

## Bağımsız Bileşen Analizi ve Makine Öğrenmesi Kullanılarak Omurilik Yaralanması Olan Kişilerden Alınan EEG Sinyallerinden El Hareketlerinin Sınıflandırılması

Ebru SAYILGAN<sup>1\*</sup> 

### Öz

Bu çalışmanın temel amacı, Omurilik Yaralanması (OY) olan kişilerin, kol ve el hareketlerinin, kodu çözülebilir nöral bağıntılarını koruduğunu göstermektir. OY'li on kişiden pronasyon, süpinasyon, palmar kavrama, lateral kavrama ve el açma hareketleri düşündürülerek alınan ElektroEnsefaloGrafı (EEG) sinyallerinin ayırt edici hareket bilgisi araştırılmıştır. Bunu yaparken kullanılan yöntemlerde Bağımsız Bileşen Analizi (BBA/ICA) yöntemi hem artefakt gidermede hem de yeni bir yaklaşım olarak öznelik vektörlerini çıkarmada kullanılmıştır. Önerilen yöntemde öznelik vektörleri bağımsız bileşenlerde ortak bilgi matrisi çıkarılarak oluşturulmuştur. Çıkarılan ve seçimi yapılan öznelik vektörleri dört farklı makine öğrenmesi modeli (Destek Vektör Makinesi (DVM), k-En Yakın Komşuluk (k-EYK), AdaBoost ve Karar Ağaçları (KA)) ile test edilmiştir. Model değerlendirme aşamasında aşırı öğrenmenin önüne geçmek için 5-katlamalı çapraz doğrulama ve hata matrisi yöntemleri kullanılmıştır. Sonuç olarak, incelenen beş sınıfa göre elde edilen başarımlar oldukça yüksek çıkmıştır. Deneklerin ortalaması alındığında elde edilen model doğruluk değerleri sırasıyla DVM'de  $0.9024 \pm 0.0781$ , k-EYK'da  $0.8582 \pm 0.0985$ , AdaBoost'ta  $0.7924 \pm 0.0937$  ve KA'da  $0.8089 \pm 0.0645$  olarak hesaplanmıştır. Bu sonuçlara dayanarak OY olan bireylerin kol ve el hareketlerinin ayırt edicilik performansının önerilen yöntem ile oldukça yüksek sonuçlar verdiği görülmektedir. BBA yöntemine dayalı bir öznelik çıkarma ve DVM modeli ile sınıflandırma metodolojisinin OY'li hastaların rehabilitasyon tedavisinde EEG temelli beyin bilgisayar arayüzü uygulamalarına önemli bir katkısı olacağı düşünülmektedir.

**Anahtar Kelimeler:** Omurilik yaralanması, EEG, Bağımsız bileşen analizi, Sınıflandırma, Makine öğrenmesi.

## Classification of Hand Movements from EEG Signals from Persons with Spinal Cord Injury Using Independent Component Analysis and Machine Learning

### Abstract

The main aim of this study is to demonstrate that people with Spinal Cord Injury (SCI) preserve decipherable neural correlates of arm and hand movements. The distinctive movement information of ElectroEncephaloGraphy (EEG) signals obtained by imagining pronation, supination, palmar grasp, lateral grasp and hand open movements from eight subjects with SCI was investigated. In doing so, Independent Component Analysis (ICA) was used in both artifact removal and feature vector extraction as a new approach. In the proposed method, feature vectors were created by extracting the common information matrix in independent components. Extracted and selected feature vectors were tested with four different machine learning models (Support Vector Machine (SVM), k-Nearest Neighbor (kNN), AdaBoost, and Decision Trees (DT)). In the model evaluation phase, 5-fold cross validation and confusion matrix methods were used to prevent over-learning. As a result, according to the five classes the obtained performance is quite high. Depending on all subject's average values, the model accuracies were calculated as  $0.9024 \pm 0.0781$  in SVM,  $0.8582 \pm 0.0985$  in kNN,  $0.7924 \pm 0.0937$  in AdaBoost, and  $0.8089 \pm 0.0645$  in DT, respectively. Based on these results, it is seen that the discrimination performance of arm and hand movements of individuals with SCI is high with the proposed method. It is thought that a feature extraction and classification methodology based on the ICA method and SVM model will make an important contribution to EEG-based brain computer interface applications in the rehabilitation treatment of patients with SCI.

**Keywords:** Spinal cord injury, EEG, Independent component analysis, classification, Machine learning.

<sup>1</sup>İzmir Ekonomi Üniversitesi, Mekatronik Mühendisliği Bölümü, İzmir, Türkiye, [ebru.sayilgan@ieu.edu.tr](mailto:ebru.sayilgan@ieu.edu.tr)

\*Sorumlu Yazar/Corresponding Author

Geliş/Received: 04.03.2024

Kabul/Accepted: 30.07.2024

Yayın/Published: 15.09.2024

## 1. Giriş

Omurilik Yaralanması (OY), omurga içinde bulunan sinir dokusunun çeşitli nedenlerle (trafik kazası, yüksekte düşme, sığ sulara balıklama atlama, ateşli silah yaralanmaları vb.) zarar görmesine verilen genel bir isimdir. OY, birey üzerinde önemli bir sosyal ve ekonomik etkiye sahip olan ve kalıcı olabilecek sakatlığın en önemli nedenlerinden biridir. OY'li hastaların diğer insanlara oranla 28,8 kat daha yüksek bir ölüm riskine sahip olduğu da yapılan araştırmalar sonucunda belirtilmektedir (Leite ve ark., 2019). OY'nin dünya çapındaki yayılma hızının milyonda 440-526 aralığında olduğu tahmin edilmektedir. İnsidans oranı (risk altındaki sağlam kişilerin belirli bir hastalığa yakalanma olasılığını gösteren ölçüt) milyonda 13 ile milyonda 163,4 arasında değişmektedir ve az gelişmiş ülkelerde milyonda 220'ye ulaşmaktadır (Kang ve ark., 2018).

Son yıllarda rehabilitasyon protokollerinin iyileştirilmesi, robotik yardımcı yürüyüş sistemlerinin geliştirilmesi, yeni teknolojilerle tasarlanan rehabilitasyon robotlarının artması vb. ilerlemeler, OY'li hastalara uygulanan rehabilitasyon terapilerine önemli ölçüde katkı sağlamıştır. Bu ilerlemelere rağmen anlamlı bir iyileşme gösteremeyen ciddi düzeyde bozukluğu olan önemli sayıda hasta bulunmaktadır (Nam ve ark., 2017). OY'de fonksiyonel iyileşme mekanizmalarını anlamak ve tedavi yanıtının adımlarını geliştirmek ve yenilikçi yaklaşımların artması OY hastalarına özel tedavilerin geliştirilmesi için çok önemlidir. Yeni kanıtlar, nöro plastisitenin, OY düzeyinde ve beynin kortikal alanlarındaki devrelerin yeniden düzenlenmesi yoluyla duyuşsal, motor ve otonomik işlevlerin geri kazanılmasında önemli bir rolü olduğunu göstermektedir (Athanasioiu ve ark., 2012; Liu ve ark., 2012). Mevcut kanıtlar, beyin görüntüleme yöntemlerinden biri olan ElektroEnsefaloGrafı (EEG)'nin OY ile ilgili fonksiyonel bozukluğu ve nöro plastik değişiklikleri değerlendirmek için yararlı bir araç olabileceğini göstermektedir (Hernandez-Rojas ve ark., 2022; Simis ve ark., 2020).

Literatürdeki çalışmalar, EEG ölçümlerinin inme gibi durumlarda Beyin Bilgisayar Arayüzleri (BCI) ve/veya robot yardımcı rehabilitasyonla birlikte motor iyileşmeyi tahmin etmede ve tedavide de yararlı olabileceğini göstermiştir (Sayilgan ve ark., 2021a; Sayilgan ve ark., 2021b; Sayilgan ve ark., 2022). Üst ekstremitenin karmaşık fonksiyonel hareketlerinin kodu, bilgisayar ile insan beyni arasında daha iyi iletişim kurabilmek için hala farklı yöntemler denenerek çözülmeye çalışılmaktadır (Mohseni ve ark., 2020; Ofner ve ark., 2017). Geçtiğimiz yıllarda, motor hayali düşündürülerek yapılan EEG araştırmalarından elde edilen bilgilerin çözümlenmesinde önemli ilerlemeler kaydedilmiştir. Wang ve ark. (2004) sağ ve sol el hareketlerinin ayırt ediciliğini çalışmış, öznitelik vektörleri olarak uzaysal desenlerin korelasyonunu ve k-en yakın komşuluk (k-EYK) sınıflandırıcısını kullanarak %80'lik ortalama doğruluk elde etmiştir. Schlogl ve ark. (2005) sağ el, sol el, dil ve ayak hareketlerini araştırırken Destek Vektör Makinesini (DVM) kullanmış ve %52 ila

%77 arasında bir doğruluk elde etmiştir. Sreeja ve ark. (2019) sağ el, sol el, dil ve ayak hareketlerini dalgacık enerjilerini öznitelik vektörleri olarak kullanarak, seyreklik sınıflandırıcısı modeli ile sınıflandırmıştır. Bu metodoloji ile %91,48'lik ortalama doğruluk elde etti. Pfurtscheller ve ark. (2009) OY olan hastaların sağ el, sol el ve ayak hareketlerinin motor hayalinin EEG ile görüntülenmesini araştırdılar. Sonuç olarak, Ortak Uzaysal Desenler (OUD) öznitelikleri ve Doğrusal Diskriminant Analizi (DDA) makine öğrenmesi algoritması kullanmıştır. Mohseni ve ark. (2020) bir k-EYK sınıflandırıcı kullanarak beş farklı üst ekstremite hareketini sınıflandırmışlar ve ortalama %94'lük bir sınıflandırma doğruluğu elde etmişlerdir. Ofner ve ark. (2017), düşük frekanslı (< 3 Hz) motor hayali içeren EEG sinyallerinin zaman alanında tek üst ekstremite hareketlerinin kodlanmasını analiz etmiştir. Dirsek fleksiyonu, dirsek ekstansiyonu, önkol pronasyonu, önkol supinasyonu, el açık ve el kapalı olmak üzere altı sınıf hareket uygulamışlardır. Bir DDA sınıflandırıcısı kullanarak ve 15 sağlıklı denek ile yaklaşık %27'lik bir ortalama doğruluk elde etmişlerdir. Ofner ve ark. (2019) el açık, önkol pronasyonu, önkol supinasyonu, palmar kavrama ve lateral kavrama ile servikal OY'li 10 hastayı incelemişlerdir. Düşük frekanslı (<3 Hz) motor hayali EEG sinyallerinden beş sınıflı fonksiyonel hareketlerin kodunu çözmek için bir DDA sınıflandırıcı kullanıldığında ise, %45'lik bir ortalama sınıflandırma doğruluk oranı elde etmişlerdir.

Gerçek operasyonel ortamlarda yaygın EEG gürültülerinden (kas aktivitesi, göz kırpma, göz hareketi ve çevresel gürültü vb.) kaynaklanan yetersiz performans, bilgisayar odaklı teoride kalan sinirbilim araştırmalarının pratikteki BCI uygulamalarına geçişini hâlâ engellemektedir. Bu problemlere çözüm olarak kullanılan Bağımsız Bileşen Analizi (BBA/ICA) beyin sinyallerini artefaktlardan ayırmak için yaygın olarak kullanılan bir yöntemdir (Wang ve Jung, 2012; Dev ve ark., 2022). Görevle ilgili Bağımsız Bileşen (BB) dinamiklerini değerlendirmek için makine öğrenimi algoritmalarının uygulanması, bilişsel durumları tahmin etmekte EEG tabanlı BCI'ların performansını önemli derecede artırdığı kanıtlanmıştır (Kavuri ve ark., 2018; Sai ve ark., 2018; Kang ve ark., 2022; Cao ve Slobounov, 2010; Agarwal ve Zubair, 2021; Khoshnevis ve Sankar, 2020). Örneğin; Cao ve ark. (2010)'nın yaptığı çalışmada travmatik beyin yaralanması geçiren insanlar üzerinden alınan EEG sinyalleri analiz edilirken, Agarwal ve ark. (2021)'nin yaptığı çalışmada alkolik ve alkol kullanmayan insanların beyin aktiviteleri BBA kullanılarak sınıflandırılmaya çalışılmıştır. Bununla birlikte, çoğu BCI'nın yüksek performansla çalışması, bu ilgilenilen BB'lerin ve ardından BBA'nın seçilmesinde manuel müdahale gerektirmektedir. Bu süreçte ilk olarak, mevcut BBA tabanlı modellerin çoğu önceden tanımlanmış bir BB kullanmaktadır. Karmaşık insan davranışlarını sezgisel olarak karakterize etmek için görevle ilgili beyin süreçlerini birleştirmek, yalnızca birkaç belirli sinyal kullanmaktan daha makul bir yöntem olarak karşımıza çıkmaktadır. İkinci olarak, BB'lerin sırası belirlenmemektedir. Bu nedenle, BBA gerçekleştirildikten sonra otomatik bir BB seçim yöntemi gerekmektedir. Üçüncüsü ise, ölçülen EEG sinyallerindeki durağan

olmama hali, BBA analizinden farklı sonuçlar üretebilmektedir. Diğer deneklerden elde edilen BB'ler büyük ölçüde değişebilmektedir. Yani, bazı BB'ler bir öznenin kayıtlarında bulunurken diğerlerinde bulunmama olasılığı belirlemektedir. Yalnızca bir veya iki belirli BB kullanan çoğu BBA tabanlı BCI sistemi, elde edilen BB'lerin hiçbiri hedeflenen BB'lerle eşleşmezse başarısız olmaktadır. Bu sorunları çözmek için, bu çalışma, BBA tabanlı BCI sistemine çoklu sınıflandırıcılı bir modelin dahil edilmesini önermektedir.

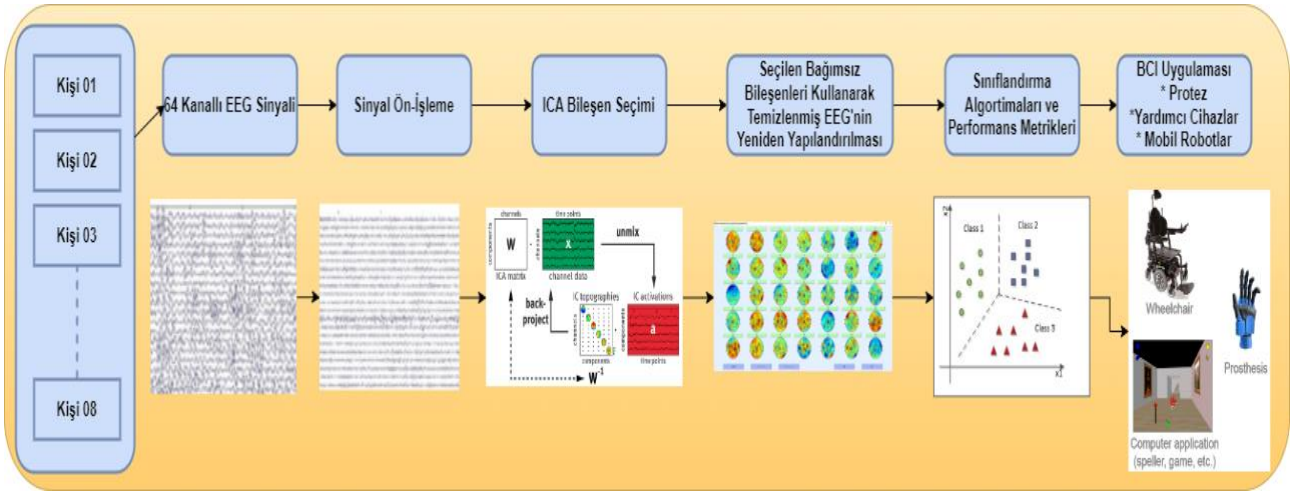
Ayrıca, literatürde BBA kullanılarak yapılan çalışmaların çoğu sağlıklı bireylerden alınan EEG sinyalleri olup OY'lı bireylerden alınan sinyallerle yapılan çalışmalar oldukça kısıtlı olarak karşımıza çıkmaktadır. Diğer taraftan ikili ve üçlü sınıflandırmalar dışında çoklu komut içeren EEG tabanlı BCI çalışmalarındaki tahmin doğruluğunun artırılması için yenilikçi yöntemlere ihtiyaç duyulmaktadır. Özellikle üç ve daha fazla sınıfı yüksek doğrulukla ayırt eden örüntü tanıma algoritmaları ile ilgili çalışmalar çok azdır. Bu nedenlerden dolayı, bu çalışmada, OY hastalarında EEG ile ölçülen beyin aktivitesindeki fonksiyonel değişikliklerin bilinen makine öğrenmesi yöntemleri kullanılarak yüksek doğrulukta sınıflandırılması hedeflenmiştir. Bu hedef doğrultusunda özellikle 5 (beş) görev sınıflandırma problemlerinde yüksek doğrulukla kullanılabilir bir yöntem önerilmektedir.

## 2. Materyal ve Yöntem

Önerilen yöntem temel olarak dört adımdan oluşmaktadır:

- (i) MATLAB programı kullanılarak EEG sinyallerinin ön işlenmesi,
- (ii) BBA yöntemi uygulanarak OY'lı insanların EEG sinyallerinden BB'lerin hesaplanması,
- (iii) Pronasyon, supinasyon, avuç içi kavrama, yanal kavrama ve el açık hareketleri düşündürülerek kaydedilen EEG sinyallerinin yaygın kullanılan makine öğrenmesi modelleri ile sınıflandırılması,
- (iv) Sınıflandırmada kullanılan makine öğrenme modellerini değerlendirme metriklerinin hesaplanması ve tüm sinyal işleme süresinin kaydedilmesi.

Adımların akış şeması Şekil 1'de gösterilmektedir.

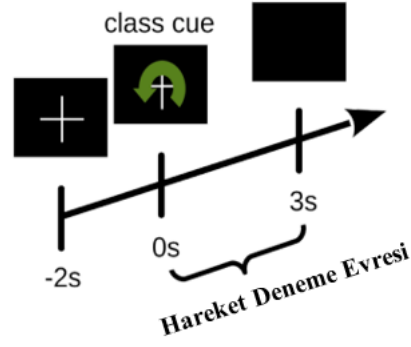


Şekil 1. Bağımsız Bileşen Analizi (ICA/BBA) kullanılarak önerilen yöntembilimin akış şeması

## 2.1. Veri seti tanımlama


Bu çalışma, Ofner ve ark. (2019)'nın açık erişimli “Attempted arm and hand movements in persons with spinal cord injury” veri setini incelemektedir (Ofner ve ark., 2019). Veri seti, her biri 5 farklı el hareketi deneyen, yaşları 20 ila 59 arasında değişen 10 katılımcıdan elde edilen verileri içermektedir. Bu hareketler: pronasyon, supinasyon, palmar kavrama, yan kavrama ve el açmadır. EEG'yi frontal, santral, parietal ve temporal alanları kapsayan 61 elektrotla ölçmektedirler. Ayrıca burun çevresi göz altına yerleştirilen 3 elektrot ile elektrookülogramı (EOG) ölçülmüştür. Sinyaller, dört adet 16 kanallı g.USBamps biyosinyal amplifikatörü ve bir g.GAMMAsys/g.LADYbird aktif elektrot sistemi (g.tec Medical Engineering GmbH, Avusturya) kullanılarak kaydedilmiştir. Sinyaller 256 Hz'de örneklenmiş ve 0,01 Hz ile 100 Hz arasında değişen bir bant geçiren (8. dereceden Chebyshev filtresi) filtre uygulanmıştır. Güç hattındaki paraziti bastırmak için bir çentik filtresi (50 Hz) uygulanmıştır. Kaydedilen veriler GDF Formatında (Biyosinyaller için Genel Veri Formatı) saklanmıştır.

Katılımcıların her biri bilgisayar ekranının önüne, kollarını kucağındaki yastığa ya da masaya dayayarak oturmaktadırlar ve bilgisayar ekranında verilen talimatları yerine getirmektedirler. Deneme başlangıcında, bir sabitleme çaprazı ve bir bip sesi sunulmaktadır. Katılımcılara Şekil 2’de gösterilen deney ekranına odaklanmaları ve göz hareketlerinden kaçınmak için 5 saniyelik tüm deneme süresi boyunca görüntülenen çapraz işarete bakışlarını odaklamaları istenilmektedir. Ayrıca, katılımcılara deneme süresi boyunca yutkunmaktan ve göz kırpmaktan kaçınmaları talimatını verilmektedir. Hayal edilmesi istenen hareketlerin (pronasyon, supinasyon, avuç içi kavrama, yanal kavrama veya el açık) sınıf işareti, deneme başladıktan 2 saniye sonra 3 saniye boyunca (yani denemenin sonuna kadar) gösterilmektedir.



**Şekil 2.** Deneme dizisinde -2'de bip sesiyle birlikte bir toplama işareti belirdi; 0'da sınıf işareti sunuldu ve katılımcılar ilgili hareketi yapmayı hayal etti. Denemenin ardından rastgele 1 ila 3 saniyelik bir ara verildi.

Katılımcılar bir hareketi gerçekleştirebilmişlerse, deneme süresinden sonra ilk konumlarına geri dönmektedirler. Her bir hareket için 8 deneme olacak şekilde toplamda 40 deneme kaydedilmiştir. Farklı zamanlarda bu çalışma 9 kez tekrar edilmiştir. Sonuç olarak, sınıf başına toplam 72 deneme yapılmıştır. Hareket hayali ve dinlenme durumuyla ilgili süreler sırasıyla 65 saniye ve 70 saniye sürdü. Katılımcılardan toplanan orijinal veriler, gereksiz bilgilerin ortadan kaldırılması için işlendi. Sonuçta elde edilen veriler 64 satır ve 77123 sütundan oluşan bir matrisin değerleri olarak kullanıldı.



**Şekil 3.** P01 katılımcısının 64 kanalın tümü için ham EEG sinyali zaman domeni grafiği (y-ekseni “voltaj ( $\mu\text{V}$ )” – x-ekseni “zaman (sn.)”).

## 2.2. Bağımsız Bileşen Analizi (BBA) ile öznitelik çıkarımı

Bağımsız Bileşen Analizi (BBA), çok değişkenli EEG verilerini istatistiksel olarak bağımsız, Gauss olmayan bileşenlerine ayrıştırmak için yaygın olarak kabul edilen bir araç olarak literatürde karşımıza çıkmaktadır. EEG sinyallerini kaynak bileşenlerine ayrıştırmak için kullanılmaktadır.

Maksimum düzeyde bağımsız bileşenleri çıkarmak için entropiyi maksimize eden Infomax BBA (Bell ve Sejnowski, 1995), EEG sinyallerini bağımsız bileşenlere (BB'lere / IC'lere) ayırtmak için kullanılmaktadır. Genişletilmiş Infomax BBA (ICA) yöntemi ise, Infomax ayrışımının bir uzantısı olarak, bileşenler arasındaki karşılıklı bilgiyi en aza indirerek ve ortak entropilerini en üst düzeye çıkararak kaynakların Gauss altı ve süper Gauss dağılımını ayırmaktadır. Bu çalışmada sunulan Infomax algoritması, varsayılan ayarlarıyla MATLAB programı kullanılarak EEGLAB araç kutusunun runica komutu kullanılarak uygulanmıştır. Bu bölüm, istatistiksel olarak bağımsız bileşenleri elde etmek için genişletilmiş infomax BBA ayrıştırma yöntemini ve yapay BB'leri tanımayla yönelik işaretleri açıklamaktadır.


İlk olarak EEG sinyalleri denklem (1) ve (2)'ye göre ayrıştırılır:

$$X_{mxn} = A_{mxm} Y_{mxn} \quad (1)$$

$$Y_{mxn} = W_{mxm} X_{mxn} \quad (2)$$

Burada X, kaydedilen EEG sinyalidir, A, tam sütun sırasına sahip karıştırma matrisidir, Y, EEG sinyallerindeki BB'leri veya kaynakları temsil etmektedir, W, A'nın ters matrisidir ve m ve n, EEG kanallarının ve zaman çerçevelerinin sayısını temsil etmektedir. Göz hareketi, kas hareketi ve elektrik hattı gürültüsü (Demir ve ark., 2022; Chaumon ve ark., 2015) ile güçlü bir şekilde ilişkili olan gürültü BB'leri manuel olarak seçilmektedir. Gürültü BB'leri EEGLAB (Delorme ve Makeig, 2004) kılavuzu ile kolayca belirlenmektedir. Buna ek olarak çıkarılan topografi görüntüleri ile de BB'lerde hangi kanalda aktivasyonun düşük veya yüksek olduğu Şekil 4'te sunulduğu gibi tespit edilebilmektedir. Bu şekilde görülen renk kodları, kırmızı renkli olan bölgeler aktivasyonun en yüksek seviyede seyrettiği ve mavi renkli bölgeler ise aktivasyonun en düşük seviyelerde tespit edildiği bölgeler olarak yorumlanmaktadır. Arada kalan renkler ise sırasıyla sıcak renklerden (kırmızı) soğuk renklere (mavi) geçiş sırasıyla aktivasyon oranını ifade etmektedir. Her bir kanaldan alınan bu topografiler ile verilen göreve bağlı olarak beynin hangi bölgesinin ve/veya lobunun diğerlerine kıyasla daha aktif ve kullanılabilir olduğu bilgisine ulaşılmaktadır. Bu durumdan EEG çalışmalarında kullanılacak minimum kanal sayısı ile beyin bilgisayar arayüzü tasarlama çalışmalarında efektif olarak faydalanılmaktadır. Veri analizi sırasında da veri işleme süresi kısıllacağından gerçek-zamanlı çalışmalar için daha uygun bir yaklaşım olarak karşımıza çıkmaktadır.






Şekil 4. Bağımsız bileşen analizi öncesi beyin aktivasyonu haritalama.

Öznitelik çıkarımı için bileşen alanı, EEG verilerinin BBA kullanılarak ayrıştırılmasından ve gürültü BB'lerinin çıkarılmasından sonra elde edilen BB'lerdir. Örneğin, bileşen uzayında, yeni BB'ler seçim ve çaprazlama işlemi ile üretilmektedir. Yeniden yapılandırılmış EEG sinyalleri, önerilen BBA öznitelik çıkarımı prosedürlerini açıklamaktadır. Tablo 1, önerilen yöntemin tüm hesaplamalarını göstermektedir. Her deneme için gürültü ve temiz BB'ler belirlendikten sonra, eğitim verilerinin etiketine göre her sınıfın yalnızca temiz BB'leri toplanır. Birikmiş BB'ler arasındaki seçim, bağımsızlığa dayalı olarak yapılır. Bu nedenle, yeni BB oluşturmak için her sınıftan BB'ler ortak bilgiye (Papana ve Kugiumtzis, 2009) dayalı olarak sıralanmaktadır. BB'leri seçmek için, Denklem (3) kullanılarak her sınıftaki BB'ler için ortalama karşılıklı bilgiler hesaplanmakta ve bunlar artan düzende sıralanmaktadır. Buna göre BB'ler seçilmektedir. Seçilen BB'ler Şekil 5'te 64 kanallı EEG bileşenleri için sunulmaktadır.





Şekil 5. 64-kanallı EEG sinyalinden çıkarılan Bağımsız Bileşenler (IC / BB).

Ortak bilgi matrisinde  $I(X; Y)$  iki ayrık değişken  $X$  ve  $Y$  şu şekilde tanımlanabilir:

$$I(X; Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left( \frac{p(x, y)}{p(x)p(y)} \right) \quad (3)$$

Burada  $p(x, y)$ ,  $X$  ve  $Y$ 'nin ortak olasılık fonksiyonudur ve  $p(x)$  ve  $p(y)$ , sırasıyla  $X$  ve  $Y$ 'nin marjinal olasılık dağılım fonksiyonlarıdır. Bileşen uzayındaki seçim sürecinin algoritması, Tablo 1'de gösterilmektedir.

**Tablo 1.** Öznitelik çıkarmak için bağımsız bileşen seçimi algoritması.

Bağımsız Bileşen Seçim Algoritması	
1.	$BB$ : Bağımsız bileşen
2.	$D \leftarrow$ Her sınıftaki bileşen sayısı
3.	$K \leftarrow$ Her sınıftan seçilen bileşen sayısı
4.	$[D \times D]$ sıfır matris olan ortak bilgi (MI) matrisi $L$ 'yi başlat
5.	for $i \leftarrow D$ do
6.	for $j \leftarrow D$ do $\setminus j = i+1$
7.	$L(i, j) = MI ( BB(i), BB(j) )$ (Denklem (3))'e göre MI hesapla
8.	$L(j, i) = L(i, j)$
9.	end for
10.	$A(i) = \frac{1}{D} \sum_{k=1}^D L(i, k)$
11.	end for
12.	$A$ artan düzende sıralanır.
13.	Sıralanan $A$ 'dan ilk- $K$ bileşenlerini seçin:

## 2.3. Sınıflandırma modelleri ve performans metrikleri

Bu çalışmada kullanılan sınıflandırma modelleri ve performans metriklerinin ölçülmesinde MATLAB programı Classification Learner araç kutusu kullanılmıştır. EEG verilerinin kaydedildiği 64 kanalın tamamı makine öğrenmesi modellerinde kullanılmıştır. Sınıflandırıcı modellerinin parametreleri varsayılan değerler üzerinden karşılaştırmalı olarak değerlendirilip, seçilmiştir.

### 2.3.1. Makine öğrenmesi modelleri

#### 2.3.1.1. Destek Vektör Makinesi (DVM)

Hem sınıflandırma hem de regresyon çalışmalarında yaygın olarak kullanılan başarılı bir yaklaşım olan Destek Vektör Makinesi (DVM), denetimli bir makine öğrenimi algoritmasıdır. Verileri sınıflandırmak için, en iyi sınıflandırma performansının gerçekleştirilebileceği hiper düzlem bulundurmaktadır. Veri, hiper düzlemin hangi tarafına düştüğüne bağlı olarak o sınıfın elemanı olarak tanımlanır (Bascil ve ark., 2016). Bu çalışmada, Kernel Radyal Tabanlı Fonksiyon (RBF) kullanan DVM kullanılmıştır.

#### 2.3.1.2. k-En Yakın Komşuluk (k-EYK)

Örüntü tanıma tekniği sınıfına ait olan k-En Yakın Komşuluk (k-EYK) sınıflandırması, parametrik olmayan, uzaklık hesabı temelli bir öğrenme modelidir. Veri seti, eğitim seti ve test seti olmak üzere iki gruba ayrılır ve eğitim setindeki bilgiler kullanılarak öğrenme işlemi gerçekleştirilir. İlk olarak sınıflandırılması gereken örnek ile tüm eğitim veri seti arasındaki mesafe belirlenir. Bir sonraki adım, en kısa mesafeye sahip en yakın “k” adet komşuyu belirlemektir. Son olarak, yeni örneğin sınıfı, bu k en yakın komşunun sınıfları arasından en yaygın olanı olarak belirlenir (Suyal ve Goyal, 2022). k-En Yakın Komşuluk sınıflandırıcısı için k değeri sırasıyla 3-10 aralığında değerler ile denenmiştir. Bu çalışmada sınıflandırıcı olarak en yakın 5 komşu k-EYK seçilmiştir. Uzaklık hesabı için Euclidean metriği kullanılmıştır.

#### 2.3.1.3. AdaBoost

AdaBoost algoritması, sürekli eğitim yoluyla veri sınıflandırma yeteneğini geliştiren basit bir zayıf sınıflandırma algoritması iyileştirme sürecidir. Eğitim örnekleri öğrenilerek ilk zayıf sınıflandırıcı elde edilir ve yanlış örnekler eğitimsiz verilerle birleştirilerek yeni bir eğitim örneği

oluşturulur. Ayrıca bu örnek öğrenilerek ikinci zayıf sınıflandırıcı elde edilmektedir. Yanlış örnek, üçüncü zayıf sınıflandırıcıyı elde etmek için eğitilebilecek başka bir yeni eğitim örneği oluşturmak için eğitilmemiş verilerle birleştirilir. Bu işlemi birçok kez tekrarladıktan sonra, sonunda geliştirilmiş sağlam sınıflandırıcı elde edilmektedir. Doğru sınıflandırma sayısını artırmak için AdaBoost algoritması örneklere farklı ağırlıklar vermektedir. Doğru sınıflandırılan örneklere nispeten düşük ağırlıklar verilir ve yanlış olanların artırılması gerekir, bu da modeli yanlış sınıflandırılan örneklere daha fazla dikkat etmeye zorlamaktadır. Her bir temel ağaç modelini eğitirken, veri setindeki her örneğin ağırlık dağılımının ayarlanması gerekmektedir. Her eğitim verisi değişeceği için eğitim sonuçları da farklı olacaktır ve son olarak tüm sonuçlar toplanmaktadır (Schapire, 2013).

#### **2.3.1.4 Karar ağacı (KA)**

Karar ağacı (KA), girdi verilerine dayalı kararlar vermek için akış şeması benzeri bir yapı kullanan tahmine dayalı bir modeldir. Karar ağacı, karar desteğinde kullanılan, kararları ve bunların potansiyel sonuçlarını, şans ihtimallerini, kaynak harcamalarını ve faydayı içeren hiyerarşik bir modeldir. Bu algoritmik model, koşullu kontrol ifadelerini kullanır ve parametrik değildir, denetimli öğrenmedir hem sınıflandırma hem de regresyon görevleri için yararlıdır. Ağaç yapısı, hiyerarşik, ağaç benzeri bir yapı oluşturan bir kök düğüm, dallar, iç düğümler ve yaprak düğümlerden oluşmaktadır (Kotsiantis, 2013).

#### **2.3.2. Makine öğrenmesi modellerini değerlendirme**

Bu çalışmada, makine öğrenmesi modellerinin başarımlarını değerlendirmek için literatürde de yaygın kullanılan hata matrisi ve k-katlamalı çapraz doğrulama yöntemleri kullanılmıştır.

##### **2.3.2.1. K- katlamalı çapraz doğrulama**

Doğrusal bir model için tipik bir K-katlamalı çapraz doğrulama prosedüründe, veri seti rastgele ve eşit şekilde K parçaya bölünür. Eğitim seti adı verilen veri setinin K - 1 parçasına dayalı olarak bir aday model oluşturulur. Bu aday modelin tahmin doğruluğu daha sonra uzatma kısmındaki (kalan 1'deki) verileri içeren bir test setinde değerlendirilir. Sırasıyla K parçalarının her birini test seti olarak kullanarak ve model oluşturma ve değerlendirme prosedürünü tekrarlayarak, en küçük çapraz doğrulama puanına sahip modeli (tipik olarak ortalama kare tahmin hatası (MSPE)) 'optimal' model olarak seçilir. p bağımsız değişken verildiğinde, toplam  $2^p - 1$  olası model vardır. K-katlamalı çapraz doğrulama prosedüründe, her model aslında K kez değerlendirilir. Bu nedenle, model

değerlendirmesinin  $K (2^p - 1)$  katı aracılığıyla tek bir 'optimal' model seçilir (Jung, 2018; Wong ve Yeh, 2020). Bu çalışmada  $K$  değeri 5 seçilmiştir.

### 2.3.2.2. Hata matrisi

Makine öğrenmesi model başarımını değerlendirmek için öncelikle hata matrisi hesaplanmaktadır. Hata matrisi her bir sınıflandırma algoritmasının test kümesine verdiği cevapların veri setindeki gerçek değerlerle karşılaştırılması ile oluşturulur. İki-sınıflı problemlerde dört farklı durumdan oluşan hata matrisi Tablo 2’de gösterildiği şekildedir (Ohsaki ve ark., 2017):

**Tablo 2.** İki sınıflı örüntü tanıma problemi için hata matrisi.

Tahmin edilen	Gerçekte olan	
	Pozitif	Negatif
Pozitif	True Positive	False Positive
Negatif	False Negative	True Negative

• Doğruya doğru (True Positive - TP) • Doğruya yanlış (True Negative - TN) • Yanlışsa doğru (False Positive - FP) • Yanlışsa yanlış (False Negative - FN) Bu değerlere bağlı olarak sınıflandırıcı performansı olarak doğruluk değeri hesaplanır:

$$Geri \text{ çağırma} = \frac{TP}{FN+TP} \quad (4)$$

$$Özgüllük (Spec) = \frac{TN}{FP+TN} \quad (5)$$

$$Hassasiyet (Prec) = \frac{TP}{TP+FP} \quad (6)$$

$$Doğruluk (CA) = \frac{TP+TN}{TP+FP+TN+FN} \quad (7)$$

$$F1 - Skor (F1) = \frac{2*Prec*Geri \text{ çağırma}}{Prec+Geri \text{ çağırma}} \quad (8)$$

### 3. Bulgular ve Tartışma

Bu çalışmada, önerilen yöntemi test etmek ve matematiksel sonuçlarıyla bir EEG analizi gerçekleştirebilmek için, ilk olarak sinyal normalizasyonu ve artefakt eliminasyonu EEGLAB üzerinden gerçekleştirilmiştir. Yüksek geçişli filtre ve alçak geçişli filtre için tipik ayarlar sırasıyla 0,5-1 Hz ve 35-70 Hz olarak ayarlanmıştır. Yüksek geçişli filtre tipik olarak elektro galvanik sinyaller ve hareket artefaktları gibi yavaş artefaktları filtrelerken, alçak geçişli filtre elektromiyografi sinyalleri gibi yüksek frekanslı artefaktları filtrelemektedir. Ek bir çentik filtresi olarak elektrik güç hatlarının (50 Hz) neden olduğu artefaktı gidermek için Notch filtre kullanılmıştır. Elimine edilen

gürültü ve diğer bozuculardan arınan sinyal üzerinde bağımsız bileşen analizi (BBA) “runICA” algoritması ile MATLAB programı üzerinden EEGLAB araç kutusu kullanılarak yapılmıştır (Delorme ve Makeig, 2004). Bağımsız bileşenler (BB’ler), Şekil 4’te gösterildiği üzere 64 kanal ve her bir katılımcı için çıkarılmıştır. Öznitelik olarak kullanılacak olan bileşenler Tablo 1’de anlatılan ve bu amaçla ilk defa kullanılan seçim algoritması ile değerlendirilip seçilmiştir. Toplamda 10 katılımcı ve 5 farklı görev için çoklu sınıflandırma yöntemi ile motor görevlerin ayırt ediciliği test edilmiştir. Sınıflandırmada kullanılan makine öğrenmesi modelleri ve değerlendirme metrikleri MATLAB programı “Classification Learner” uygulaması üzerinden modellerin algoritmasında parametreler varsayılan olarak seçilerek gerçekleştirilmiştir. Sınıflandırma sonuçları aşağıda sırasıyla Tablo 3’ten Tablo 6’ya kadar her bir makine öğrenmesi algoritması ve tüm katılımcılar için sunulmaktadır.

Tablo 3’te DVM makine öğrenmesi modeli kullanılarak elde edilen sonuçlar verilmektedir. Bu sonuçlara göre, katılımcılar kendi aralarında değerlendirildiğinde en yüksek başarımlar 0.991 doğruluk değeri ile P05 katılımcısına aittir. Bu performans hem DVM modeli için hem de diğer modeller arasında en yüksek sınıflandırma sonucunu vermektedir. Bütün katılımcıların ortalaması alındığında ise elde edilen sonuç  $0.9024 \pm 0.0781$  olmaktadır. Genel ortalamaya bakarak DVM modeli için en yüksek başarıma sahip sınıflandırıcı olarak adlandırabiliriz. Toplam model süreleri açısından irdelendiğinde DVM modelinin 4.262 sn eğitim ve 2.523 sn test süresi ile en kısa 3. sonuç veren algoritma olduğu tespit edilmiştir.

**Tablo 3.** DVM kullanılarak elde edilen model performans sonuçları.

	CA	F1	Prec	Spec
P01	0.869	0.869	0.873	0.967
P02	0.981	0.981	0.982	0.995
P03	0.931	0.931	0.932	0.983
P04	0.941	0.941	0.941	0.985
P05	0.991	0.991	0.991	0.998
P06	0.875	0.875	0.878	0.969
P07	0.884	0.885	0.889	0.971
P08	0.747	0.748	0.759	0.937
Ort.±	$0.9024 \pm$	$0.9026 \pm$	$0.9056 \pm$	$0.9756 \pm$
Std.	0.0781	0.0778	0.0743	0.0195

Katılımcı ortalamaları incelendiğinde DVM modelinden sonra ikinci en yüksek başarıma sahip olan model, k-EYK modeli olarak karşımıza çıkmaktadır. k-EYK modeli  $0.8582 \pm 0.0985$  doğruluk

performansı göstermektedir. Ayrıca Tablo 7 incelendiğinde k-EYK modelinin eğitim ve test sürelerinin diğerlerine kıyasla en kısa zamanda sonuç verdiği görülmektedir. Algoritmanın hesaplama süresi gerçek zamanlı BCI uygulamalarında kritik bir öneme sahip olduğundan performans metrikleri kadar sürenin de model seçimini etkileyen bir faktör olduğu yadsınamaz bir gerçektir.

**Tablo 4.** K-EYK kullanılarak elde edilen model performans sonuçları.

	CA	F1	Prec	Spec
P01	0.853	0.853	0.857	0.963
P02	0.950	0.951	0.954	0.988
P03	0.884	0.885	0.887	0.971
P04	0.922	0.922	0.924	0.980
P05	0.994	0.994	0.994	0.998
P06	0.803	0.803	0.806	0.951
P07	0.716	0.718	0.722	0.929
P08	0.744	0.746	0.758	0.936
Ort. $\pm$	0.8582 $\pm$	0.8590 $\pm$	0.8628 $\pm$	0.9645 $\pm$
Std.	0.0985	0.0980	0.0956	0.0245

Tablo 5'te verilen AdaBoost modelinin sonuçları irdelendiğinde kişi bazında elde edilen bazı performanslar yüksek olmakla birlikte (P05  $\leftrightarrow$  0.909), genel ortalama (0.7924  $\pm$  0.0937) bazında diğer üç yöntemden de düşük sonuçlar verdiği görülmektedir. Bu modelden elde ettiğimiz sonuçlara göre önerilen modelin kişiselleştirilmiş bir EEG tabanlı BCI sisteminde kullanılması daha uygundur. AdaBoost modelini eğitim ve test süresi (eğitim  $\leftrightarrow$  2.559 sn, test  $\leftrightarrow$  1.287 sn açısından değerlendirdiğimizde ise modelin ikinci en kısa sürede sonuç veren algoritma olduğunu görmekteyiz. Bu da pratik BCI kullanımı için uygun algoritmalar arasında olduğunu kanıtlamaktadır.

**Tablo 5.** AdaBoost kullanılarak elde edilen model performans sonuçları.

	CA	F1	Prec	Spec
P01	0.762	0.762	0.768	0.941
P02	0.891	0.891	0.892	0.973
P03	0.787	0.787	0.789	0.947
P04	0.887	0.888	0.888	0.972
P05	0.909	0.909	0.911	0.977
P06	0.747	0.747	0.747	0.937
P07	0.678	0.677	0.678	0.920



P08	0.678	0.680	0.684	0.920
Ort.±	0.7924±	0.7926±	0.7946±	0.9484±
Std.	0.0937	0.0937	0.0930	0.2323

Dördüncü model olan karar ağaçları (KA) algoritmasının sonuçları ise Tablo 6’da sunulmuştur. Bu modelin diğerlerinden farklı olarak en yüksek başarımı P02 katılımcısında 0.894 doğruluk değeri ile elde edilmiştir.

Bütün modeller arasında 3. en yüksek değeri veren algoritmadır. Ancak zaman bakımından incelendiğinde KA modelinin 7.418 sn eğitim ve 3.678 sn test süresi ile en uzun sürede sonuç veren algoritma olduğu tespit edilmiştir. Dolayısıyla KA algoritmasının BCI uygulamaları için pratik bir model olmadığı belirtilebilir.

**Tablo 6.** Karar Ağaçları kullanılarak elde edilen model performans sonuçları.


	CA	F1	Prec	Spec
P01	0.759	0.759	0.761	0.940
P02	0.894	0.894	0.895	0.973
P03	0.747	0.746	0.749	0.937
P04	0.866	0.867	0.870	0.966
P05	0.884	0.885	0.886	0.971
P06	0.806	0.805	0.805	0.952
P07	0.784	0.783	0.783	0.946
P08	0.731	0.733	0.737	0.933
Ort.±	0.8089±	0.8090±	0.8108±	0.9522±
Std.	0.0645	0.0647	0.0641	0.0158

**Tablo 7.** Makine öğrenmesi modellerinin eğitim ve test için kullandıkları toplam süre (saniye-sn).

Model	Eğitim	Test
DVM	4.262	2.523
k-EYK	1.753	1.221
AdaBoost	2.559	1.287
KA	7.418	3.678

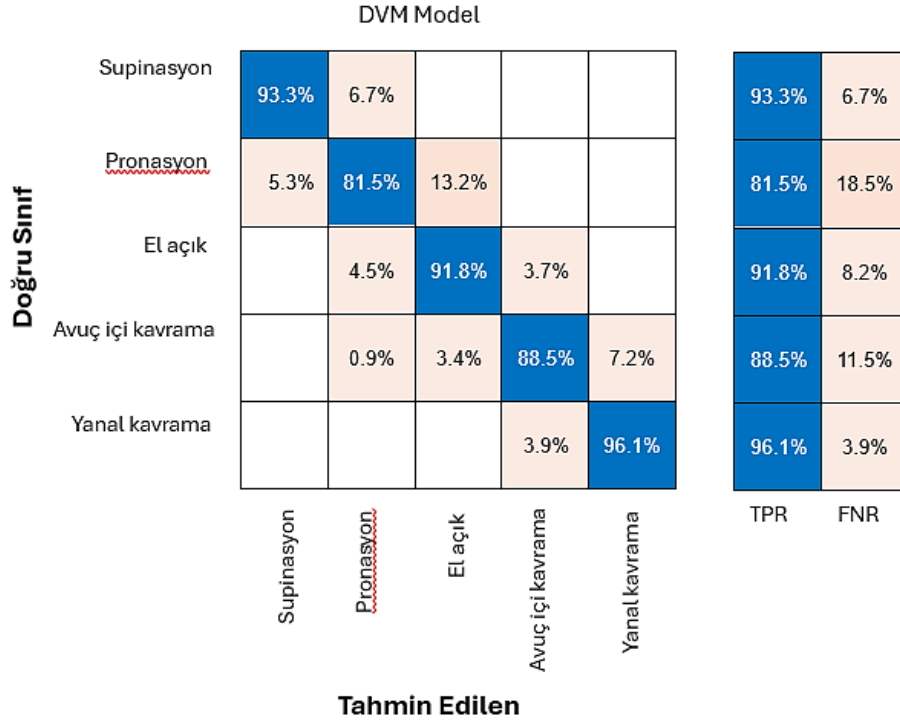
Şekil 6’da bu çalışmada kullanılan her bir makine öğrenmesi modelinin grafiksel olarak alıcı işletim karakteristiği (ROC) eğrileri verilmiştir. Bu grafik, farklı sınırlama eşikleri altında duyarlılık ve özgüllük arasındaki ilişkiyi göstermektedir. DVM, k-EYK, AdaBoost ve KA modellerinin farklı duyarlılık ve özgüllük değerlerinde nasıl performans gösterdiğini görsel olarak anlaşılır kılmaktadır. Aynı zamanda makine

öğrenmesi modellerinin doğru sınıflandırma yeteneğini ve yanlış sınıflandırma oranlarını değerlendirmek veya optimize etmek için rehberlik sağlamaktadır. Bu sonuçlara göre performanslar sırasıyla şu şekilde karşımıza çıkmaktadır: DVM, k-EYK, AdaBoost ve KA. Tablolarda elde edilen sonuçlardan farklı olarak ROC eğrisi ile gösterilmek istenen AdaBoost modelinin KA modelinden TP ve FP oranlarına göre daha başarılı performans gösterdiği görülmüştür.



**Şekil 6.** Farklı makine öğrenimi modelleri için ROC eğrisi.

Makine öğrenmesi modellerinin doğru sınıflandırma yeteneğini ve yanlış sınıflandırma oranlarını değerlendirmek veya optimize etmek için Doğru-Pozitif ve Yanlış-Negatif oranlarını inceleyebildiğimiz bir diğer kriter olan karmaşıklık matrisi de Şekil 7’de sunulmaktadır. Karmaşıklık matrisi bize aynı zamanda sınıfların doğru tahmin edilme oranını da karşılaştırmalı olarak göstermektedir. Şekil 7’de bu çalışma kapsamında kullanılan makine öğrenmesi modellerinden en yüksek sonucun elde edildiği DVM modelinde sınıfların TPR (Doğru-Pozitif Oranı) ve FNR (Yanlış-Negatif Oranı) başarı oranlarını karmaşıklık matrisi kullanılarak belirtilmiştir. Diğer makine öğrenmesi modellerinde de benzer sonuçlar elde edildiği için sadece DVM modelinin karmaşıklık matrisi verilmiştir. Ayrıca sınıflandırılan el hareketleri arasında “yanal kavrama” görevinin en başarılı sınıflandırma sonucunu verdiği tespit edilmiştir. İkinci başarılı performans olarak “süpinasyon” görevi ve sırasıyla “el açık”, “avuç içi kavrama” ve “pronasyon” görevleri takip etmektedir.



Şekil 7. En başarılı makine öğrenmesi modelinin karmaşıklık matrisi (DVM 90.24%)

Bu araştırma analizinden çıkarılan başarımların performansları literatürde aynı veri setini kullanarak elde edilen sonuçlar ile Tablo 8’de karşılaştırılmıştır. Çalışmalarda kullanılan performansı doğrudan etkileyen öznelik ve makine öğrenmesi modelleri üzerinden doğruluk değerleri baz alınarak değerlendirme yapılmıştır. Bu değerlendirme sonucunda beş sınıf kullanılarak yapılan sınıflandırma çalışmaları arasında uygulanan metodoloji ile en yüksek başarımlar bu çalışmaya aittir.

Tablo 8. Literatürde mevcut aynı veri setini kullanarak yapılan çalışmalar ve elde edilen en yüksek sonuçlar.

Öznelik Çıkarımı	Sınıflandırıcı	Doğruluk Değeri (%)	Referans
—	Katz’s Fractal Dimension (KFD) + DVM	96.47 (2-sınıf)	Akman Aydın, E. 2023
Standart Sapma	1D CNN+LSTM model	75.75 (5-sınıf)	Makouei, S.T.Z. ve ark. 2023
Movement-Related Cortical Potentials (MRCP)	ConvNet AlexNet	76.00 (5-sınıf)	Cancino, S. ve ark. 2023
Dalgacık Paketi, Decomposition (WPD)	Wavelet neural network	85.24 (5-sınıf)	Zhou, X. ve ark. 2021
—	Temporal-Spatial Convolutional Iterative Residual Network)TSCIR-Net	71.11 (5-sınıf)	Mirzabagherian, H. ve ark. 2023
<b>Bağımsız Bileşenlerde Ortak Bilgi Matrisi</b>	<b>DVM</b>	<b>90.24 (5-sınıf)</b>	<b>Bu çalışma</b>

#### 4. Sonular ve neriler

Bu alıřmada temel hedef omurilik yaralanması geiren insanların bařlıca tedavi yntemi olan rehabilitasyon iin EEG tabanlı bir beyin bilgisayar arayz tasarımı gerekleřtirmektir. Bu hedef doėrutusunda kullanılan yntemler oklu sınıflandırma bařarımlarının dřk olması sebebiyle arařtırılmaya devam etmektedir. BCI alıřmalarında genellikle OY'lı insanlardan veri toplamanın zorluklarından dolayı genellikle saėlıklı insanlardan alınan veriler zerinde alıřılmaktadır. Ancak bu alıřmada amacına uygun olarak aık eriřimli OY hastalarına ait EEG veri seti zerinde alıřılmıřtır. BCI alıřmalarında karřılařılan bir diėer zorluk olan oklu komut retmek iin gereken oklu sınıflandırma sonularının henz dřk performanslar gstermesidir. Ancak bu alıřma ile grlmektedir ki, BB bileřenleri temelli znitelik ıkarımı ve DVM ile sınıflandırılması sonucu OY hastalarından alınan EEG verileri  $0.9024 \pm 0.0781$  deėerinde bir bařarım ortaya koymaktadır. Bu sınıflandırma bařarımı řans oranı 0.20 olan beř grevi sınıflandırma problemi olarak dřnldėnde oldukça yksek bir deėerdir. Bunun yanı sıra diėer uygulanan makine ėrenmesi yntemleri de kayda deėer doėrulukta bařarım gstermektedirler. Gerek zamanlı BCI uygulamaları iin nemli olan bir diėer lt ise sinyal iřleme ve kontrol komutu retme sresidir. Dolayısıyla uygulanan makine ėrenmesi algoritmaları aısından sreler karřılařtırıldığında en kısa srede 1.753 ile k-EYK algoritması sonu vermektedir.

Sonu olarak BB ıkarma ve ilk defa znitelik olarak kullanma yaklařımıyla oluřturulan yntembilim yksek doėrulukta sonular retmektedir. Dolayısıyla bu da ideal EEG tabanlı BCI tasarımı iin uygun bir metodolojisi olduėunu kanıtlanmaktadır.

#### Arařtırma ve Yayın Etiėi Beyanı

Yapılan alıřmada arařtırma ve yayın etiėine uyulmuřtur.

#### Kaynaklar

- Agarwal, S., Zubair, M. (2021). Classification of Alcoholic and Non-Alcoholic EEG Signals based on Sliding-SSA and Independent Component Analysis. *IEEE Sensors Journal*, 21(23), 26198-26206. doi: 10.1109/JSEN.2021.3120885
- Akman Aydın, E. (2023). Detection of Movement Related Cortical Potentials from Single Trial EEG Signals. *Gazi University Journal of Science Part C: Design and Technology*, 11(1): 25-38. doi: 10.29109/gujsc.1083912
- Athanasiou, A., Klados, M. A., Pandria, N., Foroglou, N., Kavazidi, K. R., Polyzoidis, K., Bamidis, P. D. (2012). A Systematic Review of Investigations into Functional Brain Connectivity Following Spinal Cord Injury. *Frontiers in Human Neuroscience*, 11, 517. doi: 10.3389/fnhum.2017.00517
- Bascil, M. S., Tesneli, A. Y., Temurtas, F. (2016). Spectral Feature Extraction of EEG Signals and Pattern Recognition During Mental Tasks of 2-D Cursor Movements for BCI Using SVM and ANN.

- Australasian Physical and Engineering Sciences in Medicine*, 39, 665–676. doi: 10.1007/s13246-016-0462-x
- Bell, A. J., Sejnowski, T. J. (1995). An Information-Maximization Approach to Blind Separation and Blind Deconvolution. *Neural Computation*, 7(6), 1129–1159.
- Cancino, S., López, J. M., Delgado Saa, J. F., Schettini, N. (2023). ConvNets for Electroencephalographic Decoding of Attempted Arm and Hand Movements of People with Spinal Cord Injury. *Advanced Intelligent System*, 5(12): 2023. doi: 10.1002/aisy.202300094
- Cao, C., Slobounov, S. (2010). Alteration of Cortical Functional Connectivity As A Result of Traumatic Brain Injury Revealed by Graph Theory, ICA, and sLORETA Analyses of EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18(1), 11-19. doi: 10.1109/TNSRE.2009.2027704
- Chaudhary, S., Taran, S., Bajaj, V., Siuly, S. (2020). A Flexible Analytic Wavelet Transform Based Approach For Motor-Imagery Tasks Classification In BCI Applications. *Computer Methods and Programs in Biomedicine*, 187(2020), 105325. doi: 10.1016/j.cmpb.2020.105325
- Chaumon, M., Bishop, D. V., Busch, N. A. (2015). A Practical Guide to The Selection of Independent Components of The Electroencephalogram for Artifact Correction. *Journal of Neuroscience Methods*, 250, 47–63.
- Demir, A., Bekiryazıcı, Ş., Coşkun, O., Eken, R., Yılmaz, G. (2022). Detection and Analysis of Driver Fatigue Stages with EEG Signals. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 28(5), 643-651.
- Delorme, A., Makeig, S. (2004). EEGLAB: An Open-Source Toolbox for Analysis of Single-Trial EEG Dynamics Including Independent Component Analysis. *Journal of Neuroscience Methods*, 134(1), 9–21.
- Dev, A., ve ark. (2022). Exploration of EEG-Based Depression Biomarkers Identification Techniques and Their Applications: A Systematic Review. *IEEE Access*, 10, 16756-16781. doi: 10.1109/ACCESS.2022.3146711
- Hernandez-Rojas, L. G., ve ark. (2022). Brain-Computer Interface Controlled Functional Electrical Stimulation: Evaluation with Healthy Subjects and Spinal Cord Injury Patients. *IEEE Access*, 10, 46834-46852. doi: 10.1109/ACCESS.2022.3170906
- Jung, Y. (2018). Multiple Predicting k-Fold Cross-Validation for Model Selection. *Journal of Nonparametric Statistics*, 30(1), 197-215. doi: 10.1080/10485252.2017.1404598
- Kang, J. S., Kavuri, S., Lee, M. (2022). ICA-Evolution Based Data Augmentation with Ensemble Deep Neural Networks Using Time and Frequency Kernels for Emotion Recognition from EEG-Data. *IEEE Transactions on Affective Computing*, 13(2), 616-627. doi: 10.1109/TAFFC.2019.2942587
- Kang, Y., Ding, H., Zhou, H., Wei, Z., Liu, L., Pan, D. Y., Feng, S. Q. (2018). Epidemiology of Worldwide Spinal Cord Injury: A Literature Review. *Neurorestoratology*, 6, 1–9. doi: 10.2147/jn.s143236
- Kavuri, S. S., Veluvolu, K. C., Chai, Q. H. (2018). Evolutionary Based ICA with Reference for EEG  $\mu$  Rhythm Extraction. *IEEE Access*, 6, 19702-19713. doi: 10.1109/ACCESS.2018.2821838
- Khoshnevis, S. A., Sankar, R. (2020). Applications of Higher Order Statistics in Electroencephalography Signal Processing: A Comprehensive Survey. *IEEE Reviews in Biomedical Engineering*, 13, 169-183. doi: 10.1109/RBME.2019.2951328
- Kotsiantis, S. B. (2013). Decision Trees: A Recent Overview. *Artif Intell Rev*, 39, 261–283. doi: 10.1007/s10462-011-9272-4
- Leite, V. F., deSouza, D. R., Imamura, M., Batistella, L. R. (2019). Post-discharge Mortality in Patients with Traumatic Spinal Cord Injury in A Brazilian Hospital: A Retrospective Cohort. *Spinal Cord*, 57, 134–140. doi: 10.1038/s41393-018-0183-y
- Liu, J., Yang, X., Jiang, L., Wang, C., Yang, M. (2012). Neural Plasticity After Spinal Cord Injury. *Neural Regeneration Research*, 7, 386–391.
- Makouei, S.T.Z., Uyulan, Ç. (2023). Classification of the Attempted Arm and Hand Movements of Patients with Spinal Cord Injury Using Deep Learning Approach. doi: 10.1101/2023.07.06.23292320
- Mirzabagherian, H., Menhaj, M. B., Suratgar, A. A., Talebi, N., Abbasi Sardari, M. R., Sajedin, A. (2023). Temporal-Spatial Convolutional Residual Network for Decoding Attempted Movement Related EEG Signals of Subjects with Spinal Cord Injury. *Computers in Biology and Medicine*, 164(2023), 107159. doi: 10.1016/j.compbiomed.2023.107159
- Mohseni, M., Shalchyan, V., Jochumsen, M., Niazi, I. K. (2020). Upper Limb Complex Movements Decoding from Pre-Movement EEG Signals Using Wavelet Common Spatial Patterns. *Computer Methods and Programs in Biomedicine*, 183 (2020), 105076. doi: 10.1016/j.cmpb.2019.105076

- Nam, K. Y., Kim, H. J., Kwon, B. S., Park, J. W., Lee, H. J., Yoo, A. (2017). Robot-Assisted Gait Training (Lokomat) Improves Walking Function and Activity in People with Spinal Cord Injury: A Systematic Review. *Journal of NeuroEngineering and Rehabilitation*, 14(1), 24.
- Ohsaki, M., Wang, P., Matsuda, K., Katagiri, S., Watanabe, H., Ralescu, A. (2017). Confusion-Matrix-based Kernel Logistic Regression for Imbalanced Data Classification. *IEEE Transactions on Knowledge and Data Engineering*, 29(9), 1806-1819. doi: 10.1109/TKDE.2017.2682249
- Ofner, P., Schwarz, A., Pereira, J., ve ark. (2019). Attempted Arm and Hand Movements Can Be Decoded from Low-Frequency EEG from Persons with Spinal Cord Injury. *Scientific Reports*, 9, 7134. doi: 10.1038/s41598-019-43594-9
- Ofner, P., Schwarz, A., Pereira, J., Muller-Putz, G. R. (2017). Upper Limb Movements Can Be Decoded from The Time-Domain of Low-Frequency EEG. *PLoS One*, 12 (2017), e0182578. doi: 10.1371/journal.pone.0182578
- Papana, A., Kugiumtzis, D. (2009). Evaluation of Mutual Information Estimators for Time Series. *International Journal of Bifurcation and Chaos*, 19(12), 4197–4215.
- Pfurtscheller, G., Linortner, P., Winkler, R., Korisek, G., Muller-Putz G. (2009). Discrimination of Motor Imagery-Induced EEG Patterns in Patients with Complete Spinal Cord Injury. *Computational Intelligence and Neuroscience*, 104180. doi: 10.1155/2009/104180
- Sai, C. Y., Mokhtar, N., Arof, H., Cumming, P., Iwashashi, M. (2018). Automated Classification and Removal of EEG Artifacts with SVM and Wavelet-ICA. *IEEE Journal of Biomedical and Health Informatics*, 22(3), 664-670. doi: 10.1109/JBHI.2017.2723420
- Sayilgan, E., Yuce, Y. K., Isler, Y. (2021). Evaluation of Mother Wavelets on Steady-State Visually-Evoked Potentials for Triple-Command Brain-Computer Interfaces. *Turkish Journal of Electrical Engineering and Computer Sciences*, 29(5), 2263-2279.
- Sayilgan, E., Yüce, Y., İşler, Y. (2021). Uyarım Frekansının Kestiriminde İstatistiksel Anlamlılığa Dayalı Olarak Seçilen Durağan Durum Görsel Uyarılmış Potansiyellere Ait Dalgacık Özniteliklerinin Değerlendirilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 593-606. doi: 10.17341/gazimmfd.664583
- Sayilgan, E., Yuce, Y. K., Isler, Y. (2022). Investigating The Effect of Flickering Frequency Pair and Mother Wavelet Selection in Steady-State Visually-Evoked Potentials on Two-Command Brain-Computer Interfaces. *Innovation and Research in BioMedical engineering*, 43(6), 594-603. doi: 10.1016/j.irbm.2022.04.006
- Schapire, R. E. (2013). *Explaining AdaBoost*. Editors: Schölkopf B, Luo Z, Vovk V. Empirical Inference. Berlin, Heidelberg, Springer. doi: 10.1007/978-3-642-41136-6\_5
- Schlogl, A., Lee, F., Bischof, H., Pfurtscheller, G. (2005). Characterization of Four-Class Motor Imagery EEG Data for The BCI-Competition 2005. *Journal of Neural Engineering*, 2 (2005): L14–22. doi: 10.1088/1741-2560/2/4/L02
- Simis, M., Uygur-Kucukseymen, E., Pacheco-Barrrios, K., Battistella, L. R., Fregni, F. (2020). Beta-Band Oscillations As A Biomarker of Gait Recovery in Spinal Cord Injury Patients: A Quantitative Electroencephalography Analysis. *Clinical Neurophysiology*, 131, 1806–1814.
- Sreeja, S.R., Samanta, D. (2019). Classification of Multiclass Motor Imagery EEG Signal Using Sparsity Approach. *Neurocomputing*, 368 (2019): 133–145. doi: 10.1016/j.neucom.2019.08.037
- Suyal, M., Goyal, P. (2022). A Review on Analysis of k-Nearest Neighbor Classification Machine Learning Algorithms Based on Supervised Learning. *International Journal of Engineering Trends and Technology*, 70(7), 43-48. doi: 10.14445/22315381/IJETT-V70I7P205
- Wang, T., Deng, J., He, B. (2004). Classifying EEG-Based Motor Imagery Tasks By Means Of Time-Frequency Synthesized Spatial Patterns. *Clinical Neurophysiology*, 115 : 2744–2753. doi: 10.1016/j.clinph.2004.06.022
- Wang, Y., Jung, T. P. (2012). *Improving Brain-Computer Interfaces Using Independent Component Analysis*. In: Allison, B., Dunne, S., Leeb, R., Del R. Millán, J., Nijholt, A. (eds) Towards Practical Brain-Computer Interfaces. Biological and Medical Physics, Biomedical Engineering. Berlin, Heidelberg, Springer. doi: 10.1007/978-3-642-29746-5\_4
- Wong, T. T., Yeh, P. Y. (2020). Reliable Accuracy Estimates from k-Fold Cross Validation. *IEEE Transactions on Knowledge and Data Engineering*, 32(8), 1586-1594. doi: 10.1109/TKDE.2019.2912815
- Zhou, X., Zou, R., Huang, X. (2021). Single Upper Limb Functional Movements Decoding from Motor Imagery EEG Signals Using Wavelet Neural Network. *Biomedical Signal Processing and Control*, 70(2021), 102965. doi: 10.1016/j.bspc.2021.102965