEHB: Dikkat eksikliği hiperaktivite bozukluğu, WOS: Web of Science, EEG: Elektroensefalogram

Elektroensefalogram Çalışmaları

Tosun'un¹⁹ EEG ile değerlendirilen 8 DEHB tanılı olgu ve 8 adet kontrol grubu bireyi kıyasladığı, küçük örneklem sayılı bir çalışmada destek vektör makine (DVM) yöntemi ile (Fp1,F7) kanalları için elde edilen özgüllük ve duyarlılık değerleri sırasıyla %87,8 ve %90,0 olarak bulunmuştur. Tor ve ark.¹⁶ ise 123 çocuktan elde edilen EEG sinyallerinin k-en yakın komşu yöntemi kullanılarak %97,9 doğrulukla tanı gruplarına atanabildiğini bildirmişlerdir. Dolayısıyla elde edilen veriler, EEG sinyallerinin DEHB ve davranış bozukluklarının ayırımında kullanılabileceğini düşündürmektedir.¹⁶ Parashar ve ark.²⁰ DEHB tanılı 60 çocuk ve 60 kontrolde 19 EEG kanalı üzerinden elde edilen verileri inceledikleri çalışmalarında, ML ile DEHB

tanısında %84,0 duyarlılık ve %96,0 özgünlük elde edilebildiğini bildirmişlerdir. Altınkaynak ve ark.²¹ ise 7-12 yaş arası DEHB tanılı 23 çocuk ve 23 sağlıklı kontrol verilerinin değerlendirildiği ve çok katmanlı algılama yönteminin kullanıldığı çalışmalarında DEHB tanısının %91,3 doğrulukta konabildiğini bildirmiştir.

Aynı yazar grubunun gerçekleştirdiği diğer bir çalışmada da Naive Bayes yöntemi kullanıldığında, sırasıyla EEG ve EEG yakın kızılötesi spektroskopi verileri için DEHB tanısında %79,5 ve %93,2 doğruluk oranı elde edilebildiği bildirilmiştir.²² Yine çocuklarda gerçekleştirilen, EEG kayıtlarını çapraz yineleyen grafikler yöntemi ile ve ML aracılığı ile değerlendiren diğer bir çalışmada ise DEHB tanısının %97,3 doğrulukla konabildiği rapor edilmiştir.²³

Tablo 1. İncelenen makalelerin genel özellikleri

Yazar	Araştırma	Makine öğrenimi yöntemi	Örneklem sayısı	Özgüllük duyarlılık AUC
Tosun ¹⁹	EEG	DVM	8, DEHB 8, kontrol	Özgüllük: %87,8 Duyarlılık: %90,0
Tor ve ark. ¹⁶	EEG	K en yakın komşu	123	Doğruluk: %97,9
Parashar ve ark. ²⁰	EEG	DVM	60, DEHB 60, kontrol	Özgüllük: %96,0 Duyarlılık: %84,0
Altınkaynak ve ark. ²¹	EEG	Sinir ağları	23, DEHB 23, kontrol	Doğruluk: %91,3
Güven ve ark. ²²	EEG EEG-fNIRS	Naive Bayes		Doğruluk: %79,5 Doğruluk: %93,2
Das ve Khanna. ²³	Pupil hareketleri	DVM	28, DEHB 22, kontrol	Özgüllük: %75,3 Duyarlılık: %77,3 AUC: 0,86
Zhang-James ve ark. ²⁴	Yapısal MR	Sinir ağları	18, DEHB 18, kontrol	Doğruluk: %69,4 AUC: 0,65
Liu ve ark. ²⁵	Fonksiyonel MR	AdaDT	362, DEHB 585, kontrol	Doğruluk: %75,6
Deshpande ve ark. ¹⁷	Fonksiyonel MR	YSA	433, DEHB 744, kontrol	Doğruluk: %90,0
Peng ve ark. ²⁶	Yapısal MR	AÖM	55, DEHB 55, kontrol	AÖM: %90,18 DVM: %84,73
Yasumura ve ark. ²⁷	Yürütücü işlevler	DVM	62, DEHB 37, kontrol	Özgüllük: %83,8 Duyarlılık: %88,7
Yeh ve ark. ²⁸	Sanal gerçeklik	DVM	37, DEHB 31, kontrol	Doğruluk %83,2
Maniruzzaman ve ark. ²⁹	Sağlık kayıtları	RF	5218 DEHB	Özgüllük: %86,4 Duyarlılık: %84,4 AUC: 0,94
Altun ve ark. ³⁰	Mizaç özellikleri	AdaDT	60, DEHB 60, kontrol	Doğruluk: %92,5
Aceves-Fernandez ³¹	EGG	Çapraz yineleme grafikleri	61, DEHB 60, kontrol	Doğruluk: %97,2-3

DVM: Destek vektör makineleri, AÖM: Aşırı öğrenme makineleri, YSA: Yapay sinir ağları, AdaDT: Karar ağaçları, RF: Rastgele orman, EEG-fNIRS: Elektroensefalogram-yakın kızılötesi spektroskopisi, AUC: Eğri altında kalan alan, MR: Manyetik rezonans

DEHB'li ve kontrol hastanın değerlendirildiği çalışmada EEG sinyalleri izlenirken performans testleri uygulanmıştır, EEG tabanlı uzun kısa süreli bellek ağlarının ortalama %90,50 doğrulukla normal gelişim ile DEHB'yi ayırt edebildiği gösterilmiştir.³¹

Beyin Görüntüleme Çalışmaları

ML yöntemi ile beyin görüntülemeyi birleştiren çalışmalar son dönemlerde giderek daha çok ilgi çekmektedir.³² ML aracılığı ile DEHB tanılı 18 çocuk ve 18 kontrolde beyin yapısının kortikal ve subkortikal kalınlık ve hacimlerin değerlendirildiği bir çalışmada DEHB tanısının %69,4 doğrulukta konabildiği ve eğri altında kalan alanın (AUC) 0,65 olduğu bildirilmektedir.²⁴ Daha geniş kapsamlı başka bir çalışmada ise DEHB tanısı alan 362 çocuk/ergen ve 585 kontrol değerlendirilmiş ve tanının %75,6

doğrulukta konabildiği saptanmıştır.²⁵ DEHB olgularında, beyin yapıları ve işlevlerinin zaman içerisindeki etkileşimini değerlendirmeyi mümkün kılan işlevsel MR görüntüleme (f-MRG) üzerine ilgi de giderek artmaktadır.³³ f-MRG ile ML yöntemlerinin birleştirildiği farklı çalışmalarda DEHB tanısının %69,2-76,0 doğrulukta konulabildiği bildirilmiştir.^{26,27,34,35} Deshpande ve ark.¹⁷ çalışmasında ise bu oran %90,0'a kadar yükselmektedir. Eslami ve ark.¹⁸ ise çocuk, ergen ve yetişkin DEHB olgularında f-MRG ile gerçekleştirilen çalışmaları, ML ile değerlendirdiklerinde tanısal doğruluğun %58,0-94,6 arasında değiştiğini bildirmiştir. Peng ve ark.²⁶ yapısal MRG verilerini DVM yöntemi ile değerlendirdiği çalışmaları, DEHB tanısının %90,1 doğrulukla konabildiğini saptamıştır. Ayrıca çocuk, ergen ve yetişkin DEHB olgularında yapısal MRG ile ML yöntemleri birlikte kullanıldığında tanısal doğruluğun %60,8-90,2 arasında değiştiği saptanmıştır.¹⁸

Sağlık Kayıtlarından Dikkat Eksikliği Hiperaktivite Bozukluğu Tanısı

Tüm sağlık verilerinin kayıtlara geçtiği sistemlerde, ulusal verileri analiz etmek oldukça yararlı olabilmektedir. Amerika'da ulusal sağlık merkezi verilerinden elde edilen veriler ile 3-17 yaş aralığındaki 45.779 çocuğun verileri analiz edilmiştir ve bu çocukların yaklaşık 5218'inde DEHB tanısı olduğu saptanmıştır. ML yöntemleri ile sağlık verilerinin incelenmesi sonrasında rastgele orman modellemesi %85,5 ile en yüksek sınıflandırma doğruluğunu göstermiştir, modelin %84,4 duyarlılığı, %86,4 özgüllüğü ve 0,94'lük bir AUC'yi sağladığını bildirilmiştir.²⁹

Ayrırcı Tanı, Ek Tanı ile İlgili Çalışmalar

DEHB'nin tanınmasında EEG ve görüntüleme dışı diğer yöntemlerle de ML birleştirilebilmektedir. Yasumura ve ark.²⁷ yürütücü işlevlerin (enterferansa karşı koyma) Stroop testi ile değerlendirildiği bir çalışmada; DVM yöntemini kullanarak DEHB tanısı için %88,7 duyarlılık ve %83,8 özgüllüğe eriştiklerini bildirmiştir. Diğer bir çalışmada ise olağan gelişim gösteren çocuklar, DEHB tanısı alanlar ve otizm spektrum bozukluğu (OSB) tanısı alanlar DVM ile ayırt edilmeye çalışılmıştır.³⁶ Bu çalışmada olağan gelişim OSB'den, olağan gelişim DEHB'den ve OSB, DEHB'den sırasıyla %76,3, %84,1 ve %79,3 doğruluk oranlarında ayırt edilebilmiştir.³⁵

Madde Kullanımı, Dikkat Eksikliği Hiperaktivite Bozukluğu ve Makine Öğrenimi

Zhang-James ve ark.'nın³⁶ İsveç toplum örneğinde DEHB tanısı alan çocuklarda madde kullanım riskini ML ile değerlendirdikleri çalışmaları klinik önemi açısından dikkat çekicidir. On dokuz binin üzerinde DEHB tanılı çocuğu rastlantısal orman sınıflandırma yöntemi ile değerlendiren çalışmada yeni ortaya çıkan madde kullanımı ve yeni alınan madde kullanım bozukluğu tanısı (iki ay önceden) için eğri altında kalan alanlar sırasıyla 0,73 ve 0,67 olarak bildirilmiştir.³⁷

Genetik, Biyomarker ve İlaç Yanıtı

Genetik polimorfizmler ile DEHB belirti şiddeti arasındaki ilişki de ML kullanılan çalışmalarda değerlendirilmiş ve *DRD4*, *SNAP25* ve *ADGRL3* genlerinin bu açıdan önemli olduğu saptanmıştır.³⁸ Tam genom dizilimine sahip kişilerin sağlık kayıtlarına erişilerek tanı ayırımının yapıldığı bir çalışmada %65,0 doğruluk oranı ile ruhsal hastalığı olanlar ile sağlıklı popülasyon birbirinden ayırt edilmiştir.³⁹ Tek hastalığı ayırt etmede ise DEHB %39,4 ile en yüksek kesinlik oranını göstermiştir.³⁹

DEHB tahmini ve tedaviye yanıtı mikroRNA'lar ile değerlendiren bir başka çalışmada 145 DEHB ve 83 kontrol çalışmaya dahil edilmiş ve mikroRNA değerleri DEHB hastalarını kontrollerden ayırt etmede duyarlılık: %96,0; özgüllük: %94,2 oranları ile iyi bir geçerlilik göstermişlerdir.⁴⁰ Tedaviye yanıt açısından da 92 hastada mikroRNA değerleri farklılık göstermiştir.⁴⁰

Göz bebeği ölçümlerinin biyomarker olarak kullanıldığı bir çalışmada ise 28 DEHB ve 22 kontrol grubu karşılaştırılarak nitel sonuçlar üzerinden DEHB tanısı konulmaya çalışılmış

ve AUC %85,6, duyarlılık %77,3, özgüllük ise %75,3 şeklinde raporlanmıştır.²³

ML yöntemi ile DEHB'li kişilerin metilfenidat tedavisine cevabını değerlendiren başka bir çalışmada ise çalışmacılar DVM ML yöntemi ile DEHB'ye iyi yanıt veren grubu, DEHB'ye zayıf yanıt veren gruptan %84,6 doğruluk ve 0,84'lik AUC oranı ile ayırabildiğini bildirmişlerdir.⁴¹

Mizaç ve Dikkat Eksikliği Hiperaktivite Bozukluğu

2022 yılında Türkiye'de yapılan bir çalışmada mizaç özelliklerine göre DEHB tanısı konulmaya çalışılmış, karar ağaçları yönteminin %92,5 doğruluk oranı ile başarılı bir şekilde DEHB olan çocukları sınıflandırabildiği görülmüştür.³⁰

Çalışmalar, DEHB sınıflamasında EEG raporlarının oldukça yüksek oranda kullanışlı olduğunu, yapısal MRG'nin kısmen daha düşük başarı gösterdiğini ve f-MRG'nin DEHB'yi ayırt etmede oldukça başarılı olduğunu göstermektedir. Ayrıca ML ek tanı, ayırt edici tanı, risk altında grubu tahmin etme, ilaç cevabı gibi birçok alanda da umut vaat edici olarak görünmektedir.

Gelecek çalışmalar; klinisyen değerlendirmesi ile DEHB tanısı koyulan çocukların ML yöntemleri ile ne kadar başarı ile tanımlanabildiğini ortaya koyabilir. Ayrıca el yazısı ya da ses tonundan klinik tanı koyma gibi ML yöntemleri ile ilgili yeni çalışmalar planlanabilir. Halihazırda bu önemli konuda ülkemizde yapılan çalışma sayısı oldukça kısıtlıdır ve bunların çok azında çocuk ve ergen ruh sağlığı uzmanları çalışmaya katılmıştır.^{21,42}

Sonuç

ML umut vaat eden bir teknik olmasına karşın klinik kullanımı açısından henüz emekleme aşamasında gibi görünmektedir. Sonuçlar değerlendirildiğinde; tanısal doğruluk oranları oldukça yüksek gibi görünmekle birlikte, bulgular açısından bir yanlış vurgusundan söz edilmektedir. Bu teknolojiler yakın gelecekte geliştirilerek tanıya yardımcı önemli araçlar olarak kullanılabilir. Öte yandan, klinik kullanım açısından oldukça fazla veriye ihtiyaç duyulduğu, ilişkili etik konularının da hassasiyetle değerlendirilmesi gerektiği unutulmamalıdır.

Dipnot

Yazarlık Katkıları

Konsept: E.S., Ç.Y., Dizayn: E.S., Ç.Y., A.E.T., Veri Toplama veya İşleme: E.S., A.E.T., Analiz veya Yorumlama: Ç.Y., A.E.T., Literatür Arama: E.S., A.E.T., Yazan: E.S., Ç.Y., A.E.T.

Çıkar Çatışması: Bu makalenin iki yazarı, Çiğdem Yektaş, Ali Evren Tufan, Çocuk ve Gençlik Ruh Sağlığı Dergisi'nin Editörler Kurulu üyesidir. Ancak, makalenin editöryal kararının herhangi bir aşamasında yer almamışlardır. Bu makaleyi değerlendiren editörler farklı kurumlardan gelmektedir. Diğer yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

Finansal Destek: Yazarlar tarafından finansal destek almadıkları bildirilmiştir.

Kaynaklar

- American Psychiatric Association. Diagnostic and Statistical Manual of Mental Disorders. American Psychiatric Publishing, Arlington, VA 2013.
- Polanczyk G, de Lima MS, Horta BL, Biederman J, Rohde LA. The worldwide prevalence of ADHD: a systematic review and meta-regression analysis. *Am J Psychiatry*. 2007;164:942-98.
- Ercan ES, Unsel-Bolat G, Tufan AE, Karakoc Demirkaya S, Bilac O, Celik G, Kılıç BG, Akyol Ardic U, Yalin Sapmaz S, Aksu H, Yolga Tahiroglu A, Karacetin G, Tural U, Aktepe E, Rodopman Arman A, Başgöl S, Coşkun M, Dursun OB, Durukan İ, Perdahlı Fiş N, Gençoğlan S, Gökçen C, Sarı Gokten E, Görker I, Görmez V, Yıldız Gündoğdu Ö, Hesapçioğlu ST, Kandemir H, Mutluer T, Nasiroğlu S, Özcan Ö, Şahin N, Toros F, Perçinel Yazıcı İ, Yazıcı KU, Yulaf Y, Yüksel T, Bilgic A, Altun H, Akdemir D, Mazlum B, Çakın Memik N, Foto Özdemir D, Üneri Ö, Ünal F. Effect of Impairment on the Prevalence and Comorbidities of Attention Deficit Hyperactivity Disorder in a National Survey: Nation-Wide Prevalence and Comorbidities of ADHD. *J Atten Disord*. 2022;26:674-684.
- Shaw P, Sudre G. Adolescent Attention-Deficit/Hyperactivity Disorder: Understanding Teenage Symptom Trajectories. *Biol Psychiatry*. 2021;89:152-161.
- Johnson J, Morris S, George S. Attention deficit hyperactivity disorder in adults: what the non-specialist needs to know. *Br J Hosp Med (Lond)*. 2020;81:1-11.
- Wong ICK, Banaschewski T, Buitelaar J, Cortese S, Döpfner M, Simonoff E, Coghill D; European ADHD Guidelines Group. Emerging challenges in pharmacotherapy research on attention-deficit hyperactivity disorder-outcome measures beyond symptom control and clinical trials. *Lancet Psychiatry*. 2019;6:528-537.
- Mulraney M, Arrondo G, Musullulu H, Iturmendi-Sabater I, Cortese S, Westwood SJ, Donno F, Banaschewski T, Simonoff E, Zuddas A, Döpfner M, Hinshaw SP, Coghill D. Systematic Review and Meta-analysis: Screening Tools for Attention-Deficit/Hyperactivity Disorder in Children and Adolescents. *J Am Acad Child Adolesc Psychiatry*. 2022;61:982-996.
- Faraone SV, Asherson P, Banaschewski T, Biederman J, Buitelaar JK, Ramos-Quiroga JA, Rohde LA, Sonuga-Barke EJ, Tannock R, Franke B. Attention-deficit/hyperactivity disorder. *Nat Rev Dis Primers*. 2015;1:15020.
- Zhang Z, Li G, Xu Y, Tang X. Application of Artificial Intelligence in the MRI Classification Task of Human Brain Neurological and Psychiatric Diseases: A Scoping Review. *Diagnostics (Basel)*. 2021;11:1402.
- Kosinski M, Behrend TS. Editorial overview: Big data in the behavioral sciences. *Curr Opin Behav Sci*. 18, iv-vi.
- Gillan C, Whelan R. What big data can do for treatment in psychiatry. *Curr Opin Behav Sci*. 2017;18:34-42.
- Levy H, Levy BK. Diagnosis and effectiveness of monitoring attention deficit hyperactivity disorder. 2020. Accessed May 13, 2022. <https://patents.google.com/patent/WO2020144575A1/en>
- Tai AMY, Albuquerque A, Carmona NE, Subramaniepillai M, Cha DS, Sheko M, Lee Y, Mansur R, McIntyre RS. Machine learning and big data: Implications for disease modeling and therapeutic discovery in psychiatry. *Artif Intell Med*. 2019;99:101704.
- Handelman GS, Kok HK, Chandra RV, Razavi AH, Lee MJ, Asadi H. eDoctor: machine learning and the future of medicine. *J Intern Med*. 2018;284:603-619.
- Camargo G, Bugatti PH, Saito PTM. Active semi-supervised learning for biological data classification. *PLoS One*. 2020;15:e0237428.
- Tor HT, Ooi CP, Lim-Ashworth NS, Wei JKE, Jahmunah V, Oh SL, Acharya UR, Fung DSS. Automated detection of conduct disorder and attention deficit hyperactivity disorder using decomposition and nonlinear techniques with EEG signals. *Comput Methods Programs Biomed*. 2021;200:105941.
- Deshpande G, Wang P, Rangaprakash D, Wilamowski B. Fully Connected Cascade Artificial Neural Network Architecture for Attention Deficit Hyperactivity Disorder Classification From Functional Magnetic Resonance Imaging Data. *IEEE Trans Cybern*. 2015;45:2668-2679.
- Eslami T, Almuqhim F, Raiker JS, Saeed F. Machine Learning Methods for Diagnosing Autism Spectrum Disorder and Attention-Deficit/Hyperactivity Disorder Using Functional and Structural MRI: A Survey. *Front Neuroinform*. 2021;14:575999.
- Tosun M. Effects of spectral features of EEG signals recorded with different channels and recording statuses on ADHD classification with deep learning. *Phys Eng Sci Med*. 2021.
- Parashar A, Kalra N, Singh J, Kumar Goyal R. Machine Learning Based Framework for Classification of Children with ADHD and Healthy Controls. *Intell Autom Soft Comput*. 2021;28:669-682.
- Altınkaynak M, Dolu N, Güven A, Pektaş F, Özmen S, Demirci E, Izzetoglu M. Diagnosis of Attention Deficit Hyperactivity Disorder with combined time and frequency features. *Biocybern Biomed Eng*. 2020;40:927-937.
- Güven A, Altınkaynak M, Dolu N, Izzetoglu M, Pektaş F, Özmen S, Demirci E, Batbat T. Combining functional near-infrared spectroscopy and EEG measurements for the diagnosis of attention-deficit hyperactivity disorder. *Neural Comput Appl*. 2020;32.
- Das W, Khanna S. A Robust Machine Learning Based Framework for the Automated Detection of ADHD Using Pupillometric Biomarkers and Time Series Analysis. *Sci Rep*. 2021;11:16370.
- Zhang-James Y, Helminen EC, Liu J; ENIGMA-ADHD Working Group; Franke B, Hoogman M, Faraone SV. Evidence for similar structural brain anomalies in youth and adult attention-deficit/hyperactivity disorder: a machine learning analysis. *Transl Psychiatry*. 2021;11:82.
- Liu S, Zhao L, Wang X, Xin Q, Zhao J, Guttery DS, Zhang YD. Deep Spatio-Temporal Representation and Ensemble Classification for Attention Deficit/Hyperactivity Disorder. *IEEE Trans Neural Syst Rehabil Eng*. 2021;29:1-10.
- Peng X, Lin P, Zhang T, Wang J. Extreme learning machine-based classification of ADHD using brain structural MRI data. *PLoS One*. 2013;8:e79476.
- Yasumura A, Omori M, Fukuda A, Takahashi J, Yasumura Y, Nakagawa E, Koike T, Yamashita Y, Miyajima T, Koeda T, Aihara M, Tachimori H, Inagaki M. Applied Machine Learning Method to Predict Children With ADHD Using Prefrontal Cortex Activity: A Multicenter Study in Japan. *J Atten Disord*. 2020;24:2012-2020.
- Yeh SC, Lin SY, Wu EH, Zhang KF, Xiu X, Rizzo A, Chung CR. A Virtual-Reality System Integrated With Neuro-Behavior Sensing for Attention-Deficit/Hyperactivity Disorder Intelligent Assessment. *IEEE Trans Neural Syst Rehabil Eng*. 2020;28:1899-1907.
- Maniruzzaman M, Shin J, Hasan MAM. Predicting Children with ADHD Using Behavioral Activity: A Machine Learning Analysis. *Appl Sci*. 2022;12:2737.
- Altun S, Alkan A, Altun H. Application of deep learning and classical machine learning methods in the diagnosis of attention deficit hyperactivity disorder according to temperament features. *Concurr Comput Pract Exp*. 2022;34
- Aceves-Fernandez MA. Methodology proposal of ADHD classification of children based on cross recurrence plots. *Nonlinear Dyn*. 2021;104:1491-1505.
- Chang Y, Stevenson C, Chen IC, Lin DS, Ko LW. Neurological state changes indicative of ADHD in children learned via EEG-based LSTM networks. *J Neural Eng*. 2022;19.
- Zhao K, Duka B, Xie H, Oathes DJ, Calhoun V, Zhang Y. A dynamic graph convolutional neural network framework reveals new

- insights into connectome dysfunctions in ADHD. *Neuroimage*. 2022;246:118774.
34. Sidhu GS, Asgarian N, Greiner R, Brown MR. Kernel Principal Component Analysis for dimensionality reduction in fMRI-based diagnosis of ADHD. *Front Syst Neurosci*. 2012;6:74.
 35. Zou L, Zheng J, Miao C, Mckeown MJ, Wang ZJ. 3D CNN Based Automatic Diagnosis of Attention Deficit Hyperactivity Disorder Using Functional and Structural MRI. *IEEE Access*. 2017;5:23626-23636.
 36. Jung M, Tu Y, Park J, Jorgenson K, Lang C, Song W, Kong J. Surface-based shared and distinct resting functional connectivity in attention-deficit hyperactivity disorder and autism spectrum disorder. *Br J Psychiatry*. 2019;214:339-344.
 37. Zhang-James Y, Chen Q, Kuja-Halkola R, Lichtenstein P, Larsson H, Faraone SV. Machine-Learning prediction of comorbid substance use disorders in ADHD youth using Swedish registry data. *J Child Psychol Psychiatry*. 2020;61:1370-1379.
 38. Cervantes-Henríquez ML, Acosta-López JE, Martínez AF, Arcos-Burgos M, Puentes-Rozo PJ, Vélez JI. Machine Learning Prediction of ADHD Severity: Association and Linkage to ADGRL3, DRD4, and SNAP25. *J Atten Disord*. 2022;26:587-605.
 39. Liu Y, Qu HQ, Mentch FD, Qu J, Chang X, Nguyen K, Tian X, Glessner J, Sleiman P, Hakonarson H. Application of deep learning algorithm on whole genome sequencing data uncovers structural variants associated with multiple mental disorders in African American patients. *Mol Psychiatry*. 2022;27:1469-1478.
 40. Wang LJ, Kuo HC, Lee SY, Huang LH, Lin Y, Lin PH, Li SC. MicroRNAs serve as prediction and treatment-response biomarkers of attention-deficit/hyperactivity disorder and promote the differentiation of neuronal cells by repressing the apoptosis pathway. *Transl Psychiatry*. 2022;12:67.
 41. Kim JW, Sharma V, Ryan ND. Predicting Methylphenidate Response in ADHD Using Machine Learning Approaches. *Int J Neuropsychopharmacol*. 2015;18:pyv052.
 42. Uluyagmur-Ozturk M, Arman AR, Yilmaz SS, Findik OTP, Genc HE, Carkaxhiu-Bulut G. ADHD and ASD Classification Based on Emotion Recognition Data. *IEEE*. 2016:810-813.