



EEG sinyallerinden majör depresif bozukluğun yapay zekâ uygulamaları ile tespiti üzerine bir inceleme

Derya ÖZCAN^{1*}, Esmâ UZUNHİSARCIKLİ²

¹ Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri, Türkiye

² Yozgat Bozok Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Yozgat, Türkiye

MAKALE BİLGİSİ

Makale Tarihleri:

Geliş tarihi
22.07.2024
Kabul tarihi
01.10.2024
Yayın tarihi
31.12.2024

Anahtar Kelimeler:

Majör Depresif Bozukluk
Elektroensefalografi
Yapay Zekâ
Sinyal İşleme

ÖZET

Majör depresyon yaygın görülen bir ruh sağlığı bozukluğudur ve son yıllarda depresyonla mücadele önemli bir küresel sorun haline gelmiştir. Uzman, hastalık teşhisini psikometrik anketler ve kişiyle yaptığı görüşmeler neticesinde yapmaktadır. Fakat depresyon belirtilerinin somut olmaması, hastanın söylemleri ve tanımlanamayan semptomlar teşhisin doğruluğunu ciddi derecede etkilemektedir. Bu durum uzmanın tecrübesini daha önemli kalmaktadır. Objektif bir yöntemin geliştirilmesi erken ve doğru bir teşhis için uzmana yardımcı olmak ve tedavi sürecine de olumlu katkıda bulunmak açısından önem arz etmektedir. Bu çalışmada Elektroensefalografi sinyallerinin kullanılarak Majör Depresif Bozukluk tanısında Yapay Zekâ uygulamalarına ve diğer yöntemlere dayalı ayrıntılı literatür taraması verilmiştir. Yapılan bu inceleme sonucunda sinyal işleme ve öznel çıkarımında kullanılan yöntemler, uygulanan sınıflandırıcılar karşılaştırmalı bir tablo halinde verilmiştir. Ayrıca incelenen çalışmalardan yola çıkarak ileriye yönelik yapılacak çalışmalarla ilgili veri seti ve kullanılacak yöntemler hakkında ayrıntılı bilgilere yer verilmiş, daha yüksek doğruluk oranının elde edilmesi ve literatüre olumlu katkı sağlanması amaçlanmıştır.

EEG signaling of major depressive disorder a review on detection with artificial intelligence applications

ARTICLE INFO

Article history:

Received
22.07.2024
Accepted
01.10.2024
Published
31.12.2024

Keywords:

Major Depressive Disorder Electroencephalography
Artificial Intelligence
Signal Processing

ABSTRACT

Major depression is a common mental health disorder, and in recent years, combating depression has become a significant global issue. Experts diagnose the condition through psychometric questionnaires and interviews with patients. However, the lack of concrete symptoms, along with the patients' descriptions and undefined symptoms, severely impacts the accuracy of the diagnosis. This situation underscores the importance of the expert's experience. Developing an objective method is crucial for aiding experts in making early and accurate diagnoses, as well as positively contributing to the treatment process. This study presents a detailed literature review of artificial intelligence applications and other methods for diagnosing Major Depressive Disorder using Electroencephalography signals. The analysis includes a comparative table of the methods used in signal processing and feature extraction, as well as the classifiers applied. Additionally, based on the studies reviewed, detailed information is provided regarding datasets and methods for future research, aiming to achieve higher accuracy rates and make a positive contribution to the literature.

ORCID ID: Derya ÖZCAN: 0009-0008-1679-2977

*Sorumlu yazar(lar)/Corresponding author(s): Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri, Türkiye
E-mail: 4012230088@erciyes.edu.tr

Bu makaleye atıfta bulunmak için/To cite this article: Özcan, D ve Uzunhisarıklı, E "EEG sinyallerinden majör depresif bozukluğun yapay zekâ uygulamaları ile tespiti üzerine bir inceleme" Bozok Journal of Engineering and Architecture, vol. 3, no. 2, pp. 13-21, 2024.

1. GİRİŞ

Beyin, vücudu ve zihinsel fonksiyonları düzenleyen ve denetleyen karmaşık bir kontrol merkezidir. Aynı zamanda beyin; düşünme, mantık yürütme, sonuç çıkarma, duygusal tepkiler verme, bilişsel işlevler, dikkat, algı, hafıza ve öğrenme gibi çok çeşitli işlevleri yönetir [1]. Beyin içindeki sinir hücreleri, bu işlevlerin yerine getirilmesinden sorumludur. Bu sinir hücreleri, bilgi akışını birbirlerine sağlar ve sinir iletimi sonucunda beyin içinde biyoelektrik aktivite oluşturur. Sinir hücresi yani nöron; dentritler, hücre gövdesi (soma) ve akson olmak üzere üç ana kısımdan oluşmaktadır. Uç düğümler ise aksonun sonunda bulunan küçük yumrulardır. Bu uç düğümler ile bağlantı yapılacak dendritler arasında sinaps adı verilen boşluklar bulunur. Sinyalin iletimi, uç düğümlerinden sinapsa nörotransmitter adı verilen kimyasal bileşiklerin salınmasıyla gerçekleşir. Nörotransmitterler, mesaj taşımak için özel olarak üretilmiş kimyasal yapılardır [2].


Beyin yapısını ve işlevlerini incelemek için birçok farklı teknik mevcuttur. Bu teknikler yapısal ve fonksiyonel görüntüleme olarak iki ana kategoriye ayrılır. Elektroensefalografi (EEG) bir fonksiyonel görüntüleme çeşididir. EEG, beyindeki elektriksel aktivitenin non-invaziv bir şekilde incelenmesi için kullanılan elektrofizyolojik izleme yöntemidir [3]. Bu yöntem beyin yapısı özelliklerinden çok ölçüm sırasındaki fonksiyonel durumunu göstermektedir. Beynin elektriksel aktivitesinin gözlemlenmesi ve araştırılmasında kullanılan EEG ile uyku bozuklukları, nörolojik hastalıklar ve zihinsel sağlık sorunları gibi çeşitli patolojilerin teşhisini desteklemek mümkün olabilmektedir. EEG, klinik araştırmalarda ve nörobilim çalışmalarında yaygın bir şekilde kullanılmaktadır [4].

1.1. Elektroensefalografi (EEG)

EEG beyin elektriksel aktivitesinin kayıdır. 1924 yılında Alman nörolog Hans Berger EEG alanına önemli katkılarda bulunmuştur. Beyin elektrik aktivitesini insanın saç derisi üzerinden ölçmek için sıradan radyo ekipmanını kullanmıştır. Berger, beyinde üretilen zayıf elektrik akımlarının kafatası açılmadan kaydedilebileceğini göstermiştir. Bu aktiviteyi bir kâğıt şeridi üzerine grafiksel olarak göstermiştir. Böylece birçok modern EEG uygulamasının temellerini atmıştır ve "elektroensefalogram" terimini ilk kez insanlardaki beyin elektrik potansiyellerini tanımlamak için kullanmıştır [5].

EEG cihazı elektrotlardan, iletken jelinden, amplifikatörlerden ve Analog-Dijital dönüştürücülerden oluşur. Elektrotlar, beyin derisinin yüzeyinden gelen elektriksel aktiviteyi iletmek için kullanılır ve aktif elektrot, referans elektrot ve toprak elektrot olarak adlandırılan üç elektrot grubundan oluşur. EEG işaretleri, aktif elektrot ile referans elektrot arasındaki potansiyel farkı ölçerek kaydedilir. Toprak elektrot, referans elektrot ile aynı seviyede tutularak aktif elektrot ile referans elektrot arasındaki gerilim farkını ölçer. EEG ölçümü, bu minimum konfigürasyon kullanılarak gerçekleştirilir [6].






EEG ölçümü, uluslararası düzeyde kabul görmüş 10-20 elektrot konum sistemi kullanılarak yapılmaktadır. Bu yöntem standartlaştırılmış tekrarlanabilirliği sağlamak amacıyla geliştirilmiştir [7]. Bu sistemde "10" ve "20", bitişik elektrotlar arasındaki gerçek mesafelerin, kafatasının toplam ön-arka veya sağ-sol mesafesinin %10 veya %20'si olduğu gerçeğini ifade eder [8].



Şekil 1. 10-20 Uluslararası Elektrot Yerleşim Sistemi [9]

EEG sinyallerinin genliği tepeden tepeye 1–100 μ V ve frekans bandı ise 0.5- 100 Hz (ancak genellikle ilgilenilen alan 30 Hz'in altındadır) aralıklarındadır. EEG sinyalleri durağan olmayan sinyaller olup genlik, faz ve frekans bakımından zaman içerisinde değişmektedir [10]. Tablo 1'de EEG sinyallerinin alt bantlarına ait özellikler verilmiştir.

Tablo 1. EEG sinyal alt bantları

Dalga Tipi	Frekans Aralığı (Hz)	Gözlemlenen Durumlar	Sinyal Örneği
Delta	0.5-4	Derin uyku	
Teta	4-8	REM uykusu	
Alfa	8-13	Gözler kapalı dinlenme	
Beta	13-30	Zihinsel aktivite	
Gama	>30	Tüm beyin aktivitesi	

1.2. Majör Depresif Bozukluk (MDB)

Majör depresif bozukluk (MDB), depresyonun en yaygın ve belirgin türlerinden biridir. Majör depresyon, beynin normal işlevlerinde bozulmalar ve düşünce, davranış ve bedensel işlevlerde önemli değişikliklerin gözlemlendiği bir psikiyatrik bozukluktur [11]. Dünya genelinde yaklaşık 280 milyon insan depresyonla mücadele etmektedir. Bu rakam yaklaşık olarak dünya nüfusunun %3.8'ine karşılık gelir. Her yıl 700.000'den fazla insan intihar nedeniyle yaşamını yitirmektedir. İntihar, 15-29 yaş aralığındaki insanlar için ölümün dördüncü en yaygın nedenidir. Bu istatistikler depresyonun dünya genelinde ciddi bir halk sağlığı sorunu olduğunu göstermektedir [12]. MDB tanılı hastalar olumsuz olaylara karşı abartılı tepkiler verebilir ancak MDB sadece duygusal belirtilerle sınırlı kalmaz. Bilişsel işlev bozukluğu MDB tanısı için önemli ana kriterlerden biridir. Bilişsel işlevler; psikomotor hız, dikkat, bellek, yürütücü işlevler gibi konuları kapsamaktadır [13]. Sinir bilimi, psikoloji ve bilişsel bilim alanlarında yapılan araştırmalar EEG kullanarak psikolojik aktivitelerin ve bilişsel davranışların ölçülebileceğini göstermiştir. Bu nedenle bilişsel işlev bozukluğu, uykusuzluk, uyku bozukluğu gibi hastalık semptomlarının; psikoz, anksiyete ve depresyon gibi zihinsel bozuklukların teşhisinde objektif bir fizyolojik yöntem olarak EEG kullanılmaktadır [14].

1.3. MDB ve EEG İlişkisi

MDB hastalığının tespiti, uzman ile kişinin yüz yüze görüşmesi ve psikometrik anketler gibi subjektif yöntemlerle mümkündür. Hastalar kişilik yapısına bağlı olarak depresyonu farklı şekilde ifade edebilmektedir. Bazıları daha çok ruhsal şikayetler ile bazıları ise fiziksel şikayetlerle uzmana başvurmaktadır. Ancak hastalık belirtilerinin çoğunlukla soyut olması doğru teşhisin konulmasını zorlaştırmaktadır. Bu nedenle başvuru uzmanın yetkinliğinin ve belirtilerin doğru analiz edilmesinin önemi daha da artmaktadır [15]. Bilişsel işlev bozukluğu MDB tanısı için önemli ana kriterlerden biridir. Bilişsel işlevler çoğunlukla beyinde frontal lob ve prefrontal korteks ile ilişkilidir ve dikkat, algı, bellek gibi temel fonksiyonlarla bağlantı kurar. Beynin bilişsel işlev ile ilgili bu alanları MDB tanılı hastalarda etkilenmektedir [16]. Zihinsel işlevlerdeki herhangi bir bozulma beyin biyoelektriksel aktivitesini etkiler ve bu durum EEG ile alınan sinyallerde gözlemlenebilir. Literatürdeki EEG sinyallerine dayalı depresyon tespiti çalışmalarında hastaların sağlıklı bireylerden elektrofizyolojik açıdan farklı olduğu sonuçları elde edilmiştir [17]. Bu sebeplerden dolayı tanıya yönelik mevcut yöntemlere ek objektif ve yaygın bir teşhis yöntemi ihtiyacı fark edilmektedir. EEG verileri ile depresyonun tespit edilmesi, erken ve doğru teşhis ile tedavi sürecine olumlu katkı sağlayarak uzmana yardımcı olmak açısından büyük önem taşımaktadır. Yapılan literatür taramasında elde edilen bulgulara ait tablo aşağıda verilmiştir:

Tablo 2. Literatürdeki çalışmalar


Çalışma	Yıl	Veri Seti ve Yöntemler	Sınıflandırıcı	Doğruluk / Sonuç
Knott ve ark. [18]	2001	<ul style="list-style-type: none"> 23 normal ve 70 depresif erkek birey Güç, Frekans, Asimetri ve Koherans 	İstatistiksel Analiz	%91,3
Hinrikus ve ark. [19]	2009	<ul style="list-style-type: none"> 18 normal ve 18 depresif birey SASI, Inter-Hemisferik Asimetri ve Koherans 	İstatistiksel Analiz	SASI, depresif ve kontrol gruplarını açıkça ayırmaktadır. ($p<0,005$)
Puthankattil ve ark. [20]	2012	<ul style="list-style-type: none"> 15 normal ve 15 depresif birey Relative Wavelet Energy Entropi 	YSA	%98,11
Hosseinifard ve ark. [21]	2013	<ul style="list-style-type: none"> 45 normal ve 45 depresif birey Lineer olmayan öznelikler Öznelik seçimi 	LR	%90
Faust ve ark. [22]	2014	<ul style="list-style-type: none"> 15 normal ve 15 depresif birey Wavelet Packet Decomposition Entropi 	PNN	%99,5
Acharya ve ark. [23]	2015	<ul style="list-style-type: none"> 15 normal ve 15 depresif birey Lineer olmayan öznelikler Öznelik seçimi 	SVM	%98
Li ve ark. [24]	2016	<ul style="list-style-type: none"> 10 normal ve 10 depresif birey Lineer ve lineer olmayan öznelikler Öznelik seçimi 	SVM	Duygusal: %91,70 Nötr: %96
Mohan ve ark. [25]	2016	<ul style="list-style-type: none"> 53 normal ve 63 depresif birey Fast Fourier Transform 	YSA	%90
Liao ve ark. [26]	2017	<ul style="list-style-type: none"> 12 normal ve 12 depresif birey Principal Component Analysis 	SVM	%81,23
Mümtaz ve ark. [27]	2017	<ul style="list-style-type: none"> 30 normal ve 33 depresif birey Asimetri 	SVM	%98,4
Acharya ve ark. [28]	2018	<ul style="list-style-type: none"> 15 normal ve 15 depresif birey 13 Katmanlı CNN 	CNN	Sağ: %95,96 Sol: %93,54
Mahato ve ark. [29]	2018	<ul style="list-style-type: none"> 30 normal ve 30 depresif birey Bant geçiren filtre Independent Component Analysis 	SVM	%88,33
Cai ve ark. [30]	2018	<ul style="list-style-type: none"> 121 normal ve 92 depresif birey Finite Impulse Response 	KNN	%79,27
Ay ve ark. [31]	2019	<ul style="list-style-type: none"> 15 normal ve 15 depresif birey End-to-end 	CNN-LSTM	Sağ: %99,12 Sol: %97,66
Duan ve ark. [32]	2020	<ul style="list-style-type: none"> 16 normal ve 16 depresif birey Finite Impulse Response Independent Component Analysis 	CNN	%94,13
Saeedi ve ark. [33]	2020	<ul style="list-style-type: none"> 30 normal ve 34 depresif birey Bant Geçiren Filtre ve Wavelet 	EKNN	%98,44

İzci ve ark. [34]	2021	<ul style="list-style-type: none"> 16 normal ve 16 depresif birey Bant Geçiren ve Çentik Filtre 	Torbalama	%89,5
Raghavendra ve ark. [35]	2021	<ul style="list-style-type: none"> 15 normal ve 15 depresif birey Continuous Wavelet Transform 	Optimize edilebilir SVM	Sağ: %99,33 Sol: %99,13
Sun ve ark. [36]	2022	<ul style="list-style-type: none"> 30 normal ve 34 depresif birey Bant Geçiren ve Çentik Filtre 	CN-GCN	%99,29
Zhu ve ark. [37]	2022	<ul style="list-style-type: none"> 28 normal ve 27 depresif birey Finite Impulse Response 	GCN	%96,50
Chen ve ark. [38]	2023	<ul style="list-style-type: none"> 30 normal ve 34 depresif birey Bant Geçiren Filtre ve ICA 	LG-GCN	%99,30
Zhang ve ark. [39]	2023	<ul style="list-style-type: none"> 29 normal ve 24 depresif birey Bant Geçiren Filtre Ayrık Dalgacık Dönüşümü 	CNN	%95,87

2. MATERYAL ve METOT

2.1. Veri Seti

Yapılması hedeflenen çalışmada Çin/Gansu’da bulunan Lanzhou Üniversitesi İkinci Hastanesi’nde yapılan bir deney ile açık erişime sunulan; MDB hastalarına ve sağlıklı bireylere ait görsel uyaranlar sonucunda elde edilen EEG sinyallerini içeren veri seti kullanılacaktır. Bu katılımcılara, depresyon tanısı almış 24 ayakta tedavi hastası (13 erkek ve 11 kadın; 16-56 yaş arası) ve 29 sağlıklı kontrol (20 erkek ve 9 kadın; 18-55 yaş arası) dahil edilmiştir. Veri setinde 53 katılımcının EEG sinyalleri hem dinlenme halinde hem de nokta prob görevlerini yaparken kaydedilmiştir. İki durumda da katılımcılardan başları da dahil olmak üzere bedensel hareket ve gereksiz göz hareketleri yapmadan uyanık ve hareketsiz kalmaları istenmiştir. Dinlenme durumunda 5 dakika gözler kapalıyken EEG verisi kaydedilmiştir. Nokta prob görevinde ise katılımcılar 17 inçlik, 1280x1024 çözünürlük ve 60 Hz yenileme hızına sahip monitörün önüne 60 cm mesafede oturtulmuştur. Deney başladığında katılımcılardan tüm dikkatlerini duygusal-nötr yüz çiftlerine odaklamaları istenmiştir. Nokta görüldüğünde ise tepki kutusundaki düğmeye mümkün olduğunca hızlı ve doğru bir şekilde basmaları istenmiştir. Görev üç bloktan (korku-nötr, üzgün-nötr ve mutlu-nötr) oluşmaktadır. Her blokta 160 deneme bulunmaktadır. Her denemenin başlangıcında merkezi ekranda 300 ms sabit beyaz bir artı işareti belirmiştir. Daha sonra artı işareti ekranda merkezi olarak gösterilmiştir. Duygusal-nötr yüz uyaran çifti (çiftler rastgele bir sıraya göre düzenlenmiştir) 500 ms boyunca bir ipucu olarak ekranda gösterilmiştir. 100-300 ms’lik kısa bir aradan sonra nokta prob 150 ms boyunca sabit artı işaretinin sol veya sağ konumunda rastgele bir hedef olarak görünmüştür. Eş zamanlı olarak katılımcılardan ‘nokta’nın uzaysal konumunu belirleyerek tepki kutusu üzerindeki ‘1’ veya ‘4’ düğmesine mümkün olduğunca hızlı basmaları istenmiştir. Nokta sabit artı işaretinin solunda ise katılımcı ‘1’ tuşuna; sağında ise katılımcı ‘4’ tuşuna basmalıdır. Katılımcıların yanıtını almak için 2000 ms’lik otomatik aralık kullanılmıştır. Aksi halde katılımcılar bir sonraki denemeye yönlendirilmiş ve ardından 600 ms boyunca siyah bir ekran gösterilmiştir. İşlem bir blok tamamlanana kadar kademeli olarak devam etmiştir. Her blok tüm görev bitene kadar çalıştırılmış ve görevin tamamı yaklaşık 25 dakikada bitirilmiştir. Nokta prob görevinin deney sıralaması Şekil 2’de gösterilmiştir [40].



Şekil 2. Nokta Prob Görevi Deney Sıralaması

2.2. Sinyal Ön İşleme

Sayısal sinyal işleme, bir sinyalin frekans spektrumunda belirli frekanslarda hedeflenen işlemleri gerçekleştirerek istenen özelliklere sahip sonuçlar elde etmeyi amaçlar. Sonlu dürtü yanıtı filtreler (FIR), dijital sinyal işleme için kullanılan bir filtreleme tekniğidir ve sinyalleri işlemek için uygulanır. Bağımsız Bileşen Analizi (BBA), çok değişkenli istatistiksel bir yöntem olup EEG sinyallerinin ön işleme aşamalarından biridir. BBA, EEG sinyallerini bileşenlerine ayrıştırarak karmaşık bileşenleri birbirinden bağımsız hale getirir [41].

2.3. Öznitelik Çıkarımı ve Seçimi

Öznitelik çıkarma, veri boyutunu azaltmak için kullanılan bir tekniktir. Bu süreç, makine öğrenmesi modelinin eğitim sürecinde kaynakları daha verimli kullanarak modelin performansını artırabilir. Makine öğrenmesi uygulamalarında, kullanılacak özneliklerin çıkarılması ve seçilmesi modelin sınıflandırma başarısını büyük ölçüde etkiler.

Bir sinyal genellikle çeşitli frekans bileşenlerinin toplamından oluşur. Bu bileşenler farklı frekanslara sahip olabilir ve her birinin gücü değişiklik gösterebilir. EEG analizlerinde kullanılan Shannon entropisi, sinyalde gözlemlenen genlik değerlerinin olasılık dağılımına dayanarak EEG'nin gelecekteki genlik değerlerinin tahmin edilebilirliğini ölçer. Hjorth parametreleri, bir sinyalin istatistiksel özelliklerini zaman ekseninde gösterir ve sinyallerin aktivite, hareketlilik ve karmaşıklık özelliklerini incelemeye olanak tanır. Fraktal boyut analizi, EEG analizi de dahil olmak üzere biyomedikal sinyal işlemlerinde yaygın olarak kullanılan bir yöntemdir. Bu analiz, sinyalin zaman alanındaki karmaşıklığının doğrusal olmayan bir ölçüsü olarak tanımlanır.

Öznitelik seçimi aşamasında sınıflandırma sürecinin karmaşıklığını azaltmak için tüm verilerin temsili bir alt kümesi seçilir ve bu sayede sınıflandırma süreci geliştirilebilir. Ki-kare testi, literatürde yaygın olarak kullanılan öznitelik seçme yöntemlerinden biridir. Bu yöntemde, ayrıklaştırılan değişkenlerdeki ki-kare değerleri hesaplanır ve en yüksek değerlere sahip olanlar seçilerek özellik seçimi gerçekleştirilir [42].

2.4. Sınıflandırma

Sınıflandırma, insan beynindeki karar verme süreçlerinin makine dilindeki karşılığıdır. Klasik sınıflandırıcılar, istatistiksel ve matematiksel özellikleri kullanarak bir modele bağlı olarak karşılık gelen sınıf etiketlerini belirlerler.

Yapay Sinir Ağları (YSA), insan beynindeki nöronlara benzer şekilde çalışan birimlerden oluşur. YSA; genellikle giriş katmanı, gizli katman(lar) ve çıkış katmanı gibi ardışık katmanlardan meydana gelir. Her katmandaki nöronlar, bir önceki katmandaki nöronlarla bağlantılıdır. Giriş katmanına verilen veriler gizli katmanlarda işlenir ve sonuç çıkış katmanında elde edilir. Bu, modelin tahmin ettiği değer veya sınıflandırmadır. Bu süreçte, her katmandaki birimlerin ağırlıkları öğrenme algoritmaları ile ayarlanır ve böylece ağ eğitilmiş olur. Sonuç olarak YSA, verileri işlerken öğrenme ve genelleme yeteneği kazanarak çeşitli görevleri yerine getirme kapasitesine sahip hale gelir [43].

Destek Vektör Makineleri (SVM), veri kümesini farklı çekirdek fonksiyonları kullanarak hiper düzlemler aracılığıyla bölen bir yöntemdir. Verinin özelliklerine bağlı olarak uygun çekirdek fonksiyonları seçilebilir. SVM, farklı veri gruplarını ayıran sınıf sınırlarını oluşturur. Bu sınıf sınırları sınıfa ait tüm verileri kapsayan ve mümkün olduğunca uzak noktalardan geçen hiper düzlemlerle belirlenir. Bu düzlemler sayesinde yeni verilerin hangi sınıf sınırları içinde yer aldığı belirlenir ve bu verilere sınıf etiketleri atanır. Bu işlemden sonra sınıf sınırları yeniden düzenlenir. SVM, düzenleme parametresi adı verilen bir parametre kullanarak oluşturulan sınıf sınırlarında etkili bir genelleştirme sağlar. Bu sayede SVM, aşırı öğrenmeye ve veriye özgü model oluşumuna karşı dirençli olup yüksek genelleştirme yeteneğine sahiptir [44].

Rastgele Orman (RO), özneliklerin rastgele seçildiği bir makine öğrenmesi topluluk yöntemidir. Bu yöntem hızlı, hassas ve gürültüye dayanıklı bir sınıflandırma sağlar. Bir Karar Ağacı oluşturulurken özneliklerin bir alt kümesi rastgele seçilir ve her ağaç bağımsız olarak bir sınıflandırma tahmininde bulunarak ilgili sınıf için oy verir. Birkaç Karar Ağacının kullanımı tek bir Karar Ağacının çıktısına göre daha az gürültü ve aykırı değerlere karşı daha az duyarlıdır, bu da küçük veri setlerinden kaynaklanan değişkenliği azaltır ve tahminlerin güvenilirliğini artırır. Bu nedenle, tıbbi veri setleri için RO tercih edilen bir yöntemdir [45].

3. BULGULAR ve TARTIŞMA

Modelin sınıflandırma performansını değerlendirmek için kullanılan ölçütler, karmaşıklık matrisinden elde edilir. Bu matris, sınıflandırılan verilerin doğru veya yanlış olarak hangi sınıfa atandığını göstererek modelin başarısını değerlendirir. Sınıflandırıcı belirli tekniklerle test edildikten sonra karmaşıklık matrisi kullanılarak modelin performansını ölçmek için çeşitli önemli parametreler hesaplanır.

Doğruluk, sınıflandırıcının her iki sınıf için de doğru tahmin ettiği örnek sayısının toplam örnek sayısına oranıdır.

Duyarlılık (hassasiyet), sınıflandırıcının 1 numaralı sınıfı doğru tahmin ettiği örnek sayısının gerçek 1 numaralı sınıfa ait olan toplam örnek sayısına oranıdır.

Özgüllük, sınıflandırıcının 0 numaralı sınıfı doğru tahmin ettiği örnek sayısının gerçek 0 numaralı sınıfa ait olan toplam örnek sayısına oranıdır.

Kesinlik (pozitif kestirim doğruluğu), sınıflandırıcının 1 numaralı sınıfı doğru tahmin ettiği örnek sayısının 1 numaralı sınıf olarak tahmin edilen toplam örnek sayısına oranıdır [46].

4. SONUÇLAR

Literatürde incelenen çalışmalar neticesinde Tablo 2’de yer alan doğruluk oranları bize elde edilen sonuçların anlamlı olduğunu göstermektedir. Hangi öznelikler kullanıldığında ve hangi sınıflandırıcı yöntemleri uygulandığında daha başarılı sonuçlar elde edildiği gözlemlenmiştir. Bu kapsamda doğruluk oranlarını artıracak sınıflandırma yöntemleri kullanılarak hazır veri seti ile bir çalışma yapılması planlanmaktadır. Kullanılacak veri setindeki ham EEG sinyallerine ön işleme, öznelik çıkarımı, öznelik seçimi ve sınıflandırma olarak sinyal işleme prosedürleri uygulanacaktır. Ön işleme aşamasında FIR filtre ve ICA uygulanacaktır. Öznelik çıkarımı aşamasında her EEG sinyali için frekans özellikleri, entropi, kompleksite, fraktal boyut ve Hjort parametreleri öznelik olarak belirlenecektir. Ki-kare yöntemi kullanarak sınıflandırma aşamasında kullanılacak öznelik seçiminin yapılması planlanmaktadır. Üç farklı sınıflandırma algoritması kullanılacaktır: YSA, SVM ve RF. Bu sınıflandırıcılara ait doğruluk, kesinlik ve hassasiyet parametreleri kıyaslanacaktır. Sonuç olarak elde edilen en yüksek performansa sahip yöntem belirlenecektir.

53 katılımcının EEG sinyallerinin analiz edilmesi planlanan bu çalışmada kullanılacak yöntemlerle doğruluk, kesinlik ve hassasiyet parametrelerinin iyileştirilmesi hedeflenmektedir. Ayrıca EEG sinyallerine uygulanacak sinyal işleme adımları ve yapay zekâ teknikleri açısından da literatüre katkı sağlanacaktır.

YAZAR KATKILARI

1. yazar %70, 2. yazar %30

ÇIKAR ÇATIŞMASI

Bu çalışmada herhangi bir kurum, kuruluş, kişiler ve yazarlar arasında çıkar çatışması bulunmamaktadır.

ETİK

Bu makalenin yayınlanmasında herhangi bir etik sorun bulunmamaktadır.

KAYNAKLAR

- [1] E. Keleş ve E. Kol, «An Overview of the Brain Imaging Techniques from the,» *Elementary Education Online*, cilt 14, no. 1, p. 349- 363, 2015.
- [2] P. A. Young, P. H. Young ve D. L. Tolbert, *Basic Clinical Neuroscience*, Lippincott Williams & Wilkins, 2008.
- [3] N. V. Thakor ve S. Tong, «Advances in Quantitative Electroencephalogram Analysis Methods,» *Annual Review of Biomedical Engineering*, no. 6, pp. 453-495, 2004.
- [4] «Mayfield Brain & Spine,» [Çevrimiçi]. Available: <https://mayfieldclinic.com/pe-anatbrain.htm>. [Erişildi: Temmuz 2024].
- [5] M. Teplan, «Fundamentals Of Eeg Measurement,» *Measurement in Biomedicine*, cilt 2, no. 2, 2002.
- [6] J. S. Kumar ve P. Bhuvaneshwari, «Analysis of Electroencephalography (EEG) Signals and Its Categorization–A Study,» *Procedia Engineering*, no. 38, pp. 2525-2536, 2012.
- [7] P. L. Nunez ve R. Srinivasan, «Electroencephalogram,» 2007. [Çevrimiçi]. Available: <http://www.scholarpedia.org/article/Electroencephalogram>. [Erişildi: Eylül 2024].
- [8] M. Khazi, A. Kumar ve V. M J, «Analysis of EEG Using 10:20 Electrode System,» *International Journal of Innovative Research in Science, Engineering and Technology*, cilt 2, no. 1, 2012.
- [9] D. Silverman, «The Rationale and History of the 10-20 System of the International Federation,» *American Journal of EEG Technology*, cilt 1, no. 3, pp. 17-22, 2015.
- [10] D. L. Schomer ve F. H. Lopes da Silva, *Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*, Lippincott Williams & Wilkins, 2011.
- [11] L. Heimer, *The Human Brain and Spinal Cord: Functional Neuroanatomy and Dissection Guide*, Springer Science & Business Media, 2012.

- [12] W. H. Organization, «World Health Organization,» 31 Mart 2023. [Çevrimiçi]. Available: <https://www.who.int/news-room/fact-sheets/detail/depression>. [Erişildi: Eylül 2024].
- [13] P. Gorwood, E. Corruble ve B. Falissard, «Toxic Effects of Depression on Brain Function: Impairment of Delayed Recall and the Cumulative Length of Depressive Disorder in a Large Sample of Depressed Outpatients,» *American Journal of Psychiatry*, cilt 6, no. 165, 2008.
- [14] S. Salık, Soner Çakmak ve Şükrü Uğuz, «Tedavi almamış major depresyon hastalarında erken dönemde bilişsel işlevler,» *Klinik Psikiyatri Dergisi*, no. 22, pp. 408-415, 2019.
- [15] P. A. Young, Paul Henry Young ve D. L. Tolbert, *Basic Clinical Neuroscience*, Lippincott Williams & Wilkins, 2008.
- [16] M. D. Lezak, *Neuropsychological Assessment*, Oxford University Press, 2004.
- [17] E. Mtui, G. Gruener ve P. Dockery, *Fitzgerald's Clinical Neuroanatomy and Neuroscience E-Book*, Elsevier Health Sciences, 2020.
- [18] V. Knott, C. Mahoney, S. Kennedy ve K. Evans, «EEG power, frequency, asymmetry and coherence in male depression,» *Psychiatry Research: Neuroimaging Section*, no. 106, pp. 123-140, 2001.
- [19] H. Hinrikus, A. Suhhova ve M. Bachmann, «Electroencephalographic spectral asymmetry index for detection of depression,» *Med Biol Eng Comput*, no. 47, pp. 1291-1299, 2009.
- [20] S. D. Puthankattil ve P. K. Joseph, «Classification Of Eeg Signals In Normal And Depression Conditions By Ann Using Rwe And Signal Entropy,» *Journal of Mechanics in Medicine and Biology*, cilt 12, no. 4, 2012.
- [21] B. Hosseinifard, M. H. Moradi ve R. Rostami, «Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal,» *computer methods and programs in biomedicine*, no. 109, pp. 339-345, 2013.
- [22] O. Faust, P. C. Alvin Ang ve S. D. Puthankattil, «Depression Diagnosis Support System Based On Eeg Signal Entropies,» *Journal of Mechanics in Medicine and Biology*, cilt 3, no. 14, 2014.
- [23] U. R. Acharya, V. K. Sudarshan ve H. Adeli, «Computer-Aided Diagnosis of Depression Using EEG Signals,» *European Neurology*, no. 73, 2015.
- [24] X. Li, B. Hu, S. Sun ve H. Cai, «EEG-based mild depressive detection using feature selection methods and classifiers,» *computer methods and programs in biomedicine*, no. 136, pp. 151-161, 2016.
- [25] Y. Mohan, S. S. Chee ve D. K. Pei Xin, «Artificial Neural Network for Classification of Depressive and Normal in EEG,» %1 içinde *2016 IEEE EMBS Conference on Biomedical Engineering and Sciences*, 2016.
- [26] S.-C. Liao, C.-T. Wu ve H.-C. Huang, «Major Depression Detection from EEG Signals Using Kernel Eigen-Filter-Bank Common Spatial Patterns,» *Sensors*, no. 17, 2017.
- [27] W. Mumtaz, L. Xia ve S. S. Azhar Ali, «Electroencephalogram (EEG)-based computer-aided technique to diagnose major depressive disorder (MDD),» *Biomedical Signal Processing and Control*, no. 31, pp. 108-115, 2017.
- [28] U. R. Acharya, S. Lih Oh ve Y. Hagiwara, «Automated EEG-based screening of depression using deep convolutional neural network,» *Computer Methods and Programs in Biomedicine*, no. 161, pp. 103-113, 2018.
- [29] S. Mahato ve S. Paul, «Classification of Depression Patients and Normal Subjects Based on Electroencephalogram (EEG) Signal Using Alpha Power and Theta Asymmetry,» *Journal of Medical Systems*, cilt 28, no. 44, 2020.
- [30] H. Cai, J. Han ve Y. Chen, «A Pervasive Approach to EEG-Based Depression Detection,» *Hindawi Complexity*, 2018.
- [31] B. Ay, O. Yildirim ve M. Talu, «Automated Depression Detection Using Deep Representation and Sequence Learning with EEG Signals,» *Journal of Medical Systems*, cilt 43, no. 205, 2019.
- [32] L. Duan, H. Duan ve Y. Qiao, «Machine Learning Approaches for MDD Detection and Emotion Decoding Using EEG Signals,» *Frontiers in Human Neuroscience*, cilt 284, no. 14, 2020.
- [33] M. Saeedi, A. Saeedi ve A. Maghsoud, «Major depressive disorder assessment via enhanced k-nearest neighbor method and EEG signals,» *Physical and Engineering Sciences in Medicine*, no. 43, pp. 1007-1018, 2020.
- [34] E. İzci, . M. A. Özdemir ve A. Akan, «Majör Depresif Bozukluğun Tespiti için EEG ve Makine Öğrenmesi Tabanlı Bir Yöntem,» *ResearchGate*, 2021.
- [35] U. Raghavendra, A. Gudigar ve Y. Chakole, «Automated detection and screening of depression using continuous wavelet transform with electroencephalogram signals,» *Wiley Expert Systems*, pp. 1-20, 2021.
- [36] X. Sun, Chao Ma ve P. Chen, «A Novel Complex Network-Based Graph Convolutional Network in Major Depressive Disorder Detection,» *Ieee Transactions On Instrumentation And Measurement*, no. 71, 2022.
- [37] J. Zhu, C. Jiang ve J. Chen, «EEG based depression recognition using improved graph convolutional neural network,» *Computers in Biology and Medicine*, no. 148, 2022.
- [38] Y. Chen, X. Hu ve L. Xia, «A Local-Global Graph Convolutional Network for Depression Recognition using EEG Signals,» *International Journal of Advanced Computer Science and Applications*, cilt 7, no. 14, 2023.
- [39] B. Zhang, D. Wei ve G. Yan, «Spatial–Temporal EEG Fusion Based on Neural Network for Major Depressive Disorder Detection,» *Interdisciplinary Sciences: Computational Life Sciences*, 2023.

- [40] HanshuCai, Z. Yuan, Y. Gao ve S. Sun, «A multi-modal open dataset for mental-disorder analysis,» *Scientific Data* /, cilt 9, no. 178, 2022.
- [41] F. Cong, T. Ristaniemi ve H. Lyytinen, *Advanced Signal Processing On Brain Event-related Potentials: Filtering Erps In Time, Frequency And Space Domains Sequentially And Simultaneously*, World Scientific, 2015.
- [42] F. Çifçi, C. Kaleli ve S. Günel, «Öznitelik Seçme ve Makine Öğrenmesi Yöntemleriyle Eğitim Performansının Tahmin Edilmesi,» *Anadolu Journal of Educational Sciences International*, cilt 8, no. 2, pp. 419-440, 2018.
- [43] S. B. Maind ve P. Wankar, «Research Paper on Basic of Artificial Neural Network,» *International Journal on Recent and Innovation Trends in Computing and Communication*, cilt 1, no. 2, 2014.
- [44] S. Gunn, *Support Vector Machines, Image Speech and Intelligent Systems Group*, 1997.
- [45] V. Podgorelec, P. Kokol ve B. Stiglic, «Decision Trees: An Overview and Their Use in Medicine,» *Journal of Medical Systems*, no. 26, pp. 445-463, 2002.
- [46] A.-M. Šimundić, «Measures of Diagnostic Accuracy: Basic Definitions,» *Ejyfcc*, cilt 19, no. 4, pp. 203-211, 2009.