



ISSN:1306-3111

e-Journal of New World Sciences Academy
2011, Volume: 6, Number: 1, Article Number: 1A0169

ENGINEERING SCIENCES

Received: October 2010

Accepted: January 2011

Series : 1A

ISSN : 1308-7231

© 2010 www.newwsa.com

Oğuzhan Özer

Mücahid Günay

Ahmet Alkan

Kahramanmaraş Sutcu Imam University

alkan@ksu.edu.tr

Kahramanmaraş-Turkey

EEG İŞARETLERİNİN SINIFLANDIRMA VE KÜMELEME TEKNİKLERİ İLE ANALİZİ

ÖZET

Bu çalışmada, sağlıklı ve epilepsi hastası olan kişilerden alınan EEG işaretleri farklı ön işleme ve sınıflandırma yöntemleri kullanılarak analiz edilmiş ve bu yöntemlerin başarı oranları karşılaştırılmıştır. EEG işaretlerinin sınıflandırılması veya öbekleştirilmesi için öznitelik çıkarım (Ortalama Mutlak Değer (OMD), Yule-Walker AR ve Kovaryans AR), öbekleştirme (K-Ortalama, Bulanık C-Ortalama (BCO)) ve sınıflandırma (Destek Vektör Analizi ve Lineer Diskriminant Analizi) metotları kullanılmıştır. Elde edilen yüksek sınıflandırma başarımları sonuçları karşılaştırmalı olarak verilmiştir.

Anahtar Kelimeler: EEG, Epilepsi, LDA, DVM, K-Ortalama

ANALYSIS OF EEG SIGNALS BY USING CLASSIFICATION AND CLUSTERING METHODS

ABSTRACT

In this study, normal and epileptic EEG signals are analyzed by using different preprocessing, classification/clustering methods and results are compared. Mean absolute values and parametric models such as Yule-Walker AR and Covariance methods are used for the feature extraction. For the classification of EEG signals Linear Discriminant Analysis, Support Vector Machine (SVM) methods are used. Clustering techniques such as K-means and Fuzzy C-means are also used for the analysis of the EEG signals. The comparative results confirmed that the proposed methods achieved high classification rates.

Keywords: EEG, Epilepsy, LDA, SVM, K-Means

1. GİRİŞ (INTRODUCTION)

İnsan beyni tarafından üretilen EEG işaretleri günümüzde araştırmacıların artan bir ilgi ile inceledikleri bir konudur. Beynin faaliyetleri hakkında detaylı bilgi edinme ve tıbbi analizler için bu işaretlerin incelenmesi önemini korumaktadır. Son zamanlarda araştırmacıların bu işaretleri hangi amaç için çözümlenmeye çalıştıklarına birkaç örnekle bakacak olur isek; Altunay ve ark. (2010), "Doğrusal Kestirim Hata Enerjisi Kullanarak Epileptik EEG Algılama" konulu bir makale yazmışlardır. EEG işaretlerinden epileptik nöbetleri ayırmak için bir yöntem önermişlerdir. Bu amaçla, EEG işaretleri üzerindeki sivri ve keskin dalgaların varlığını tespit etmek için doğrusal kestirim filtresi kullanmışlardır. Doğrusal kestirim hatası enerjisi analizinin zaman-serisi işaretlere uygulanacak en iyi yöntem olduğunu öne sürmüşlerdir. Bu analizde pencereleme yapılmış ve her pencere için bir katsayı seti oluşturulmuştur. Öngörülen hata sinyali üzerinde; sivriliklerin ve diğer nöbetlere ait keskin dalgaların varlığı modelin başarısını artırdığını ve filtre kestirim hatasını azalttığını ileri sürmüşlerdir. Nöbet esnasındaki hata işaretine ait enerjinin, nöbetsiz aralıklara göre yüksek olduğundan bahsetmişlerdir. Bu enerjinin nöbet aralıklarını bulmada kullanılabilceğini düşünmüşlerdir. Yöntemlerini 250 farklı EEG işareti üzerine uygulamışlardır. Kullandıkları bu yöntemle, nöbet varlığını tespit etme başarısını %93,6 olarak bulmuşlardır. Epilepsi nöbetlerini tespit etmede önerdikleri yönteminin etkin olduğunu dile getirmişlerdir [1].

Naghsh-Nilchi ve Aghashahi (2010), "Epilepsi Nöbeti Algılamada, Öz-Sistem Spektral Kestirim ve Çok Katmanlı Geri Yayılım Sinir Ağı Kullanımı" konulu makale ile yeni bir yaklaşımdan bahsetmişlerdir. Öz-vektör (EV), çoklu sinyal sınıflandırma (MUSIC) ve çoklu katmanlı algılayıcı (MLP) sinir ağının tanımını yapmışlardır. Bu yaklaşımda, EEG sinyalini alt-bantlara ayırmışlar ve daha sonra bu alt bantlardan bir özellik seti (maksimum, entropi, ortalama, standart sapma ve hareketlik) oluşturmuşlardır. Daha sonra bu özellik vektörü, MLP sinir ağı ile EEG sinyalini üç farklı duruma ayırması için uygulanmıştır. Bu durumlar; normal, nöbet arası ve nöbet olarak tanımlanmıştır. Bu yöntem ile %97,5 doğruluk ve %0,095 varyans elde ettiklerinden bahsetmişlerdir. Bu yöntemi, yüksek doğruluk başarısı, hızlı sonuç vermesi ve düşük oranda hatalı sınıflandırma yapması dolayısıyla, gerçek zamanlı kronik bozukluğu tespit için önermişlerdir [2].

Nasibov ve Ulutagay (2010), "Beyin Aktivitesine Ait Bispektral İndeks Dizisinin Karşılaştırmalı Kümeleme Analizi" konulu makale yazmışlardır. EEG ye ait bir parametre olan bispektral indeks ölçülerini (BIS) kullanmışlardır. BIS beyin üzerindeki sedasyonu, bilinç ve bellek eksikliğini ve beyin üzerindeki anestezi etkileri izlemek için tasarlanmıştır. Çalışmalarında, BIS serisi verilerin analizi için kümeleme yöntemi kullanmışlardır. Önerdikleri yöntemin kararlı süre aralıklarını ve BIS aşamalarını teşhis etmede daha gerçekçi sonuçlar verdiğinden bahsetmişlerdir [3].

Mirowski ve ark. (2009), "Nöbet Kestirimi İçin EEG Senkronizasyonu Örüntülerinin Sınıflandırılması" konulu bir yazı yazmışlardır. EEG den nöbet kestiriminde bulunmak için iki değişkenli ölçümlerin kullanışlı olduğundan bahsetmişlerdir. Spatio-temporal iki değişkenli özelliklerin çok yüksek boyutlu olmasından dolayı klasik istatistiksel yöntemlerle analiz edilemeyeceğini ileri sürmüşlerdir. Dolayısıyla "state-of-art" makine öğrenim yöntemini önermişlerdir. 21 hastadan alınan EEG senkronizasyonundan elde edilen iki değişkenli özelliklerden (çapraz korelasyon, doğrusal olmayan karşılıklı bağımlılık, dinamik sürüklenme veya dalgacık senkronizasyonu) bir veri seti oluşturmuşlardır. Bir örüntü oluşturmak için tüm kanal çiftlerinden ve frekanslardan ardışık zaman noktalarında, özellikler toplanmıştır. Hastaya-özel, makine öğrenme tabanlı sınıflandırıcılar (destek vektör makineleri, lojistik regresyon ve katlamalı sinir ağları) pre-iktal ve inter-iktal evrelerini ayırt etmesi

için eğitilmiştir. Önerdikleri yöntemin başarısının %71 olduğunu 15 hasta üzerinde görmüşlerdir. Spatio-temporal dinamiklerin öğrenilmesinin, hastaya özgü nöbet belirtilerinin yakalaması için incelemeye değer olduğunu ileri sürmüşlerdir [4].

Gandhi ve ark. (2010), "EEG İşaretindeki Epileptik Aktivitenin Tespiti İçin Uzman Model " konulu makalelerinde çok hızlı ve yüksek doğrulukta epileptik nöbet tespiti yapan yeni bir yaklaşım öne sürmüşlerdir. Bu yaklaşımda ayırık dalgacık dönüşümü, ayrıştırma ağacının her bir düğümü için enerji kestirimi ve olasılıksal sinir ağları kullanılmıştır. Ayırık dalgacık dönüşümü altıncı düzeye kadar kullanılmıştır. Tüm ağaç düğümlerinin dalgacık katsayılarının tahmini enerjileri bir özellik vektörü olarak kullanılmıştır. Bu vektör, EEG kaydı içindeki aktiviteleri karakterize etmek için kullanılmıştır. Sınıflandırma başarısını artırmak için önerilen olasılıksal sinir ağı on kat çapraz uzman model olarak uygulanmıştır. Bu plan hem normal hem de epileptik bozuklukları olan bireylerden alınan EEG sinyallerine uygulanmıştır. Önerilen yöntemin doğruluğunun %99,33 ve özgünlüğünün %99,6 olduğundan bahsetmişlerdir. Yüksek başarısından dolayı uzman nörolog bulunmayan yerlerde kullanılabilceğini öne sürmüşlerdir [5].

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)


EEG (elektroensefalogram) beyin üzerinden alınan biyoelektriksel işaretlere verilen addır. Bu işaretler, beyin aktivitesi hakkında bilgiler içerdiğinden beyin faaliyetlerine ait bozuklukların teşhisinde sıklıkla kullanılmaktadır. Nörolojide EEG'nin temel uygulaması epilepsi tanısıdır. Epilepsi, beyinde bulunan sinir hücrelerinin normal olmayan bir şekilde elektro-kimyasal deşarj yapması sonucu oluşan nörolojik bir hastalıktır. İkincil klinik kullanımı koma, ensefalopati ve beyin ölümüdür. Beyindeki sinirsel aktivitenin yüksek miktarda ve kontrolsüz yayılımıyla ortaya çıkar. Geçici bilinç kaybına neden olur.

Oldukça kompleks bir yapıya sahip olan EEG işaretlerinin analizinde farklı öznelik çıkarımı ile sınıflandırma teknikleri kullanılır. Önişleme veya öznelik çıkartımı ve bir sonraki adım olan sınıflandırma veya karar verme süreci, kullanılan algoritmalara bağlı olarak farklı başarı sonuçları vermektedir.

3. ANALİTİK ÇALIŞMA (ANALYTICAL STUDY)

3.1. Veri (Data)

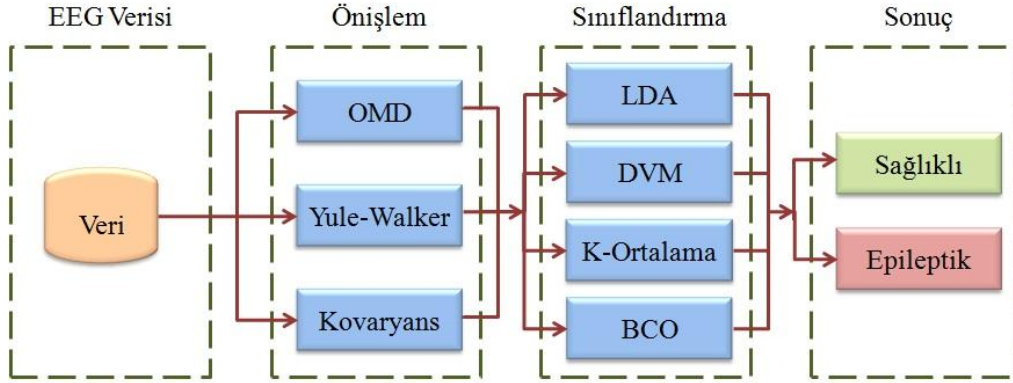
Bu çalışmada kullanılan EEG verileri değişik yaşlardan sağlıklı ve hasta (epilepsi geçiren) kişilere aittir. Kullanılan EEG işaretleri 23.6 saniyelik bölümler halinde olup, 173 Hz'lik örnekleme frekansıyla örneklenmiştir. Uluslararası 10-20 elektrot yerleştirme düzenine göre toplanmış olan veriler, 12 bitlik analog-sayısal dönüşümden sonra örneklenerek kaydedilmiştir. Veriler 0.53-40 Hz'lik band geçiren filtreden geçirilerek, EEG'deki klinik ilginin odaklandığı aralığın varlığı sağlanmıştır. 100 adet epileptik 100 adet normal EEG işareti kullanılmıştır [6].



Şekil 1. Örnek EEG verisi (a) Epileptik (b) Normal
(Figure 1. Sample EEG data (a) Epileptic (b) Normal)

3.2. Metot (Method)

Bu çalışmada, önışleme ve sınıflandırma temel aşamaları oluşturmaktadır. EEG işaretinden oluşan veri setine farklı önışlemler uygulandıktan sonra, sınıflandırma ve kümeleme için birkaç değişik yöntem kullanıldı. Sınıflandırma sonucu veri setindeki işaretler, sağlıklı ve epileptik olarak ayrıldı. Sonuçlar, kısmında önışlem ve sınıflandırma sonuçları, gerçek veri setinin sınıfları ile karşılaştırıldı (Şekil 2).



Şekil 2. Uygulanan yöntemlerin /algoritmaların sırasıyla gösterildiği diyagram

(Figure 2. Diagram showing the applied algorithms/methods)

3.2.1. Ortalama Mutlak Değer (Mean Absolute Value)

EEG işaretlerini analiz etmek için öznelik çıkartma işlemi oldukça önemlidir. Bu amaçla çok farklı özellik çıkarım metotları kullanılabilir. Her ön işleme yönteminin başarıları farklı olmaktadır. Bu çalışmada özellik çıkarımı amacıyla işaretin boyutu azaltılarak 16 adet değer elde edilmiştir. Her bir değer 256 örneklik pencerelerin mutlak değerinin ortalamasıdır (Ortalama Mutlak Değer, OMD). Sonuç olarak her bir işaret için 16 örneklik özellik vektörü elde edilmiştir. Elde edilen özellikler kullanılarak iki tür işareten oluşan EEG verisi öbikleştirme ve sınıflandırma işlemlerine için hazırlanmıştır [7].

3.2.2. Özbağlanımlı Kovaryans Yöntemi (Covariance AR Method)

Özbağlanımlı (AR) Kovaryans yöntemi, parametrik metotlardan biridir. Model parametreleri, doğrusal denklemlerin çözümüyle elde edildiği için çok sık kullanılmaktadır. Bir veri, girişi beyaz gürültü, çıkışı tüm-kutuplu ayırık filtre olacak şekilde modellenilebilir. Bu bağlamda derecesi p olan AR model,

$$x(n) = - \sum_{k=1}^p a(k)x(n-k) + w(n) \quad (1)$$

ifadesi ile oluşturulur. Özbağlanımlı spektral yöntemde, model katsayıları a(k) ve varyansı σ^2 olan ise w(n) beyaz gürültüdür. Özbağlanımlı model; AR(p), {a[1], a[2], ..., a[p], σ^2 } AR model parametreleri ile ifade edilir.

Kovaryans yöntemi, özbağlanımlı spektral analiz yöntemlerinden biridir. Bu yöntemde, tüm veri noktalarının hata tahmin güç kestiriminin hesaplanması gereklidir. Özbağlanımlı parametre tahminleri kullanarak spektral yoğunluk şu şekilde ifade edilir [8-11].

$$P_{cov}^{\wedge}(f) = \frac{\hat{\sigma}^2}{\left| 1 + \sum_{k=1}^p a(k) \exp(-j2\pi fk) \right|^2} \quad (2)$$

Bir önışleme yöntemi olarak işarete uygulanmış ve her bir işaret için 16 adet katsayı elde edilmiştir.

3.2.3. Yule-Walker AR Yöntemi (Yule-Walker AR Method)

Özbağlanımlı Yule-Walker metodu için MATLAB™ Signal Processing Toolbox rutinleri kullanılmıştır. Bir p dizisinin AR modelinde mevcut çıkışı, önceki p çıkışlarıyla beyaz bir gürültü girişinin toplamının doğrusal kombinasyonudur. Önceki p çıkışları üzerindeki ağırlık, otoregresyonun karelerinin ortalamasının tahmin hatasını en aza indirir. Şayet y[n] çıkışın mevcut değeri ve x[n] de sıfır ortalamalı bir beyaz gürültü girişi ise, AR(p) modeli şu şekilde olacaktır:

$$\sum_{k=0}^p a[k]y[n-k] = x[n] \quad (3)$$

Bir önişleme yöntemi olarak işarete uygulanmış ve her bir işaret için 16 adet katsayı elde edilmiştir.

3.3. Kümeleme Analizi (Clustering Method)

Kümeleme analizi danışmansız sınıflandırma metotlarından biridir. Özellikle vektörlerinin sınıflandırılması, eğitim aşaması olmadan yapılır. Burada asıl kavram kümelenecek veriler arasındaki benzerliktir. Verilerin birbirlerine benzerliklerine göre kümeleme işlemi gerçekleştirilir.

3.3.1. K-Ortalama (K-Means Method)

K-ortalama, verileri kendisine en yakın merkezin olduğu kümeye atayan algoritmadır. Aynı kümedeki tüm verilerin ortalaması merkezi belirtir. K-ortalama, büyük veri setlerini öbekleştirmek için basit ve hızlı bir yöntemdir. Fakat her koşuturulmada aynı sonucu üretmemektedir. Çünkü kümeler başlangıçta rasgele atamaktadır. Kümeler içi varyansı minimize eder fakat varyansın global minimum durumunu garanti etmez.

Özellik vektör kümesini asıl yapısındaki kümelere ayırıştıran bu istatistiksel yöntem çok değişik alanlarda ve amaçlarla kullanılmaktadır. Bu, çizebilen, görsel olarak gösterilebilen ve her kümenin bir nesne sınıfı olarak kabul edilebildiği iki boyutlu vektörlerde oldukça kolaydır. Benzerlik, vektörler arasındaki uzaklıkla ilişkilidir. x ve y iki vektör ise bunların arasındaki uzaklık öklid uzaklığı olarak bilinir ve d(x,y) ile gösterilir.

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4)$$

Burada x ve y vektörlerinin uzunluğu n'dir. Öklid uzaklığı ise aşağıdaki formülde gösterilen daha genel uzaklık ölçü yapısının p=2 için elde edilmiş özel bir türüdür.

$$d(x, y) = \left(\sum_{i=1}^n (x_i - y_i)^p \right)^{1/p} \quad (5)$$

'City blok' mesafesi için ise p=1 olarak alınır. d(x,y) değeri küçükse ilgili vektörler arasında benzerliğin büyük olduğunu ifade ederken, d(x,y) değeri büyükse benzerliğin az olduğunu ifade eder [12].

Değişik performans göstergeleri ile kümeleme fonksiyonunun başarısı ölçülebilir. Bu göstergelerden sıkça kullanılanlarından biri karesel hataların toplamı performans indeksi uygulamasıdır ve kümeleme başarısı hakkında önemli bir bilgi verir. Karesel hataların toplamı;

$$J = \sum_{j=1}^{N_c} \sum_{x \in S_j} \|x - m_j\|^2 \quad (6)$$

ifadesiyle verilir. N, küme alan sayısını, S_j ise J. kümedeki örnek setini belirtmektedir.

$$m_j = \frac{1}{N_j} \sum_{x \in S_j} x \quad (7)$$

Bu formül ise S_j vektörünün örnek ortalamasıdır ve N_j 'de S_j 'deki örnek sayısıdır.

3.3.2. Bulanık C-Ortalama (Fuzzy C-Means Method)

Mantıksal olarak, bir nesnenin bir sınıfa ait olma durumuna "doğru" olmama durumuna "yanlış" denilebilir. Esasen bir nesnenin, herhangi bir sınıfa tam anlamıyla aittir denilmesi pek mümkün değildir. Burada bir nesnenin herhangi bir sınıfa ait olma derecesinden bahsedilebilir. Bu ait olma derecesi, Bulanık tabanlı algoritmalarla belirlenebilir. Ait olma derecesi 0 ile 1 arasında değerler almaktadır. Kısaca bulanık algoritmalarda, bir nesnenin (veya işaretin) ait olduğu sınıf ve o sınıfa olan aidiyetlik derecesi belirlenebilmektedir. Aidiyetlik derecesine, bir sınıfa olan aidiyetlik değeri de denilebilir. Dolayısıyla bulanık algoritmalar, diğer klasik sınıflandırma algoritmalarına oranla daha fazla bilgi içerir. Kümeleme yöntemi, eğiticişiz sınıflandırma yöntemlerinden biridir. Eğiticişiz algoritmalar, veri setini kendileri düzenler. Bu düzenlemeyle öznitelik uzayının kümelenmesini de eğitilmiş algoritmalarda belirlenen eğitim alanından bağımsız bir şekilde oluştururlar. Kümeleme algoritmalarını, sürekli örnekleme yapılan ölçümlere uygulamak mümkündür. Dolayısıyla hem mevcut kümelerin sürekli farklı kombinasyonu, hem de yeni kümelerin oluşturulması sağlanır. Bu sebeple, aynı sonuçları verecek olan zaman-serisi yeni ölçümler, aynı kümeye dâhil edilecektir. Tam durağan veya tam sürekli denilemeyen biyolojik işaretlerin sınıflanmasında uyarlamalı (adaptif) küme oluşturabilmesi açısından bulanık algoritmalar daha etkin kullanılabilir [13]. Bulanık C-Ortalama Yöntemi: küme sayısı G , veri sayısı p , veri indisi k , küme indisi i , bulanıklığı artırmada kullanılan kontrol parametresi r [$r \in (1, \infty)$] olmak üzere;

$$\mu_i = \frac{\sum_{k=1}^p (z_{ki})^r x_k}{\sum_{k=1}^p (z_{ki})^r} \quad (8)$$

d_{ki} , k . elemana ait vektörün i . kümeye olan öklidyen uzaklığı

$$d_{ki}^2 = (x_k - \mu_i)^T (x_k - \mu_i) \quad (9)$$

; μ_i , sınıf merkezi olmak üzere, kümelere olan üyelik değerleri ise z_{ki} 'dir [13];

$$z_{ki} = \frac{1}{\sum_{j=1}^G \left[\frac{d_{ki}}{d_{kj}} \right]^{r-1}} \quad \begin{cases} k=1,2,\dots,p \\ i=1,2,\dots,G \end{cases} \quad (10)$$

3.4. Sınıflandırma Analizi (Classification Method)

3.4.1. Linear Diskriminant Analiz (Linear Discriminant Analysis)

Diskriminant analizi, istatistiksel sınıflandırma yöntemlerinden biridir. Diskriminant fonksiyonlarının bulunması için eğitim verisi kullanılır. Diskriminant fonksiyonları farklı sınıflar ile kestirim uzayı arasındaki sınırları belirler. Sınıflandırıcı, kestirim verilerine dayanarak sınıflar arasında ayırım yapar [14]. Özellik vektörleri

sınıflandırıcı tarafından sağlanır. Bu analizde sınıflandırıcının eğitimi daha hızlı ve uygulaması daha basittir.

Diskriminant analizin beş farklı tipinden biri olan "linear discriminant analizi" EEG işaretinin tanımlanmasında kullanılmıştır. Linear diskriminant fonksiyonu, kovaryans matrisin genel kestirimiyle her grup için çok değişkenli normal yoğunluğu varsayar. Diskriminant fonksiyonu, nesnelere arasındaki ayrımı maksimum yapacak şekilde elde edilir. Bu amaçla,

$$(W^{-1}B - \lambda I)V = 0 \quad (11)$$

denklemler incelenir. Burada W, gruplar içi kare toplamı matrisi; B ise gruplar arası kare matrisidir. (11) numaralı denklemi çözmek demek $W^{-1}B$ 'nin özdeğer ve özvektörlerini bulmak demektir. Buradan elde edilen λ değerleri özdeğerleri; V ise özvektörleri göstermektedir. Bu özvektörler kullanılarak diskriminant değişkenleri (12) numaralı denklemdeki gibi hesaplanabilir. Bu özvektörler kullanılarak diskriminant değişkenleri (12) numaralı denklemdeki gibi hesaplanabilir [15].

$$\begin{aligned} Y_1 &= v_{1,1}X_1 + v_{1,2}X_2 + \dots + v_{1,p}X_p \\ Y_2 &= v_{2,1}X_1 + v_{2,2}X_2 + \dots + v_{2,p}X_p \\ &\vdots \\ Y_s &= v_{s,1}X_1 + v_{s,2}X_2 + \dots + v_{s,p}X_p \end{aligned} \quad (12)$$

3.4.2. DVM Sınıflandırıcı (Support Vector Machine)

Vapnik (2009), destek vektör makinesi adında yeni bir hesaplama metodu ileri sürmüştür [16]. Teorisi, 1995-1998 yılları arasında geliştirilmiştir [17]. DVM, giriş verisini (n) boyutlu bir özellik uzayı olarak ele alır. Bu uzayı ikiye ayıran (n-1) boyutlu bir hiper düzlem oluşturur. n-boyutlu giriş dizisi x_i ($i=1,2,\dots,l$) (sınıf-1 ve sınıf-2 olarak) y_i matrisi tarafından sınıf-1 için $y_i = 1$ sınıf-2 için $y_i = -1$ olarak etiketlenir. Doğrusal olarak ayrılan veriler için bir hiper düzlem tanımlanabilir.

$$f(x) = \omega \cdot x + b = \sum_{i=1}^n \omega_i x_i + b = 0 \quad (13)$$

ω , n-boyutlu bir vektör, b skaler bir değerdir ve bunlar hiper düzlemin pozisyonuna karar verir. $Sgn(f(x))$ fonksiyonu karar fonksiyonudur. Ayırma işlemi tamamen yapan hiper düzlem belirli sınırlara uymak zorundadır.

$$y_i(x_i \cdot \omega + b) - 1 \geq 0 \Leftrightarrow \begin{cases} f(x_i) = x_i \cdot \omega + b \geq 1 & y_i = +1 \\ f(x_i) = x_i \cdot \omega + b \leq -1 & y_i = -1 \end{cases} \quad (14)$$

Ayrılcı maksimum sınırları oluşturan hiperdüzlem'e optimal hiperdüzlem denir. Burada ξ_i bağımsız değişken, C ise error penaltı'yı gösterir. Optimal hiperdüzlem'in minimize edilmiş çözümü şöyledir:

$$\phi(\omega, \xi) = 1/2(\omega \cdot \omega) + C(\sum_{i=1}^l \xi_i) \quad (15)$$

Şu koşulla:

$$y_i[(x_i \cdot \omega) + b] \geq 1 - \xi_i, \quad i=1,2,\dots,l \quad (16)$$

ξ_i sınır ile sınırın diğer tarafındaki örnek x_i arasındaki mesafeyi ölçer. Bu hesaplama aşağıdaki gibi sadeleştirilebilir.

$$V(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (17)$$

Şu koşulla:

$$\sum_{i=1}^l y_i \alpha_i = 0, \quad C \geq \alpha \geq 0, i=1,2,\dots,l \quad (18)$$

Çekirdek fonksiyonu olarak adlandırılan $K(x_i, x_j)$ fonksiyonu, orijinal data noktalarının özellik uzayı haritalarının nokta çarpımını döndürür. Bu nedenle veri kümesinin tüm elemanları eğitim için kullanılmıştır. Böylece manüel seçimlere göre daha az hata oranı elde edilmiştir; fakat hata oranları arasında rastgele seçimden kaynaklanan çok küçük farklılıklar bulunabilir [18].

4. BULGULAR VE TARTISMALAR (FINDINGS AND DISCUSSIONS)

Tüm biyoelektriksel işaretlerin işlenmesinde olduğu gibi EEG işaretlerinin de işlenmesinde öznelik çıkarımı ve sınıflandırma algoritmaları çok önemlidir. Bu çalışmada, öznelik çıkartma için Ortalama Mutlak Değer, Yule-Walker ve Kovaryans AR yöntemleri kullanılmıştır. Ortalama mutlak değer yöntemi belli uzunlukta pencereleme yapılarak kullanılmıştır.


Tablo 1. Öznelik çıkarma ve sınıflama algoritmalarının başarı yüzdeleri
Table 1. Achievements percentages of feature extraction and classification algorithms

	OMD	Yule-Walker	Kovaryans
LDA	86,5	99	99,5
DVM Sınıflandırıcı	99,5	99	99,5
K-Ortalama	80	97	96
Bulanık C-Ortalama	79,5	97	96

Tablo 1’de görüldüğü üzere Özbağlanımlı Yule-Walker ve Kovaryans yöntemleri ilgili model parametrelerinin kullanımıyla bir nevi boyut azaltma yöntemleri olarak kullanılmıştır. Başarım sonuçları incelendiğinde (Tablo 1), genelde OMD’nin diğer öznelik çıkarım yöntemlerine göre daha başarısız sonuçlar verdiği görülmektedir. Kullanılan sınıflama yöntemleri, danışmanlı olduğu için kullanılan danışmansız kümeleme yöntemlerine göre daha başarılı olmuştur.

5. SONUÇLAR (CONCLUSIONS)

Şekil 3’te kullanılan önışleme yöntemlerinden elde edilen öznelik vektörlerinin sınıflama ve kümeleme başarı oranları grafiği verilmiştir. Test edilen EEG verisi ve uygulanan önışleme yöntemlerine göre bütün yöntemler göreceli olarak başarılı sonuçlar vermiş olmakla birlikte en başarılı yöntemin DVM sınıflandırıcı olduğu görülmektedir.



Şekil 3. Öznelik çıkarma ve sınıflama algoritmalarının başarı düzeyleri.

Figure 3. Achievement levels of feature extraction and classification algorithms

KAYNAKLAR (REFERENCES)

1. Altunay, S., Telatar, Z., and Eroğul, O., (2010). Epileptic EEG detection using the linear prediction error energy. *Expert Systems with Applications*, 37, pp:661-5665.
2. Naghsh-Nilchi, A.R. and Aghashahi, M., (2010). Epilepsy seizure detection using eigen-system spectral estimation and Multiple Layer Perceptron neural network. *Biomedical Signal Processing and Control*, 5, pp:147-157.
3. Nasibov, E.N. and Ulutagay, G., (2010). Comparative clustering analysis of bispectral index series of brain activity. *Expert Systems with Applications*, 37, pp:2495-2504.
4. Mirowski, P., Madhavan, D., Lecun, Y., and Kuzniecky, R., (2009). Classification of patterns of EEG synchronization for seizure prediction. *Clinical Neurophysiology*, 120, pp:1927-1940.
5. Hsu, W.Y., (2010). EEG-based motor imagery classification using neuro-fuzzy prediction and wavelet fractal features. *Journal of Neuroscience Methods*, (baskıda).
6. Andrzejak, R.G., Lehnertz, K., Rieke, C., Mormann, F., David, P., and Elger, C.E., (2001). Indications of Nonlinear Deterministic And Finite Dimensional Structures In Time Series Of Brain Electrical Activity: Dependence On Recording Region And Brain State, *Phys. Rev. E*, 64, 061907.
7. Günay, M. ve Alkan, A., (2009). EMG İşaretlerinin K-Ortalama Algoritması Kullanılarak Öbekleştirilmesi. *KSÜ Mühendislik Bilimleri Dergisi*, 12(2), ss:25-29.
8. Alkan, A. and Kıymık, M.K., (2006). Comparison of AR and Welch Methods in Epileptic Seizure Detection. *J Med Syst*, 30, pp:413-419.
9. Bronzino J.D., (2006). *The Biomedical Engineering handbook*. IEEE Pres. 3rd edition.
10. Proakis, J.G. and Manolakis, D.G., (1996). *Digital Signal Processing Principles. Algorithms and Applications*. Prentice-Hall, New Jersey.
11. Ubeyli, E.D. and Guler I., (2004). Selection of optimal AR spectral estimation method for internal carotid arterial Doppler signals using Cramer-Rao bound. *Comput.Electr.Eng.*, 30, pp:491-508.
12. Englehart, K., Hudgins, B., and Parker, P.A., (2001). A Wavelet-based continuous classification scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 48, pp:302-311.
13. Koçyiğit, Y. ve Korürek, M., (2005). EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama. *itü dergisi mühendislik*, 3, ss:25-31.
14. Cao, J. and Sanders, D.B., (1996). Multivariate discriminant analysis of the electromyographic interference pattern: statistical approach to discrimination among controls, myopathies and neuropathies. *Medical and Biological Engineering and Computing Vol.34*, 5, pp:369-374.
15. Tatsuoaka, M.M., (1971). *Multivariate Analysis: Techniques for Educational and Psychological Research*. New York: John Wiley & Sons, Inc., pp:159-162.
16. Wang, A., Yuan, W., Liu, J., Yu, Z., and Li, H., (2009). A novel pattern recognition algorithm: Combining ART network with SVM to reconstruct a multi-class classifier. *Computers and Mathematics with Applications*, 57, pp:1908-1914.
17. Qian, H., Mao, Y., Xiang, W., and Wang, Z., (2010). Recognition of human activities using SVM multi-class classifier. *Pattern Recognition Letters*, 31, pp:100-111.
18. Alkan, A. and Gunay, M., (2010). "Identification of EMG signals using discriminant analysis and SVM classifier", *ISCSE 2010*, Aydın/Kuşadası.