

Şizofrenik ve Sağlıklı EEG Zaman Serilerinin Sınıflandırılması ve İstatistiksel Analizi

Classification and Statistical Analysis of Schizophrenic and Normal EEG Time Series

Delal ŞEKER ve Mehmet Sıraç ÖZERDEM

Elektrik-Elektronik Mühendisliği Bölümü Dicle Üniversitesi

Diyarbakır, Türkiye delalkabak93@gmail.com, sozerdem@dicle.edu.tr

Özetçe— Bu çalışmada sağlıklı ve şizofrenik EEG zaman serilerinin lineer öznelikler kullanılarak farklı sınıflandırma yöntemleri ile ayırt edilmesi amaçlanmıştır. Bu amaçla 39 şizofreni hastası ve 39 sağlıklı kişiden 16 kanallı EEG sistemi ile 1 dakikalık kayıtları alınmış ve bu kayıtlarının minimum, maksimum, ortalama, standart sapma ve medyan öznelikleri elde edilmiştir. Tüm kanallardan elde edilen öznelik vektörlerine k- en yakın komşuluk (k-NN), çok katmanlı algılayıcılar (MLP), destek vektör makinası (SVM) ve Rastgele Orman (RO) sınıflandırma algoritmaları uygulanmıştır. Önerilen yöntem ile en yüksek başarımları oranı %99.95'e kadar çıkmıştır. MLP performansı en iyi sınıflandırma algoritması olarak görülürken, C4 kanalı şizofreni EEG'sinin kontrol grubundan en iyi ayırt edildiği kanal olarak gözlemlenmiştir. İstatistiksel analiz amacıyla kullanılan bağımsız örneklem t-testi ve Mann-Whitney U testi sonucunda, tüm kanallarda istatistiksel olarak anlamlılık gözlemlenmiştir. Önerilen çalışmaya bakıldığında, elde edilen sonuçlar literatürdeki benzer çalışmaları destekler nitelikte olduğu görülmüştür.

Anahtar Kelimeler — EEG; şizofreni; sınıflandırma; istatistiksel analiz

Abstract— In this study, discrimination of normal and schizophrenic EEG is aimed by using linear features with different classifiers. For this purpose, 1 minutes of EEG records through 16 channels were recorded from 39 normal and 39 schizophrenia patients and minimum, maximum, mean, standard deviation and median features were extracted from these records. k-neighbors, Multi-layer perceptron, support vector machines and Random forest classifier were applied to feature vectors extracted from each channel. Highest classification accuracy is reached to 99.95 % in proposed work. While MLP seems to be best classifier, channel C4 is observed most relevant to discriminate schizophrenic EEG from healthy control group. As a result of independent sample t-test and Mann-Whitney U Test for the purpose of statistical analysis, there is a distinct statistical significance for whole channels. When considering proposed work, obtained results are so promising and make contributions to literature view according to related works.

Keywords — EEG; schizophrenia; classification; statistical analysis

I. GİRİŞ

İnsan beyni nörolojik hastalıklardan etkilenerek düşünme yetisinde ve genel davranışlarda aksaklıklar yaşamaktadır [1]. Şizofreni hastalığı da bu tür bir kronik rahatsızlıktır. Dünya

Sağlık Örgütüne (WHO) göre dünya çapında yaklaşık 21 milyon insan bu hastalıktan etkilenmektedir [2]. Bu hastalığın teşhisi ve tedavisi önem arz etmektedir; çünkü düşünme yetisine, hafızaya, algılama yetisine etkisi yadsınamayacak derecede fazladır. Hastalığın erken teşhisi, gerekli ilaç temini ile tedaviyi hızlandırır ve hastalığın ileri evrelere geçmesini engeller [3]. Birçok mental rahatsızlık görüntü ve sinyal işleme teknikleriyle saptanır [4].

Elektroensefalografi (EEG) son zamanlarda beyin bilgisayar tabanlı arayüzler (BCIs); beyin bilimi, nöral mühendislik ve rehabilitasyon çalışmalarında oldukça popüler hale geldi [5]. Manyetik rezonans görüntüleme (MRI) ve bilgisayarlı tomografi (CT), EEG' ye karşın maliyeti yüksek ve kurulum gücü gerektiren yöntemlerdir [6]. EEG, çok kanallı sensörler yardımıyla beynin aktivitesi hakkında önemli bilgiler içerir [7]. Alzheimere, uyku apnesi, epilepsi ve Parkinson gibi nörolojik hastalıkların tespitinde EEG kayıtları kullanılır [8-9].

Kim ve ark. [10] çalışmalarında 90 sağlıklı, 90 şizofreni hastası ile EEG tabanlı sınıflandırma gerçekleştirmişlerdir. Analizlerinde 5 farklı EEG alt bandı kullanılmıştır. Hızlı Fourier Dönüşümü (FFT) yöntemiyle bantlara ait güç spektrum değerleri hesaplanmıştır. İki sınıfın ayırt edilmesinde ROC analizi tercih edilmiştir. En yüksek başarımları oranı delta bandında %62.2 saptanmıştır. Dvey-Aharon ve ark. [11] çalışmalarında 25 sağlıklı, 25 şizofreni hastası ile sınıflandırma gerçekleştirmişlerdir. Şizofreni hastalarının EEG sinyallerini incelemiş ve daha sonra elde edilen kayıtları görüntüye dönüştürerek özellik çıkarımı yapmıştır. Elde edilen sonuçlar ile gelişmiş bir sınıflandırma işlemi gerçekleştirmişlerdir. Ölçüm sonuçlarından en iyi beş elektrot saptanarak %92.0 ve %93.9 gibi ideal ölçümler rapor edilmiştir. En iyi sonucu veren elektrot ise F2 olarak gözlemlenmiştir. Johannesen ve ark. [12], 12 sağlıklı ve 40 şizofreni hasta kayıtlarını inceleyip, 64 elektrot sistemini kullanarak Destek Vektör Makinaları (SVM) ve Çok Katmanlı Algılayıcı (MLP) sınıflandırıcıları ile sınıflandırma gerçekleştirmişlerdir. Her katılımcıdan 60 öznelik çıkarılmıştır. Teta 1-2, alfa, beta ve gama frekans bantları kullanılmıştır. Frontal bölgeye ait teta ve alfa bandı kullanılarak şizofreni ve sağlıklı bireylerin ayırt edilmesinde %87 başarımları elde edilmiştir. Santos-Mayo ve ark. [13] 31 sağlıklı ve 16 şizofreni hasta ile EEG-ERP sinyallerini analiz ederek sınıflandırma işlemi uygulamıştır. Ön işlem aşamasında EEGLAB kullanılarak 16 zaman frekans tabanlı ve 4 frekans tabanlı öznelik çıkarılmıştır. MLP ve SVM sınıflandırıcılarıyla sırası


ile %93.42 ve %92.23 sınıflandırma başarımları elde edilmiştir. İbanez ve ark. 17 sağlıklı ve 18 şizofreni hastası ile Lempel-Ziv karmaşıklık analizi kullanmışlardır. Sağ frontal bölgede sağlıklı gruplarda daha yüksek karmaşıklık değerleri saptanmıştır. V. Jahmunah ve ark. [14], 14 sağlıklı ve 14 şizofreni hastası ile 11 katmanlı evrimsel sinir ağı kullanmışlardır. 10 fould çaprazkorelasyon ile sınıflandırma gerçekleşmiştir. Kişi tabanlı sınıflandırmada %81.26, kişi tabanlı olmayan sınıflandırmada %98.07 başarımlar elde edilmiştir. V. Jahmunah ve ark. [15] 14 sağlıklı ve 14 hasta katılımcı ile doğrusal olmayan öznitelikler kullanılmış ve t-test ile öznitelik seçimi yapılmıştır. KNN, SVM, LDA sınıflandırıcıları tercih edilmiştir. En iyi sonuç %92.91 ile RBF tabanlı SVM sınıflandırıcısında elde edilmiştir.

Bu çalışmada 16 kanallı 10-20 sistemine göre dizilmiş elektrot sistemi ile 39 sağlıklı 39 şizofreni hastasından alınan EEG kayıtlarıyla şizofreni hastalığının kontrol grubundan ayırt edilmesi amaçlanmıştır. Literatürdeki mevcut sınıflandırma başarımlarının yükseltilmesi hedeflenmektedir.

II. MATERYAL VE METOD

A. Materyal

Yaşları ortalama 12-13 arasında değişen 39 sağlıklı ve 39 hasta erkek çocuktan alınan EEG sinyalleri kullanılmıştır. Tüm teşhisler Mental Health Research Center (MHRC) uzmanları tarafından doğrulanmıştır. EEG kayıtları gözler kapalı, uyanık ve rahatlamış bir şekilde 16 elektrottan, uluslararası 10-20 sistemine sadık kalınarak alınmıştır. O1, O2, P3, P4, Pz, T5, T6, C3, C4, Cz, T3, T4, F3, F4, F7 ve F8 kanalları kullanılmıştır. Bu çalışmada 128 Hz. Örnekleme frekansı kullanılmış, her kanaldan 1'er dakikalık EEG kayıtları elde edilmiş ve her biri için 2'şer saniyelik bölümler alınmıştır. Her katılımcıdan 30 tane bölüt, her bölütten 5 adet öznitelik vektörü, her katılımcı grubundan (39x30) 1170 öznitelik çıkarılmıştır. Sonuç olarak her kanal için, her iki katılımcı grubunu içeren 2340x6 boyutunda öznitelik vektörü elde edilmiştir. Öznitelik vektörünün son sütunu etiket verilerine (0:sch, 1:norm) aittir.



Şekil.1. Sağlıklı (a) ve Hasta (b) EEG Kayıtları

B. Metod

Çalışma; ön işlem, özellik çıkarımı ve sınıflandırma olarak 3 aşamadan oluşmuştur. Ön işlem olarak artefakt kirlenmeler olarak adlandırılan kas gürültüsü, göz kırpmaları hareketleri ve bunun dışında 50 Hz. olan şebeke frekansının sebep olduğu gürültülerden arındırılmıştır. Öznitelikler MATLAB kullanılarak elde edilmiştir. Çıkarılan öznitelikler min, mean, max, std ve median olmak üzere 5 farklı gruptur. Sonrasında normalizasyon yapılarak veriler 0-1 aralığına indirgenir. Kullanılan sınıflandırma yöntemleri ise KNN, SVM, MLP ve Rastgele Orman olmak üzere 4 farklı sınıflandırıcıdır. Ayrıca SPSS analizi ile istatistiksel olarak sağlıklı ve hasta gruplarını student t-test kullanarak anlamlı bir fark olup olmadığına bakılmıştır.

Katsayılarının mutlak değerlerinin minimumu (min):

$$x_{min} = \min|x(n)| \quad (1)$$

Katsayılarının mutlak değerlerinin maksimumu (max):

$$x_{max} = \max|x(n)| \quad (2)$$

Katsayı kuvvetlerinin ortalaması (mean):

$$x_{ort} = \sum_{n=1}^N \frac{x(n)}{N} \quad (3)$$

$x(n)$, $n=1, 2, 3, \dots, N$ içindir.

Standard sapma (std):

$$x_{std} = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - x_{ort})^2} \quad (4)$$

Medyan:

$x(n)$, $n=1,2,3,\dots,N$ için;

$$M = \begin{cases} x_{(N+1)/2}, N \text{ tek ise} \\ \frac{x_{N/2} + x_{(N/2)+1}}{2}, N \text{ çift ise} \end{cases} \quad (5)$$

min ve max değerleri denklem (1-2), EEG işaretine ait zaman serisi içindeki en küçük ve en büyük değerleri mean değeri denklem (3) serinin aritmetik ortalama değeri, medyan değeri denklem (4), sinyal işaretlerinin ortada kalan değeri standart sapma denklem (5) seri içindeki verilerin ortalamaya yakınlığı değeridir.

Sınıflandırma uygulamaları WEKA kullanılarak yapıldı. KNN için 2-8 arası komşuluklar denendi. En yüksek k-komşuluk 4 bulundu. MLP için öğrenme oranı 0.7 alındı. SVM ve Rastgele Orman için ise default değerler sabit bırakıldı.

KNN: k-en yakın komşuluk, parametrik ve doğrusal olmayan temel sınıflandırıcılardan biridir. Bu metod basit olduğu için daha çok karmaşık ve yoğun data setlerde tercih edilir. Veri seti içindeki bir nokta kendine en yakın sınıfa aradaki uzaklığın yakınlığına oranla atanır. Aşağıda bu mesafe türlerinden en çok kullanılan öklit mesafesinin formülize edilmiş hali denklem (6) 'da gösterilmiştir.

$$d(y) = \sqrt{\sum_{i=1}^n (y_{1i} - y_{2i})^2} \quad (6)$$

$$y_{1i} = (y_{11}, y_{12}, \dots, y_{1n}) \text{ ve } y_{2i} = (y_{21}, y_{22}, \dots, y_{2n})$$

Eşitlik hesaplanmadan önce her özelliğin değerinin normalizasyonu yapılabilir. Alternatif olarak veri kümesinden en yakın komşuluğu almak için normal sınıflandırıcı en yakın k-komşudan çoğunluğu alır. k'nın değeri komşularının sayısı 2 seçilerek en küçük hata oranını alır. [16]

SVM: İstatiksel öğrenme üzerine kurulan destek vektör makinaları Cortes ve Vapnik tarafından 1995 yılında yapılmıştır. İkili ve örüntü sınıflandırmada yaygın olarak kullanılır. Sınıflandırma kullanılacak öznelik uzayını daha büyük bir boyuta taşıyarak bu öznelikleri ayıracak hiper düzlemi çekirdek fonksiyonları yardımı ile üretir. Çekirdek fonksiyonları doğrusal, polinom tabanlı ve radial fonksiyon tabanlı olarak sayabiliriz. Bu çalışmada radial fonksiyon tabanlı çekirdek kullanılmıştır [17]. Aşağıda SVM' nin temel formülize hali verilmiştir denklem (7).

$$K(x, y, \alpha) = \exp(-(x - y)^2 / 2 \alpha^2) \quad (7)$$

MLP: Çok katmanlı algılayıcı en çok kullanılan ve en yüksek başarımları veren yapay sinir ağı sınıflandırıcısıdır. Algoritma mantığı hatanın geri yayılımına dayalıdır. Tek giriş ve çıkış katmanlı, bir veya daha fazla saklı katmandan oluşan, giriş verilen değerler ile beklenen çıkışlara göre en uygun ağı buluna kadar sürekli ağırlık güncellemesi yapan bir sınıflandırıcıdır [18].

Rastgele Orman: Breiman tarafından ortaya atılmıştır. Makina öğrenmesi konularından biri olan karar ağaçları sınıflandırmasının doğruluk oranını arttırmak amacıyla uygulanan bir sınıflandırma yöntemidir. Birden fazla karar ağacı kullanılarak, en iyi olan dallar hedef alınır. En düşük hataya sahip karar ağacı en yüksek, en yüksek hataya sahip karar ağacı ise en düşük ağırlığa sahip olur. Bu ağırlıklara göre yapılan sınıf tahmininde oy verme işlemi gerçekleştirilir. Sonrasında oylar toplanarak en son karar verilir. [19].



Şekil.2. Çalışmada Önerilen Metodun Gösterimi

III. BULGULAR VE TARTIŞMA

KNN' de en iyi sınıflandırmayı C4 (99.95); SVM'de C4 (99.95); MLP' de F8, C4, T5 (99.95); RO'da T3 (99.95) kanalları vermiştir. Frontal bölgede F8, temporal bölgede T6, central bölgesinde C4, parietal bölgede P2, oksipital bölgede O2 kanalları en iyi sonucu vermiştir. Tüm sınıflandırma sonuçları ve kanallardan elde edilen verilere bakılınca en iyi kanalın C4, en iyi sınıflandırıcının ise MLP olduğu tespit edilmiştir. Yapılan sınıflandırma işlemi sonuçları Tablo.1 de verilmiştir. MLP performansı en iyi sınıflandırma algoritması olarak görülürken, C4 kanalı şizofreni EEG'sinin kontrol grubundan en iyi ayırt

edildiği kanal olarak gözlemlenmiştir. Mevcut sonuçlarla önerilen yöntemin literatürdeki çalışmalardan üstün olduğu ve klinik uygulamalara katkı sağlayacağı yorumunu getirmektedir.

Bu çalışmada analiz edilen şizofreni ve sağlıklı bireylerle ait EEG kayıtlarından çıkarılan öznelik vektörlerini kullanarak iki gruptan elde edilen değerlerin ortalamaları arasında istatistiksel olarak anlamlı bir fark olup olmadığını belirlemek için parametrik bir yöntem olan bağımsız örneklem t testi tercih edilmiştir. Bu testin ön şartı verilerin normal dağılımı, gruplara ait varyansların eşitliği ve iki verinin birbirinden bağımsız olmasıdır. Bu şartları sağlamayan veriler için ise parametrik bir yöntem olmayan Mann-Whitney U testi kullanılacaktır [20]. SPSS'in hesapladığı p değerinin 0.05'ten küçük olduğu durumlarda şizofreni ve sağlıklı EEG verileri arasındaki fark istatistiksel olarak anlamlıdır. Her kanaldan hesaplanan 5 farklı özneliğe göre p değerleri Tablo 2.'de verilmiştir. Sonuçlar incelendiğinde tüm kanallarda istatistiksel olarak anlamlılık gözlemlenmiştir. Bu sonuçlar yüksek çıkan sınıflandırma başarımlarını desteklemekte ancak başarımların yüksek olduğu kanallarda istatistiksel anlamlılığın da arttığı çıkarımı tam olarak yapılamamaktadır.

TABLO I. Sınıflandırma sonuçları

Kanallar	K-NN	SVM	MLP	Random Forest(RO)
F7	92.09	90.51	92.86	93.86
F3	97.94	98.16	98.84	97.64
F4	70.76	74.52	74.44	81.62
F8	99.87	99.91	99.95	99.65
T3	79.61	79.27	84.01	99.95
C3	98.24	98.24	98.67	98.16
Cz	98.84	98.63	99.40	98.29
C4	99.95	99.95	99.95	99.70
T4	97.05	96.58	97.56	96.32
T5	99.82	99.87	99.95	99.70
P3	94.05	94.05	95.00	93.63
Pz	99.65	99.65	99.70	99.35
P4	99.48	99.31	99.61	98.93
T6	97.82	97.73	98.63	97.77
O1	97.05	96.83	96.92	96.41
O2	99.87	99.78	99.87	99.70

IV. SONUÇ

Bu çalışmada, önerilen öznelik çıkarım yöntemleri ve mevcut sınıflandırma teknikleri ile şizofreni hastaları ve sağlıklı kontrol gruplarına ait EEG kayıtlarını sınıflandırılması ve istatistiksel analizi amaçlanmıştır. 2 veri grubunun başarılı şekilde ayrıştırılması, ilgili paradigmanın klinik tedavilerde kullanılabileceğini, analiz edilecek EEG kayıtlarından hangisinin sağlıklı veya hasta grubuna ait olduğu konusunda doğruluk tahminini arttırabileceğini göstermiştir. İlerleyen çalışmalarda şizofreni hastalığı ile ilgili en ilintili EEG marker belirlenip daha az kanal ile sınıflandırma işlemi hedeflenmektedir. Bir başka açıdan bakılırsa, güç spektrum tabanlı, karmaşıklık analizi ile ilgili, uyumlulukla (coherence) ilişkili markerlar ile kişi tabanlı sınıflandırma önerilebilir. Çalışmada başarılı sonuçlar veren çok katmanlı algılayıcıların daha derin versiyonu olan evrimsel sinir ağları ile bir başka uygulama geliştirmek de planlanabilir. Önerilen çalışma mevcut hali ile de şizofreni hastalığı tespitinde literatüre katkı sunmakta ve pratik uygulamalarda umut vadetmektedir.

TABLO II. SPSS Analiz Sonuçları

Kanallar	Öznitelikler	p value (sig 0.05)	Kanallar	Öznitelikler	p value (sig 0.05)
F7	min	0,005*	T4	min	0,009*
	mean	0,015*		mean	0,000*
	max	0,000*		max	0,000*
	std	0,043*		std	0,032*
	median	0,018**		median	0,001*
F3	min	0,000*	T5	min	0,047*
	mean	0,012*		mean	0,000*
	max	0,037*		max	0,000*
	std	0,044*		std	0,009
	median	0,000*		median	0,041*
F4	min	0,003*	P3	min	0,000*
	mean	0,021*		mean	0,001*
	max	0,000*		max	0,035*
	std	0,020*		std	0,000*
	median	0,005*		median	0,042**
F8	min	0,000*	Pz	min	0,005*
	mean	0,004*		mean	0,000**
	max	0,010*		max	0,033**
	std	0,003*		std	0,019**
	median	0,033*		median	0,000*
T3	min	0,000*	P4	min	0,011*
	mean	0,000*		mean	0,000*
	max	0,011*		max	0,011**
	std	0,028*		std	0,003**
	median	0,024*		median	0,019*
C3	min	0,022**	T6	min	0,000**
	mean	0,000*		mean	0,024*
	max	0,006**		max	0,009**
	std	0,014*		std	0,021**
	median	0,049*		median	0,000*
Cz	min	0,001*	O1	min	0,023*
	mean	0,000*		mean	0,000*
	max	0,022*		max	0,011**
	std	0,000*		std	0,043*
	median	0,018*		median	0,000*
C4	min	0,006*	O2	min	0,044**
	mean	0,000*		mean	0,008*
	max	0,025*		max	0,025**
	std	0,005*		std	0,015**
	median	0,044*		median	0,000*

* : Mann-Whitney U Test, **: Independent Sample t Test.

Kaynaklar

- [1] V. Rajinikanth, S. C. Satapathy, S. L. Fernandes, and S. Nachiappan, "Entropy based segmentation of tumor from brain MR images – a study with teaching learning based optimization," *Pattern Recognit. Lett.*, vol. 94, pp. 87–95, 2017.
- [2] WHO: https://www.who.int/mental_health/management/schizophrenia/en/.
[Google Scholar](#)
- [3] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, and H. Adeli, "Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals," *Comput. Biol. Med.*, vol. 100, no. July 2017, pp. 270–278, 2018.
- [4] Z. Wang and T. Oates, "Imaging time-series to improve classification and imputation," *IJCAI Int. Jt. Conf. Artif. Intell.*, vol. 2015-January, no. Ijcai, pp. 3939–3945, 2015.
- [5] S. Sanei and J. A. Chambers, *EEG Signal Processing*. New York: Wiley, 2007.
- [6] A. Subudhi, U. R. Acharya, M. Dash, S. Jena, and S. Sabut, "Automated approach for detection of ischemic stroke using Delaunay Triangulation in brain MRI images," *Comput. Biol. Med.*, vol. 103, no. August, pp. 116–129, 2018.
- [7] U. R. Acharya *et al.*, "Characterization of focal EEG signals: A review," *Futur. Gener. Comput. Syst.*, vol. 91, pp. 290–299, 2019.
- [8] Ö. Yıldırım, U. B. Baloglu, and U. R. Acharya, "A deep convolutional neural network model for automated identification of abnormal EEG signals," *Neural Comput. Appl.*, vol. 0123456789, 2018.
- [9] R. K. Tripathy and U. Rajendra Acharya, "Use of features from RR-time series and EEG signals for automated classification of sleep stages in deep neural network framework," *Biocybern. Biomed. Eng.*, vol. 38, no. 4, pp. 890–902, 2018.
- [10] J. W. Kim, Y. S. Lee, D. H. Han, K. J. Min, J. Lee, and K. Lee, "Diagnostic utility of quantitative EEG in un-medicated schizophrenia," *Neurosci. Lett.*, vol. 589, pp. 126–131, 2015.
- [11] J. W. Kim, Y. S. Lee, D. H. Han, K. J. Min, J. Lee, and K. Lee, "Diagnostic utility of quantitative EEG in un-medicated schizophrenia," *Neurosci. Lett.*, vol. 589, pp. 126–131, 2015.
- [12] Z. Dvey-Aharon, N. Fogelson, A. Peled, and N. Intrator, "Schizophrenia detection and classification by advanced analysis of EEG recordings using a single electrode approach," *PLoS One*, vol. 10, no. 4, pp. 1–12, 2015.
- [13] J. K. Johannesen, J. Bi, R. Jiang, J. G. Kenney, and C.-M. A. Chen, "Machine learning identification of EEG features predicting working memory performance in schizophrenia and healthy adults," *Neuropsychiatr. Electrophysiol.*, vol. 2, no. 1, pp. 1–21, 2016.
- [14] L. Santos-Mayo, L. M. San-Jose-Revuelta, and J. I. Arribas, "A computer-aided diagnosis system with EEG based on the p3b wave during an auditory odd-ball task in schizophrenia," *IEEE Trans. Biomed. Eng.*, vol. 64, no. 2, pp. 395–407, 2017.
- [15] V. Jahmunah *et al.*, "Automated detection of schizophrenia using nonlinear signal processing methods," *Artif. Intell. Med.*, vol. 100, no. June, p. 101698, 2019.
- [16] N. Pradhan, P. K. Sadasivan, and G. R. Arunodaya, "Detection of seizure activity in EEG by an artificial neural network: A preliminary study," *Comput. Biomed. Res.*, vol. 29, no. 4, pp. 303–313, Aug. 1996.
- [17] Y. Liu, W. Zhou, Q. Yuan and S. Chen, "Automatic Seizure Detection Using Wavelet Transform and SVM in Long-Term Intracranial EEG," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 20, no. 6, pp. 749-755, Nov. 2012. doi: 10.1109/TNSRE.2012.2206054
- [18] M. Şeker, "İyi – Kötü Kokular İle İlişkili EMOTIV-EPOC tabanlı EEG Kayıtlarının Makine Öğrenmesi Yöntemleri ile Sınıflandırılması", Dicle Üniversitesi FBE, YL Tezi, Haziran, 2017.
- [19] L. Breiman : "Random forests–random features," Technical Report 567, Department of Statistics, University of California, Berkeley, 1999.
- [20] M. Şeker and M. S. Özerdem, "Application of Higuchi's Fractal Dimension for the Statistical Analysis of Human EEG Responses to Odors," 2018 41st International Conference on Telecommunications and Signal Processing (TSP), Athens, 2018, pp. 1-4, doi: 10.1109/TSP.2018.8441305.