

EEG İşaretlerinde Boyut İndirgeme Algoritmalarının Karşılaştırılması

Comparison of Dimension Reduction Algorithms on EEG Signals

Ümit Özsandıkcioglu¹, Ayten Atasoy¹, Yavuz Kablan², Yusuf Sevim¹, Murat Aykut³

¹Elektrik Elektronik Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
{umitozsandikci, ayten, ysevim}@ktu.edu.tr

²Elektrik Elektronik Mühendisliği Bölümü, Avrasya Üniversitesi, Trabzon, Türkiye
yavuz.kablan@avrasya.edu.tr

³ Bilgisayar Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye
murat_aykut@ktu.edu.tr

Özetçe—Bütün sınıflandırma algoritmalarında olduğu gibi, elektroensefalografi (EEG) uygulamalarının sınıflandırma başarısını arttıran en önemli işlem, işarete ait uygun özniteliklerin elde edilmesi aşamasıdır. Sınıflandırma uygulamalarında belirli bir öznitelik çıkarma metodu bulunmadığından dolayı, seçilen özniteliklerin oluşturduğu öznitelik matrisi büyük boyutlarda olabilmekte ve bu durum sistemin hızını ve başarısını olumsuz olarak etkilemektedir. Bu çalışmada, ‘BCI Competition III’ yarışmasında kullanılan III. veri seti kullanılmıştır. Bu veri seti için, Temel Bileşen Analizi, Çekirdek Temel Bileşen Analizi ve veri setindeki komşuluk yapısını koruyarak verinin projeksiyonunu sağlayan, Temel Bileşen Analizine alternatif yöntem olan Yerellik Koruyucu İzdüşüm algoritmaları kullanılarak öznitelik matrisi üzerinde boyut azaltma işlemi yapılmıştır. Sonuç olarak, Chebyshev mesafe ölçümü yöntemini kullanan Yerellik Koruyucu İzdüşüm algoritması ile en yüksek başarı % 83.28 olarak elde edilmiştir.

Anahtar Kelimeler — EEG, Temel Bileşen Analizi, Çekirdek Temel Bileşen Analizi ve Yerellik Koruyucu İzdüşüm algoritması.

Abstract—Like in all classification applications, the most important process which increases classification success of electroencephalography (EEG) applications is to choose the proper features for signals. Since there is not certain feature extraction method for data classification applications, used feature matrix size can be redundantly large and this state effect the system's speed and success negatively. In this study Data Set III of BCI competition 2003 was used. We extract features using this data set and then dimension of feature matrix size reduced by using Principal Component Analysis, Kernel Principal Component Analysis and Locality Preserving Projections method which is alternative to Principal Component Analysis. As a result, the best success rate is obtained as 83.28% when Linearity Preserving Projections algorithm with Chebycev distance measuring method is used.

Keywords — EEG, Principal Component Analysis, Kernel Principal Component Analysis and Locality Preserving Projection.

I. GİRİŞ

Hasta kişilerin kas sistemlerini kullanmadan, yapmak istediklerini anlayabilen ve bu konuda onlara yardımcı

olabilecek makinelerin tasarlanmasına yönelik çalışmalar son zamanlarda yoğunluk kazanmıştır. Bu çalışmalarda kullanılabilecek en önemli işaretlerden biri Beyin Bilgisayar Arayüzü (BBA) uygulamaları ile elde edilen Elektroensefalografi (EEG) işaretidir.

EEG insan kafatası üzerinden beyindeki sinir hücreleri aktiviteleri sonucunda oluşan elektriksel işaretlerin algılanarak elde edilmesi işlemi olarak adlandırılabilir. EEG elektrotları yapılacak uygulamanın cinsine bağlı olarak kafatasının uygun bölümlerine yerleştirilir. EEG yöntemi insan beyni tarafından oluşturulan 1-100µV gerilim aralığındaki işaretleri ölçebilecek bir yöntemdir ve beyin bilgisayar arayüzü uygulamaları arasında en fazla tercih edilen yöntemdir [1,2]. EEG işaretleri sahip oldukları farklı frekans seviyelerine göre kategorize edilirler. Delta dalgaları 4 Hz’ den daha düşük frekanslı işaretlerdir. Teta dalgaları 4Hz ile 8Hz arasındaki işaretleri, Beta dalgaları 14Hz ile 32Hz arasındaki işaretleri ve Gamma dalgaları da 32 Hz ve üzerindeki işaretleri belirtmektedir [1]. Verilen bu frekans bantları kişilerin gerçekleştirdiği aktivite türlerine karşılık gelmektedir ve her bir frekans bandı beyin aktivitesi hakkında farklı bilgiler içermektedir. EEG yönteminde alınan işaretler yukarıda belirtilen frekans bantlarındaki işaretlerden oluşmaktadır ancak elde edilen bu işaretlerin analizi ve bu işaretlerden bilgi çıkarımı çok boyutlu işaret işleme ve sınıflandırma algoritmalarının kullanılmasını gerektirmektedir [3].

Literatürde birçok EEG işaret işleme ve sınıflandırma uygulamasına ulaşmak mümkündür. Örneğin, EEG sınıflandırma sonuçlarındaki başarının artırılması amacıyla araştırmacılar ERD/ESR ve Hareket Bağımlı Kortikal Potansiyel yöntemlerini kullanmışlar ve bu iki yöntemin beraber kullanıldığı kombine bir yöntemin sınıflandırma sonuçlarını artırdığını ortaya koymuşlardır [4]. Üç farklı sınıfın bulunduğu diğer bir çalışmada araştırmacılar sağ/sol el ve ayak hareketlerinin hayal edilmesine bağlı olarak bir tekerlekli sandalyenin hareket ettirilmesini sağlayan bir sistem oluşturmaya çalışmışlar ve %85 başarı ile bu sistemi gerçekleştirmişlerdir. [5].

Farklı bir çalışmada, 100 farklı denek üzerinden alınan EEG işaretlerini kullanarak hem sağ ve sol yumrukların hareketi sonucunda oluşan EEG işaretlerini, hem de sağ ve sol yumrukların hareket edildiğinin hayali sonucunda oluşan EEG işaretlerini sınıflandırmışlardır ve çalışmalarında belirledikleri dalgacık katsayıları için birçok dalgacık ailesi kullanmışlardır [6].

Fourier dönüşümü tabanlı özniteliklerin kullanıldığı farklı bir çalışmada ise araştırmacılar sağ ve sol el hareketlerinin düşünülerek kaydedildiği EEG işaretlerini sınıflandırmışlardır [7]. EEG işaretlerinden Sara nöbetlerinin tespitine yönelik yapılan bir çalışmada ise öznitelik çıkarımı için farklı dalgacık dönüşümü yöntemleri, sınıflandırma için ise YSA kullanılmış ve sınıflandırma doğruluğu % 99.26 olarak elde edilmiştir [8].

Yerellik Koruyucu İzdüşüm (YKİ) yönteminin kullanıldığı ve korteks tabanlı BBA uygulamalarındaki verimi artırmak için YKİ yöntemiyle Doğrusal Ayırıştırma Analizi (DDA) yöntemini birlikte kullanmış ve klasik uyumlu süzgeç yaklaşımı yönteminden daha iyi bir sonuç elde etmişlerdir [9].

Diğer bir çalışmada araştırmacılar epileptiform deşarjların tespit edilmesi amacıyla YKİ ve Destek Vektör Makineleri (DVM) yöntemini kullanarak daha hassas ve daha düşük hatalı pozitif oranına sahip bir sistem elde etmişlerdir [10].

EEG işaretleri kullanılarak duygu tanıma çalışmalarında bileşen analizi yardımıyla denek transfer sisteminin önerildiği farklı bir çalışmada Aktarma Bileşen Analizi (ABA) ve ÇTBA analizi kullanılmış ve en iyi ortalama başarı 79.83% ile ÇTBA yönteminin kullanılmasıyla elde edilmiştir [11].

TBA ve Bağımsız Bileşen Analizi yöntemlerinin kullanıldığı ve karşılaştırıldığı diğer bir çalışmada ise araştırmacılar EEG işaretlerinde oluşan bozucu işaretleri tespit etmişler ve gerçekleştirdikleri bu çalışmanın başarısını bir uzman tarafından yapılan bozucu işaret tespitiyle karşılaştırmışlardır [12].

Bu çalışmada ise, sınıflandırılacak EEG işaretlerinden dalgacık dönüşümü ve Fourier dönüşümünün de içinde bulunduğu birçok öznitelik elde edildi. Elde edilen yüksek boyutlu öznitelik matrisinde boyut azaltmak için Temel Bileşen Analizi (TBA), Çekirdek Temel Bileşen Analizi (ÇTBA) ve YKİ yönteminin sınıflandırma başarısına etkisi, sınıflandırıcı olarak kullanılan k-En Yakın Komşu, Destek Vektör Makineleri ve YSA yöntemleriyle belirlenmiştir. Çalışmada elde edilen sonuçlar Bölüm III'de ayrıntılı olarak verilmiştir.

II. MATERYAL VE METOD

A. Kullanılan Veri Seti

Bu çalışmada 'BCI Competition III' yarışmasındaki III. veri seti kullanılmıştır. Bu verilerin elde edilmesi için beyinde oluşan elektriksel işaretler kafatası üzerine yerleştirilen 3 adet elektrotla (C3, Cz, C4) kaydedilmiştir. Her bir deney 9 saniye sürmüştür. Elektrotlardan alınan işaretler 128 Hz örnekleme frekansı ile örnekleştirilerek alt kesim ve üst kesim frekansları sırasıyla 0.5 ve 30 Hz olan bant geçiren filtreyle filtrelendikten sonra bilgisayara kaydedilmiştir.

Verilerin elde edilirken, ilk 2 saniye boyunca denek herhangi bir harekette bulunmamıştır. 2. saniyenin ardından denegın karşısında bulunan bilgisayardan uyarıcı bir ses aktarılmış ve

ekranda 1 saniye boyunca "+" işareti gösterilmiştir. 1 saniye gösterilen bu işareten sonra bilgisayar ekranında sağ tarafa veya sol tarafa hareket ettirilmesi istenen bir yön şekli belirlenmiştir. Ardından denegın bu şekli ekranda gösterilen yöne hareket ettirdiğinin hayal etmesi istenmiştir. Bu aşamalarda EEG kayıtları gerçekleştirilmiştir. Eşit sayıda eğitim ve test deneyi yapılmıştır ve toplamda 280 deney bulunmaktadır. Ayrıca bu deneylerden 140 tanesi ekranda oluşan şeklin sağ tarafa hareketi, 140 tanesi sol tarafa hareketinin hayal edilmesinden oluşmaktadır [13].

B. Öznitelik Çıkarımı

EEG elektrotlarından elde edilen işaretlerden (Delta, Theta, Gama) her biri beynin farklı bir elektriksel aktivitesine karşılık gelmektedir. Bu nedenle EEG işaretleri üzerine yapılan çalışmalar incelendiğinde Fourier dönüşümü ve Dalgacık dönüşümü tabanlı çalışmalar oldukça fazla yer almaktadır [6]. Bu çalışmada ilk öznitelik çıkarımı için (1) denklemi kullanılarak EEG işaretlerinin Fourier dönüşümü alınmış ve işaretlerin frekans bölgesinde incelemesi yapılmıştır.

$$G(f) = \int_{-\infty}^{+\infty} g(t)e^{-j2\pi ft} dt \quad (1)$$

(1) denkleminde $g(t)$, zaman bölgesindeki orijinal işareti göstermekteyken $G(f)$, Fourier dönüşümü sonucu frekans bilgisinin içinde olduğu işareti göstermektedir. Fourier dönüşümü sonucu elde edilen işaretin en büyük, en küçük değerlerinin yanı sıra ortalama ve varyans değerleri hesaplanarak öznitelik matrisine eklenmiştir. Yapılan ikinci işlemde ise EEG işaretlerinin (2) denklemi kullanılarak dalgacık katsayıları elde edilerek iki sınıf arasındaki ayrımın en fazla olduğu öznitelikler belirlenmeye çalışılmıştır.

$$\gamma(s, \tau) = \int g(t)\Psi_{s, \tau}^*(t) dt \quad (2)$$

(2) denkleminde, $\gamma(s, \tau)$ ifadesi $g(t)$ orijinal işaretinin dalgacık katsayıları bilgisini ve $\Psi(t)$ de temel dalgacık fonksiyonunu göstermektedir. Bu çalışmada sürekli dalgacık dönüşümü kullanılmış ve ana dalgacık fonksiyonu olarak Morlet fonksiyonu kullanılmıştır. Dalgacık dönüşümü sonucu elde edilen işaretlerin en büyük ve en küçük değerleri ile birlikte ortalama ve varyans değerleri hesaplanarak öznitelik olarak kullanılmıştır. Verilen bu frekans tabanlı öznitelikler yanında orijinal EEG işaretinin zaman bölgesindeki ortalama ve varyans değerleri, en büyük ve en küçük değerleri, ayrıca işaretin gücü de hesaplanarak öznitelik matrisine sınıflandırma başarısını artırmak için öznitelik olarak eklenmiştir.

C. Boyut Azaltma Yöntemleri

C.1 Temel Bileşen Analizi

Orjinal EEG işareti, Fourier dönüşümü ile elde edilen öznitelikler ve dalgacık dönüşümü katsayı öznitelikleri kullanıldığında öznitelik matrisi oldukça büyük boyutlara ulaşabilmektedir. Yüksek boyutlu veriler sınıflandırıcılarının işlem yükünü artırdığından, sistem performansını olumsuz yönde etkileyebilmektedir.

Literatürde yaygın olarak kullanılan boyut azaltma yöntemlerinden biri TBA yöntemidir. Bu yöntem veri içerisindeki benzerlikleri ve farklılıkları ortaya çıkararak, grafiksel olarak ortaya koyulamayan büyük boyutlu verinin

boyutunun azaltılmasını ve analizini kolaylaştırmasını sağlayan bir yöntemdir. Bu yöntemin bir diğer ve en önemli avantajı ise veri içerisinde bulunan ilintiyi ortadan kaldırarak veriyi ilintisiz hale getirmesidir [14]. TBA yönteminde kullanılan amaç fonksiyonu (3) denklemiyle ifade edilebilir.

$$\operatorname{argmax}_w w^T C w \quad (3)$$

Burada C , (4) denklemiyle hesaplanan ve TBA uygulanacak verinin varyans-kovaryans matrisini göstermekteyken w , amaç fonksiyonunu maksimum yapacak olan varyans-kovaryans matrisinin özvektörlerini göstermektedir.

$$C = \frac{1}{N} \sum_{i=1}^N x_i x_i^T \quad (4)$$

Bu denklemde x orijinal veriyi göstermektedir.

C.2 Çekirdek Temel Bileşen Analizi

Çekirdek Temel Bileşen Analizi (ÇTBA) yönteminde orijinal x veri matrisinin elemanları öncelikle (5) bağıntısı kullanılarak farklı bir veri uzayına aktarılır.

$$\begin{aligned} \Phi : R^N &\rightarrow F \\ x &\rightarrow X \end{aligned} \quad (5)$$

Yapılan bu işlemin ardından (6) denklemdeki amaç fonksiyonu maksimize edilmeye çalışılır.

$$\operatorname{argmax}_w \bar{w}^T \bar{C} \bar{w} \quad (6)$$

(4) denklemde \bar{C} , yeni uzaya aktarılan verinin (X) varyans kovaryans matrisi iken \bar{w} , \bar{C} varyans-kovaryans matrisinin özvektörlerini göstermektedir. Bu çalışmada Gauss, Lineer ve Polinom çekirdek fonksiyonları kullanılarak veri farklı bir uzaya aktarılmış ve bu çekirdek fonksiyonlarının sınıflandırma başarısı üzerine etkisi incelenmiştir.

C.3 Yerellik Koruyucu İzdüşüm

Yerellik Koruyucu İzdüşüm (YKİ) yöntemi TBA yöntemine alternatif olarak ortaya konulan doğrusal bir boyut azaltma yöntemidir. TBA yönteminden farklı olarak, boyutu azaltılacak olan verinin komşuluk ilişkisini maksimum yapacak şekilde çalışan bir algoritmadır. Bu yöntemde; öncelikle (7) denklemde verilen formülle verinin komşuluk matrisi elde edilir.

$$S_{ij} = e^{-\frac{\|x_i - x_j\|^2}{t}} \quad (7)$$

Bu denklemdeki x_i ve x_j ifadeleri boyutu azaltılacak olan verinin elemanlarını göstermekteyken $\|x_i - x_j\|$ ifadesi iki veri noktası arasındaki Euclidean uzaklığını göstermektedir. Bu çalışmada mesafe ölçümü olarak 8 farklı mesafe ölçüm yöntemi (Euclidean, Chebychev, Cityblock, Correlation, Cosinus, Hamming, Standardized Euclidean, Spearman) kullanılarak öznel matrisinin boyutu azaltılmıştır. (7) denkleminin

hesaplanmasının ardından (8) ve (9) denklemleri kullanılarak D ve L matrisleri elde edilir.

$$D_{ii} = \sum_j S_{ij} \quad (8)$$

$$L = D - S \quad (9)$$

(7), (8), (9) denklemleri kullanılarak YKİ yöntemi ile (10) denklemdeki amaç fonksiyonu minimum yapılmaya çalışılır.

$$\operatorname{argmin}_w w^T X L X^T w \quad (10)$$

Burada, X ifadesi boyutu azaltılacak olan veriyi ve w değerleri $X L X^T$ matrisinin özvektörlerini göstermektedir. Dikkat edilirse (10) denklemi artık bir özdeğer-özvektör problemidir ve $X L X^T$ ifadesinin en küçük özdeğerlerine karşılık gelen özvektörler (10) denklemiyle verilen amaç fonksiyonunun minimize edilmesini sağlar [15].

D. Verilerin Sınıflandırılması

Tüm sınıflandırma algoritmalarının kendi içlerinde güçlü veya zayıf olduğu özellikleri bulunmakta, hatta bazı durumlarda güçlü bir sınıflandırıcının sınır durumları olabilmektedir. Bunun yanında bir sınıflandırma algoritması bir veri seti için başarılı sonuçlar verirken, farklı bir veri için olumlu sonuçlar veremeyebilir. Bu nedenle kullanılan veriyi en iyi sınıflandırabilecek, farklı sınıflandırma algoritmaları araştırılarak ve en yüksek başarının elde edildiği yöntemler belirlenir [16].

Bu çalışmada EEG işaretlerinin sınıflandırılması amacıyla kullanılan birinci yöntem, k-EYK algoritmasıdır. k-EYK algoritması parametrik olmayan ve verinin olasılık dağılımından bağımsız bir yöntemdir. Bu yöntemde sınıflandırılacak olan test verisinin, mesafe ölçüm yöntemleri kullanılarak, eğitim verileriyle olan uzaklıklarına bakılır ve en uygun sınıflandırma gerçekleştirilir [16]. Bu çalışmada, k-EYK yöntemi için Öklid mesafe ölçüm yöntemi kullanılmıştır ve yapılan işlemler sonucunda en yüksek başarı oranı $k=5$ değeriyle elde edilmiştir.

Kullanılan diğer sınıflandırma yöntemi DVM' nin (radyal tabanlı çekirdek fonksiyonlu) en önemli avantajı, sınıflandırma problemini kareli optimizasyon problemine dönüştürerek çözmesidir. Böylece öğrenme aşamasında işlem sayısı azalmakta ve çözüme daha hızlı ulaşılmaktadır. DVM yöntemiyle yapılan sınıflandırmada en yüksek başarı kernel fonksiyonu olarak Gauss fonksiyonu kullanılmasıyla elde edilmiştir.

Bu çalışmada kullanılan son yöntem ise YSA algoritmasıdır. Yapısında bulunan yapay sinir hücreleri sayesinde insan beyninin çalışmasını taklit etmektedir ve aktivasyon fonksiyonlarının yardımıyla doğrusal olmayan problemlerin çözümünde oldukça başarılı sonuçlar vermektedir [16]. Çalışmamızda öğrenme algoritmasının Bayesian Regulation (trainbr) olan ileri beslemeli bir YSA kullanılmıştır. En uygun YSA mimarisinin belirlenmesi için gizli katman nöron sayısı, gizli katman ve çıktı katmanındaki aktivasyon fonksiyonları değiştirilerek en yüksek doğruluk değerinin elde edildiği YSA

mimarisi belirlenmeye çalışıldı. Yapılan denemeler sonucunda YSA ile en yüksek başarı oranı gizli ve çıktı katmanlarının her ikisinde de hiperbolik tanjant (tansig) aktivasyon fonksiyonuyla elde edilmiştir. Boyut azaltma yapılmadığı durumda, girdi-gizli-çıkış katmanlarında kullanılan nöron sayısı sırasıyla 39-39-1 şeklindeyken, boyut azaltıldığı durumda ise 9-9-1 nöron dizilimi kullanılarak en yüksek başarı elde edilmiştir.

III. SONUÇLAR

Bu çalışmada kullanılan EEG verilerine ait öznitelik matrisinin boyutu, 39 öznitelik olmak üzere 240x39 olmaktadır. İlk olarak, elde edilen bu öznitelik matrisinin boyutunda azaltma işlemi yapılmaksızın k-EYK, YSA ve DVM sınıflandırıcıları ile sınıflandırılmıştır. Daha sonra öznitelik matrisinin boyutları sırasıyla; ÇTBA, TBB ve YKİ algoritmaları ile azaltılarak aynı sınıflandırma algoritmaları kullanılarak sınıflandırılmış ve başarı sonuçları karşılaştırılmıştır.

Bu çalışmada yapılan bütün sınıflandırma işlemlerinin başarı sonuçları 10 kat çapraz doğrulama yöntemi ile gerçekleştirilmiş ve başarı değerlerinin ortalama değerleri tablolarda verilmiştir.

Yukarıda anlatılan sırada, önce öznitelik matrisinin boyutu azaltılmadan EEG işaretleri için sınıflandırma yapılmıştır.

İkinci olarak öznitelik matrisinin boyutunun azaltılması için ÇTBA yöntemi kullanılmıştır. Bu yapılırken dikkat edilen en önemli hususlardan biri boyutu azaltılmış verinin, orijinal verinin içerdiği bilginin en az %95' ini oluşturmasıdır. ÇTBA yönteminde Gauss, Lineer ve Polinom çekirdek fonksiyonları kullanılmış ve veri boyutu 240x9 olacak şekilde azaltılmıştır. Farklı çekirdek fonksiyonları için ÇTBA yöntemi kullanılarak elde edilen sınıflandırma sonuçları Tablo I' de verilmiştir. Görüldüğü gibi, çalışmada kullanılan çekirdek fonksiyonlarından Lineer çekirdek fonksiyonun ve k-EYK sınıflandırıcı algoritmasının kullanılması ile en yüksek başarı sonucu elde edilmiştir.

Sınıflandırıcı	Kullanılan Çekirdek Fonksiyonları ve Sınıflandırma Başarıları (%)		
	Gauss	Polinom	Lineer
k-EYK	57.54	58.57	80.35
DVM	49.64	48.21	79.64
YSA	51.07	59.25	79.85

Tablo I. ÇTBA yöntemine göre sınıflandırma başarıları

Üçüncü olarak, öznitelik matrisinin TBA yöntemiyle hem boyutu (240x9 olarak) azaltılmış hem de veri birbirinden ilintisiz hale getirilmiştir. TBA yönteminde de boyutu azaltılmış verinin içerdiği bilgi, orijinal verinin en az %95 ini içermektedir. Yine aynı sınıflandırma algoritmaları kullanılarak sınıflandırma sonuçları elde edilmiştir.

Çalışmada kullanılan son boyut azaltma yöntemi YKİ ile, sekiz farklı mesafe ölçüm yöntemleri (Euclidean, Chebychev, Cityblock, Correlation, Cosinus, Hamming, Standardized Euclidean, Spearman) kullanılarak veri boyutu azaltılmıştır ve mesafe ölçüm yöntemlerinin sınıflandırma başarısına etkisi incelenmiştir. Tablo II' de görüldüğü gibi en yüksek

sınıflandırma başarısı, Chebychev mesafe ölçümü ve k-EYK yöntemlerinin kullanıldığı durumda elde edilmiştir.

Mesafe Ölçüm Yöntemleri	Sınıflandırma Başarıları (%)		
	k-EYK	DVM	YSA
Euclidean	76.42	75.38	75.24
Chebychev	83.21	82.45	80.16
Cityblock	80.35	78.54	79.78
Correlation	76.77	76.23	77.34
Cosinus	77.14	75.78	73.61
Hamming	64.28	62.51	65.43
S. Euclidean	72.14	73.29	72.45
Spearman	79.64	79.15	78.67

Tablo II. YKİ yöntemine göre sınıflandırma başarıları

YKİ yöntemi ile öznitelik matrisinin boyutu azaltılırken, hangi boyut sayısının daha uygun olacağı konusunda deneme yanılma yöntemi kullanıldı ve en yüksek başarı 240x9 boyutunda elde edildi. Bu nedenle YKİ algoritması için verilen başarı sonuçlarında, boyut 240x9 olarak alınmıştır.

Bu çalışmada; EEG işaretleri için boyut azaltma yapılmadan ve tüm boyut azaltma yöntemleri kullanılarak yapılan sınıflandırma işlemlerinin sonuçları Tablo III' de verilmektedir. Tablodan görüldüğü gibi en yüksek başarı oranı, boyut azaltma işleminde YKİ yöntemi ve sınıflandırma işleminde k-EYK sınıflandırıcısı kullanılarak elde edilmiştir.

Boyut Azaltma Yöntemi	Sınıflandırıcı Başarıları (%)		
	k-EYK	DVM	YSA
Gerçek Boyutlu	79.32	80	76.07
ÇTBA	80.35	79.64	79.85
TBA	80.46	81.27	78.58
YKİ	83.21	82.45	80.16

Tablo III. Farklı boyut azaltma ve sınıflandırma işlemleri için elde edilen Sonuçlar

TBA ve ÇTBA yöntemlerini kıyaslamak adına Tablo I ve Tablo III incelendiğinde ÇTBA yöntemiyle en yüksek başarı oranı çekirdek fonksiyon olarak Lineer fonksiyonun kullanılmasıyla elde edilmiştir. ÇTBA yönteminde Lineer çekirdek fonksiyonunun kullanılması bu yöntemin çekirdeksiz kullanılması anlamına geldiğinden dolayı bu veri yapısı üzerinde ÇTBA yerine TBA yönteminin kullanılması sistem performansını olumlu yönde etkileyecektir.

Bu çalışmada sınıflandırma başarıları yanında boyut azaltma yöntemlerinin işlem süreleri ve boyut azaltma ile birlikte sınıflandırma işlemlerinin süreleri incelenmiştir. Intel® Core™2 Quad CPU Q6600 @2.4GHz işlemcinin ve 4GB Yüklü Belleği (RAM) olan bir bilgisayarla, Matlab 2015a kullanılarak gerçekleştirilen işlemler sonucunda belirlenen işlem süreleri Tablo 4 ve Tablo 5' de verilmektedir.

	Boyut Azaltma Yöntemi (sn)		
	TBA	ÇTBA	YKİ
İşlem Süresi	0.02	0.24	0.27

Tablo IV. Boyut azaltma yöntemlerine ait işlem süreleri

Sınıflandırılan Veri Boyutu	Sınıflandırıcı (sn)		
	k-EYK	DVM	YSA
(240x39)	1.65	1.45	3.05
(240x9)	1.39	1.13	1.48

Tablo V. Sınıflandırma yöntemlerine ait işlem süreleri

En yüksek başarı oranı YKİ yöntemi kullanılarak elde edilmişti ancak Tablo 4 incelendiğinde işlem süresinin en fazla olduğu boyut azaltma yönteminin de YKİ olduğu görülmektedir. Tablo V incelendiğinde de boyut azaltma sonrasında özellikle YSA işlem süresinin yaklaşık yarı yarıya azaldığı görülmektedir.

KAYNAKLAR

- [1] Teplan, M., "Fundamentals of EEG Measurement", *Measurement Science Review*, Vol. 2, Sec.2, 2002.
- [2] Saka, K., Aydemir, Ö., Öztürk, M., "Classification of EEG signals recorded during right/left hand movement imagery using Fast Walsh Hadamard Transform based features," *39th International Conference on Telecommunications and Signal Processing (TSP)*, Vienna, 2016, pp. 413-416.
- [3] Varela, F., Lachaux, J., Rodriguez, E. and Martinerie, J., "The brainweb: phase synchronization and largescale integration", *Nature Reviews Neuroscience*, Vol. 2, 2001., pp.229-239.
- [4] Mohamed, A. K., "Towards improved EEG interpretation in a sensorimotor BCI for the control of a prosthetic or orthotic hand". Faculty of Engineering, Johannesburg, University of Witwatersrand. Thesis, Master of Science in Engineering, 2011.
- [5] Wang, Y., Hong, B., Gao, X., & Gao, S., "Implementation of a Brain-Computer Interface Based on Three States of Motor Imagery", *29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 5059-5062, 2007.
- [6] Cheong, L. C., Sudirman, R. and Hussin, S. S., "Feature Extraction Of Eeg Signal Using Wavelet Transform For Autism Classification", *ARPJ Journal of Engineering and Applied Sciences*, Vol. 10, No. 19, 2015.
- [7] Lin, S.C., Chang, Y.C.I. and Yang, W.N., "Meta-learning for imbalanced data and classification ensemble in binary classification", *Neurocomputing*, 73(1-3):484-494, 2009.
- [8] Guerra, E.J., Aquino, V. A., Gil, P. G., "Epilepsy Seizure Detection in EEG Signals Using Wavelet Trans. and Neural Networks", *International Joint Conferences on Computer, Information and Systems Sciences and Engineering*, 2013.
- [9] R. Xu, N. Jiang, C. Lin, N. Mrachacz-Kersting, K. Dremstrup and D. Farina, "Enhanced Low-Latency Detection of Motor Intention From EEG for Closed-Loop Brain-Computer Interface Applications," in *IEEE Transactions on Biomedical Engineering*, vol. 61, no. 2, pp. 288-296, Feb. 2014.
- [10] E. I. Zacharaki, K. Garganis, I. Mporas and V. Megalooikonomou, "Spike detection in EEG by LPP and SVM," *IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)*, Valencia, 2014, pp. 668-671.
- [11] W. L. Zheng, Y. Q. Zhang, J. Y. Zhu and B. L. Lu, "Transfer components between subjects for EEG-based emotion recognition," *2015 International Conference on Affective Computing and Intelligent Interaction (ACII)*, Xi'an, 2015, pp. 917-922.
- [12] M. Kaczorowska, M. Plechawska-Wojcik, M. Tokovarov and R. Dmytruk, "Comparison of the ICA and PCA methods in correction of EEG signal artefacts," *2017 10th International Symposium on Advanced Topics in Electrical Engineering (ATEE)*, Bucharest, 2017, pp. 262-267.
- [13] S.C. Lin, Y.C.I. Chang and W.N. Yang, "Meta-learning for imbalanced data and classification ensemble in binary classification", *Neurocomputing*, 73(1-3):484-494, 2009.
- [14] Smith, L.I., "A tutorial on Principal Components Analysis", 2002.
- [15] He, X., Niyogi, P., "Locality Preserving Projections", *NIPS* 16, 2003.
- [16] Kiang, M. Y., "A comparative assessment of classification methods", *Decision Support Systems*, Vol.35, pp.441-454, 2003.