

İmleç Hareketine Dayalı EEG Sinyallerinin Sinyal-Görüntü Dönüşümü Yöntemiyle Sınıflandırılması

Classification of the EEG Signals for the Cursor Movement with the Signal-to-Image Transformation

Bahar Hatipoğlu Yılmaz, Cağatay Murat Yılmaz, Cemal Kose
Bilgisayar Mühendisliği Bölümü
Karadeniz Teknik Üniversitesi
Trabzon, Türkiye
{baharhatipoğlu,cmyılmaz,ckose}@ktu.edu.tr

Özetçe —Elektroensefalografi (EEG) günümüzde epilepsi tedavisi gibi tıbbi araştırmalar ve beyin-bilgisayar arayüzü (BBA) gibi sistemlerin geliştirilmesinde sıklıkla kullanılmaktadır. Bu çalışmada, daha önce tarafımızca önerilen sinyal-görüntü dönüşümü (SGD) yöntemi ile EEG sinyallerinin sınıflandırılması gerçekleştirilmeye çalışılmıştır. SGD yöntemi, sonlu bir dönüşüm yöntemi olmakla birlikte sinyal üzerindeki yerel minimum ve maksimum noktalarının tespitine dayanmaktadır. Çalışma genel olarak dört bölüme ayrılmıştır. İlk bölümde EEG sinyalleri 2-boyutlu sonlu görüntülere dönüştürülmüş; ikinci bölümde Temel Bileşenler Analizi (TBA) yöntemiyle öznelik çıkarma işlemi gerçekleştirilmiştir ve üçüncü bölümde ise k -En Yakın Komşuluk (k -EYK), Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) yöntemleri yardımıyla sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yöntem %94'ün üzerinde sınıflandırma doğruluğu elde etmiş ve literatürdeki birçok çalışmaya kıyasla başarılı sonuçlar elde etmiştir. Elde edilen sonuçlar, söz konusu dönüşüm yöntemiyle EEG sinyallerinin başarılı bir şekilde sınıflandırıldığını göstermektedir.

Anahtar Kelimeler—sinyal-görüntü dönüşümü, elektroensefalografi (EEG), öznelik çıkarma, sınıflandırma, motor hareket hayali, beyin-bilgisayar arayüzü (BBA).

Abstract—Nowadays, EEG signals are highly used in the field of medical research, such as the treatment of epilepsy, and in the brain-computer interface systems. In this paper, our previously proposed Signal-to-Image Transformation (StIT) method is used for classification of EEG signals. StIT is a kind of finite transformation based on the detection of local maximum and minimum points on an EEG signal. This paper consists of four main stages. In the first stage, arbitrary time domain EEG signals are converted to two-dimensional finite images; in the second stage, principal component analysis is employed for feature extraction; in the third stage, k -nearest neighbour (k -NN), support vector machine, and artificial neural network methods are applied for the classification. The performance of the proposed method is over 94% and the results are better compared to most of the previous ones. The obtained results also show that the EEG signals are quite successfully classified by using the transformation.

Keywords—signal-to-image transformation, electroencephalog-

raphy (EEG), feature extraction, classification, motor imagery, brain-computer interface (BCI).

I. GİRİŞ

EEG sinyalleri kafa yüzeyinden elektrotlar yardımıyla alınan ve durağan bir yapıya sahip olmayan düşük genliğe sahip elektriksel işaretlerdir [2]. Bu sinyaller, nöron zarlarındaki kanallar boyunca pompalanan iyonlardan oluşan elektrik akımı sonucunda meydana gelmektedir [1], [3]. Literatürde birçok EEG tabanlı beyin bilgisayar etkileşimi çalışması mevcuttur ve bu çalışmalar genel olarak üç önemli aşamadan oluşmaktadır. İlk aşamada ham EEG sinyalleri insan kafasına yerleştirilen elektrotlar yardımıyla kaydedilmekte ve gerekirse gürültülerin kaldırılması, ilgili frekans bantlarının seçilmesi gibi ön-işlem aşamalarına tabi tutulmaktadır. İkinci aşamada EEG sinyalinden öznelikler çıkarılmakta ve üçüncü aşamada ise çıkarılan özneliklerin sınıflandırılması gerçekleştirilmektedir. Bu şekilde yürütülen çalışmalardan bazıları şu şekildedir.

Sabeti ve ark., EEG işaretlerini kullanarak şizofren hastaları ve normal kişilere ait EEG sinyallerini entropi ve karmaşıklık ölçütü yardımıyla sınıflandırmışlardır [4]. Çalışmalarını 20 şizofreni hastası ve benzer yaşlarda 20 sağlıklı denek üzerinde gerçekleştirmişlerdir. Her durum için EEG sinyallerini 20 kanal bilgisinden oluşacak şekilde kaydetmişler ve sinyallerden Shannon entropi, spektral entropi, yaklaşık entropi, Lempel-Ziv karmaşıklık ve Higuchi fraktal boyut yöntemleri yardımıyla öznelik çıkarma işlemi gerçekleştirmişlerdir. Doğrusal ayırtaç analizi (DAA) ve Adaboost yöntemlerini de sınıflandırma amacıyla kullanmışlardır. Başka bir çalışmada, Boostani ve ark. şizofreni tanısında EEG sinyallerini kullanmışlardır [5]. Çalışma 13 şizofreni hastası ve 18 sağlıklı birey üzerinde yürütülmüş ve Boosted Direct LDA (BDLDA), Adaboost, Destek Vektör Makineleri (DVM) ve Bulanık DVM olarak adlandırılan 4 farklı sınıflandırma yöntemi kullanılmıştır. Pfurtscheller ve ark. ise sağ ve sol el hareketlerinin hayali sırasında oluşan EEG verilerinin ayrıştırılmasına yönelik bir çalışma yapmışlardır [6]. Çalışmada 3 denekten sağ

ve sol ellerini hareket ettirdiklerini hayal etmeleri istemişlerdir. Her denek 3-4 oturumda toplam 160 el hareketi hayal etmiştir. Ting ve arkadaşları BBA için EEG sinyallerinden Dalgacık Paket Ayırma (DPA) yöntemine dayanan yeni bir öznelik çıkarma metodu önermişlerdir [7]. Özel alt bantların enerjisini ve buna bağlı olarak DPA'nın katsayılarını öznelik olarak kullanmışlardır. Önerilen yöntem BCI Competition 2003 Dataset I(a ve b) veri setlerinde sınanmıştır. Sun ve Zhang yaptıkları çalışmada yine BCI Competition 2003 Dataset Ia'yı kullanarak EEG sinyal kategorizasyonu için öznelik belirleme üzerine çalışmışlardır [8]. Wang ve arkadaşları da aynı veri setini kullanarak dalgacık paket ayırımı ve sinir ağıyla yöntemiyle EEG tanıma üzerine çalışmışlardır [9]. Bu yöntemleri kullanarak EEG tabanlı beyin bilgisayar etkileşimli uygulamada ikili sınıflandırma yapmışlar ve ağı yapısını değiştirerek performans üzerine etkilerini incelemişlerdir. Aynı veri setini kullanarak çalışma yapan diğer bir grup da Mensh ve ark. EEG sinyallerinin sınıflandırılması için yüksek frekanslı gama bandını kullanmışlardır [10]. Bunun yanında, çalışmada daha anlamlı tahminler yapmak amacıyla farklı bir yaklaşımda bulunarak yavaş kortikal potansiyeller kullanarak başarı oranlarını artırmışlardır. Kayıkçıoğlu ve Aydemir aynı veri seti üzerinde yaptıkları çalışmada polinom uydurma yöntemi önermişlerdir [11]. Çalışmada EEG verilerinden çıkarılan öznelikler k -EYK metodu ile sınıflandırılmıştır.

Bu çalışmada ise anlaşılması ve uygulanması oldukça kolay bir yöntem olan sinyalleri görüntülere dönüştürme yöntemi kullanılmıştır. Yöntemde ilk olarak sinyal üzerindeki tüm yerel maksimum ve minimum (çalışmada değişim noktaları olarak adlandırıldı) noktaları tespit edilmiştir. İkinci olarak ise belirlenen bu değişim noktaları arasındaki uzaklıklar ve açılar hesaplanmıştır. Son olarak ise elde edilen bu uzaklık ve açı değerleri yardımıyla sinyaller 2-boyutlu görüntülere dönüştürülmüştür. Bu dönüşüm işleminin ardından öznelik çıkarma ve sınıflandırma aşamaları görüntüler üzerinde gerçekleştirilmiştir. Çalışmada, öznelik çıkarma aşamasında Temel Bileşenler Analizi (TBA) yöntemi kullanılırken, sınıflandırma aşamasında ise k -EYK, YSA ve DVM yöntemleri kullanılmıştır. En yüksek sınıflandırma doğruluğu TBA ve DVM yöntemlerinin birlikte kullanılmasında elde edilmiştir. Literatürdeki çalışmalara göre kıyaslamalar yapıldığında, mevcut yöntemin başarılı sonuçlar elde ettiği ve EEG sinyallerinin sınıflandırılması için etkili bir araç olabileceği görülmüştür.

Bildirinin diğer bölümleri şu şekilde düzenlenmiştir. Bölüm II'de kullanılan veri seti ve yöntemler, Bölüm III'te deneysel sonuçlar, Bölüm IV'te ise değerlendirme ve öneriler verilmiştir.

II. MALZEME VE YÖNTEM

A. Dataset Ia

Yapılan bu çalışmada 2003 yılındaki Beyin Bilgisayar Etkileşimi yarışmasında (BCI Competition 2003) yayınlanan ve Almanya'da Tübingen Üniversitesi tarafından hazırlanan Dataset Ia veri seti kullanılmıştır [13]. Veri setinde kayıtlar sağlıklı bir deneğin bilgisayar ekranındaki imleci aşağı ve yukarı hareket ettirmesi sırasında 256 Hz. ile örneklenerek alınmıştır. Kayıt sırasında elektrotlar kafa yüzeyine uluslararası 10 – 20 standardına göre referans elektrodu C_z olacak şekilde yerleştirilmiştir. Bu referans elektroda göre A1, A2, FC3, CP3, FC4 ve CP4 elektrotlardan kayıtlar alınmıştır. Veri seti 268 adet eğitim ve 293 adette test verisi içermektedir.

III. SINYAL-GÖRÜNTÜ DÖNÜŞÜM YÖNTEMİ

Bu çalışmada, daha önceki çalışmamızda önermiş olduğumuz sinyal-görüntü dönüşümü (SGD) yöntemiyle [12] EEG sinyalleri sınıflandırılmaya çalışılmıştır. Söz konusu yöntem sinyal üzerindeki yerel minimum (sinyal üzerinde bir bölgede komşularına göre en küçük genlik değerine sahip nokta) ve maksimum noktalarının (sinyal üzerinde bir bölgede komşularına göre en yüksek genlik değerine sahip olan nokta) tespitine dayanmaktadır. Çalışma boyunca yerel minimum ve maksimum noktaları birlikte değişim noktaları olarak adlandırılmıştır. Örnek bir sinyal ve değişim noktaları Şekil 1(a)'da ki gibidir. Kırmızı noktalar yerel maksimumları, yeşil noktalar ise de yerel minimumları ifade etmektedir.

Değişim noktaları belirlendikten sonra, her minimum ve maksimum noktasının sağ ve sol yanındaki doğrular arasındaki açı tanjant formülü ile hesaplanmaktadır. Buradaki açı değeri, bir değişim noktasının sağ ve sol yanındaki diğer değişim noktasına çizilen doğruların kesiştiği yerde oluşmaktadır. Yöntemde, açı değerleri $\alpha \in \{\alpha_r\}$, $r \in \{0, 1, \dots, K\}$ şeklinde temsil edildiğinde K değeri toplam açığı ifade etmektedir. α_r açı değeri sırasıyla (1) eşitliği ile hesaplanan m_r ve m_{r+1} eğimli doğrular arasındaki açığı ifade etmektedir. Örneğin, herhangi bir değişim noktasında kesişen iki doğru $y_r = m_r x_r + c_r$ ve $y_{r+1} = m_{r+1} x_{r+1} + c_{r+1}$ şeklinde olsun. Buradaki m_r ve m_{r+1} eğimleri, x_r ve x_{r+1} sinyal üzerindeki noktaları, c_r ve c_{r+1} ise sabitleri ifade etmektedir.

$$m_r = \frac{y_{r+1} - y_r}{x_{r+1} - x_r} \quad (1)$$

Çalışmada α_i değeri pozitif yönlü bir açı olarak kabul edilmiş ve açı değeri $(m_r - m_{r+1}) / (1 - (m_r * m_{r+1}))$ arktanjan trigonometrik fonksiyonu ile hesaplanmıştır. Benzer şekilde, α_k negatif yönlü bir açı olarak kabul edilmiş ve açı değeri $(-1) \times (m_r - m_{r+1}) / (1 - (m_r * m_{r+1}))$ arktanjan trigonometrik fonksiyonundan faydalanılarak hesaplanmıştır.

Yöntemde ifade edilen genlik değeri ise, her değişim noktasının sağ ve sol yanındaki doğrulardan (i) uzunluğu daha büyük olan belirlenmesi ve ardından (ii) büyük olanın küçük olana bölünmesi ile hesaplanmaktadır. Uzaklık değerleri ilgili yerel maksimumu ve minimum noktaları arasındaki öklid mesafesi ile hesaplanmıştır. Herhangi bir değişim noktasına ait $R_r(t_r)$ genlik değerini hesaplanması aşağıda (2) ile verilen denklemdeki gibidir.


$$R_r(t_r) = \begin{cases} \frac{b_r(t_r)}{a_r(t_r)} & b_r(t_r) < a_r(t_r) \\ -\frac{a_r(t_r)}{b_r(t_r)} & otherwise \end{cases} \quad (2)$$

Son olarak söz konusu noktalar 2 boyutlu düzleme yerleştirilerek sinyalleri temsil edecek 2-B görüntüler elde edilmiştir. Örnek bir EEG sinyaline ait açı-genlik grafiği Şekil 1(b)'de ki gibidir.

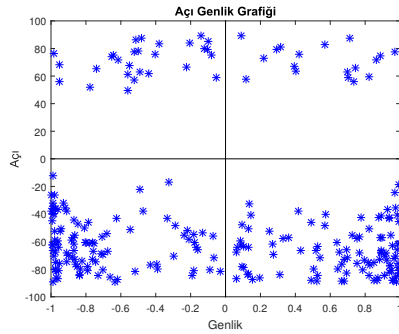
IV. ÖZNETELİK ÇIKARMA VE SINIFLANDIRMA

A. Temel Bileşen Analizi

Temel Bileşen Analizi (TBA), ortogonal doğrusal dönüşüm kullanarak veriyi yeni bir koordinat düzlemine taşıyan bir dönüşüm tekniğidir [18]. Yöntemde temel amaç, n boyutlu



(a) Bir EEG sinyali ve sinyale ait değişim noktaları



(b) Sinyale ait açı-genlik görüntüsü

Şekil 1: Örnek bir sinyale ait açı-genlik grafiği

veriden daha az boyutlu veri elde etmek ve elde edilen anlamlı verilerle tüm veri setinin temsil edilmesini sağlayarak boyutu azaltmaktadır. Teorik olarak TBA'nın mantığı oldukça basittir. İlk olarak d -boyutlu ortalama vektörü hesaplanır, ikinci olarak $d \times d$ boyutunda kovaryans matrisi tüm veri setinden faydalanarak hesaplanır. Bir sonraki aşamada özdeğerler ve özvektörler hesaplanır ve özdeğerlere bağlı olarak özvektörler azalan şekilde sıralanırlar. Tüm bu işlemlerden sonra ilk k adet özvektör seçilir (geri kalanı göz ardı edilir) [14]. Bu çalışmada ilk 70 öznitelik vektörü kullanılmıştır.

B. Destek Vektör Makineleri

Gerçek hayattaki birçok uygulamaya ait problemlerin Destek Vektör Makineleri (DVM) ile çözülmesi istendiğinde doğrusal DVM yöntemleri başarılı olmamaktadır. Çünkü elde edilecek model probleme uygun olmamaktadır. Verilerin doğrusal ayrışmadığı bu gibi durumlarda çekirdek fonksiyonları ile optimal ayırıcı hiper düzlem aranmalıdır. Çalışmada, TBA sonucu elde edilen öznitelik vektörleri radyal tabanlı çekirdek fonksiyonları ile sınıflandırılmaya çalışılmıştır. Başarılı bir sınıflandırma performansı için DVM ve dolayısıyla çekirdek fonksiyonları kullanılırken uygun parametre değerlerinin seçilmesi ve ayarlanması oldukça önemlidir. Çalışmada kullanılan yöntemin sınıflandırma başarısı belirlenirken, kullanılan çekirdek fonksiyonun alt ve üst sınırları arasındaki parametre değerleri belirli aralıklarla değerleri ile atlanarak sınanmıştır (sınıflandırma doğruluğundan faydalanarak).

C. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA) temel olarak biyolojik sinir hücrelerinin işleyişinden esinlenerek oluşturulmuştur. Yöntemde, işleme elemanları beyindeki nöronların çalışmasına benzer şekilde çalışmakta ve nöron ya da yapay nöronlar olarak da adlandırılmaktadırlar [16]. Ağın öğrenme yeteneği bağlantı yapısına, transfer fonksiyonuna, gizli katman sayısı ve her gizli katmandaki nöron sayısına bağlı olarak değişebilmektedir [17]. Bu çalışmada, sigmoid aktivasyon fonksiyonunu kullanan geri beslemeli ve çok katmanlı (3 katman) perseptron (ÇKP) modeli kullanılarak sınıflandırılma yapılmıştır.

D. k -En Yakın Komşuluk Algoritması

k -En Yakın Komşuluk (k -EYK) kolay anlaşılabilir ve uygulanabilir bir algoritma oluşu nedeniyle sıklıkla tercih edilen bir yöntemdir [15]. Özellikle birçok probleme ait temel sınıflandırma başarısının belirlenmesinde kullanılsa da, birçok problemde başarılı sonuçlar elde etmiştir. k -EYK ile başarılı sonuçlar almak için, karar verme aşamasında en yakın kaç adet örneğin kullanılacağını ifade eden k parametresinin belirlenmesi oldukça önemlidir. Çalışmada iki sınıflı problemler üzerinde çalışıldığından, k değeri tek sayılar olacak şekilde sınanarak en uygun elle belirlenmeye çalışılmıştır. En yüksek doğruluk değerleri $k = 3$ için elde edilmiştir.

V. DENEYSEL SONUÇLAR

EEG işaretleri, beyne ait çok miktarda bilgi içeren durağan olmayan yapıdaki karmaşık işaretlerdir. Bu işaretlerin incelenmesi ve değerlendirilmesi için kesin ölçütler yoktur ve işaretlere ait birçok problemin çözümü için yeni yöntemlerin önerilmesi gerekmektedir. EEG sinyalleri birçok hastalık tespiti, beyin-bilgisayar arayüzleri (BBA) vb. çalışma alanlarında etkin olarak kullanılmaktadır. Bu işlemlerde, kafa yüzeyinden elektrotlar yardımıyla kaydedilen sinyaller, kayıt sonrasında işlenmekte ve hastalık ve/veya belirtileri tespit edilmeye çalışılmakta veya beyin sinyalleri bilgisayarları kontrol edecek kontrol sinyallerine dönüştürülmektedir. Bu tarz sistemlerin geliştirilmesinde, kayıt işlemi esnasında EEG sinyallerine sıklıkla gürültü karışabilmektedir (kan basıncı, kan akış hızı, deri direnci ve yüz ifadeleri gibi faktörler vb. nedeniyle). Geliştirilecek sistemin başarısına ve doğruluğuna negatif yönde etki eden bu tarz gürültülerin kaldırılması amacıyla literatürde ön-işlem aşaması olarak birçok yöntem önerilmiştir.

Çalışmada bu amaç doğrultusunda, EEG sinyallerinin sınıflandırılması için SGD yöntemi kullanılmıştır. Bu işlem, EEG sinyallerinin açı-genlik bilgilerinden oluşan 2-B sonlu grafik görüntüsüne dönüştürülmesi ile gerçekleştirilmiş ve yöntem imleç hareketinin hayali sırasında kaydedilmiş EEG sinyallerinde sınanmıştır. Sınıflandırma işleminin doğruluğu k -kat çapraz doğrulama yöntemiyle test edilmiştir. Öznitelik çıkarma ve boyut azaltma işlemlerinde kullanılan TBA yönteminde tüm bileşenlerin kullanılmasına gerek olmadığı ve yeterli sayıda bileşen ile yüksek sınıflandırma doğruluğunun sağlanabileceği görülmüştür. Gereksiz olan temel bileşenlerin sınıflandırma performansını azaltacağı ve bu ilgisiz verilerin sistem çalışmasına negatif yönde katkı sağlayacağı gözlemlenmiştir. Sınıflandırma aşamasında k -EYK, YSA ve DVM yöntemleri kullanılmıştır. Bu yöntemlerdeki en uygun model

parametreleri ızgara tabanlı arama ve el ile belirlenmeye çalışılmıştır. k-EYK yönteminde uzaklık metriği olarak öklid mesafesi kullanılmıştır. YSA'nın çok katmanlı olarak kullanılması doğrudan sınıflandırma başarısını etkilemektedir. Bu nedenle görüntüleri sınıflandırmak amacıyla öğrenme kuralı olarak çok katmanlı ve geri yayımlı perseptron kullanılmasına karar verilmiştir. DVM yönteminde ise kullanılan çekirdek fonksiyonun yanı sıra en doğru parametre değerlerinin kullanılmasının sınıflandırma başarısını oldukça etkilediği görülmüştür.

Önerilen yöntemlerin başarısının doğruluğu eğitim ve test işlemlerinin güvenilir ve geçerli veri setlerinde yürütülmesi ile elde edilebilir. Çalışmada bu amaçla önerilen yöntemler BCI Competition III Dataset Ia veri setinde sınanmıştır. Sinyal-görüntü dönüşümü yöntemi sonrasında TBA ile öznitelik çıkarılması ve sonrasında sırasıyla k-EYK, DVM ve YSA yöntemleri ile sınıflandırma sonrasında elde edilen sonuçlar Tablo I'de ki gibidir. Tabloda verilen sonuçlar 7-kat çapraz doğrulama sonucunda ortalama alınarak hesaplanmıştır. En başarılı sonuçlar, SGD dönüşüm yöntemi sonrasında uygulanan TBA öznitelik çıkarma ve DVM sınıflandırma yöntemleri ile elde edilmiştir. Literatürde aynı veri seti üzerinde uygulanan bazı diğer çalışmalarda Tablo II'de verildiği gibi %88.70 ile %92.15 arasında sınıflandırma doğruluğu elde edilmiştir. Bu sonuçlara göre kıyaslama yapıldığında, bu çalışmada kullanılan dönüşüm yöntemi ve sonrasında uygulanan öznitelik çıkarma ve sınıflandırma yöntemlerinin oldukça başarılı olduğu görülmektedir.

Tablo I: Dataset Ia veri setinde sınıflandırma doğrulukları

Kanal	Yöntem		
	SGD+TBA+DVM	SGD+TBA+YSA	SGD+TBA+k-EYK
Kanal 1	94.47	73.98	70.89
Kanal 2	93.98	70.94	66.49
Kanal 3	90.97	63.79	52.37
Kanal 4	90.25	69.56	57.82
Kanal 5	65.51	70.94	60.79
Kanal 6	60.14	73.98	57.04

Tablo II: Dataset Ia veri setindeki çalışmaların kıyaslaması

Yöntem	Sınıflandırma Doğruluğu (%)
Mensh ve ark. [10]	88.70
Sun ve Zhang [8]	90.44
Ting ve ark. [7]	90.80
Wang ve ark. [9]	88.70
Kayikcioglu ve Aydemir [11]	92.15
SGD+TBA+DVM Yöntemi	94.47

VI. DEĞERLENDİRME VE GELECEK ÇALIŞMALAR

Çalışmada elde edilen başarılı ve ümit verici sonuçlardan, SGD dönüşüm yöntemi ile EEG sinyallerinin etkili bir şekilde sınıflandırılabilmesi görülmektedir. Ancak kullanılan yöntemin başarısının tam olarak ortaya konması ve daha başarılı sonuçların alınması için yapılabilecek bir çok çalışma mevcuttur. Örneğin, yöntem motor hareket hayali dışında farklı EEG işaretlerinin sınıflandırılmasında sınanarak başarısı ölçülebilir. Bunun yanında yöntem üzerinde de değişikliklere gidilebilir. EEG işaretleri daha sık örneklenerek daha fazla değişim noktası tespit edilebilir ve dolayısıyla açığa çıkarılması daha net elde edilebilir (bu işlemin sınıflandırma yöntemlerinden daha etkin sonuçlar elde edilmesine olanak sağlayacağı düşünülmektedir). Ayrıca, dönüşüm sonrasında farklı

öznitelik çıkarma ve sınıflandırma yöntemleri uygulanabilir ve sınıflandırma performansı artırılabilir.

KAYNAKÇA

- [1] M., Teplan, "Fundamentals of EEG measurement. Measurement science review", 2(2), 1-11.
- [2] D. K., Reddy, A., Manglick, R., Upadhyay, P. K., Padhy, "Feature extraction and classification of Electroencephalogram signals for vigilance level detection", In Control, Automation, Robotics and Embedded Systems (CARE), 2013 International Conference on (pp. 1-4), IEEE.
- [3] Güven, M. (2012). Biyopotansiyeller ve ölçüm cihazları. Arşiv Kaynak Tarama Dergisi, 21(3), 174-188.
- [4] M., Sabeti, S., Katebi, R., Boostani, "Entropy and complexity measures for EEG signal classification of schizophrenic and control participants", Artificial Intelligence in Medicine, 47(3), 263-274, 2009.
- [5] R., Boostani, K., Sadatnezhad, M., Sabeti, "An efficient classifier to diagnose of schizophrenia based on the EEG signals", Expert Systems with Applications, 36(3), 6492-6499, 2009.
- [6] G., Pfurtscheller, C., Neuper, D., Flotzinger, M., Pregenzer, "EEG-based discrimination between imagination of right and left hand movement", Electroencephalography and clinical Neurophysiology, 103(6), 642-651.
- [7] W., Ting, Y., Guo-zheng, Y., Bang-hua, S. Hong, "EEG feature extraction based on wavelet packet decomposition for brain computer interface", Measurement, 41(6), 618-625.
- [8] S., Sun, C., Zhang, "Assessing features for electroencephalographic signal categorization", In International Conference on Acoustics, Speech, and Signal Processing, (Vol. 5, pp. v-417), IEEE.
- [9] B., Wang, L., Jun, J., Bai, L., Peng, G., Li, Y., Li, "EEG recognition based on multiple types of information by using wavelet packet transform and neural networks", In 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference, (pp. 5377-5380), IEEE.
- [10] B. D., Mensh, J., Werfel, H. S., Seung, "BCI competition 2003-data set Ia: combining gamma-band power with slow cortical potentials to improve single-trial classification of electroencephalographic signals", IEEE Transactions on Biomedical Engineering, 51(6), 1052-1056.
- [11] T., Kayikcioglu, O., Aydemir, "A polynomial fitting and k-NN based approach for improving classification of motor imagery BCI data", Pattern Recognition Letters, 31(11), 1207-1215.
- [12] B., Hatipoglu, C. M. Yilmaz, and C., Kose, "A signal-to-image transformation approach for EEG and MEG signal classification", Signal, Image and Video Processing, 13(3), 483-490, 2019.
- [13] B. Blankertz, K.R. Mueller, G. Curio, T.M. Vaughan, G. Schalk, J.R. Wolpaw, A. Schloegl, C. Neuper, G. Pfurtscheller, T. Hinterberger, M. Schroeder, and N. Birbaumer. The BCI Competition 2003: progress and perspectives in detection and discrimination of EEG single trials. IEEE Trans Biomed Eng, 51:1044-1051, Jun 2004.
- [14] A., Subasi, M. I., Gursoy, "EEG signal classification using PCA, ICA, LDA and support vector machines", Expert Systems with Applications, 37(12), 8659-8666, 2010. (38)
- [15] R., Bose, A., Khasnobish, S., Bhaduri, D. N., Tibarewala, "Performance analysis of left and right lower limb movement classification from EEG", In Signal Processing and Integrated Networks (SPIN), 3rd International Conference on (pp. 174-179), IEEE, 2016. (41)
- [16] K., Abhishek, A., Kumar, R., Ranjan, S., Kumar, "A rainfall prediction model using artificial neural network", In Control and System Graduate Research Colloquium (ICSGRC), IEEE (pp. 82-87), 2012. (42)
- [17] Z., Bo, "The prediction of warp breakage rate of weaving by considering sized yarn quality using artificial neural network theory", In Computer Design and Applications (ICCD), (Vol. 2, pp. V2-526), IEEE, 2010. (43)
- [18] E., Gumus, N., Kilic, A., Serbas, O. N., Ucan, "Evaluation of face recognition techniques using PCA, wavelets and SVM", Expert Systems with Applications, 37(9), 6404-6408, 2010. (63)