

Hilbert Dönüşümü Kullanılarak EEG İşaretlerinden

Kanal Bazlı Şizofren Hastalığının Tespiti

Detection of Schizophrenia from Channel Based EEG Signals Using Hilbert Transform

Ömer TÜRK
Mardin Artuklu Üniversitesi,
Midyat MYO
Mardin, Türkiye
omerturk@artuklu.edu.tr
ORCID: 0000-0002-0060-1880

Mesut ŞEKER
Dicle Üniversitesi,
Elektrik-Elektronik
Mühendisliği Bölümü,
Diyarbakır, Türkiye
mesut.seker@dicle.edu.tr
ORCID: 0000-0001-9245-6790

Mehmet Sıraç ÖZERDEM
Dicle Üniversitesi,
Elektrik-Elektronik
Mühendisliği Bölümü,
Diyarbakır, Türkiye
sozerdem@dicle.edu.tr
ORCID: 0000-0002-9368-8902

Öz

Elektroensefalografi (EEG) nörolojik hastalıkların tespitinde sahip olduğu çok kanallı ve yüksek zaman çözünürlüklü yapısı ile çalışmalarda etkili bir görüntüleme aracı olarak popülerliğini korumaktadır. Bu çalışmada, Hilbert Dönüşümü (HD) kullanılarak EEG kayıtlarından kanal bazlı şizofreni hastalığının tespiti amaçlanmıştır. İşarete ait sanal bileşenler bu dönüşümle analiz edilip hasta/kontrol gruptan oluşan öznitelik vektörleri Destek Vektör Makinası (DVM) ile sınıflandırılmıştır. Kullanılan EEG veri seti, yaşları 10-14 arasında değişen 39 şizofreni ve yaşları 11-13 arasında farklılık gösteren 39 sağlıklı katılımcıdan elde edilmiştir. Mevcut kayıtlar katılımcının gözleri kapalı konumda iken 10-20 sistemine göre düzenlenmiş 16 elektrot aracılığı ile 1 dakika süresince alınmıştır. Çalışmada kullanılan kanallar frontal, parietal, temporal, central ve oksipital lob'un ilgili bölgelerinden seçilmiştir. Yapılan sınıflandırma işleminde $k=10$ çapraz doğrulama kullanılarak eğitim ve test kümeleri oluşturulmuştur. Çalışmada sınıflandırma başarımının yanında Tuturma (Precision), Bulma (Recall), F1-Score

değerleri de hesaplanmıştır. Çalışmada en iyi sınıflandırma başarımı %95,19 ile frontal lob 'dan oluşan özniteliklerden elde edilmiştir. En düşük sınıflandırma performansının ise temporal lob bölgesinden alınan kanal öznitelikleri olduğu görülmüştür. Sağlıklı ve hasta grupların başarılı şekilde ayrıştırılması, izlenen metodun klinik tedavilerde uygulanabileceğini, klinisyenlere tedavi edilecek kişinin durumu konusunda fikir verebileceğini göstermektedir. Önerilen çalışma mevcut hali ile şizofreni hastalığı tespitinde literatüre katkı sunacak pratik bir uygulama olarak umut vadetmektedir.

Anahtar Sözcükler: EEG, şizofreni, Hilbert Dönüşümü, Destek Vektör Makinası, sınıflandırma

Abstract

Electroencephalography (EEG) maintains its popularity as an effective neuroimaging tool in studies with its multi-channel and high time resolution features for detection of neurological diseases. In this study, it was aimed to detect channel-based schizophrenia disease from EEG recordings using Hilbert Transform (HT). The imagenary components of the markers were analyzed with this transform, and the feature vectors consisting of patient / control groups were classified

Gönderme ve kabul tarihi: 11.11.2020 - 30.11.2020

Makale türü: Araştırma

with the Support Vector Machine (SVM). The EEG data set used was obtained from 39 schizophrenia aged 10-14 and 39 healthy participants aged 11-13. The current recordings were taken during participant's eyes closed for 1 minute through 16 electrodes arranged according to the 10-20 system. The channels used in the study were selected from the relevant regions of the frontal, parietal, temporal, central and occipital lobes. In the classification process, training and test sets were divided with using $k = 10$ fold cross validation. In addition to the classification accuracy, Precision, Recall, F1-Score values were also calculated in the study. The best classification performance was obtained from the features from frontal lobe with 95,19% rate. The lowest classification performance was found to be the features taken from the temporal lobe region. Discrimination rate of healthy and patient groups shows that the proposed method can be applied in clinical treatments and can give an idea to the clinicians about the status of the patients to be treated. In its current form, the proposed study serves promising results as a practical application that will contribute to the literature in the detection of schizophrenia.

Keywords: EEG, schizophrenia, Hilbert Transform, Support Vector Machine, classification

1. Giriş

Nörolojik hastalıklar sonucu bireyler düşünme yetisini kaybetmekte ve genel davranış bozuklukları yaşamaktadır. Şizofreni hastalığı da bu tür etkilerde bulunan nörolojik bir hastalık türüdür [1]. Dünya Sağlık Örgütü (DSÖ)'ne göre dünya genelinde 21 milyon şizofreni hastası bulunmaktadır [2]. Şizofreni hastalığının erken teşhisi ve saptanacak tedavi yöntemleri ile hastalığın ileri seviyelere ulaşması önlenemez, gerekli ilaç temini ile tedavi süreci hızlanabilecektir [3].

Mental rahatsızlıkların birçoğu sinyal ve görüntü işleme teknikleri ile saptanabilmektedir. Özellikle, Elektroensefalografi (EEG), Beyin Bilgisayar Ayarüzleri (BBA), sinir bilimi, mühendislik ve rehabilitasyon uygulamalarında mental rahatsızlıklarının popüler olduğu görülmektedir [4]. EEG, sahip olduğu çok kanallı ve yüksek zaman çözünürlüklü yapısı ile uygulanışı ucuz ve kolay bir nörolojik görüntüleme tekniğidir [5]. Bu yöntem beyin dinamikleri hakkında önemli bilgiler

çermekte ve nörolojik hastalıkların tespitinde son yıllarda popülerliğini korumaktadır.

Şizofreni hastalığının teşhisinde kullanılan sınıflandırma tabanlı çalışmalar ileri derecede öznelik mühendisliği yapıldığını göstermekte ancak hala istenilen seviyede nitelikli özneliklerin elde edilemediği gözlenmektedir. Konu ile ilişkili temel çalışmalardan bazıları şu şekilde özetlenebilir: Kim ve ark. [6] EEG tabanlı sınıflandırma çalışmasında 90 sağlıklı ve 90 hasta katılımcı kullanmıştır. EEG frekans bantlarına ait Hızlı Fourier Dönüşümü (HFD) ile spektrum değerleri hesaplanmıştır. Yapılan ROC analizinde, en yüksek başarımları %62,2 ile Delta bandında tespit edilmiştir. 25 sağlıklı ve 25 hastanın kullanıldığı diğer bir çalışmada [7], EEG kayıtları ile zaman-frekans dönüşümü yapıp sınıflandırma için en iyi 5 elektrot saptanmıştır. Çalışmada %93,9 ile en yüksek başarımları F2 kanalından elde edilmiştir. Johannesen ve ark. [8] çalışmalarında 40 şizofreni ve 12 sağlıklı katılımcıdan toplamda 60 öznelik çıkarıp, Çok Katmanlı Algılayıcı (ÇKA) ve Destek Vektör Makinası (DVM) ile sınıflandırma çalışması yapmışlardır. Frontal bölgede teta ve alfa frekansları kullanılarak %87 oranında hasta ve kontrol grubu ayırt edilmiştir. 14 sağlıklı ve 14 hasta katılımcının kullanıldığı bir diğer çalışmada; 11 katmanlı Evrişimsel Sinir Ağı (ESA), 10 çapraz korelasyon ile sınıflandırma işlemi yapılmıştır. Katılımcı bazlı sınıflandırmada %81,26 başarımları elde edilmiştir [9]. Karmaşıklık ve Entropi tabanlı özneliklerin çıkarıldığı çalışmada [10] toplamda 14 öznelik kullanılmış ve en yüksek başarımları %92,91 ile Radyal Fonksiyon Tabanlı DVM (RBF-DVM) kullanılarak elde edilmiştir. Şeker ve ark. [11], 39 sağlıklı ve 39 şizofren katılımcı ile yaptıkları çalışmada, istatistiksel öznelikler (minimum, maksimum, ortalama, standart sapma, meydan) kullanarak en yüksek başarımlarını C4 kanalında ÇKA sınıflandırıcısı ile %99,95 olarak elde etmişlerdir. Aynı katılımcı grubunun kullanıldığı diğer bir çalışmada [12] ise EEG uyumluluğu bir nöro-ışaretçi olarak önerilmiş, aynı/farklı yarım küreler arası bulunan elektrotlar ile koherans değerleri hesaplanmıştır. F3-F4, F7-F8, T3-T4, C3-C4, P3-P4 ve O1-O2 simetrik elektrotlar kullanılarak k-NN sınıflandırıcısı ile %99,22 sınıflandırma başarımları gözlemlenmiştir. Literatürdeki çalışmaların özeti Çizelge-1'de görülebilir.

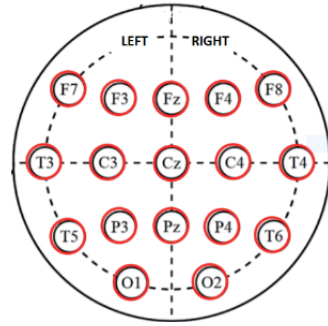
Bu çalışmada, Hilbert dönüşümü kullanarak EEG işaretlerinden kanal bazlı şizofreni hastalığının tespiti amaçlanmıştır. Çalışmada; Hilbert dönüşümü ile işarete ait sanal bileşenlerin analizi yapılmış, şizofren / kontrol grubundan oluşan EEG verileri elde edilmiş ve zamansal maliyeti düşük öznetelik vektörleri DVM ile sınıflandırılmıştır. Bu çalışmanın diğer benzer çalışmalara göre farkı, kanal bazlı şizofren hastalığının tespitini gerçekleştirmektir. Çalışmada; güç spektral yoğunluğu, lineer olmayan karmaşıklık analizi, dalgalı dönüşümü ve istatistiksel öznetelik tabanlı çalışmalarda sıklıkla elde edilen özneteliklerin genlik bilgisinden faydalanılmıştır. Bu alandaki başarı performansından dolayı, sınıflandırma algoritması olarak DVM tercih edilmiştir.

Çalışmanın organizasyonu şu şekildedir: Materyal ve Metot bölümünde, çalışmada kullanılan EEG kayıtları ve izlenen metot hakkında bilgi verilmiştir. Bulgular bölümünde, elde edilen sınıflandırma sonuçları sunulup, literatürdeki benzer çalışmalar ile karşılaştırılmıştır. Çalışmanın sonuç bölümünde ise amaç ile birlikte elde edilen kazanımlar belirtilmiştir.


2. Materyal ve Yöntem

2.1 Materyal

Bu çalışmada kullanılan EEG veri seti, yaşları 10-14 arasında farklılık gösteren 39 şizofreni ve yaşları 11-13 arasında değişen 39 sağlıklı katılımcıdan elde edilmiştir. Tüm katılımcıların cinsiyeti erkektir. EEG kayıtları, katılımcının gözleri kapalı konumda iken 10-20 sistemine göre düzenlenmiş 16 elektrot aracılığı ile alınmıştır. Kaydı alınan elektrotlar; F7, F3, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 ve O2 şeklindedir. Örnekleme frekansı 128 Hz ve kayıt süresi 1 dakikadır. Cihaz tarafından üretilen bant genişliği 0.5-45 Hz'dir. Elektrot empedansı 10 Kohm'un altındadır. Veri setine kullanıma açık halde http://brain.bio.msu.ru/eeg_schizophrenia.htm adresinden erişilebilir. Kullanılan veri seti ile ilişkili detaylara [13] nolu referanstan ulaşılabilir. Şekil 1.'de 16 elektrot konumu ve 1 saniyelik örnek EEG kaydı görülebilir.



(a)



(b)

Şekil-1: (a) Elektrot konumları ve (b) örnek EEG bölümü

Çizelge-1: EEG sinyalleri kullanarak Şizofreni tespiti temelli yapılan çalışmaların özeti

Yazarlar	Öznetelik Çıkarımı	Sınıflandırıcı	Doğruluk (Acc. %)
Johannesen vd. [8]	Teta1, teta2, alfa, Beta, gama frekans bileşenleri	SVM	%87,0
Devia vd. [14]	ERP öznetelikleri	LDA	%71,0
Kim vd. [6]	5 EEG bandına ait spectral Öznetelikler	ROC Analizi	%62,20
Piryatinska vd. [15]	e-karmaşıklık katsayıları	RF	%83,60
Sui vd. [16]	Çoklu kanonik korelasyon Analizi	SVM	%74
Boostani vd. [17]	Autoregressive (AR) model Parametreleri, band gücü ve Fraktal Boyut	LDA	%87.,50
Thilakvathi vd. [18]	Shannon, Spektral Entropi Hıguchi's Fraktal Boyut Yaklaşım Entropi	SVM	%88.,50

Siuly vd. [19]	Ampirik Mod Ayırma Tabanlı Karakteristik Özellikler	EBT (Ensemble Bagged Tree)	%89.,59
Oh vd. [9]	11 katmanlı Evrimsel Sinir Ağı	-	Genel: %98.07 Kişi Tabanlı: %81.26
V. Jahmunah [10]	Lineer olmayan öznelikler t-testi ile öznelik seçimi	SVM RBF	%92,91
Sabeti vd. [20]	Entropi öznelikleri	LDA, Adaboost	%89
Dvey-Aharon vd. [7]	Zaman-Frekans Dönüşümü	k-NN	%93,9
Santos-Mayo vd. [21]	P3b EEG Dalgasından zaman ve Frekans öznelikleri	SVM	%93,42
Krishan vd. [22]	İç Mod Fonksiyon (IMFs) tabanlı Farklı entropi öznelikleri	SVM	%93
Şeker ve Özerdem [11]	İstatistiksel Öznelikler	MLP	99.95
Şeker ve Özerdem [12]	Koherans değerleri	k-NN	%99.,22

2.2 Yöntem

İlgili veri seti mevcut gürültülerden (göz, kas hareketleri, şebeke gürültüsü) arındırılarak ham veri olarak kaydedildiği için ayrıca bir ön işlem yapmaya gerek kalmamıştır. Çalışmada takip edilen aşamalar Şekil 2.'de gösterilmiştir.

Hilbert Dönüşümü yöntemi gerçek bir zaman serisinden karmaşık bileşenler içeren bir zaman seri serisi üretimine dayanır. $a(t)$ işaretinin Hilbert Dönüşümü (1)'de verilen bağıntı ile hesaplanır.

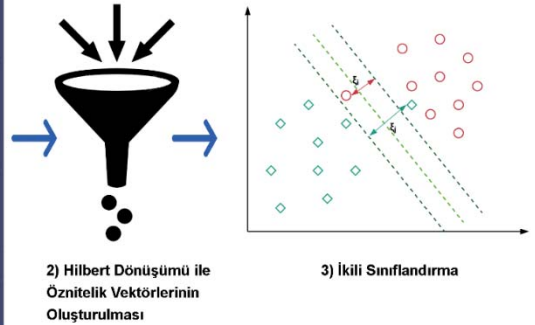
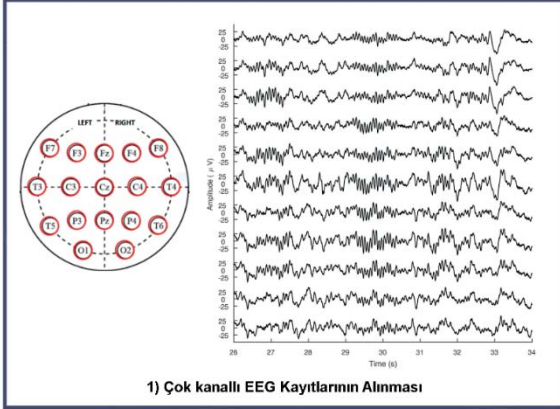
$$H[a(t)] = \frac{1}{\pi t} * a(t) \quad (1)$$

Bu dönüşüm orijinal işaretin $1/\pi t$ ile konvolüsyonunun ifadesidir. 2 no'lu bağıntı ile $a(t)$ işaretinin dönüşümünün ayrıtısına yer verilmiştir.

$$H[a(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} a(\tau) \frac{1}{1-\tau} d\tau \quad (2)$$

$a(t)$ işaretine ait analitik tanımlama (3) no'lu denklemde mevcuttur.

$$H[a(t)] = \hat{a}(t) = a(t) + j * \hat{a}(t) = |\hat{a}(t)| * e^{j\theta(t)} \quad (3)$$



Şekil-2: Çalışmada önerilen yöntemin aşamaları

Böylelikle sinyalin reel ve sanal kısımları elde edilmiştir. Elde edilen EEG sinyalin reel ve sanal kısımlarının; maksimumu, minimumu, standart sapması, ortalaması ve medyan değerleri hesaplanmıştır. Bu ifadeler Denklem (4-8) arasında verilmiştir.

Katsayıların mutlak değerlerinin minimumu:

$$x_{min} = \min|x(n)| \quad (4)$$

Katsayıların mutlak değerlerinin maksimumu:

$$x_{max} = \max|x(n)| \quad (5)$$

Katsayıların ortalaması:

$$x_{ort} = \sum_{n=1}^N \frac{x(n)}{N} \quad (6)$$

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

Standard sapma:

$$x_{std} = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - x_{ort})^2} \quad (7)$$

Medyan:

$x(n)$, $n = 1, 2, 3, \dots, N$ için;

$$M = \begin{cases} x_{(N+1)/2}, & N \text{ tek ise} \\ \frac{x_{N/2} + x_{(N/2)+1}}{2}, & N \text{ çift ise} \end{cases} \quad (8)$$

Çalışmada bu yöntemle kullanılan EEG lob kanal bilgileri ve bu bölge kanallarından elde edilen öznelik boyutu Çizelge-2' de gösterilmiştir.

Çalışmada bu iki grup EEG sinyalinden elde edilen öznelikler Destek Vektör Makinesi (DVM) kullanılarak sınıflandırılmıştır. 1995 yılında ilk kez Cortes ve Vapnik tarafından kullanılan yöntem, ikili sınıflandırmada istatistiksel öğrenme tabanlı bir yaklaşım sergiler. Bu sınıflandırıcının amacı çekirdek fonksiyonu aracılığı ile lineer olarak ayıramayan örnekleri daha üst bir boyuta taşımak ve optimal bir hiper düzlem belirlemektir.

Çizelge-2: Deneysel Sonuçları

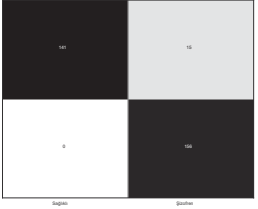
Beyin Lob Bölgesi	Kullanılan Kanallar	Elde Edilen Özellik Boyutu	
		Şizofreni	Sağlıklı
Frontal Lob	F3-F4-F7-F8	156x10	156x10
Parietal Lob	P3-Pz-P4	117x10	117x10
Temporal Lob	T3-T4-T5-T6	156x10	156x10
Central Lob	C3-Cz-C4	117x10	117x10
Oksipital Lob	O1-O2	78x10	78x10

Literatürde kullanılan çekirdek fonksiyonlar lineer, polinomlu, radyan fonksiyon tabanlı ve sigmoid nöral ağ tabanlı olarak gözlemlenebilir. Bu çalışmada radyal fonksiyon tabanlı (RBF) çekirdek kullanılmıştır [23]. Sınıflandırıcı algoritmasını kullanırken MATLAB 2019 yazılımından faydalanılmıştır. 'KernelScale' parametresi 'auto' olarak seçilmiştir. Seçilen bu opsiyon ile yazılım sezgisel bir yaklaşım kullanarak uygun bir ölçekleme faktörü seçer. Bu sezgisel yaklaşım alt örnekleri kullandığı için elde edilen sonuç her defasında farklı olabilir. Diğer bir parametre olan 'Standardize', 'true' seçilerek tahmin verilerinin her bir sütununu sırasıyla ağırlıklı sütun ortalamasına ve standart sapmaya göre merkezler ve ölçeklendirir [24].

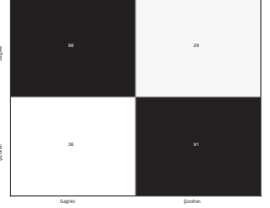
3. Sonuç

Bu çalışmada şizofreni ve sağlıklı kontrol gruplarının EEG kayıtları kullanılarak beyin lob farklılıkları ile bir sınıflandırma yapılmıştır. Sınıflandırma için kullanılan EEG veri seti 16 kanaldan oluşmaktadır. Ancak beynin lob bölgelerine konumlandırılan kanal sayısı birbirinden farklıdır. Bundan dolayı her bir bölge sınıflandırılmasında farklı boyut öznelikler kullanılmıştır. Bu öznelikler DVM sınıflandırıcıya verilmiştir. Sınıflandırma işleminde $k=10$ fold çapraz doğrulama yapılmıştır. Sınıflandırma sonuçları Çizelge 3-7'de verilmiştir.

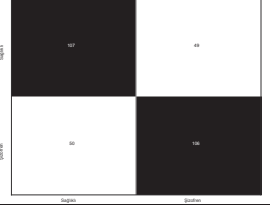
Çizelge-3: Frontal Lob Sınıflandırma Başarımı

Beyin Lob Bölgesi	Sınıflandırma Başarımı (%)	Grup	Tutturma (%)	Bulma (%)	F1-Score (%)	
Frontal Lob	95,19	Sağlıklı Grup	91,22	100	95,41	
		Şizofreni	100	90,38	94,94	

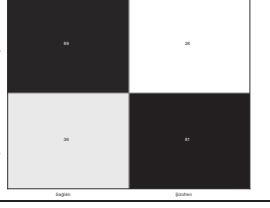
Çizelge-4: Parietal Lob Sınıflandırma Başarımı

Beyin Lob Bölgesi	Sınıflandırma Başarımı (%)	Grup	Tutturma (%)	Bulma (%)	F1-Score (%)	
Parietal Lob	76,49	Sağlıklı Grup	75,83	77,77	76,79	
		Şizofreni	77,19	75,21	76,19	

Çizelge-5: Temporal Lob Sınıflandırma Başarımı

Beyin Lob Bölgesi	Sınıflandırma Başarımı (%)	Grup	Tutturma (%)	Bulma (%)	F1-Score (%)	
Temporal Lob	68,26	Sağlıklı Grup	68,38	67,94	68,16	
		Şizofreni	68,15	68,59	68,37	

Çizelge-6: Central Lob Sınıflandırma Başarımı

Beyin Lob Bölgesi	Sınıflandırma Başarımı (%)	Grup	Tutturma (%)	Bulma (%)	F1-Score (%)	
Central Lob	72,64	Sağlıklı Grup	74,31	69,23	71,68	
		Şizofreni	71,20	76,06	73,55	

Çizelge-7: Oksipital Lob Sınıflandırma Başarımı

Beyin Lob Bölgesi	Sınıflandırma Başarımı (%)	Grup	Tutturma (%)	Bulma (%)	F1-Score (%)	
Oksipital Lob	82,69	Sağlıklı Grup	82.27	83.33	82.80	
		Şizofreni	83.11	82.05	82.58	

Çalışmada en iyi sınıflandırma başarımı %95,19 ile frontal lob 'dan oluşan özneliklerden elde edilmiştir. En düşük sınıflandırma performansının ise temporal lob bölgesinden alınan kanal öznelikleri olduğu görülmüştür. Çalışmada ayrıca Hassaslık (Precision), Bulma (Recall), F1-ölçütü (F1-Score) değerleri hesaplanmıştır. Bu değerlerden tutturma (Precision) değeri en yüksek frontal lob şizofren hastalardan elde edilmiştir. Diğer taraftan en düşük tutturma başarımı temporal lob şizofren hastalardan elde edilmiştir. Bulma ve f1-ölçütü başarımı en yüksek olarak sağlıklı kontrol grubu frontal lobunda elde edilirken, en düşük değeri temporal lob sağlıklı kontrol grubunda gerçekleşmiştir.

Bu çalışma çerçevesinde değerlendirildiğinde, şizofren ve sağlıklı kontrol grubu sınıflandırılmasında en iyi başarımlar, frontal lob'dan, en düşük başarımlar ise temporal lob'dan elde edilmiştir. Ayrıca frontal lob'un yanı sıra, oksipital lob'un da, bu tür grupların sınıflandırılmasında iyi bir sonuç verdiği görülmüştür. Çalışmada central ve parietal lob başarımlarının temporal lob sonuçlarından yüksek olduğu, ancak temporal ve oksipital lob başarımlarında daha düşük sonuçlar vermiştir. Kendi aralarında kıyaslandığında ise parietal lobun, central loba göre daha iyi sonuç verdiği görülmüştür.

4. Tartışma

Bu çalışmada, beyin farklı bölgelerinden alınmış EEG kayıtlarına kanal bazlı Hilbert Dönüşümü uygulanması sonucu elde edilen öznelik vektörleri DVM ile yüksek hassasiyet ve doğrulukta sınıflandırılmış, önerilen metodun nitelikli bir hastalık teşhis yöntemi olduğu gösterilmiştir. Sağlıklı ve hasta grupların başarılı şekilde

ayrıştırılması, izlenen metodun klinik tedavilerde uygulanabileceğini, klinisyenlere tedavi edilecek kişinin durumu konusunda fikir verebileceğini göstermektedir. Önerilen yöntemin farklı veri setlerinde uygulanması durumunda ön işleme adımları gerekebilir. Tablo I. İncelendiğinde çalışmalarda güç spektrum katsayıları, farklı entropi ölçümleri, zaman-frekans dönüşümü, Wavelet Dönüşümü, İstatistiksel öznelikler ve elektrotlar arası koherans değerleri incelenmiştir. Hilbert Dönüşümü şizofreni teşhisinde ilk kez bu çalışmada kullanılmıştır. Önerilen çalışma şizofreni teşhisinde tek bir öznelik çıkarma metodu kullanımı ve kanal bazlı sınıflandırma ile birçok çalışmaya göre başarılı sonuçlar vermiştir. Literatürde çoğunlukla mevcut kanallardaki sonuçları ayrı ayrı vermek yerine çok kanallı EEG sistemi kullanılmışlardır. Bu çalışmada kişi bazında sınıflandırılma yapılmamış olması çalışmanın eksiklikleri arasında gösterilebilir. İlerleyen çalışmalarda mevcut özellik çıkarma metoduna literatürde var olan diğer yöntemler (güç spektrum tabanlı, koherans tabanlı, entropi ve karmaşıklık tabanlı) eklenerek DVM dışında farklı sınıflandırıcılar uygulanarak bir karşılaştırma yapılabilir. Öznelik mühendisliğinin ötesine geçip Evrimsel Sinir Ağları ile başka bir analiz gerçekleştirme de ön görülebilir. Önerilen çalışma mevcut hali ile şizofreni hastalığı tespitinde literatüre katkı sunacak pratik bir uygulama olarak umut vadetmektedir.

Kaynakça

- [1] Rajinikanth, V., Satapathy, S. C., Fernandes, S. L., ve Nachiappan, S. *Entropy based segmentation of tumor from brain MR images – a study with teaching learningbased*

- optimization, Pattern Recognit. Lett., vol. 94, pp. 87–95, 2017.
- [2] Dünya Sağlık Örgütü (WHO): https://www.who.int/mental_health/managemen/schizophrenia/en.
- [3] Wang, Z. ve Oates, T. *Imaging time-series to improve classification and imputation*, IJCAI Int. Jt. Conf. Artif. Intell., vol. 2015-January, no. Ijcai, pp. 3939–3945, 2015.
- [4] Sanei S. ve Chambers, J. A. *EEG Signal Processing*. New York: Wiley, 2007.
- [5] Subudhi, A., Acharya, U. R., Dash, M., Jena, S. ve Sabut, S. *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.
- [6] Kim, J. W., Lee Y. S., Han D. H., Min K. J., Lee J., ve Lee K., *Diagnostic utility of quantitative EEG in un-medicated schizophrenia*, Neurosci. Lett., vol. 589, pp. 126–131, 2015.
- [7] Dvey-Aharon, Z., Fogelson, N., Peled, A. ve Intrator, N., *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.
- [8] Johannesen, J. K., Bi, J., Jiang, R. J., Kenney, G. ve Chen, C.-M. A., *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.
- [9] Santos-Mayo, L., San-Jose-Revuelta, L. M., ve Arribas, J. I., *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.
- [10] Jahmunah , V. ve ark., *Automated detection of schizophrenia using nonlinear signal processing methods*, Artif. Intell. Med., vol. 100, no. June, p. 101698, 2019.
- [11] Şeker, D. ve Ozerdem, M. S. *Sağlıklı ve Şizofrenik EEG Zaman Serilerinin Sınıflandırılması ve İstatistiksel Analizi*, TIPTEKNO'20, Medical Technologies Congress, 19-20 November 2020/Online.
- [12] Şeker, M. ve Ozerdem, M. S., *Şizofreni Teşhisinde Bir Nöro-ışaretçi olarak EEG Uyumluluğu*, 2020 28th Signal Processing and Communications Application Conference (SIU), Online.
- [13] Borisov, S. V., Kaplan, A. Y., Gorbachevskaya, N. L., ve Kozlova, I. A. *Analysis of EEG structural synchrony in adolescents with schizophrenic disorders*, Hum. Physiol., vol. 31, no. 3, pp. 255–261, 2005.
- [14] Devia, C. ve ark., *EEG classification during scene free-viewing for schizophrenia detection*, IEEE Trans. Neural Syst. Rehabil. Eng., vol. 27, no. 6, pp. 1193–1199, Jun. 2019.
- [15] Piryatinska, A., Darkhovsky, B. ve Kaplan, A., *Binary classification of multichannel-EEG records based on the α -complexity of continuous vector functions*, Comput. Methods Programs Biomed., vol. 152, pp. 131–139, Dec. 2017.
- [16] Sui, J. ve ark., *Combination of FMRI-SMRI-EEG data improves discrimination of schizophrenia patients by ensemble feature selection*, in Proc. 36th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc., Aug. 2014, pp. 3889–3892.
- [17] Boostani, R., Sadatnezhad, K. ve Sabeti, M., *An efficient classifier to diagnose of schizophrenia based on the EEG signals*, Expert Syst. Appl., vol. 36, no. 3, pp. 6492–6499, Apr. 2009.
- [18] Thilakvathi, B., Shenbaga, S. D., Bhanu, K. ve Malaippan, M. *EEG signal complexity analysis for schizophrenia during rest and mental activity*, Biomed. Res., vol. 28, no. 1, pp. 1–9, 2017.
- [19] Siuly, S. ve ark., *A Computerized Method for Automatic Detection of Schizophrenia Using EEG Signals*, IEEE Transactions on Neural Systems And Rehabilitation Engineering, vol. 28, no. 11, pp. 2390–2400, November 2020.
- [20] Sabeti, M., Katebi, S. ve Boostani, R., *Entropy and complexity measures for EEG signal classification of schizophrenic and control participants*, Artif Intell Med., 2009;47(3):263–74. <http://dx.doi.org/10.1016/j.artmed.2009.03.003>
- [21] Santos-Mayo, L., San-Jose-Revuelta, L. M., Arribas JI., *A computer-aided diagnosis system with EEG based on the p3b wave during an*

auditory odd-ball task in schizophrenia, IEEE Trans Biomed Eng., 2017;64(2):395–407. <http://dx.doi.org/10.1109/TBME.2016.255884>

[22] Krishnan, P. T., Raj, A. N. J., Balasubramanian, P., Chen, Y. *Schizophrenia detection using Multivariate Empirical Mode Decomposition and entropy measures from multichannel EEG signal*, Biocybernetics and Biomedical Engineering, vol. 40, pp. 1124-1139, 2020

[23] Liu, Y., Zhou W., Yuan, Q. ve Chen, S. *Automatic seizure detection using wavelet transform and SVM in long-term intracranial*

EEG, IEEE Trans. Neural Syst. Rehabil. Eng., vol. 20, no. 6, pp. 749–755, 2012.

[24] Christianini, N., ve Shawe-Taylor, J. C., *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. Cambridge, UK: Cambridge University Press, 2000.