

## Etkin epoklar ile motor hayaline dayalı EEG işaretlerinin sınıflandırma doğruluğunun artırılması

### Improving classification accuracy of motor imagery EEG signals via effective epochs

Ebru ERGÜN<sup>1</sup>, Önder AYDEMİR<sup>2</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği, Mühendislik Fakültesi, Recep Tayyip Erdoğan Üniversitesi, Rize, Türkiye.  
ebru.yavuz@erdogan.edu.tr

<sup>2</sup>Elektrik-Elektronik Mühendisliği, Mühendislik Fakültesi, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.  
onderaydemir@ktu.edu.tr

Geliş Tarihi/Received: 11.09.2017, Kabul Tarihi/Accepted: 22.02.2018

\* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2018.93824

Araştırma Makalesi/Research Article

#### Öz

Beyin bilgisayar arayüzleri (BBA) sadece beyinde üretilen işaretleri kullanarak çeşitli elektronik cihazları kullanmayı olanaklı hale getiren sistemlerdir. Bu sistemlerin yüksek başarımlı olabilmesi için bu işaretlerden çıkarılan öznelik yöntemleri ve bu işaretlere uygulanan sınıflandırıcı yöntemleri önemlidir. Bu çalışma ile motor hayaline dair kaydedilen EEG tabanlı BBA işaretlerinden yüksek sınıflandırma doğruluğu elde edebilmek için işaretlerin etkin zaman dilimlerinden çıkarılmış özneliklerle sınıflandırma doğruluğunun artırılmasına yönelik bir yöntem önerilmiştir. Öznelikler, etkin zaman dilimleri belirlenen EEG işaretlerine Hilbert Dönüşümü'nün uygulanması ve işaretin türevlerinin ortalamasının alınmasıyla elde edilmiştir. BCI Competition 2003 yarışmasında kullanıma sunulmuş 2-sınıflı motor hareketi hayaline dayalı Data Set 1a isimli veri kümesinden çıkarılan öznelikler destek vektör makineleri, k-en yakın komşuluk ve doğrusal ayırım analizi ile test edilerek performans karşılaştırması yapılmıştır. Destek vektör makineleri ile test veri kümesi üzerinde %91.46 oranında yüksek bir sınıflandırma doğruluğu elde edilmiştir. Bu sınıflandırma doğruluğu EEG işaretinin bir denemesine ait tüm örneklemelerin kullanılması durumunda elde edilen sınıflandırma doğruluğundan %17.40 daha yüksektir. Elde edilen sonuçlar, önerilen yöntemin belirlenen öznelik çıkarma yöntemi ve destek vektör makinaları sınıflandırıcısıyla birlikte EEG işaretlerinden elde edilen sınıflandırma doğruluğunu dikkat çekici miktarda arttırdığını ve hesaplama karmaşıklığını ise azalttığını göstermiştir.

**Anahtar kelimeler:** Elektroensefalografi, Beyin bilgisayar arayüzü, Hilbert dönüşümü, Etkin zaman dilimi, Etkin epok, Destek vektör makinası

#### Abstract

Brain computer interfaces (BCI) are systems which make it possible to use various electronic devices using only the signals produced in the brain. In order to ensure high performance of these systems, feature methods extracted from these signals and classifier methods applied to these signals are important. With this study, we proposed a method to obtain high classification accuracy from EEG based BBA signals recorded on the motor imaginary with the extracted features in the active time segments. Features were obtained by applying the Hilbert Transform to the active time segments selected EEG signs and calculating the average of the derivatives of the signs. Features extracted from two-class motor imaginary Data Set 1a (Presented at the BCI Competition 2003 competition) were analyzed by support vector machines, k-nearest neighborhood and linear discriminant analysis. Then the performance of the classifiers was compared. A high classification accuracy of 91.12% is calculated on the test dataset with support vector machines. This classification accuracy is 17.06% higher than the classification accuracy obtained in the case of using all samples of a trial of the EEG signal. As a result, the proposed method increased the accuracy of classification in a remarkable amount and reduced computational complexity with the feature extraction methods and support vector machine classifier.

**Keywords:** Electroencephalography, Brain computer interface, Hilbert transformation, Active time segment, Effective epoch, Support vector machine

## 1 Giriş

İnsan vücudunun merkezi konumunda olan beyin, vücut faaliyetlerini yöneten ve insan merkezî sinir sistemini kontrol eden bir organdır. En karmaşık biyolojik organizasyon olarak bilinen insan merkezi sinir sistemi, milyarlarca sinir hücresinden oluşur. Bu sinir hücrelerinin aralarındaki bağlantılar sinir sisteminin ana yapısı oluşturur. Sinir sistemindeki nöronlar sayesinde elektriksel devrelere benzer yollarla bilgi akışı sağlanır ve bu akış beyin işlevlerinin ortaya çıkmasını sağlar [1]-[3]. Beynin bu işlevleri esnasında bir tür jel yardımı ile kafa derisinin belirli bölgelerine yerleştirilen elektrotlar yardımı ile beyin dokusundaki elektriksel potansiyel değişimlere bağlı olarak elektroensefalografi (EEG) işaretleri oluşur [4]. Bu işaretler bilgisayara kayıt edilir ve elde edilen kayıtlar ile beynin birçok çalışma bozukluğu teşhis

edilebilir. Ayrıca, nörolojik hastalıkların teşhisinde kullanılan EEG işaretleri beyin bilgisayar arayüzü (BBA) sistemlerinin temelini de oluşturur. BBA, motor sinir sistemlerini kullanamayan amyotrofik lateral skleroz (ALS) gibi hastaların hayatlarını kolaylaştıran sistemlerdir [5]. Bu sistemlerin yüksek başarımlı verebilmesi için EEG işaretine uygulanan öznelik çıkarma ve sınıflandırma yöntemlerinin seçimi önemlidir [6],[7]. Bu çalışmada BBA sistemlerinin başarımlı arttırmak için yeni bir yöntem önerilmiştir. Önerilen yöntemde EEG işaretinin tüm örnekleri kullanılmadan, işaret belirlenen epoklara ayrılır ve seçilen en az sayıda epokla yüksek başarımlı BBA modeli oluşturulmaktadır.

Literatürde motor hayaline dayalı EEG tabanlı BBA işaretlerinin sınıflandırma doğruluğunu (SD) artırmak amacıyla yapılan birçok çalışma bulunmaktadır [8],[9]. Ancak,

bu işaretlerin zaman dilimlerine ayrılarak (epoklar) bir denemesine ait tüm epoklar yerine belirlenen öznitelik ve sınıflandırma yöntemlerine göre seçilen etkin epoklar ile SD'yi artırıcı çalışmalar kısıtlıdır. Bu çalışmada önerilen algoritmaya benzer olarak, Wei-Yen Hsu [10]'deki çalışmasında sağ/saol motor hareketi hayaline dayalı EEG veri kümesinin geliştirilmiş aktif bölümlerine bulanık hopfield sinir ağı kümeleme yöntemini uygulayarak SD'yi artırmaya çalışmıştır. 5 sn. uzunluğundaki verileri 1 sn.'lik zaman dilimlerine bölerek en iyi 1 sn.'lik zaman dilimi ile 3 kişi için ortalama %83.10 SD hesaplamıştır. Javier ve arkadaşları EEG işaretini yerel ayırım temelleri yöntemi ile 0.5 sn. 0.6 sn. 0.8 sn. ve 1 sn.'lik pencerelere bölmüşler ve böylece öznitelik çıkartmadan kaynaklanan hesaplama süresini azaltmayı ve SD'yi artırmayı hedeflemişlerdir. Belirlenen bu pencerelere ait EEG işaretlerinden ortak uzamsal örüntü yöntemine ait öznitelikler çıkartmışlar ve daha sonra işareti doğrusal ayırım analizi (DAA) ile sınıflandırmışlardır [11]. Aydemir ise yaptığı çalışmada, üç kişiden alınan EEG verileriyle çalışmıştır. Bu veriler, kişilerin imleci yukarı, aşağı, sola ve sağa hareketini hayali sırasında kaydedilmiştir. Aydemir en iyi zaman dilimini aradığı bu işaretlerden ortak uzamsal örüntü özniteliklerini çıkartmıştır ve öznitelikleri destek vektör makinesi ile sınıflandırmıştır. Bu çalışmada Aydemir tüm zaman dilimleriyle %54.82 ortalama SD hesaplarken, önerdiği yöntem ile ortalama %77.19 SD hesaplamıştır [12]. EEG işaretlerinin motor hayaline dayalı yapılan başka bir çalışmada Wei-Yen Hsu'un önerdiği, geliştirilmiş aktif bölüm seçimi yöntemidir. Wei-Yen Hsu önerdiği yöntemin iyi başarımı olduğunu ispatlamak için EEG işaretinin tüm örnekleri ile %66.70 SD, orijinal aktif bölüm seçimi ile %76.50 SD hesaplarken, geliştirilmiş aktif bölüm seçimi ile SD'yi %80.20'ye yükseltmiştir [13]. Yapılan başka bir çalışma da pencereleme yöntemiyle uygun zaman ve frekans bant aralığını arayan Renxiang ve Qingguo'un çalışmalarıdır. Bu çalışmalarında, ortak uzamsal örüntü yöntemini öznitelik çıkarımı için, k-en yakın komşuluk yöntemini (k-NN) ise sınıflandırma için kullanmışlardır. Belirledikleri öznitelik ve sınıflandırıcıyla 9 ayrı kişi için iki farklı durumda en iyi zaman ve frekans aralıklarını seçerek sırasıyla %72.02 ve %74.13 ortalama SD hesaplamışlardır [14].

Bu çalışmada BCI Competition 2003 yarışmasında açık kullanıma sunulmuş Data Set la [15] isimli veri kümesi ile çalışılmıştır. Literatürde [15]-[22]'de bu veri kümesine çeşitli yöntemler uygulanarak %88.70-%93.50 arasında SD'ler hesaplanmıştır. Ancak, literatürdeki bu çalışmalarda BCI Competition 2003 Data Set la veri kümesini etkin epoklara ayrılarak sınıflandırma doğruluğu artırıcı çalışmalar yapılmamıştır. Literatürde [10]-[14]'de yapılan benzer çalışmalardan farklı olarak hesaplama süresini azaltmak için BCI Competition 2003 Data Set la verilerin tüm denemeleri 0.25 sn.'lik zaman dilimlerine ayrılmıştır. Daha sonra bu zaman dilimlerinden etkin olarak seçilen epok kombinasyonlarından çıkarılan özniteliklerle, tüm zaman dilimlerinden çıkarılan özniteliklere göre daha yüksek SD hesaplanabileceği gösterilmiştir. Bu çalışma ayrıca, daha önceki çalışmamızın [23] genişletilmiş ve geliştirilmiş sürümüdür. Önceki çalışmamızda sadece destek vektör makinesi (DVM) sınıflandırıcısı test edilirken bu çalışmada DVM'ye ek olarak k-NN ve DAA sınıflandırıcı da test edilmiş, sınıflandırıcıların başarımı hata matrisi, duyarlılık (DU) ve özgüllük (ÖZ) ölçütleri ile de karşılaştırılmıştır. Ayrıca, Hilbert Dönüşümü esaslı yeni öznitelikler de ilave edilerek bir deneme için

kaydedilen EEG işaretinin tüm örnekleri kullanılarak test veri kümesi üzerinde DVM ile %74.06, k-NN ile %80.20 ve DAA ile %63.13 SD elde edilirken, önerilen etkin epok tabanlı yöntem ile birlikte test veri kümesi üzerindeki SD'ler sırasıyla %91.46, %84.30 ve %81.26'e yükseltilmiştir. Önerilen yeni öznitelik kümesi ve DVM sınıflandırıcısı ile elde edilen SD, önceki çalışmadan %2.73 daha yüksektir.


Makalenin devamında, Malzeme ve Yöntem kısmında çalışma için kullanılan veri kümesinin tanıtımı, veri kümesinden çıkartılan Hilbert Dönüşümü ve işaretin türevlerinin ortalaması esaslı özniteliklerin matematiksel tanımları ve ardından bu çalışma için önerilen DVM sınıflandırıcısının teorik tabanı ile önerilen yöntemin algoritması açıklanmıştır. Daha sonra, bulgular başlığı altında, çalışma için önerilen DVM sınıflandırıcısına ek olarak k-NN ve DAA sınıflandırıcılarıyla elde edilen sonuçlar verilmiştir. Tartışma ve sonuç kısmıyla ise önceki çalışmalarda hesaplanan sonuçlar verilerek önerilen yöntemin yüksek verimliliği gösterilmiştir.

## 2 Malzeme ve yöntem

### 2.1 Veri kümesi tanıtımı

BCI Competition 2003 yarışması için kullanıma sunulmuş olan Data Set la veri kümesi Almanya'nın Tübingen Üniversitesi'nde kayıt edilmiştir. Herhangi bir sağlık problemi olmayan bir kişiden alınan kayıtlar kişinin bilgisayar ekranında imleci yukarı (sınıf 0) ve aşağı yönde (sınıf 1) hareket ettirmesini hayal etmesi istendiği sırada kaydedilmiştir. Uluslararası 10-20 Sistemi'ne göre tepe elektrotu (Cz) referans noktası belirlenerek 6 elektrot ile birlikte kayıtlar yapılmıştır. 256 Hz'de örneklenen verilerin her denemesi için 6sn'lik kayıtlar alınmıştır. Daha sonra beyin aktif olduğu 3.5 sn.'lik (896 genlik örneği) örnekler kullanıcılara sunulmuştur. Uluslararası 10-20 Sistemi için belirlenen elektrotların pozisyonları Şekil 1'deki gibi verilmektedir.

Kayıtların alındığı 6 kanala (kanal 1: A1-Cz, kanal 2: A2-Cz, kanal 3: FC3-Cz, kanal 4: CP3-Cz, kanal 5: FC4-Cz, kanal 6: CP4-Cz) ait pozisyonlar Şekil 1'de siyah dolguyla gösterilmiştir. Burada ortada bulunan açık gri daire referans Cz'yi ifade etmektedir. Veri kümesi 268 eğitim denemesinden ve 293 test denemesinden oluşmaktadır. Eğitim verisinin 135'i, test verisinin 147'si sınıf 0'a aitken eğitim verisinin 133'ü ve test verisinin 146'sı sınıf 1'e aittir. Bu çalışma da eğitim verilerinden çıkarılacak özniteliklere dayalı olarak test veri kümesinin denemelerinin sınıf 0 ve sınıf 1 olacak şekilde sınıflandırılması amaçlanmıştır.



Şekil 1: Uluslararası 10-20 sistemine göre elektrotların pozisyonları.

Deney prosedürü, 1 sn.'lik dinlenme kısmı, 1.5 sn.'lik görsel tanıtm ve ardından 3.5 sn.'lik EEG kaydı kısmı ile üç aşamadan oluşmaktadır. 1.5 sn.'lik görsel tanıtm kısmının başında ekranın üstünde veya altında görsel bir hedef belirlemiştir. Motor hareketi hayalinin gerçekleştirildiği 3.5-sn.'lik EEG kaydı boyunca da hedef ekranda sabit kalmıştır.

## 2.2 Öznitelik çıkarma

Bu çalışmada her bir EEG denemesini temsil etmek için Hilbert Dönüşümü ile işaretlerin türevlerinin ortalaması öznitelikleri hesaplanmıştır. Bu özniteliklerin matematiksel olarak hesaplanmaları aşağıdaki alt başlıklar altında verilmektedir.

### 2.2.1 Hilbert dönüşümü

Riemann tarafından ortaya atılan ve daha sonra Hilbert 'in 1905'deki çalışmasında ortaya çıkan Hilbert Dönüşümü sinyalin genliğini değiştirmeden sadece fazını  $\pi/2$  kaydıran matematiksel bir dönüşümdür. Bu tanıma göre  $s(t)$  giriş işaretinin  $1/\pi t$  ile konvolüsyonu sonucu hesaplanan Hilbert Dönüşümü için çıkış  $\hat{s}(t)$ , Denklem 1'deki gibidir [24],[25].

$$H\{s(t)\} = \hat{s}(t) = s(t) * \frac{1}{\pi t} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{s(\tau)}{t - \tau} d\tau \quad (1)$$

Hilbert Dönüşümü alınmış  $s(t)$  işareti Denklem 2'deki gibi verilen sanal ve gerçek zamandan oluşmaktadır. Burada  $a$  işaretin gerçek kısmını,  $b$  ise sanal kısmını ifade etmektedir.

$$\hat{s}(t) = a + jb \quad (2)$$

$r$  sayıdaki örnekten oluşan Hilbert Dönüşümlü  $\hat{s}(t)$ 'nin gerçek kısmının ortalaması, standart sapması ve sanal kısmının standart sapması sırasıyla Denklem 3, 4 ve 5'te verilmiştir.

$$ORT = \frac{a_1 + a_2 + \dots + a_r}{r} \quad (3)$$

$$STD = \sqrt{\frac{(a_1 - ORT)^2 + \dots + (a_r - ORT)^2}{r - 1}} \quad (4)$$

$$STDK = \sqrt{\frac{(b_1 - b_{ort})^2 + \dots + (b_r - b_{ort})^2}{r - 1}} \quad (5)$$

Denklem 3, 4 ve 5'te  $ORT$  1'den  $r$ 'ye kadar  $\hat{s}(t)$ 'nin gerçek kısmının ortalamasını,  $STD$  1'den  $r$ 'ye kadar  $\hat{s}(t)$ 'nin gerçek kısmının standart sapmasını,  $STDK$  ise 1'den  $r$ 'e kadar  $\hat{s}(t)$ 'nin sanal kısmının standart sapmasını,  $b_{ort}$   $\hat{s}(t)$ 'nin sanal kısmının ortalamasını ifade etmektedir. Bu çalışmada EEG işaretlerini temsil etmek için  $ORT$ ,  $STD$  ve  $STDK$  değerleri öznitelik olarak kullanılmıştır.

### 2.2.2 İşaretin türevlerinin ortalaması

Türev bir fonksiyon grafiğine çizilen teğet doğrusunun eğimi olarak tanımlanmaktadır ve elektronik alanda, analog ve dijital sinyal işleme ile ilgili birçok yerde kullanılır [26].  $r$  örnekl bir  $s(t)$  EEG denemesinin ayrık zamanda türevinin formülü Denklem 6'de verilmiştir. Denklem 6'da görüldüğü üzere ayrık zamandaki türev olarak ifade edilen  $s'(t)$ , ayrık zamanda verilen  $s(t)$  fonksiyonun şimdiki değeri ile bir önceki değerinin farkının örnekleme periyodu  $T_s$  'ye bölümdür.

$$s'(t) = \frac{s(t) - s(t - 1)}{T_s} \quad (6)$$

Bir veri dizisinin orta noktasını tek bir sayı ile tanımlayan istatistik ölçüye ortalama denir. Türevi alınmış  $r$  örnekl bir  $s(t)$  fonksiyonun  $r = 1$ 'den  $(r - 1)$ 'e kadar ki ortalaması Denklem 7' de verilmiştir. Burada,  $s'(t)$  fonksiyonun türevini,  $F_{ort}$  ise türevi alınmış  $s(t)$  işaretinin ortalamasını ifade etmektedir.

$$F_{ort} = \frac{1}{(r - 1)} \sum_{t=1}^{r-1} s'(t) \quad (7)$$

Her bir EEG denemesini temsil etmek için Hilbert Dönüşümü ile 3, işaretlerin türevlerinin toplamı ile 1 adet öznitelik hesaplanmıştır. BBA uygulamalarında öznitelik sayısının az olması sistemin performansını hız açısından artırmaktadır. Bu bakımdan mümkün olduğunca az sayıda nitelikli öznitelik seçilmiştir. Belirlenen yöntemle göre makalede anlatılan toplam 4 öznitelik iki sınıflı bu örneği tanıma problemi için etkin olarak belirlenmiştir.

### 2.3 Destek vektör makinesi sınıflandırma yöntemi

Sınıflandırmayı doğrusal veya doğrusal olmayan bir fonksiyon yardımıyla yerine getiren DVM, destek vektörleri ile veri noktalarının sınıflandırılmasını sağlayan, iki veya çok sınıflı sınıflandırma problemlerinin çözümü için geliştirilmiş makine öğrenmesi algoritmasıdır. Ayrıca, DVM istatistiksel öğrenme teorisi ile yapısal risk minimizasyonuna dayanan bir yöntemdir [27]. DVM ile  $\{-1, +1\}$  olarak bilinen sınıf etiket örneklerini alt gruplara ayırabilmek için eğitim veri kümesi üzerinde en uygun hiper düzlem belirlenir [28].

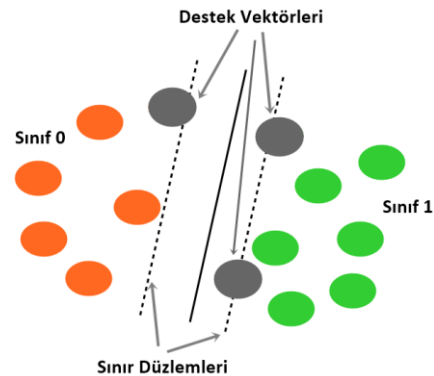
$T = \{\{x_1, y_1\}, \dots, \dots, \{x_n, y_n\}\}$  olarak tanımlanan bir eğitim veri kümesinde  $y \in (-1, 1)$  sınıf etiketlerini,  $k$  ise veri boyutunu ifade etmektedir. DVM'de amaç bu veri kümesindeki sınıflarını en iyi ayıracak düzlemi seçmektir [29].  $i = 1, 2, \dots, n$  olduğu varsayılırsa seçilebilecek optimum hiper düzlem Denklem 8'de verilmiştir. Burada  $g$  ağırlık vektörünü  $p$  ise bias ifade etmektedir.

$$g \cdot b_i + p = 0 \quad (8)$$

Hiper düzlem için belirlenen eşitsizlikler ise Denklem 9'da verilmiştir.

$$\begin{aligned} g \cdot b_i + p &\geq +1 \\ g \cdot b_i + p &\leq -1 \end{aligned} \quad (9)$$

Şekil 2'de iki sınıflı (turuncu noktalar sınıf 0'ı, yeşil noktalar sınıf 1'i temsil etmektedir) bir problem için destek vektörlerinin ve hiper düzleminin gösterimi verilmiştir.



Şekil 2: DVM için 2-sınıflı problem örneği.

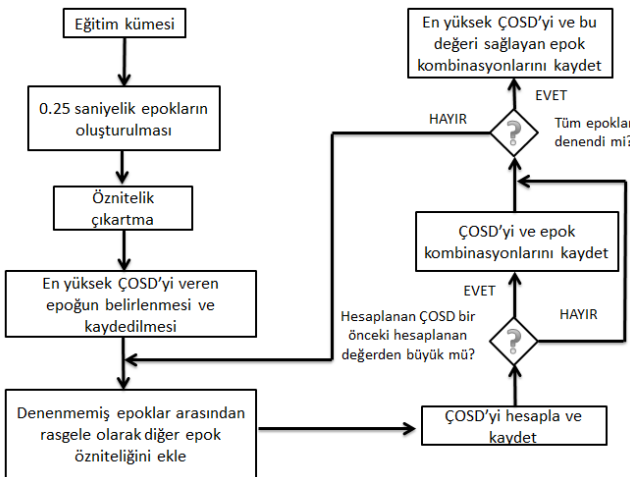
Burada iki sınıf grubu içinde sınıf elemanlarına yakın ve birbirine paralel iki sınır çizgisi çizilir. Çizilen sınır çizgilerinin

birbirine yaklaştırılmasıyla ortak sınır çizgisi üretilir. Sınır düzlemleri üzerinde bulunan her iki sınıf bilgileri destek vektörleri olarak tanımlanır. Destek vektörleri hiper düzleme en yakın olan sınıflardır. Hiper düzlem ise sınır çizgilerine eşit uzaklıkta olup tam ortadan geçen ana düzlemdir.

Bu çalışmada DVM için radyal tabanlı çekirdek fonksiyonu kullanılmıştır. Diğer taraftan bu çalışmada sonuçlar  $k$ -NN ve DAA sınıflandırıcıları ile de karşılaştırılmış ancak önerilen yöntemde DVM sınıflandırıcısı verildiğinden bu sınıflandırıcılar detaylı açıklanmamıştır. DVM için çekirdek fonksiyonun sigma parametresi ve  $k$ -NN için Öklid uzaklığına bağlı olarak hesaplanan  $k$  parametresi rastgele alt örnekleme doğrulama (random subsampling validation) yöntemi ile hesaplanmıştır.

#### 2.4 Önerilen yöntem

Şekil 3'te verilen akış diyagramı bu çalışma için genel yöntem olarak uygulanmıştır. Etkin epokların tespiti için oluşturulan algoritmada EEG verilerinin her bir denemesi 0.25 sn.'lik alt zaman dilimlerine ayrılır. Bu çalışma için kullanılan BCI Competition Data Set Ia 3.5 sn.'lik (896 örnek) verilerden oluştuğu için 14 alt zaman diliminden oluşmaktadır. Eğitim verisi içerisinde bulunan 268 adet deneme rastgele olarak 134'ü alt eğitim ve 134 denemesi de doğrulama olmak üzere 2 alt kümeye ayrılmıştır. 0.25 sn.'lik epoklara bölünen EEG denemeleri belirlenen öznelik ve sınıflandırma yöntemiyle Şekil 3'te verilen akış diyagramındaki döngüye girer. Tüm zaman dilimleri arasından en yüksek çapraz onaylama sınıflandırma doğruluğunu (ÇOSD) veren epok belirlenip kaydedilerek diğer epoklar arasından çıkarılır. Daha sonra geriye kalan epoklar, art arda en yüksek ÇOSD'yi veren epok ile tekrar döngüye girer. Elde edilen ÇOSD bir önceki döngü ile elde edilen ÇOSD'den büyük ise o epok kombinasyonları kaydedilir. Ancak, elde edilen ÇOSD bir önceki ÇOSD'den büyük değil ise tüm epokların test edilip edilmediğine bakılır. Cevap "HAYIR" ise tüm epoklar test edilene kadar döngü devam eder. Cevap "EVET" ise tüm epoklar test edilmiştir ve o zaman dilimleri etkin epok kombinasyonları olarak seçilerek kaydedilir ve program sonlanır.



Şekil 3: Önerilen yöntemin akış şeması.

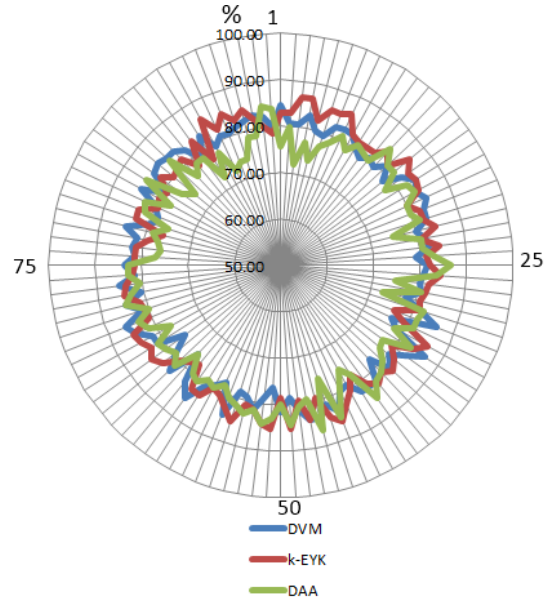
Önerilen yöntemde zaman dilimleri rastgele olarak seçilir ve 1. ve 3. kanalları kullanılan veri kümesinin tüm denemeleri için belirlenen özneliklerle sınıflandırma yapılır. Etkin epokların kararlı olabilmesi için bu çalışmada uygulanan algoritma 100

defa koşularak rastgele seçimden kaynaklanan sorunlar önlenmiştir.

### 3 Bulgular

Bu çalışmada, etkin epokların analizi için EEG işaretinin zaman dilimlerine (epok) ayrılmış şekli kullanılarak öznelikler çıkarılıp, işaret sırasıyla DVM,  $k$ -NN ve DAA sınıflandırıcılarına uygulanmıştır. Tüm sınıflandırıcılar için etkin zaman dilimleri belirlenerek sınıflandırıcılar arasında başarımlar karşılaştırılması yapılmıştır. Bu analiz rasgele alt örnekleme yöntemi ile öncelikle eğitim verileri üzerinde uygulanmıştır ve bu veriler üzerinde hesaplanan programın 100 koşum sonucu elde edilen SD sonuçları Şekil 4'te radar grafiğinde gösterilmektedir.

Şekil 4'te verilen grafiğe göre etkin zaman dilimlerinin analizi sırasında eğitim verileri üzerinde elde edilen sınıflandırma doğrulukları DVM ve  $k$ -NN için %76.29 ile %85.92 arasında, DAA için ise %71.85 ile %86.66 arasında değişmektedir. Elde edilen bu sınıflandırma doğruluklarının ortalaması ise DVM,  $k$ -NN ve DAA için sırasıyla %81.36, %82.12 ve %79.77 olarak hesaplanmıştır.



Şekil 4: Eğitim verileri üzerinde DVM,  $k$ -NN ve DAA sınıflandırıcıları ile elde edilen sınıflandırma doğrulukları.

Etkin zaman dilimlerinin analizi için uygulanan programın 100 koşum sonucu, DVM,  $k$ -NN ve DAA sınıflandırıcıları için Şekil 5'te gösterilmektedir. Burada yatay eksenle birlikte etkin zaman dilimlerinin tespiti için eğitim verileri üzerindeki 100 koşum sonucu seçilen zaman dilimlerinin sayısı, düşey eksenle ise saniye cinsinden zaman dilimlerinin ifadesi verilmiştir. Buna göre DVM sınıflandırıcısıyla 2.75-3.00 sn.  $k$ -NN ve DAA sınıflandırıcılarıyla 3.00-3.25 sn. arasında bulunan zaman dilimleri, en az veya hiç seçilmediğinden dolayı belirtilen bu epokların, bu sınıflandırıcılar için etkin bilgiyi içermediği söylenebilir.


Seçilen epoklar arasından etkin epokları belirleyebilmek için ise Tablo 1'de verilen eşik değerleri kullanılmıştır. Burada, DVM,  $k$ -NN ve DAA sınıflandırıcısının her biri için en çok sayıda seçilen epokların 0'dan 100'e kadar (10'ar arttırarak) yüzdesi hesaplanır.



Tablo 1: Test verileri üzerinde eşik değerleri ile DVM, *k*-NN ve DAA sınıflandırıcıları için hesaplanan SD'ler.

Eşik Değerleri	DVM (%)	<i>k</i> -NN (%)	DAA (%)
%0	74.06	80.20	63.13
%10	74.06	81.57	72.01
%20	75.76	82.59	72.01
%30	77.81	83.95	78.83
%40	84.64	83.95	81.26
<b>%50</b>	<b>91.46</b>	<b>84.30</b>	<b>81.26</b>
%60	91.46	84.30	77.81
%70	91.12	83.61	77.81
%80	87.71	83.61	77.13
%90	72.69	83.61	77.13
%100	72.69	83.61	77.13

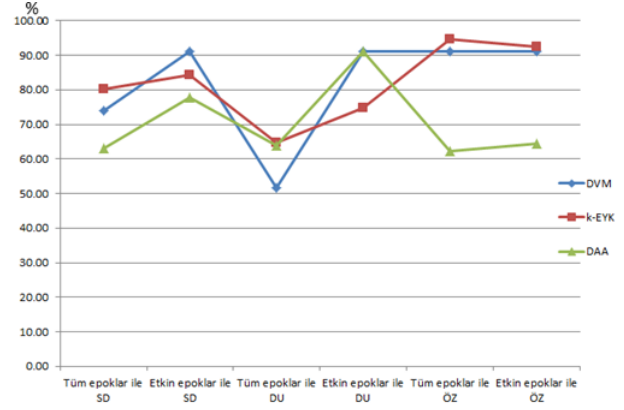
Şekil 5'teki verilere göre DVM sınıflandırıcısı için 0.00-0.25 sn. arası 40 kez, *k*-NN sınıflandırıcısı için 1.75-2.00 sn. arası 57 kez, DAA sınıflandırıcısı için 0.00-0.25 sn. arası 71 kez seçilmesi bakımından en yüksek sayıda seçilmiş zaman dilimleridir. Bu zaman dilimlerinin sırasıyla yüzdesi alınarak eşik değerleri hesaplanmıştır. Hesaplanan bu eşik değerinin üstünde seçilen epoklar ile her bir sınıflandırıcı için SD hesaplanarak Tablo 1'de gösterilmiştir.



Şekil 5: Eğitim verileri üzerinde DVM, *k*-NN ve DAA sınıflandırıcıları ile seçilen etkin zaman dilimleri.

Tablo 1'de tüm sınıflandırıcılar için en yüksek SD %50 eşik değerinde hesaplandığından bu çalışmada bu değer eşik sınır değeri olarak belirtilmiştir. Eşik sınır değerinde DVM sınıflandırıcısı için 0.00-0.25, 0.50-0.75, 0.75-1.00, 1.25-1.50 ve 1.50-1.75 sn. arasından toplam 5 etkin epok, *k*-NN sınıflandırıcısı için 1.50-1.75 ve 1.75-2.00 sn. arasında 2 etkin epok, DAA sınıflandırıcısı için 0.00-0.25, 1.25-1.50 ve 1.75-2.00 saniyeleri arasında 3 etkin epok, etkin zaman dilimleri olarak seçilmiştir. Tablo 1'de eşik sınır değerinde seçilen etkin zaman dilimlerinden çıkarılan öznelikler sırasıyla DVM, *k*-NN ve DAA sınıflandırıcılarıyla test verileri üzerinde sırasıyla %91.46, %84.30 ve %81.26 SD hesaplanmıştır. Ancak, Şekil 6'da verildiği gibi tüm epoklar hesaplamaya katıldığında aynı sınıflandırıcılar için SD'lar sırasıyla %74.06, %80.20, %63.13 olarak elde edilmiştir. Bu verilere göre etkin epoklar ile daha yüksek sınıflandırma doğruluğu hesaplanmıştır. Ayrıca, tüm

sınıflandırıcılar için seçilen etkin epoklar ve tüm epoklar ile hesaplanan DU ve ÖZ değerleri de Şekil 6'da gösterilmiştir. Bu çalışma için önerilen sınıflandırıcı olan DVM ile etkin epoklarla %90.47 DU, %92.46 ÖZ, tüm epoklarla %51.70 DU, %91.09 ÖZ değeri hesaplanmıştır.



Şekil 6: Test verileri üzerinden DVM, *k*-NN ve DAA sınıflandırıcılarıyla yapılan hesaplamalar.

DVM, *k*-NN ve DAA sınıflandırıcı ile bir deneme için özneliklerin hesaplanma süreleri Tablo 2'de verilmiştir.

Tablo 2: Test verileri üzerinden DVM, *k*-NN ve DAA ile öznelik çıkarma aşamasındaki hesaplama süresi.

Sınıflandırıcılar	Tüm Epoklar ile süre (saniye)	Etkin Epoklar ile süre (saniye)	Hesaplama Süresi Azaltım Oranı
DVM	0.3556	0.2793	%21.45
<i>k</i> -NN	0.3556	0.2455	%30.96
DAA	0.3556	0.2666	%25.02

Tüm epoklar ile öznelik çıkarma süresi hesabında aynı öznelikler çıkarıldığı ve öznelik çıkarma aşamasında sınıflandırıcıların süreye etkisi olmadığından tüm sınıflandırıcılar ile 0.3556 sn.'lik öznelik çıkarma süresi hesaplanmıştır. Etkin epoklar ile öznelik çıkarma süresi hesaplandığında ise *k*-NN, DAA ve DVM sınıflandırıcılarıyla sırasıyla 0.2455, 0.2666, 0.2793 saniye öznelik çıkarma süresi hesaplanmıştır. Önerilen yöntem ile sadece SD artırılmamış, aynı zamanda Tablo 2'de verildiği gibi öznelik çıkarma aşamasındaki hesaplama süresi DVM için %21.45, *k*-NN için %30.96 ve DAA için %25.02 oranında azaltılmıştır. Hesaplamalar Intel i5 işlemcili, 4 GB RAM bilgisayar ile Matlab R2015a ortamında gerçekleştirilmiştir.

Seçilen etkin epoklar ile DVM, *k*-NN ve DAA sınıflandırıcı için test verileri üzerindeki hata matrisleri sırasıyla Tablo 3'te verilmiştir. Burada DVM, *k*-NN ve DAA sınıflandırıcı için sırasıyla 133, 110 ve 135 deneme sınıf 0 doğru sınıflandırılırken, 14, 37, 12 deneme sınıf 0 bilgisi sınıf 1 olarak sınıflandırılmıştır. Ayrıca DVM ve *k*-NN sınıflandırıcıları için 135, DAA sınıflandırıcısı için 103 deneme sınıf 1 doğru sınıflandırılırken, DVM ve *k*-NN sınıflandırıcıları için 11, DAA sınıflandırıcısı için 43 deneme sınıf 1 bilgisi sınıf 0 olarak sınıflandırılmıştır.

Tablo 3: Sınıflandırıcılar için hata matrisleri

	Sınıf 0	Sınıf 1
Doğru Sınıflandırma	133	135
Hatalı Sınıflandırma	14	11
(a) DVM için hata matrisi		
	Sınıf 0	Sınıf 1
Doğru Sınıflandırma	110	135
Hatalı Sınıflandırma	37	11
(b) k-NN için hata matrisi		
	Sınıf 0	Sınıf 1
Doğru Sınıflandırma	135	103
Hatalı Sınıflandırma	12	43

(c) DAA için hata matrisi

#### 4 Tartışma ve sonuç

Bu çalışmada, imleç hareketinin motor hayaline dair kaydedilen EEG işaretlerinin tamamı ve zaman dilimlerine ayrılmış şekli kullanılarak öznelikler çıkarılıp test verileri sınıflandırılmıştır. Sınıflandırma işlemleri sırasıyla DVM, k-NN ve DAA ile yapılmıştır. Elde edilen sonuçlara göre diğer sınıflandırıcılarla karşılaştırıldığında en yüksek %91.46 sınıflandırma doğruluğu DVM sınıflandırıcısı ile hesaplanmıştır. DVM ile hesaplanan sınıflandırma doğruluğu diğer sınıflandırıcılar arasında algoritmanın uygulanabilirliği açısından yüksek başarımlar göstermiştir. Ayrıca, bu çalışmanın diğer önemli katkısı ise etkin epoklar ile özneliklerin hesaplama süresinin %21.45 oranında düşürülmüş olmasıdır.

Sonuçların yüksek başarımla sahip olduğunu göstermek için elde edilen sınıflandırma doğruluğu daha önce aynı veri kümesi kullanılarak yapılan çalışmalar ile karşılaştırılmıştır. Bu karşılaştırma Tablo 4'te verilmiştir.

Tablo 4: Başarımların karşılaştırması.

Çalışma	SD (%)
Aydemir ve Kayıkcıoğlu [22]	92.2
BCI competition [15]	88.7
Mensh ve diğ. [16]	88.7
Sun ve diğ. [17]	90.4
Ting ve diğ. [19]	90.8
Wang ve diğ. [18]	91.1
Duan ve diğ. [20]	93.5
Guo ve diğ. [21]	92.5
Önerilen yöntem	91.5

Önerilen yöntem BCI Competition 2003 Data Set Ia'ya uygulanarak test edilmiş ve etkin epoklar belirlenerek yapılan hesaplamaların, tüm epoklar kullanılarak yapılan sonuçlara göre daha yüksek SD sağladığı gösterilmiştir. Bu bağlamda önerilen yöntemin literatürde elde edilen sonuçlara yakın olduğu Tablo 4'te gösterilmiştir. Ayrıca önerilen yöntemin hesaplama karmaşıklığının azaltılmasına büyük katkı sağlayacağı düşünülmektedir.

#### 5 Kaynaklar

[1] Ma X, Huang X, Shen Y, Qin Z, Ge Y, Chen Y. "EEG based topography analysis in string recognition task". *Physica A: Statistical Mechanics and its Applications*, 469, 531-539, 2017.

[2] Wolpaw JR, Birbaumer N, McFarland DJ, Pfurtscheller G, and Vaughan TM. "Brain-computer interfaces for communication and control". *Clinical Neurophysiology*, 113(6), 767-791, 2002.

[3] Li Y, Long J, Yu T, Yu Z, Wang C, Zhang H, Guan C. "An EEG-based BCI system for 2-D cursor control by combining Mu/Beta rhythm and P300 potential". *IEEE Transactions on Biomedical Engineering*, 57(10), 2495-2505, 2010.

[4] Lotte F, Congedo M, Lécuyer A, Lamarche F, and Arnaldi B. "A review of classification algorithms for EEG-based brain-computer interfaces". *Journal of Neural Engineering*, 4(2), 1-13, 2007.

[5] Kübler A, Nijboer F, Mellinger J, Vaughan TM, Pawelzik H, Schalk G and Wolpaw JR. "Patients with ALS can use sensorimotor rhythms to operate a brain-computer interface". *Neurology*, 64(10), 1775-1777, 2005.

[6] Oh SH, Lee YR, Kim HN. "A novel EEG feature extraction method using Hjorth parameter". *International Journal of Electronics and Electrical Engineering*, 2(2), 106-110, 2014.

[7] Jenke R, Peer A, Buss M. "Feature extraction and selection for emotion recognition from EEG". *IEEE Transactions on Affective Computing*, 5(3), 327-339.

[8] Siuly S, Li Y. "Designing a robust feature extraction method based on optimum allocation and principal component analysis for epileptic EEG signal Classification". *Computer Methods and Programs in Biomedicine*, 119(1), 29-42, 2015.

[9] Hsu WY, Lin CH, Hsu HJ, Chen PH, Chen IR. "Wavelet-based envelope features with automatic EOG artifact removal: Application to single-trial EEG data". *Expert Systems with Applications*, 39(3), 2743-2749, 2012.

[10] Hsu WY. "Fuzzy Hopfield neural network clustering for single-trial motor imagery EEG Classification". *Expert Systems with Applications*, 39(1), 1055-1061, 2012.

[11] Asensio-Cubero J, Gan JQ, Palaniappan R. "Extracting optimal tempo-spatial features using local discriminant bases and common spatial patterns for brain computer interfacing". *Biomedical Signal Processing and Control*, 8(6), 772-778, 2013.

[12] Aydemir Ö. "Common spatial pattern based feature extraction from the best time segment of BCI data System". *Turkish Journal of Electrical Engineering and Computer Sciences*, 6, 33, 2015.

[13] Hsu WY. "EEG-based motor imagery classification using enhanced active segment selection and adaptive classifier". *Computers in Biology and Medicine*, 41(8), 633-639, 2011.

[14] Han R, Wei Q. "Joint selection of time and frequency segments for classifying multiclass EEG data in motor imagery based BCIs". *International Conference on in Fuzzy Systems and Knowledge Discovery*, Zhangjiajie, China, 15-17 August 2015.

[15] Mensh B. "BCI competition 2003 Results". <http://ida.first.fhg.de/projects/bci/competition/results> (19.02.2016)

[16] Mensh BD, Werfel J, Seung HS. "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, 2004.

- [17] Sun S, Zhang C. "Assessing features for electroencephalographic signal categorization". *IEEE International Conference on Acoustics, Speech and Signal Processing*, Philadelphia, USA, 23-23 March 2005.
- [18] Wang B, Jun L, Bai J, Peng L, Li G, Li Y. "EEG recognition based on multiple types of information by using wavelet packet transform and neural networks". In *2005 IEEE Engineering in Medicine and Biology*, Shanghai, China, 17-18 January 2006.
- [19] Ting W, Guo-zheng Y, Bang-hua Y, Hong S. "EEG feature extraction based on wavelet packet decomposition for brain computer interface". *Measurement*, 41(6), 618-625, 2008.
- [20] Duan L, Zhong H, Miao J, Yang Z, Ma W, Zhang X. "A voting optimized strategy based on ELM for improving classification of motor imagery BCI data". *Cognitive Computation*, 6(3), 477-483, 2014.
- [21] Guo X, Zhao H, Li X, Li T, Dai M. "EEG signal analysis based on fixed-value shift compression algorithm". In *Natural Computation*, Zhangjiajie, China, 15-17 August 2015.
- [22] Kayıkcıoğlu T, Aydemir O. "A polynomial fitting and k-NN based approach for improving classification of motor imagery BCI data". *Pattern Recognition Letters*, 31(11), 1207-1215, 2010.
- [23] Yavuz E, Aydemir Ö. "EEG tabanlı beyin bilgisayar arayüzü işaretlerinin etkin zaman dilimlerinden çıkarılmış özneliklerle sınıflandırma doğruluklarının artırılması". *XX. Biyomedikal Ulusal toplantısı*, İzmir, Türkiye, 3-5 Kasım 2016.
- [24] Hahn SL. *Hilbert Transforms in Signal Processing*. Boston, London, Artech House, 1996.
- [25] Medl A, Flotzinger D, Pfurtscheller G. "Hilbert-transform based predictions of hand movements from EEG measurements". In *Engineering in Medicine and Biology Society*, Paris, France, 29 October-1 November 1992.
- [26] Lyness JN, Moler CB. "Numerical differentiation of analytic functions". *SIAM Journal on Numerical Analysis*, 4(2), 202-210, 1967.
- [27] Furey TS, Cristianini N, Duffy N, Bednarski DW, Schummer M, Haussler D. "Support vector machine classification and validation of cancer tissue samples using microarray expression data". *Bioinformatics*, 16(10), 906-914, 2000.
- [28] Panda R, Khobragade P S, Jambhule PD, Jengthe SN, Pal PR and Gandhi TK. "Classification of EEG signal using wavelet transform and support vector machine for epileptic seizure diction". In *Systems in Medicine and Biology*, Kharagpur, India, 16-18 December 2010.
- [29] Blankertz B, Muller KR, Curio G, Vaughan TM, Schalk G, Wolpaw JR, Schroder M. "The BCI competition 2003: progress and perspectives in detection and discrimination of EEG single tras". *IEEE Transactions on Biomedical Engineering*, 51(6), 1044-1051, 2004.