

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/353429549>

Majör Depresif Bozukluğun Tespiti için EEG ve Makine Öğrenmesi Tabanlı Bir Yöntem (An EEG and Machine Learning based Method for the Detection of Major Depressive Disorder)

Conference Paper · July 2021

DOI: 10.1109/SIU53274.2021.9477800

CITATIONS

0

READS

20

5 authors, including:



Elif İzci

TENMAK

10 PUBLICATIONS 46 CITATIONS

SEE PROFILE



Mehmet Akif Özdemir

Izmir Katip Celebi Universitesi

31 PUBLICATIONS 93 CITATIONS

SEE PROFILE



Aydin Akan

Izmir University of Economics

349 PUBLICATIONS 1,632 CITATIONS

SEE PROFILE



Mehmet Akif Özçoban

İstanbul Gedik Üniversitesi

15 PUBLICATIONS 6 CITATIONS

SEE PROFILE

Some of the authors of this publication are also working on these related projects:



Motion Capture [View project](#)



Stigmatization Parameters in a Turkish sub-population [View project](#)

Majör Depresif Bozukluğun Tespiti için EEG ve Makine Öğrenmesi Tabanlı Bir Yöntem

An EEG and Machine Learning based Method for the Detection of Major Depressive Disorder

Elif İZCİ¹, Mehmet Akif ÖZDEMİR^{1,2}, Aydın AKAN³, Mehmet Akif ÖZÇOBAN⁴ ve Mehmet Kemal ARIKAN⁵

¹Biyomedikal Teknolojiler Programı, ²Biyomedikal Mühendisliği Bölümü,

³Elektrik-Elektronik Mühendisliği Bölümü, ⁴Teknik Bilimler MYO Elektronik ve Otomasyon Bölümü

^{1,2}İzmir Katip Çelebi Üniversitesi, ³İzmir Ekonomi Üniversitesi, ⁴Gaziantep Üniversitesi, ⁵Üsküdar Üniversitesi

^{1,2,3}İzmir, ⁴Gaziantep, ⁵İstanbul, Türkiye

elif.950@gmail.com, makif.ozdemir@ikcu.edu.tr, akan.aydin@ieu.edu.tr, mehmetakif@gantep.edu.tr, mkarikan46@gmail.com

Özetçe—Majör depresif bozukluk (MDD), dünya genelinde sıklıkla görülen bir duygu durum hastalığıdır. Hastalığın belirtileri kişiyi olumsuz etkilediği için erken teşhisi ve tedaviye başlanması büyük önem taşımaktadır. Bu çalışmanın amacı, MDD hastalarının sağlıklı bireylerden ayrılmasını sağlayan objektif bir yöntem geliştirmektir. 16 MDD hastası ve 16 sağlıklı bireyden alınan Elektroensefalografi (EEG) sinyalleri beyin bölgelerine göre analiz edilmiş, zaman bölgesi, frekans bölgesi ve doğrusal olmayan öznelikler hesaplanmıştır. Oluşturulan öznelik kümeleri beş farklı sınıflandırma algoritması kullanılarak sınıflandırılmıştır. Çalışma sonucunda beyin merkezi bölgesinden ayrılan kanallardan 7 farklı öznelik çıkarılmasıyla Torbalama sınıflandırıcısı kullanılarak %89,5 doğruluk oranında başarı elde edilmiştir.

Anahtar Kelimeler—Depresyon; Elektroensefalografi; Sinyal işleme; Sınıflandırma.

Abstract—Major depressive disorder (MDD) is a common mood disorder encountered worldwide. Early diagnosis has great importance to prevent the negative effects on the person. The aim of this study is to develop an objective method to differentiate MDD patients from healthy controls. Electroencephalography (EEG) signals taken from 16 MDD patients and 16 healthy subjects are analyzed according to the regions of the brain, and time-domain, frequency-domain, and nonlinear features were extracted. The feature sets are classified using five different classification algorithms. As a result of the study, a classification accuracy of 89.5% was yielded using the Bagging classifier with 7 features calculated from the central EEG channels.

Keywords—Depression; Electroencephalography; Signal processing; Classification.

I. GİRİŞ

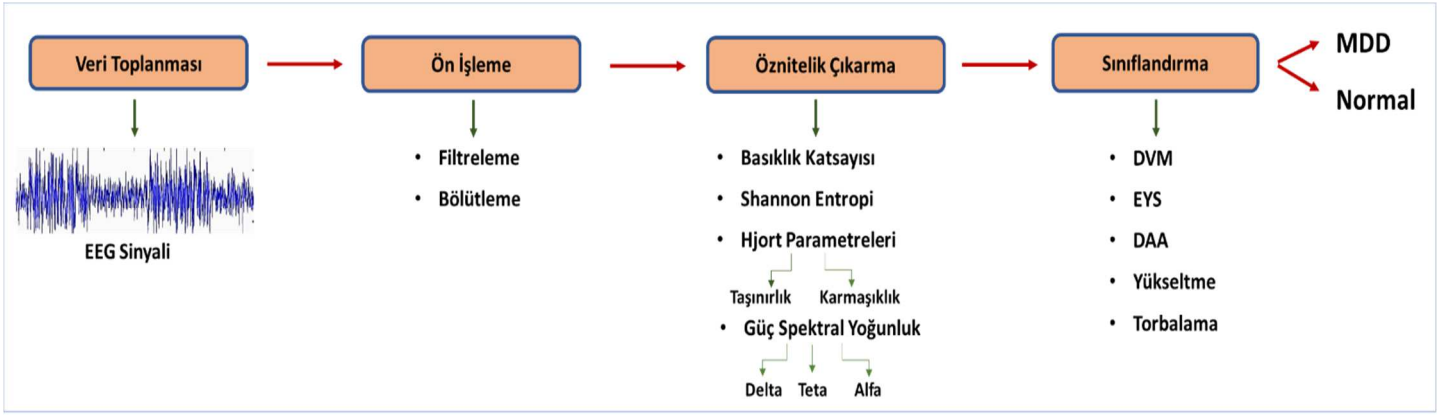
Majör depresif bozukluk (MDD), bilinen adıyla depresyon, dünya çapında 100 milyondan fazla kişiyi etkileyen en yaygın zihinsel bozukluklardan biridir. Her dört kişiden birinin hayatı boyunca ruhsal sorunlar yaşayabileceğini bildiren Dünya Sağlık Örgütü, 2030 yılına kadar oluşacak sağlık sorunlarının ana nedenlerinden birinin depresyon olacağını öngörüyor [1]. Dünya çapında etkisini giderek arttıran depresyon, kişinin düşüncelerini, davranışlarını etkilediği gibi kardiyovasküler

rahatsızlıklar [2], diyabet [3] gibi diğer sağlık sorunlarına da sebep olabilmektedir. Erken teşhis edilememesi durumunda intihara kadar yol açabilmektedir.

Hastalığın teşhisi doktorla kişinin yüz yüze görüşmesi, psikometrik anketler gibi subjektif yöntemlere dayanmaktadır [4]. Depresyon belirtilerinin soyut olması, doğru teşhis konulmasını oldukça zorlaştırmaktadır. Hastada görülen karmaşık ve belirsiz semptomlar, uzmanın tecrübesi, hastanın söylemleri, teşhisin doğruluğunu, uygun tedavinin seçilmesini ve iyileşme süresini büyük oranda etkilenmektedir. Bu nedenle, objektif bir yöntem geliştirmek; erken ve doğru teşhisi sağlamak, uzmana yardımcı olmak ve tedavi süresini azaltmak açısından büyük öneme sahiptir.

Depresyon sürecinde beyin fizyolojisindeki düzensizliklerin tespiti, hastalığın erken teşhisinde önemli rol oynamaktadır. Beyindeki sinirsel aktivitenin ve zihinsel durumdaki herhangi bir bozukluğun, beyin biyoelektriksel aktivitesine yansımaları beklenir. Biyoelektriksel aktivitedeki herhangi bir düzensizliğin de Elektroensefalografi (EEG) cihazından alınabilecek kayıtlarla saptanması yüksektir [5]. EEG, kafa derisine yerleştirilen elektrotlar yardımıyla sinir hücreleri arasındaki elektriksel aktivitenin kaydedilmesi işlemidir. Sinir hücreleri, birbirleriyle iletişim sırasında elektriksel potansiyel üretirler ve bu potansiyel EEG cihazı tarafından salınımlar şeklinde kaydedilir [6]. Bu cihazdan kaydedilecek EEG sinyallerinin işlenmesi, farklı hastalıkların tespitinde önemli rol oynamaktadır. Yapılan çalışmalar, EEG sinyalleriyle makine öğrenmesi yöntemlerinin kombinasyonunun Alzheimer [7], Parkinson [8], Epilepsi [9] gibi birçok nörolojik hastalığın tespitinde başarılı olduğunu göstermektedir.

Literatürdeki depresyon çalışmalarında EEG sinyallerinin incelenmesiyle depresyon hastalarının sağlıklı bireylerden elektrofizyolojik açıdan farkları tespit edilmiştir [10]. Bu kapsamda bilgisayar destekli birçok farklı çalışma geliştirilmiştir. Mumtaz ve ark. yürüttüğü çalışmada, EEG sinyalinin enerjisinin ve beyin frontal, oksipital, temporal, parietal bölgelerinden elde edilen interhemisferik asimetrisinin depresyon teşhisinde anlamlı öznelikler olduğu belirlenmiştir [11]. Depresyon hastaları ve sağlıklı kişileri sınıflandırmayı



Şekil 1. Çalışmanın temel adımları.

amaçlayan çalışma sonucunda EEG sinyali enerjisi ve interhemisferik asimetri öznitelikleri ve Destek Vektör Makinesi (DVM) sınıflandırıcısı kullanılarak %98,4 oranında başarı elde edilmiştir. Yapılan başka bir çalışmada, depresyon hastaları ve sağlıklı bireylerden alınan 19 kanallı EEG sinyalleri analiz edilerek lineer ve lineer olmayan öznitelikler çıkarılmış, Doğrusal Ayırma Analizi (DAA), Lojistik Regresyon (LR), K-En Yakın Komşu (EYK) algoritmaları kullanılarak sınıflandırılmıştır [12]. Çalışma sonucunda depresyon hastası ve sağlıklı kişilerin ayrılmasında lineer olmayan öznitelikler ve LR sınıflandırıcısıyla oluşturulan algoritma %90 doğruluk sağlamıştır. Cai ve ark. yürüttüğü çalışmada Fp1, Fp2 ve Fpz kanallarından ayrıştırılan öznitelikler dört farklı sınıflandırıcı kullanılarak sınıflandırılmıştır [5]. Çalışma sonucunda KNN sınıflandırıcısı kullanılmasıyla %79,27 oranında doğruluğa ulaşılmış, teta frekans aralığının depresyon teşhisi için ayırt edici öznitelik olabileceği tespit edilmiştir. Literatürdeki araştırmalar EEG sinyallerinin depresyon teşhisinde etkili olduğunu gösterse de çalışmalar arasındaki değişen çıkarımlar, geliştirilmeye açık bir alan oluşturmaktadır.

Bu çalışmayla, MDD hastalarının sağlıklı bireylerden ayrılmasını sağlayan bilgisayar destekli yeni bir algoritma geliştirilmiştir. Hasta ve sağlıklı bireylerden alınan EEG kayıtlarının incelenip özniteliklere ayrılması ve makine öğrenmesi yöntemlerinin kullanılmasıyla başarılı bir sınıflandırma algoritmasının geliştirilmesi amaçlanmıştır. Çalışma kapsamında 7 farklı öznitelik ve 5 farklı sınıflandırıcı kullanılmıştır. Geliştirilen yöntem dört temel adımdan oluşmaktadır. Bu aşamalar çalışmada kullanılacak verilerin toplanması, ön işleme, öznitelik çıkarma ve sınıflandırma aşamalarıdır.

II. MALZEME VE YÖNTEM

Çalışma boyunca izlenen adımlar Şekil 1’de verilmiştir.

A. Veri Seti

Çalışmada, Kemal Arıkan Psikiyatri Kliniği’nde kaydedilen MDD hastası ve sağlıklı kişilerden elde edilen EEG sinyalleri kullanılmıştır. Araştırma protokolü psikiyatri kliniği etik kurulu tarafından onaylanmıştır. Uzman kişiler tarafından yapılan tanı testlerinden sonra gönüllü olan depresyon hastaları ve sağlıklı kişiler belirlenmiştir. Neuroscan Synamps II cihazı kullanılarak uluslararası kabul edilen 10–20 elektrot pozisyonuna göre 19 kanallı (FP1, FP2, F3, F4, Fz, C3, C4, Cz, P3, P4, Pz, O1, O2, F7, F8, T3, T4, T5, T6) EEG kayıtları alınmıştır. 16 depresyon hastası ve 16 sağlıklı kişiden dinlenme ve gözler kapalı pozisyonda yaklaşık 7 dakikalık EEG sinyalleri kaydedilmiştir. Kaydedilen sinyallerin frekansı 500 Hz’dir.

B. Ön İşleme

EEG sinyalleri kaydedilirken taban hattı kayması, güç hattı girişimi, hastanın istemli ya da istemsiz hareketleri sinyal üzerinde gürültüye sebep olmaktadır. Bu gürültüleri gidermek amacıyla sinyale filtreleme işlemi uygulanmaktadır. Çalışmada kullanılan sinyallerden gürültüleri temizlemek amacıyla 0,5-70 Hz arasında bant geçiren filtre, 50 Hz Çentik filtre uygulanmıştır.

Filtreleme işleminden sonra yaklaşık 7 dakikalık olan EEG sinyallerinden, kayıt sırasında hastaların odaklanması düşünülüp 1 dakikalık kısmı kırılarak 6 dakikalık EEG sinyalleri elde edilmiştir. EEG sinyalleri beyin bölgelerine göre (frontal, merkezi, temporal, pariyetal, oksipital) ayrı ayrı incelenmiş olup, her biri 15000 örneklem olacak şekilde 30 saniyelik 12 bölüme ayrılmıştır. Bölütleme sonucunda oluşan veri sayısı Tablo I’de verilmiştir.

TABLO I. ÇALIŞMADA KULLANILAN EEG SİNYALİ KANALLARI VE TOPLAM VERİ SAYISI

Beyin Bölgeleri	Kullanılan Kanallar	Toplam Veri Sayısı (Kişi x Bölüm x Kanal)
Frontal	Fp1, Fp2, F3, F4, Fz	32x12x5= 1920
Merkezi	C3, C4	32x12x2= 768
Temporal	T3, T4, T5, T6	32x12x4= 1536
Pariyetal	P3, P4	32x12x2= 768
Oksipital	O1, O2	32x12x2= 768

C. Öznitelik Çıkarma

Beyin bölgelerine göre kanallarına ve bölümlere ayrılan EEG sinyallerinden başarılı bir sınıflandırma algoritması oluşturmak için 7 farklı öznitelik çıkarılmıştır. Bu çalışmada kullanılan öznitelikler, son yıllarda yürütülen çalışmaların bildirdiği üzere depresyon teşhisinde daha iyi başarı göstermiş öznitelikler arasında seçilmiştir [13, 14]. Çalışmada kullanılan öznitelikler zaman bölgesi, frekans bölgesi ve doğrusal olmayan gruplandırılmaya göre aşağıdaki gibidir;

- Zaman bölgesi öznitelikleri: Basıklık katsayısı, Hjort parametreleri (taşınırılık, karmaşıklık)
- Frekans bölgesi öznitelikleri: delta, teta, alfa frekans bantlarının güç spektral yoğunluğu
- Doğrusal olmayan öznitelikler: Shannon entropi

1) Zaman Bölgesi Öznitelikleri

Basıklık Katsayısı: İşaretlerin tepe noktalarını inceleyerek veri dağılımıyla ilgili bilgi verir.

$$\text{Basıklık} = \frac{\sum (x - \bar{x})^4}{Ns^4} \quad (1)$$

Denklemden x veriyi, \bar{x} aritmetik ortalamayı, N veri uzunluğunu, s standart sapmayı ifade eder.

Hjort Parametreleri: Verinin 1. ve 2. türevi alınarak çıkarılan özniteliklerdir. Hjort parametreleri üç öznitelikten oluşmaktadır; aktivite, taşınırılık ve karmaşıklık. Çalışmada taşınırılık ve karmaşıklık öznitelikleri kullanılmıştır.

$$\text{Aktivite} = \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2 \quad (2)$$

$$\text{Taşınırılık} = \sqrt{\frac{\text{aktivite}(\frac{dx}{dt})}{\text{aktivite}(x)}} \quad (3)$$

$$\text{Karmaşıklık} = \frac{\text{Taşınırılık}(\frac{dx}{dt})}{\text{Taşınırılık}(x)} \quad (4)$$

Denklemler (2)'de x_n veriyi, \bar{x} aritmetik ortalamayı, N veri uzunluğunu ifade eder.

2) Frekans Bölgesi Öznitelikleri

Güç Spektral Yoğunluk: EEG sinyalinin frekans dağılımı, kişinin zihinsel aktivitesiyle ilgili bilgi içerir. EEG işareti, frekans aralığına göre beş temel frekans bandından oluşur. Bu dalgalar delta (0,5-4Hz), teta (4-8Hz), alfa (8-13 Hz), beta (13-30Hz) ve gama (>30) dalgaları olarak sınıflandırılır. Bu çalışmada her kanal filtreleme yöntemiyle frekans bantlarına ayrılmış olup delta, teta, alfa bantlarının güç spektral yoğunlukları Fourier dönüşümü kullanılarak hesaplanmıştır.

$$s(w_k) = \frac{1}{N} |X(w_k)|^2 \quad (5)$$

$$\text{Toplam Güç} = \sum_{k=0}^{N-1} (s(w_k))^2 \quad (6)$$

Denklemler (5)'te $X(w_k)$ sinyalin Fourier dönüşümüne, $s(w_k)$ güç spektral yoğunluğa karşılık gelir.

3) Doğrusal Olmayan Öznitelikler

Shannon Entropi: İşaretlerin taşıdığı belirsizlikleri ölçmek için kullanılan entropi çeşitlerinden birisidir [5].

$$SE = - \sum_{i=1}^n p_i \log p_i \quad (7)$$

Denklemden i sinyalin genlik aralığını, p_i sinyalin verilen genlikte olma olasılığını ifade eder [15].

D. Sınıflandırma

EEG sinyalleri beyin bölgelerine göre ayrı ayrı incelenmiş, her kanal ayrıca 12 bölüme ayrılmıştır. Bölütleme işleminden sonra oluşan toplam veri sayısı %80 eğitim, %20 test datası olacak şekilde gruplandırılmıştır. 7 farklı öznitelik, eğitim ve

test datalarına uygulanmış, öznitelik matrisleri oluşturulmuştur. Z skor normalleştirme yöntemi kullanılarak matris değerleri normalize edilmiştir. Oluşan öznitelik matrisleri MDD hastası ve sağlıklı kişileri ayırmak amacıyla DVM, EYK, DAA, Yükseltme (Boosting) ve Torbalama (Bagging) Sınıflandırıcıları kullanılarak sınıflandırılmıştır. Sınıflandırma sonuçları doğruluk, duyarlılık, özgüllük değerleri hesaplanarak değerlendirilmiştir [16].

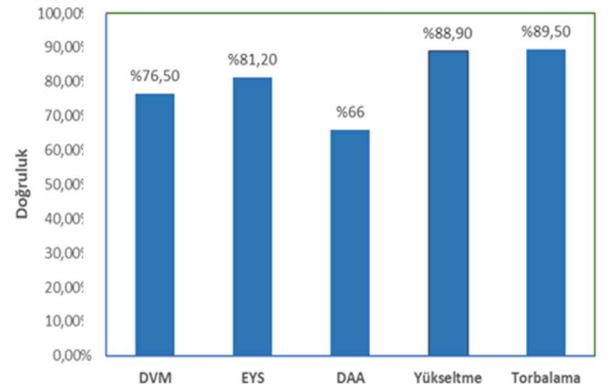
III. DENEYSEL SONUÇLAR

Bu çalışmada MDD hastaları ve sağlıklı kişileri ayırma amacıyla yeni bir algoritma geliştirilmiştir. Çalışma boyunca tüm adımlar MATLAB uygulaması kullanılarak yapılmıştır. Kişilerden alınan EEG sinyalleri etkili özniteliklere ayrılmış ve 5 farklı sınıflandırıcıyla sınıflandırılmıştır. EEG sinyalleri beyin bölgelerine göre ayrı ayrı incelenmiştir. 5 farklı sınıflandırma sonucunda Torbalama Sınıflandırıcısı en yüksek doğrulama başarısı göstermiştir. Bölgelerin Torbalama sınıflandırıcısı sonucu sınıflandırma performansı Tablo II'de verilmiştir.

TABLO II. BEYİN BÖLGELERİNE GÖRE SINIFLANDIRMA PERFORMANSI (%)

Beyin Bölgeleri	Doğruluk	Duyarlılık	Özgüllük
Frontal	83,9	81,5	86,5
Merkezi	89,5	85,7	94,2
Temporal	87,3	84,8	90
Paryetal	85	83,5	86,4
Oksipital	86,9	83,3	91

Merkezi bölge ve Torbalama sınıflandırıcısı kullanılarak geliştirilen yöntem en yüksek başarıya ulaşmış olup sınıflandırma sonucunda %89,5 doğruluk elde edilmiştir. Beş farklı sınıflandırıcının merkezi bölgesi için doğruluk değerleri Şekil 2'de verilmiştir.



Şekil 2. Sınıflandırıcıların merkezi bölgesi için performansları.

IV. TARTIŞMA VE ÇIKARIMLAR

MDD, kişiler üzerinde birçok olumsuz etki gösteren, dünya genelinde yaygın bir duygu durum bozukluğudur. Erken teşhisi, yaşam kalitesini arttırmak ve tedavi sürecini hızlandırmak açısından büyük önem taşımaktadır. Bu çalışmada amaç, hastalığın teşhisi için bilgisayar destekli yeni bir yöntem geliştirmektir. MDD hastası ve sağlıklı kişilerden alınan EEG sinyalleriyle makine öğrenmesi algoritması oluşturulmuştur.

Yapılan çalışmanın diğer çalışmalarla karşılaştırılması Tablo III'de verilmiştir.

TABLO III. ÖNERİLEN ÇALIŞMANIN DİĞER ÇALIŞMALARLA KARŞILAŞTIRILMASI

Çalışma	Veriseti	Sınıflandırıcı	Doğruluk
Mahato ve ark. [17]	34 MDD 30 Normal	DVM	%88,3
Cai ve ark. [5]	92 Depresyon Hastası 121 Normal	EYS	%79,27
Mumtaz ve ark. [11]	33 MDD 30 Normal	DVM	%98,4
Liao ve ark. [10]	20 MDD 20 Normal	DVM	%81,3
Önerilen Çalışma	16 MDD 16 Normal	Torbalama	%89,5

Çalışmada EEG sinyallerinden zaman bölgesi, frekans bölgesi ve doğrusal olmayan öznelikler çıkarılmıştır. Literatürdeki çalışmalar MDD hastalığının teşhisi için beyin bölgelerinin farklı şekilde etkisi olduğunu belirtmiştir [18-20] Bu çalışma sonucunda, merkezi bölge EEG kanalları kullanılarak yapılan sınıflandırma, daha yüksek sınıflandırma başarısı sağlamıştır. 5 farklı sınıflandırıcı arasında torbalama ile yapılan sınıflandırma işlemi en yüksek başarı elde edilmiştir. Torbalama, diğer sınıflandırıcıların doğruluğunu ve kararlılığını arttırmak için oluşturulmuş makine öğrenimleri topluluğudur. Farklı sınıflandırıcıların kombinasyonundan oluştuğu için tek bir sınıflandırıcıya göre daha yüksek başarı elde edilmesine olanak sağlamaktadır [21]. Geliştirilen yöntem, hızlı ve başarılı sonuç vermesi nedeniyle, uzmanların MDD tanısı aşamasında başvurabileceği bir yöntem olarak kullanılabilir. Sonraki çalışmalarda farklı öznelikler ve farklı sınıflandırma teknikleri kullanılarak yöntemin başarısının artırılması hedeflenmektedir.

BİLGİLENDİRME

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) Bilim İnsanı Destekleme Daire Başkanlığı (BİDEB) tarafından 2210/C programı 1649B021906973 numarası altında desteklenmiştir.

KAYNAKLAR

- [1] C. D. Mathers and D. Loncar, "Projections of global mortality and burden of disease from 2002 to 2030," *PLoS medicine*, vol. 3, no. 11, p. e442, 2006.
- [2] C. M. Celano and J. C. Huffman, "Depression and cardiac disease: a review," *Cardiology in review*, vol. 19, no. 3, pp. 130-142, 2011.
- [3] D. Korczak, S. Pereira, K. Koulajian, A. Matejcek, and A. Giacca, "Type 1 diabetes mellitus and major depressive disorder: evidence for a biological link," *Diabetologia*, vol. 54, no. 10, pp. 2483-2493, 2011.
- [4] W. Mumtaz, S. S. A. Ali, M. A. M. Yasin, and A. S. Malik, "A machine learning framework involving EEG-based functional connectivity to diagnose major depressive disorder (MDD)," *Medical & biological engineering & computing*, vol. 56, no. 2, pp. 233-246, 2018.
- [5] H. Cai *et al.*, "A pervasive approach to EEG-based depression detection," *Complexity*, vol. 2018, 2018.
- [6] W. Mumtaz, A. S. Malik, M. A. M. Yasin, and L. Xia, "Review on EEG and ERP predictive biomarkers for major depressive disorder," *Biomedical Signal Processing and Control*, vol. 22, pp. 85-98, 2015.
- [7] R. Cassani, M. Estarellas, R. San-Martin, F. J. Fraga, and T. H. Falk, "Systematic review on resting-state EEG for Alzheimer's disease diagnosis and progression assessment," *Disease markers*, vol. 2018, 2018.

- [8] S. L. Oh *et al.*, "A deep learning approach for Parkinson's disease diagnosis from EEG signals," *Neural Computing and Applications*, pp. 1-7, 2018.
- [9] S. Yol, M. A. Ozdemir, A. Akan, and L. F. Chaparro, "Detection of epileptic seizures by the analysis of EEG signals using empirical mode decomposition," in *2018 Medical Technologies National Congress (TIPTEKNO)*, 2018, pp. 1-4: IEEE.
- [10] S.-C. Liao, C.-T. Wu, H.-C. Huang, W.-T. Cheng, and Y.-H. Liu, "Major depression detection from EEG signals using kernel eigen-filter-bank common spatial patterns," *Sensors*, vol. 17, no. 6, p. 1385, 2017.
- [11] W. Mumtaz, L. Xia, S. S. A. Ali, M. A. M. Yasin, M. Hussain, and A. S. Malik, "Electroencephalogram (EEG)-based computer-aided technique to diagnose major depressive disorder (MDD)," *Biomedical Signal Processing and Control*, vol. 31, pp. 108-115, 2017.
- [12] B. Hosseinifard, M. H. Moradi, and R. Rostami, "Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal," *Computer methods and programs in biomedicine*, vol. 109, no. 3, pp. 339-345, 2013.
- [13] X. Li *et al.*, "Depression recognition using machine learning methods with different feature generation strategies," *Artificial intelligence in medicine*, vol. 99, p. 101696, 2019.
- [14] H. Cai, Z. Qu, Z. Li, Y. Zhang, X. Hu, and B. Hu, "Feature-level fusion approaches based on multimodal EEG data for depression recognition," *Information Fusion*, vol. 59, pp. 127-138, 2020.
- [15] C. Cao and S. Slobounov, "Application of a novel measure of EEG non-stationarity as 'Shannon-entropy of the peak frequency shifting' for detecting residual abnormalities in concussed individuals," *Clinical Neurophysiology*, vol. 122, no. 7, pp. 1314-1321, 2011.
- [16] M. A. Ozdemir, M. Degirmenci, E. Izci, and A. Akan, "EEG-based emotion recognition with deep convolutional neural networks," *Biomedical Engineering / Biomedizinische Technik*, vol. 66, no. 1, pp. 43-57, 2021.
- [17] S. Mahato and S. Paul, "Classification of depression patients and normal subjects based on electroencephalogram (EEG) signal using alpha power and theta asymmetry," *Journal of medical systems*, vol. 44, no. 1, pp. 1-8, 2020.
- [18] L. Duan *et al.*, "Machine learning approaches for MDD detection and emotion decoding using EEG signals," *Frontiers in Human Neuroscience*, vol. 14, 2020.
- [19] S. Sun *et al.*, "Graph theory analysis of functional connectivity in major depression disorder with high-density resting state EEG data," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 27, no. 3, pp. 429-439, 2019.
- [20] M. Ahmadlou, H. Adeli, and A. Adeli, "Spatiotemporal analysis of relative convergence of EEGs reveals differences between brain dynamics of depressive women and men," *Clinical EEG and neuroscience*, vol. 44, no. 3, pp. 175-181, 2013.
- [21] M. Skurichina and R. P. Duin, "Bagging, boosting and the random subspace method for linear classifiers," *Pattern Analysis & Applications*, vol. 5, no. 2, pp. 121-135, 2002.