

# El İle Kavrama Girişiminin Hayali Sırasında Kaydedilmiş EEG İşaretlerinin Sınıflandırılması Classification of EEG Signals Recorded During Imagery of Hand Grasp Movement

Osman Kerem ATEŞ ve Önder AYDEMİR

Elektrik Elektronik Mühendisliği  
Karadeniz Teknik Üniversitesi  
Trabzon, Türkiye

keremates.eee@gmail.com, onderaydemir@ktu.edu.tr

**Özetçe**—Beyin bilgisayar arayüzleri (BBA), kullanıcıların yalnızca beyin aktivitesi ile dış bir cihazla iletişim kurmasını sağlayan sistemlerdir. BBA teknolojisinin önemli amaçlarından biri de hareket kabiliyeti kısıtlanmış veya felçli hastalar gibi kişilerin dünyayla iletişimini sağlamaktır. Bu iletişim genellikle elektroensefalografi (EEG) adı verilen beyin dalgalarının aktivesini elektriksel yöntemle izlenmesini sağlayan yöntemle yapılabilir. Bu çalışmada, sağ veya sol el fonksiyon yetersizliği olan kişilerin, el hareket kavrama hayali esnasında kaydedilen EEG verileri ile çalışılmıştır. Sekiz farklı kişi için istatistiksel tabanlı özneliklerle öznelik vektörü oluşturulup yüksek sınıflandırma doğruluğu (SD) bulunması hedeflenmiştir. Sınıflandırmada, k-En yakın komşu (k-EYK), destek vektör makineleri (DVM) ve doğrusal ayırma analizi (DAA) yöntemleri kullanılmıştır. Çıkarılmış özneliklerle sekiz kişi için, ortalama olarak en yüksek SD %81.17 ile k-EYK algoritması ile elde edilmiştir. Bulunan sonuçlar, önerilen öznelik yöntemlerinin hareket hayali EEG işaretlerinin sınıflandırması için uygulanabileceğini göstermiştir.

**Anahtar Kelimeler** — beyin bilgisayar arayüzü; motor hayali; EEG; hayali el hareketi; öznelik çıkarımı; sınıflandırma.

**Abstract**—Brain-computer interfaces (BCI) are the systems that enable to provide communication between users and an external device through only brain activities. One of significant purposes of BBA technology is to enable communication of the patients like who has motor disability or are paralyzed. This communication can be performed by electroencephalogram (EEG) that is a method providing to be followed brain activities through electrical system. In this study, the EEG data set recorded during brain imagination of right or left hand grasp attempt movements of subjects having hand functional disability was used. It is aimed to have high classification accuracy (CA) for eight different subjects by creating feature vectors using statistical based features. k-nearest neighbors (kNN), support vector machines (SVM) and linear discriminant analysis (LDA) methods were used for classification. We obtained the highest average CA as 81.17% for eight subjects using kNN algorithm. The results indicate that these proposed

features can be used for the classification of motor imagery EEG signals.

**Keywords** — brain computer interface; motor imagery; EEG; motor imagery hand movement; feature extraction; classification.

## I. GİRİŞ

Beyin-bilgisayar arayüzü (BBA); tıp, psikoloji, sinyal işleme, sinir bilim ve makine öğrenmesi gibi bir çok alanla iç içe olan ve son derece disiplinler arası bir araştırma konusudur [1]. Bu arayüz, kullanıcının aktivitesine bağlı olarak Elektroensefalografi (EEG) sinyallerini hesaplar ve farklı uygulama alanlarında kullanılması için kaydedilmiş bu sinyalleri kontrol komutlarına çevirir [2]. Kullanıcının beyin dalgalarını kaydederek, verilen görevi tamamlamak için bu sinyalleri bilgisayar sistemine gönderir. İletilen dalga veya sinyaller sayesinde fikir veya nesnenin kontrolü sağlanabilir [3].

BBA'nın en önemli uygulama alanlarından biri de engelli bireyler için dış ortamla haberleşmelerini sağlayacak yeni teknolojiler geliştirmektir [4]. Son yıllarda yapılan çalışmalar, insan beyninin, kişinin herhangi bir hareket yapmasına gerek kalmadan, sadece hayal ederek cihazları kontrol edebileceğini ve ayrıca felçli hastalarında hayatlarını kolaylaştıracak sistemlerin oluşturulabileceğini göstermiştir. Hayal edilen hareketin otomatik çözülmesi, robot-destekli tedavilerin veya destekleyici teknoloji ve rehabilitasyon amaçlı ara yüzlerinin geliştirilmesine katkı sağlayacaktır.

Literatürde sağ veya sol el, kol hareketlerinin veya hayal edilmesinin esnasında kaydedilen EEG işaretlerinin sınıflandırmasıyla ilgili birçok çalışmanın yapıldığı görülmektedir. Yapılan bir çalışmada; Bhattacharyya ve arkadaşları, sağ-sol kol hareketinin meydana getirdiği EEG sinyallerinin, doğrusal ayırma analizi (DAA), karesel ayırma analizi (KAA) ve k-en yakın komşu (k-EYK) gibi algoritmalar kullanılarak bunların performansını analiz etmek istemişlerdir. En yüksek doğruluğu ise k-EYK ile ortalama güç bandı vektörünü kullanarak %84.29 olarak elde

etmişlerdir [5]. Hajibabazadeh ve Azimirad, 6 kanaldan EEG sinyalleri topladıktan sonra alçak geçiren filtre ile filtreleme işlemi gerçekleştirmişlerdir. Sonra, destek vektör makinesi yöntemi sayesinde sağ el veya sol el motor hayalini sınıflandırmışlardır ve %75 sınıflandırma doğruluğu elde etmişlerdir [6]. Diğer bir çalışmada ise; Liu ve arkadaşları sol el ve sağ el hareketinin hayalini içeren bir görev için ortaya çıkan EEG sinyallerini sınıflandırmayı öneren bir yöntem sunmuşlardır. Bu iki görev için yüksek sınıflandırma oranı bulmayı hedeflemişlerdir. Yapılan çalışma sonucu destek vektör makinesi (DVM) ile ortalama %82.10 sınıflandırma doğruluğuna ulaşmışlardır [7]. Zhichuan ve arkadaşları ise (2017) sağ ve sol el motor hayalinin EEG sinyalleri için, evrimsel sinir ağlarına dayanan yeni bir yöntem önermişlerdir. Bu yöntem iki kişiden toplanan veri setleri üzerinde uygulanmıştır ve diğer üç klasik sınıflandırıcı yöntemleriyle karşılaştırılmıştır. Çalışmada yeni yöntemin diğer sınıflandırıcıları geçerek %86.41 oranında bir sınıflandırma doğruluğuna ulaştığı gösterilmiştir [8].

Bu çalışmada, sadece beyin aktivitesi sağlanarak yapılan sol veya sağ elin kavramayı deneme hareketlerinin kaydedilmesiyle ortaya çıkan EEG verileri üzerinde çalışılmıştır. Ham EEG verisine herhangi bir ön işlem de bulunulmadan, farklı kişilerde belirleyici sonuç veren bazı istatistiksel tabanlı özellikler çıkarılmıştır. Kullanılan özellikler; entropi (E), çarpıklık (Ç), karekök ortalama (RMS), sıfır geçiş sayısı (SGS), varyans (VAR) ve standart sapmadır (STD).

Sekiz farklı kişi için seçilen kanallar üzerinde sınıflandırma doğrulukları tespit edilmiştir. Farklı sınıflandırıcıların, sınıflandırma doğruluğuna etkisini göstermek amaçlı olarak k-EYK, DVM ve DAA olmak üzere üç farklı sınıflandırıcı sonuçları ele alınmıştır.


## II. MATERYAL VE YÖNTEM

### A. Veri Kümesi Tanıtımı ve Analizi

Çalışma el hareket ve fonksiyon yetersizliği olan 8 kişinin sağ veya sol elinin kavramayı deneme hareketinin hayal edilmesiyle ortaya çıkan ve ayrıca Clinical BCI Challenge-WCCI 2020 yarışmasında kullanılan veri seti üzerinde gerçekleştirilmiştir.

DeneySEL çalışma, iki aşamadan oluşan klasik bir sensör motor ritim BBA yapısını izlemektedir. Birinci aşamada herhangi bir geri bildirimde bulunmadan, ilk sınıflandırıcı çıkarılmış özellikleri kullanarak eğitilmektedir. Bu aşamada veri edinme, 40 denemenin 2 kez koşumunu içerir ve her biri yaklaşık 7 dakika 30 saniye sürmektedir. Sonra, sınıflandırıcı çevrim dışı moda eğitilir ve bu da yaklaşık 30 saniye sürer, devamında 40 denemenin çevrim içi BBA moda bir geri bildirim koşusuyla takip edilmektedir. Her koşumda 20 deneme sağ ve 20 deneme sol motor hayalidir. Eğitilme evresi 8 saniyedir ve bunun ilk 3 saniyesi de bilgisayar ekranının ortasında hazır ol mesajı içeren bir hazırlık aşamasıdır. 2 saniyeden sonra, bir bip sesi oluşmakta ve 3. saniyenin sonunda, ekranın sol veya sağ tarafında el-görüntüsü şeklinde bir işaret ortaya çıkmaktadır. İşaretin belirmesine

göre, katılımcılardan sol veya sağ elin kavraması hareketi temelli bir görev yapması istenmektedir. Eğitim aşamasında beliren işaret 8.saniyenin sonuna kadar sürmektedir. Sonrasında ekran diğer denemenin başlamasından önce 2-3 saniye kadar bir süre için kararmaktadır. Yapılan EEG verilerinin kaydedilme süreci Şekil 1'de gösterilmiştir.



Şekil 1. Bir adet EEG verisinin kaydedilme süreci

EEG verileri, uluslararası 10-20 sistemine göre yerleştirilmiş olan 12 elektrottan kaydedilmiştir. Sinyaller, veri edinme esnasında 512 Hz frekansında örneklendi ve 0.1 den 100 Hz'e kadar bant-geçiren filtre ile, 50 Hz de ise bir bant-durduran filtre ile filtrelendi.

Kullanılan veri analizi yöntemi Şekil 2'de kısa gösterilmiştir: İlk aşamada ham EEG verisinden, herhangi bir ön işlem aşamasında bulunulmadan, sinyallerin özneliğinin yani sinyalleri en iyi temsil eden parçaların bulunması sağlanır. Diğer aşamada ise çıkarılan bu özellikler, farklı sınıflandırıcılar kullanılarak sınıflandırılır. Sonuç olarak EEG sinyalinden hangi elin hareketinin hayalinin düşünüldüğü tespit edilir.



Şekil 2. EEG verisinin analiz şeması

### B. Öznitelik Çıkarımı

Bu işlem kısaca ham EEG verisini en iyi temsil eden özelliklerin belirlenmesi olarak tanımlanabilir. Kullanılacak olan EEG veri seti, matematiksel ve istatistiksel yöntemlerle analiz edilip, öznitelik çıkarma işlemi yapılacaktır. Yalnız her yöntem, her uygulama için iyi sonuç vermemektedir. Tüm kişilerden alınan EEG işaretleri de aynı olmayacağından, çıkarılan öznitelikler kişiden kişiye farklı sonuçlar vermektedir. Bu yüzden, EEG verisinde tüm elektrotlardan (kanallardan) elde edilen veriler yerine, yapılan uygulamaya uygun şekilde beyinsel aktivitenin yoğun olduğu bölgeleri kullanmak sınıflandırma için çıkartılan en iyi özneliğin bulunmasını kolaylaştırmaktadır.

Bu çalışmada da, öznitelik vektörleri olarak, entropi (E), çarpıklık (Ç), karekök ortalama (RMS), sıfır geçiş sayısı (SGS), varyans (VAR) ve standart sapma (STD) denenmiştir.

1) *Entropi (E)*: Sinyaldeki düzensizliği bir ölçüsüdür. E sinyalin entropisi, N sinyalin uzunluğu ve  $P(X=x_i)$  olasılık dağılım fonksiyonu ise

$$E = -\sum_{i=1}^N P(X = x_i) \cdot \log_2 P(X = x_i) \quad (1)$$

2) *Çarpıklık (Ç)*: Bir rastgele sürecin olasılık dağılımını asimetrisinin bir ölçüsü olarak ifade edilir. Bir x işareti için Denklem 2'de çarpıklık verilmiştir.  $\bar{x}$  ortalama,  $\sigma$  standart sapma, n veri sayısıdır.

$$\zeta = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1) \sigma^3} \quad (2)$$

3) *Karekök Ortalama (RMS)*: Kare fonksiyonunun ortalama değerinin karekökü veya anlık değerlerdir. N veri sayısıdır.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3)$$

4) *Sıfır Geçiş Sayısı (SGS)*: İşaretin sıfır noktasından geçiş sayısıdır. Denklem (4)'deki şekilde bulunabilir. N veri sayısı,  $x_i$ , i.veridir.

$$SGS = \sum_{i=1}^N \text{sign}(-x_i x_{i+1}) \quad \text{sign}(x) = \begin{cases} 1, & x > 0 \\ 0, & \text{diğer} \end{cases} \quad (4)$$

5) *Varyans (VAR)*: Varyans, standart sapmanın karesidir.

$$VAR = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (5)$$

6) *Standart Sapma (STD)*: Verilerin ne kadar ortaya yakın olduğunu bulur.

$$STD = \sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (6)$$

### C. Sınıflandırma

Sınıflandırma aşamasında, elde edilen öznitelik vektörleri, sınıflandırıcı yöntemleri olan k-EYK, DVM ve DAA ile sınıflandırılmıştır.

k-EYK, k tane en yakın komşusunun durumuna göre etiketsiz denemelerin sınıfının tayin edilmesi yöntemidir [9]. Sınıflandırılacak olan test verisinin, eğitim verilerine bakılarak belli mesafe ölçüm yöntemleri kullanılarak, test verisinin sınıfı belirlenir. Bu sınıflandırmada, mesafe ölçümü için bir kaç uzaklık metodu olsa da, bu çalışmada kullanılan Öklid uzaklığı metodudur. Rasgele alt örnekleme doğrulama yöntemi ile en ideal k parametresi seçilmiştir. Toplam 50 koşum olarak yapılan bu çalışmada, en çok seçilen k değeri bu yöntem için esas alınmıştır.

Destek vektör makineleri de, hiper düzlemler veya karar sınırları belirleyerek, iki sınıfa ait verileri birbirinden ayırt etmek için kullanılır. Bu yöntemde özellikle az sayıda veri ile doğru sınıflandırma sonuçları bulunabilir [10]. DVM'nin önemli avantajları ise karmaşık yapıları modelleyebilme, yüksek doğruluk sağlaması ve çok sayıda değişkenle çalışabilmesi olarak sıralanabilir.

Doğrusal ayırma analizinde ise, veri sınıflandırması ve veri boyutu azaltılması için sıklıkla kullanılan bir yöntemdir. Sınıfların dağılımını inceleyip, ortalama değerleri arasındaki farklılığı kullanarak sınıfları birbirinden ayırmak için kullanılır [11]. Analiz aşamasında ise dışarıdan alınan bir verinin hangi gruba dahil edileceğini gösterir.

### III. SONUÇLAR VE TARTIŞMA

Bu çalışmada, sekiz kişi için sol veya sağ elin kavrama hareketinin düşünülmesiyle kaydedilen EEG işaretleri üzerinde çalışılmıştır. Temel olarak, farklı özniteliklerin kullanıldığı durumlarda kişiler üzerindeki sınıflandırma başarıları araştırılmıştır. Bunun için k-EYK, DVM ve DAA gibi sınıflandırma algoritmaları denenmiştir. Çalışılan veri setinde, her kişi için alınan 80 EEG veri kaydı kullanılmıştır. Bu veri kaydı ise 40 EEG verisi eğitim için ve 40 EEG verisi test için olmak üzere rastgele bir şekilde ayrılmıştır.

Kişi 1 için, bir ve ikinci kanal üzerinde yoğunlaşmıştır. Aynı öznitelik çıkarım yöntemi ile ikinci kanalda k-EYK ile %82.60 SD elde edilmiştir. Kişi 2 için ise, DVM algoritmasıyla %92,10'luk bir sonuç ile bu çalışmanın en yüksek SD gerçekleştirilmiştir. Kişi 3 için de, E, Ç, RMS ve SGS gibi özniteliklerin beraber ve farklı iki kanalda sınıflandırılmasıyla sonuçlar elde edilmiştir. Burada en yüksek SD, DVM yöntemiyle ikinci seçilen kanal üzerinden elde edilmiştir. Kişi 4 için, öznitelik çıkarımı esnasında varyans tabanlı öznitelik kullanılmıştır. Tablo 1'de ilk sütunda görüldüğü üzere %45-49 bandında bir sonuç başarı sağlanmıştır. Bu özneliğin daha sonra türevinin alınması ile k-EYK sınıflandırıcısıyla %30'un üzerinde bir SD artışı sağlanmıştır.

Kişi 5-6-7-8 için ise, öncelikle varyans özneliği tek başına işleme alınarak öznitelik vektörleri çıkarılmıştır. Bu vektörler kullanılarak elde edilen SD değerleri Tablo 1'de ilk

sütunda yer almaktadır. Bunlara ek olarak, SD artırmak için ek olarak RMS ve STD öznitelikleri kullanılmıştır. Tablo 1'de ikinci sütunda görüldüğü gibi Kişi 8 için k-EYK algoritmasıyla yaklaşık %7'lik bir artış gözlemlenmiştir. Kişi 6 için ise DVM yöntemiyle yaklaşık %3'lük bir yükseliş yakalanmıştır.

TABLO I. TÜM KİŞİLER İÇİN SINIFLANDIRMA DOĞRULUĞU SONUÇLARI

Kişiler	Kullanılan Öznitelik ve SD (%)					
	k-EYK		DVM		DAA	
Kişi1	VAR <sup>a</sup> 80,95	VAR 82,60	VAR 60,35	VAR 66,50	VAR 69,70	VAR 66,90
Kişi2	VAR 90,50	VRS <sup>b</sup> 90,95	VAR 91,75	VRS 92,10	VAR 91,60	VRS 91,85
Kişi3	EÇRS <sup>c</sup> 77,05	EÇRS 80,65	EÇRS 57,90	EÇRS 81,10	EÇRS 52,75	EÇRS 76,55
Kişi4	VAR 49,20	VV <sup>d</sup> 81,05	VAR 46,50	VV <sup>d</sup> 68,95	VAR 45,90	VV 70,40
Kişi5	VAR 77,45	VRS 77,70	VAR 48,35	VRS 47,90	VAR 51,65	VRS 50,35
Kişi6	VAR 78,60	VRS 81,85	VAR 66,90	VRS 69,65	VAR 60,20	VRS 60,30
Kişi7	VAR 85,30	VRS 84,95	VAR 85,90	VRS 86,70	VAR 84,65	VRS 85,70
Kişi8	VAR 62,80	VRS 69,60	VAR 60,65	VRS 59,85	VAR 60,20	VRS 61,05
Ortalama	75,23	81,17	64,79	71,59	64,58	70,38

<sup>a</sup> VAR Özniteliği, <sup>b</sup> VAR, RMS ve STD Öznitelikleri, <sup>c</sup> E, Ç, RMS ve STD Öznitelikleri, <sup>d</sup> VAR'ın Türevi Özniteliği

İki sınıflı olan bu veri setleri için, hangi elin hareket hayalinin düşünüldüğü farklı sınıflandırıcılar kullanılarak bulunmaya çalışılmıştır. Ulaşılan sonuçlar sekiz kişi için de genel olarak değerlendirildiğinde, bu veri setleri için DAA sınıflandırıcısının, k-EYK ve DVM sınıflandırıcısının kişilerin çoğunluğu için SD olarak geride kaldığı görülmüştür. Kişiler için ortalama olarak en yüksek değerler k-EYK ile elde edilse de, bu çalışmanın en yüksek sınıflandırma doğruluk oranı DVM ile yakalanmıştır.

Elde edilen sonuçlara göre; tüm kişiler için ortalama %81.17 ve Kişi 5, Kişi 8 harici %80'i geçen tahmin oranları veren k-EYK algoritması verilen özniteliklerin bu çalışmalarda etkili olabileceğini göstermektedir. Ayrıca, kullanılan veri setinin güncel olmasının yanında, çıkarılan öznitelik vektörü boyutlarının düşük olması ve klasik öznitelik çıkarma yöntemlerinin kullanılması önerilen yöntemlerin uygulanabilir olduğunu ortaya koymaktadır. İlerleyen çalışmalarda diğer kişiler için de etkili olan öznitelikler belirlenip yüksek sınıflandırma doğruluğu elde edilmeye çalışılacaktır.

#### KAYNAKLAR

[1] M. Smith, G. Salvendy, K. R. Müller, M. Krauledat, G. Dornhege, G. Curio, and B. Blankertz, "Machine Learning and Applications for Brain-Computer Interfacing," in *Human Interface and the Management of Information. Methods, Techniques and Tools in Information Design*. vol. 4557: Springer Berlin Heidelberg, 2007, pp. 705-714.

[2] B. Graimann, G. Pfurtscheller, and B. Allison, "Brain-Computer Interfaces: A Gentle Introduction," in *Brain-Computer Interfaces*: Springer Berlin Heidelberg, 2010, pp. 1-27.

[3] Van Erp, J., Lotte, F., & Tangermann, M. (2012). *Brain-Computer Interfaces: Beyond Medical Applications*. *Computer*, 45(4), 26–34. doi:10.1109/mc.2012.107

[4] A. E. Selim, M. A. Wahed, and Y. M. Kadah, "Machine Learning Methodologies in Brain-Computer Interface Systems," in *Biomedical Engineering Conference, 2008, CIBEC 2008*. Cairo, 2008, pp. 1-5.

[5] Bhattacharyya, S., Khasnobish, A., Chatterjee, S., Konar, A., & Tibarewala, D. N., "Performance analysis of LDA, QDA and KNN algorithms in left-right limb movement classification from EEG data", *In Systems in Medicine and Biology, 2010 International Conference on IEEE*, (pp. 126-131), 2010.

[6] M. Hajibabazadeh and V. Azimirad, "Brain-robot interface: Distinguishing left and right hand EEG signals through SVM," in *2014 Second RSI/ISM International Conference on Robotics and Mechatronics (ICRoM)*, 2014, pp. 813-816.

[7] C. Liu, H. Wang, H. Pu, Y. Zhang, and L. Zou, "EEG feature extraction and pattern recognition during right and left hands motor imagery in brain-computer interface," in *2012 5th International Conference on BioMedical Engineering and Informatics*, 2012, pp. 506-510.

[8] Tang, Z., Li, C., & Sun, S. (2017). Single-trial EEG classification of motor imagery using deep convolutional neural networks. *Optik - International Journal for Light and Electron Optics*, 130, 11–18.

[9] Yazdani, A., Ebrahimi, T., & Hoffmann, U., "Classification of EEG signals using Dempster Shafer theory and a k-nearest neighbor classifier", *In Neural Engineering, 2009. NER'09. 4th International IEEE/EMBS Conference on*, Antalya, Turkey, (pp. 327-330), 2009.

[10] Foody, G.M. ve Mathur, A. (2004). Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification. *Remote Sensing of Environment*, 93, 107–117.

[11] S. Balakrishnama and A. Ganapathiraju, "Linear Discriminant Analysis - A brief Tutorial," <http://www.isip.msstate.edu/publications/reports/>, Institute for Signal and Information Processing, Mississippi State University, MS State, MS, USA, March 2, 1998.