

# EEG+YKS Tabanlı Beyin Bilgisayar Arayüzü Sistemlerinde Makine Öğrenme Tekniklerinin Kullanımına İlişkin İnceleme

## Research on the Use of Machine Learning Techniques in EEG+YKS-Based Brain Computer Interface Systems

 Ebru Ergün<sup>1</sup>,  Önder Aydemir<sup>2</sup>,  Onur Erdem Korkmaz<sup>3</sup>

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

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

<sup>3</sup>Elektrik-Elektronik Mühendisliği Bölümü, Atatürk Üniversitesi, Erzurum, Türkiye  
onurerdem.korkmaz@atauni.edu.tr

### Özet

Beyin-bilgisayar arayüzü (BBA), kişinin beyin aktivitesini algılayan ve bu aktiviteyi bir bilgisayar veya diğer dış cihazlarla iletişim kurmak için kullanılabilir bir formata çeviren sistemdir. BBA sistemleri için çeşitli beyin görüntüleme teknikleri, giriş işareti olarak kullanılmaktadır. Diğer alternatiflere göre birçok avantajı olmasından dolayı elektroensefalografi (EEG), BBA sistemlerinde sıkça tercih edilmektedir. Ancak, sadece EEG kullanarak yapılan çalışmalar, BBA sistemlerinin performansını tatmin edici bir seviyeye yükseltememiştir. Son yıllarda, beyin görüntüleme yöntemlerinin kendilerine özgü avantaj ve dezavantajlarından ötürü farklı sinyal kayıt yöntemlerini bir araya getirerek kullanma eğilimi artmıştır. Bu çalışmada, EEG+yakın kızılötesi spektroskopisi (YKS) tabanlı BBA sistemlerinde makine öğrenme tekniklerinin kullanımına ilişkin yapılan mevcut araştırmaların bir incelemesi sunulmaktadır. Öncelikle, EEG ve YKS sinyallerinin tekli nasıl kullanıldığı ve daha sonra bu iki sinyalin nasıl hibrit BBA sistemlerinde bir araya getirildiği ilgili literatürle sunulmuştur. Çalışmalar incelendiğinde, hibrit BBA ile EEG'ye göre sınıflandırma doğruluğu ortalama %7.58, YKS'ye göre ise %13.04 artış hesaplanmıştır. Ulaşılan sonuç, hibrit BBA sistemlerinin insan-makine etkileşimini iyileştirmeye önemli katkılar sağlayacağını göstermektedir.

**Anahtar Kelimeler:** Hibrit, Elektroensefalografi, Yakın Kızılötesi Spektroskopisi, Beyin Bilgisayar Arayüzü, Sınıflandırma, Öznitelik Çıkarma

### Abstract

A brain-computer interface (BCI) is a system that detects a person's brain activity and translates this activity into a usable format for communicating with a computer or other external devices. Various neuroimaging techniques are used as input

signals for BCI systems. Electroencephalography (EEG) is frequently preferred in BCI systems because it has many advantages over other alternatives. However, studies using only EEG have not been able to increase the performance of BCI systems to a satisfactory level. In recent years, there has been an increased tendency to combine different signal recording methods due to the unique advantages and disadvantages of brain imaging methods. In this study, a review of current research on the use of machine learning techniques in EEG+near-infrared spectroscopy (YKS) based BCI systems is presented. First of all, how single EEG and YKS signals are used and then how these two signals are combined in hybrid BCI systems are presented with the relevant literature. When the studies were examined, an average increase of 7.58% in classification accuracy was calculated with hybrid BCI compared to EEG and 13.04% compared to YKS. The result shows that hybrid BCI systems will make significant contributions to improving human-machine interaction.

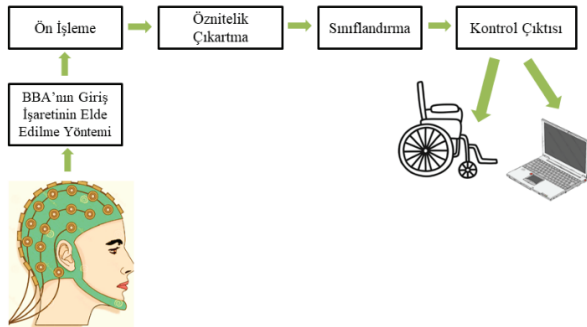
**Keywords:** Hybrid, Electroencephalography, Near Infrared Spectroscopy, Brain Computer Interface, Classification, Feature Extraction

### 1. Giriş

Beyin bilgisayar arayüzü (BBA), beyin ile bilgisayar arasında iletişim kurmayı sağlayan bir sistemdir [1]. BBA, beyinden gelen elektriksel sinyalleri algılayarak bunları bilgisayar sistemlerine dönüştürür ve kullanıcının beyin aktivitesini bilgisayar tarafından anlaşılabilir bir formata çevirmesine olanak tanır. BBA, genellikle Şekil 1'de yer alan ana bloklardan oluşur [2]. Bunlardan ilki beyin sinyallerinin alındığı kısımdır. Bu kısımda beyin aktivitesini ölçmek için sensörler veya elektrotlar kullanılır. Elektroensefalografi (EEG), yakın kızılötesi spektroskopisi (YKS), elektrokortikografi (ECoG), magnetoensefalografi (MEG), fonksiyonel manyetik

görüntüleme ve pozitron emisyon tomografisi gibi yöntemler beyin sinyallerini kaydetme yöntemlerinden bazılarıdır [3]. İkinci kısımda beyinden kaydedilen sinyallerin ön işleme ve filtrelemelerinin yapıldığı bloğa geçilir. Bu blok, sinyalleri düzeltmek, arka plan gürültüsünü azaltmak ve istenmeyen bileşenleri filtrelemek için işlemler yapar. Örneğin, sinyaller düşük frekanslı gürültüden arındırılabilir veya hareket artefaktları giderilebilir. Üçüncü kısım ise öznelik çıkarım bloğudur. Öznelik çıkarım bloğu, işlenmiş beyin sinyallerinden anlamlı özneliklerin çıkarılmasını sağlar. Bu blok, sinyalleri analiz ederek kullanıcının niyetlerini, düşüncelerini veya isteklerini yansıtan belirli örüntü tanımlar. Dördüncü blok sınıflandırma veya tahmin işlemlerinin yapıldığı bloktur. Bu blokta sınıflandırma algoritmaları ile kullanıcının niyeti veya düşüncesi belirlenmeye çalışılır. Son kısım ise kontrol çıktısı bloğudur. Bu blok, kullanıcıya beyin aktivitesine dayalı bir geri bildirim sunar. Örneğin, bir görüntü, ses veya titreşim geri bildirim sağlanabilir. Bu geri bildirim, kullanıcının beyin sinyallerini anlamasını ve kontrol etmesini kolaylaştırır.

Son yıllarda, BBA teknolojileri hızla gelişse de hala istenilen seviyeye ulaşmadığı literatürde yer alan çalışmalardan anlaşılmaktadır [4]. Bu durum araştırmacıları daha yüksek performanslı BBA çalışmaları için yeni yöntemler arayışına yöneltmiştir. Son yıllarda, bu yeni yöntemler arasında BBA sisteminin giriş işareti olarak hibrit beyin görüntüleme tekniği kullanma eğilimi artmıştır. Hibrit (multimodal) BBA, birden fazla beyin görüntüleme yöntemini kullanarak beyin aktivitesini ölçen bir sistemdir [5]. Bu tür bir arayüz, beyin sinyallerini algılamak için birden çok görüntüleme yöntemini (örneğin, EEG, fMRI, ECoG) birleştirir ve farklı duyuşal veya motor tepkileri sağlamak için çeşitli geri bildirim yöntemlerini kullanır. Multimodal BBA sistemi, daha fazla hassasiyet, doğruluk ve kullanılabilirlik sağlamak için geliştirilmeye devam etmektedir.




Şekil 1. Beyin bilgisayar arayüzü ana blokları

## 2. Temel Bilgiler

### 2.1. Elektroensefalografi

EEG, beyindeki elektriksel aktivitenin kaydedilmesi ve analiz edilmesi için kullanılan bir yöntemdir [6]. Beyindeki sinir hücrelerinin elektriksel aktiviteleri sonucunda oluşur. Sinir hücreleri veya nöronlar, bilgiyi elektriksel sinyaller halinde ileten ve iletişim kuran özelleşmiş hücrelerdir. Beyinde milyarlarca nöron bulunur ve bu nöronlar arasındaki etkileşimler elektriksel sinyallerin oluşmasına neden olur. Beyin hücreleri arasındaki iletişim, nöronların hücre zarlarındaki iyon akışlarıyla gerçekleşir. Hücre zarının iç ve dış kısımları arasında iyon konsantrasyonları farklıdır ve bu fark, bir elektrik potansiyeli oluşturur [7]. Bu potansiyel, "aksiyon potansiyeli" adı verilen

elektriksel bir uyarı şeklinde iletilir. Bir nöron uyarıldığında, hücre zarındaki iyon kanalları açılır ve iyonlar hücre zarı boyunca geçerken potansiyel değişir. Bu değişim, nöronun elektriksel aktivitesini temsil eden bir aksiyon potansiyeli olarak adlandırılır. EEG sinyalleri, elektrotlar aracılığıyla beyin yüzeyindeki elektriksel aktiviteyi ölçerken bu aksiyon potansiyellerini algılar. Elektrotlar, beyin yüzeyine yerleştirilen ve hücre zarındaki potansiyel değişikliklerini algılamak için kullanılan metal elektrotlardır. Beyin hücrelerinin elektriksel aktivitesi, elektrotlardan alınan sinyallere yansır ve amplifikatörler aracılığıyla güçlendirilir. EEG, beyindeki farklı nöron gruplarının senkronize elektriksel aktivitelerini topluca ölçer. Bu nedenle, kaydedilen EEG sinyali, genellikle birleşik bir sinyal olarak ifade edilir. EEG sinyali, belirli frekans aralıklarında ritmik desenler olarak gözlemlenebilir. Bu desenler, beyin dalgaları olarak adlandırılır ve belirli frekans bantlarına ayrılır [8]. Bazı yaygın beyin dalgaları beta, alfa, teta ve deltadır ve Şekil 2'de gösterilmiştir. Bunlar arasında beta dalgaları yüksek frekanslı (13-30 Hz) beyin dalgalarıdır. Uyanıklık, dikkat, konsantrasyon ve zihinsel aktivite ile ilişkilidir. Alfa dalgaları orta frekanslı (8-12 Hz) beyin dalgalarıdır. Dinlenme, gevşeme ve gözlerin kapatılmasıyla ilişkilidir. Teta dalgaları ise düşük frekanslı (4-7 Hz) beyin dalgalarıdır. Uykunun hafif aşamaları, rüyalar ve meditasyon ile ilişkilidir. Son olarak, delta dalgaları çok düşük frekanslı (0.5-4 Hz) beyin dalgalarıdır. Derin uyku aşamaları, restoratif dinlenme ve bazı nörolojik bozukluklarla ilişkilidir [9].



Şekil 2. EEG verileri için frekans bant aralıkları

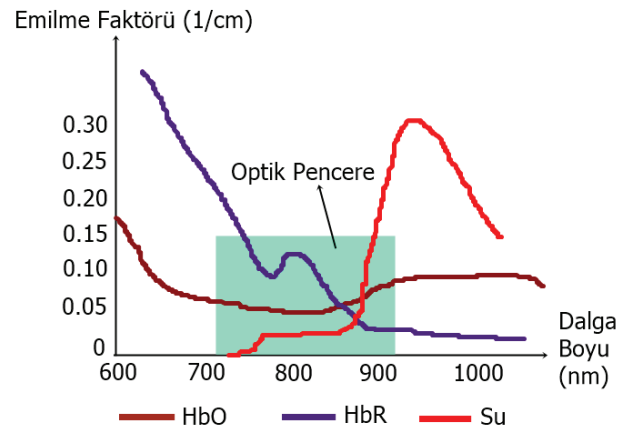
EEG sinyalleri, beyin aktivitesini yansıtan elektriksel bir ölçüm sağlar ve bu ölçümler, beyin fonksiyonlarını incelemek, beyin aktivitesiyle ilişkili bozuklukları tanımlamak ve nörolojik araştırmalar için değerli bir kaynak olarak kullanılır. EEG, BBA sisteminin giriş işareti olarak en yaygın olarak kullanılan beyin görüntüleme tekniğidir. Bu amaçla literatürde 2 sınıflı veya çok sınıflı EEG tabanlı BBA işaretlerini sınıflandırıcı çalışmalar mevcuttur. Bunlar arasında Çai ve arkadaşları çalışmalarında sol, sağ ve ileri tekerlekli sandalye hareketi hayaline dayalı EEG veri kümesi ile çalışmışlardır. Veri kümesinden güç spektral yoğunluğu (GSY) tabanlı öznelikler çıkartmışlar ve çıkarılan öznelikleri yapay sinir ağları ile sınıflandırmışlardır. En iyi ikili sınıflandırma ile %85 sınıflandırma doğruluğuna (SD) ulaşmışlardır [10]. Verma ve arkadaşları çalışmalarında BCI Yarışması III veri kümesi ile ilgilenmişlerdir. Sağ el-sağ ayak hareketi hayaline faydalı EEG veri kümesinden ayırık dalgacık dönüşümü (ADD) tabanlı öznelikler çıkartmışlar ve bu öznelikleri en küçük kareler destek vektör makineleri (DVM) ile sınıflandırarak %99.40 SD'ye ulaşmışlardır [11]. Bhatti ve arkadaşları ise BCI Yarışması IV veri kümesi ile çalışmışlardır. Sağ-sol el, ayak ve dil motor hareketi hayaline dayalı 4 sınıflı veri kümesinden ortak uzamsal örüntü (OUÖ) tabanlı öznelikler çıkartmışlardır. Çıkarılan öznelikler DVM ile sınıflandırarak %90.57'lik SD hesaplamışlardır [12]. Bagh ve arkadaşlarının

yaptığı EEG tabanlı çalışmada ise BCI yarışma III veri kümesi analiz edilmiştir. Burada Hilbert Dönüşümü kullanılarak sağ-sol el, ayak ve dil tabanlı motor hareketi hayaline dayalı veri kümesinden öznitelikler çıkarılmıştır. Çıkarılan öznitelikler ise DVM ile sınıflandırılarak 4 sınıf için %86.11 SD hesaplamışlardır [13]. Wang ve Sourina 10 kişiden kaydedilmiş 14 kanallı zihinsel aritmetik tabanlı kaydedilen EEG veri kümesi ile çalışmışlardır. Veri kümesinden GSY, istatistiksel ve Higuchi fraktal boyut spektrumu (HFBS) tabanlı öznitelikler çıkartarak bu öznitelikleri DVM ile sınıflandırmışlardır. HFBS tabanlı öznitelikler ile en iyi sonuca ulaşarak her bir kanal için %69.42 ile %84.15 arasında SD hesaplamışlardır [14]. Yi ve arkadaşları sol/sağ el, ayaklar motor hareketi hayaline (MHH) dayalı veri kümesinden OUÖ tabanlı öznitelikler çıkartmışlar ve bunları DVM ile sınıflandırarak %84 SD elde etmişlerdir [15]. Başka bir EEG ile yapılan çalışmada ise Dokare ve arkadaşları sağ ve sol el MHH dayalı veri kümesi ile çalışarak %78.57'lik SD'ye ulaşmışlardır. Burada EEG işaretlerinden ADD tabanlı öznitelikler çıkartmışlar ve öznitelikleri DVM ile sınıflandırmışlardır [16]. Lindig-Leon ve arkadaşları ise çalışmalarında sağ-sol el, iki el MHH dayalı ve dinlenmek tabanlı EEG verileri ile çalışmışlardır. İşaretten OUÖ tabanlı öznitelikler çıkartmışlar ve bu öznitelikleri doğrusal ayırım analizi (DAA) ile sınıflandırarak %51.67 SD hesaplamışlardır [17].

## 2.2. Yakın Kızılötesi Spektroskopisi

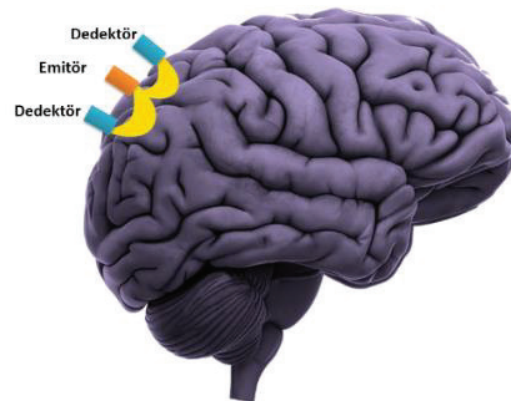
Yakın kızılötesi (YK), elektromanyetik spektrumun kızılötesi bölgesinde yer alan bir ışık türüdür. Kızılötesi ışık, insan gözü tarafından algılanamaz, ancak bazı özel cihazlarla görülebilir hale getirilebilir. Bu ışık, elektromanyetik spektrumun görünür ışık bölgesinin hemen ötesinde yer alır. Yaklaşık 700 nanometreden (nm) başlayarak 2.500 nm'ye kadar olan dalga boylarını kapsar. YK ışık, termal ışınım ve moleküler titreşimlerden kaynaklanır [18]. YKS, YK ışığın maddelerle etkileşimini kullanarak maddelerin kimyasal yapısını ve özelliklerini inceleyen bir analiz yöntemidir. Bu yöntemde, bir YK ışık kaynağı, bir örnek üzerine yönlendirilir ve örneğin yansımaları, absorpsiyonu veya saçılması ölçülerek spektrum elde edilir. YKS, elektromanyetik spektrumun YK bölgesindeki dalga boylarının kullanılmasına dayanır. Bu bölgedeki ışık, maddenin kimyasal bağlarındaki titreşimlerden kaynaklanan enerji emilim ve yansıma olaylarına neden olur. Her bir molekülün kendine özgü bir titreşim spektrumu vardır ve bu spektrum, örneğin içinde bulunan kimyasal bileşenlerin tanımlanması ve miktarlarının belirlenmesi gibi bilgileri sağlar. YKS birçok farklı uygulama alanında kullanılmaktadır. Örneğin, kimyasal analizde bu yöntem, birçok kimyasal bileşimin tanımlanması, niceliksel analizi ve kalite kontrolü için kullanılır. Gıda endüstrisinde, ilaç endüstrisinde, petrokimya alanında ve diğer kimyasal süreçlerde kullanılabilir. Diğer bir kullanım yeri ise tarım ve gıda sektörüdür. Tarım ürünlerinin kalite kontrolü, olgunluk seviyelerinin belirlenmesi, nem içeriğinin ölçümü ve diğer tarımsal uygulamalarda YKS kullanılır. Buna ek olarak ilaç endüstrisinde kullanılmaktadır. İlaç üretiminde, etken madde analizi, formülasyon kontrolü ve saflık tespiti gibi amaçlarla YKS kullanılır. Diğer bir önemli kullanıldığı yer ise biyomedikal araştırmalar alanıdır. YKS, biyolojik dokularda oksijenlenme düzeyini ve doku metabolizmasını ölçmek, kan analizi yapmak, kanser teşhisinde kullanılan tümör sınıflandırması gibi alanlarda kullanılır. YKS, acı vermeyen, hızlı ve hassas bir analiz yöntemi olarak bilinir. Özellikle örnek hazırlığına ihtiyaç duymaz ve gerçek zamanlı veri alımı sağlar. Bu nedenle birçok endüstriyel ve araştırma

alanında yaygın bir şekilde kullanılan bir analiz yöntemidir. YKS aynı zamanda son yıllarda beyin görüntüleme alanında kullanılması ile popüler olmuştur [19]. YKS, beyindeki oksijenlenme düzeylerini ve nöral aktivite ile ilişkilendirmeyi sağlar. Bu teknik, beyin dokusuna YK ışık verilmesi ve dokudan yansıyan veya geçen ışığın ölçülmesi prensibine dayanır. YKS, beyin aktivitesini ölçmek için iki temel prensibe dayanır: oksijenlenme durumunun ölçümü ve nöral aktivite ile bağlantılandırma durumudur. Oksijenlenme durumu, beyin dokusuna yönlendirilen YK ışığın dokuda absorbe edilip saçılması yoluyla belirlenir. Oksijenlenme durumu, oksijenli hemoglobin (HbO) ve deoksijenli hemoglobin (HbR) miktarının oranına dayanır ve absorpsiyon spektrumları Şekil 3'te gösterilmiştir.



Şekil 3. Optik penceredeki emilme spektrumu

Nöral aktiviteyle ilişkilendirme, bu oksijenlenme değişikliklerinin sinirsel aktivitenin bir göstergesi olması ilkesine dayanır. Şekil 4'te hemoglobin konsantrasyonlarının emilme ve saçılma yöntemiyle elde edilmesi gösterilmiştir. Burada ışık, yayıcıdan gelen kızılötesi ışık dokuyla temas ederek detektör yardımıyla kanallara veri sağlamaktadır, Burada görüldüğü gibi detektör ile ışık yayıcı arasında veri alımı sırasında yay şeklinde bir görüntü oluşmaktadır.



Şekil 4. Hemoglobin konsantrasyonlarının elde edilmesi

YKS'de modifiye edilmiş Beer-Lambert (MBL) yasası ile işaret HbR ve HbO hemoglobin konsantrasyonlarına ayrılır. MBL, Denklem 1'de verildiği gibi, optik yoğunluktaki ( $\Delta OPDE$ ) değişikliklerin, bir test koşulundan önce ve sonra ışık

zayıflamasında ölçülen bir değişiklikten hesaplanabileceğini göstermektedir.

$$\Delta OPDE = \log \frac{I_E}{I_G} = \dagger \Delta cr(dPF) \quad (1)$$

Denklem 1'de,  $I_E$  ve  $I_G$ , ilgi duyulan problem için sırasıyla ortalama baz çizgisi ve aktivasyon koşulları altında ölçülen ışık yoğunluğunu temsil etmektedir.  $I_G$ , ışığı emen bileşiğin molar konsantrasyonları için sönümleme katsayısıyla, bileşiğin konsantrasyonu ( $c$ ) ve optik yolu uzunluğuyla orantılıdır. Optik yol uzunluğu, kaynak-alıcı mesafesi ( $r$ ) ve dökülme ortamının sönümleme katsayısının bir fonksiyonu olan diferansiyel yol uzunluğu faktörü ( $dPF$ ) olarak bilinen bir çarpanın çarpımı olarak ifade edilir [20]. Işık sönümlemesindeki toplam değişiklikler, her bir emici bileşiğin katkılarından oluşan lineer bir toplam olarak ifade edilir. Çünkü serebral dokudaki YK ışığının temel emicileri HbO ve HbR'dir ve Denklem 1, Denklem 2 olarak genişletilebilir.

$$\Delta OPDE^\lambda = \{ \dagger_{HbO}^\lambda \Delta[HbO] + \dagger_{HbR}^\lambda \Delta[HbR] \} r(dPF^\lambda) \quad (2)$$

Denklem 2'de,  $\Delta OPDE^\lambda$ ,  $\lambda$  dalga boyunda optik yoğunluğu ifade eder.  $\dagger_{HbO}^\lambda$  ve  $\dagger_{HbR}^\lambda$  sırasıyla HbO ve HbR'nin  $\lambda$  dalga boyundaki sönümleme katsayılarıdır.  $dPF^\lambda$  ise  $\lambda$  dalga boyundaki yetişkin insan kafasının diferansiyel yol uzunluğu faktörüdür. Bu durumda  $\Delta[HbO]$  ve  $\Delta[HbR]$  değişiklikleri  $\lambda_1$  ve  $\lambda_2$  dalga boylarında optik yoğunluk değişikliklerini hesaplayarak belirlenebilir. Denklemler sistemi çözülerek, sırasıyla Denklem 3 ve Denklem 4 olarak verilen  $\Delta[HbO]$  ve  $\Delta[HbR]$  elde edilir.

$$\Delta[HbR] = \frac{\dagger_{HbO}^{\lambda_2} \left( \frac{\Delta OPDE^{\lambda_1}}{DPF^{\lambda_1}} \right) - \dagger_{HbO}^{\lambda_1} \left( \frac{\Delta OPDE^{\lambda_2}}{DPF^{\lambda_2}} \right)}{r(\dagger_{HbR}^{\lambda_1} \dagger_{HbO}^{\lambda_2} - \dagger_{HbR}^{\lambda_2} \dagger_{HbO}^{\lambda_1})} \quad (3)$$

$$\Delta[HbO] = \frac{\dagger_{HbR}^{\lambda_2} \left( \frac{\Delta OPDE^{\lambda_1}}{DPF^{\lambda_1}} \right) - \dagger_{HbR}^{\lambda_1} \left( \frac{\Delta OPDE^{\lambda_2}}{DPF^{\lambda_2}} \right)}{r(\dagger_{HbR}^{\lambda_2} \dagger_{HbO}^{\lambda_1} - \dagger_{HbR}^{\lambda_1} \dagger_{HbO}^{\lambda_2})} \quad (4)$$

YKS'nin bazı avantajları nedeniyle beyin görüntüleme alanında kullanımı, giderek artmaktadır. Avantajlarından biri acı vermeyen bir yöntem olmasıdır. Başın üzerine yerleştirilen problarla beyin aktivitesini ölçmek için cilde temas eden ışık kullanır [20]. Bu nedenle, cerrahi müdahale gerektirmez ve katılımcılar için rahattır. Diğer bir avantaj, gerçek zamanlı ölçüm sağlamasıdır. Anlık beyin aktivitesini izlemek için hızlı veri toplama ve analiz yeteneği sunar. YKS cihazlarının, taşınabilir ve hareket halinde kullanılabilir olması diğer avantajlarından biridir. Taşınabilir olması YKS'nin laboratuvar ortamının dışında, gerçek dünya koşullarında kullanılabilmesini sağlar. YKS ayrıca çocuklar ve bebekler için uygundur. Bu nedenle, pediatrik araştırmalarda ve klinik uygulamalarda yaygın olarak kullanılmaktadır. Araştırmacılar, literatürde şimdiye kadar farklı deneysel görev tanımlı YKS tabanlı BBA çalışmalarını ile ilgilenmişlerdir. Bunlar arasından Naseer ve arkadaşları 4

sınıflı sağ/sol MHH, mental aritmetik ve mental hesaplama tabanlı YKS verilerini kaydettiler. 10 kişiden kaydedilen veri kümesini DDA ile sınıflandırarak ortalama %73.30 SD hesapladılar [21]. Li ve arkadaşları sağ ve sol el hareketine dayalı 11 kişiden kaydedilen YKS veri kümesi ile çalıştılar. Öznitelikleri, HbO ve HbR'nin ortalamasını alarak çıkarttıktan sonra bu öznitelikleri DVM ile sınıflandırdılar. Tüm analizler sonucunda ise %85.55 SD elde etmişlerdir [22]. Tomita ve arkadaşları ise 13 kişiden kaydedilen YKS veri kümesinden HbO ve HbR'nin 1. ve 2. dereceden türevini alarak öznitelikler çıkarttılar. Çalışmalarında, ortak sınıflandırıcı kullanarak YKS işaretlerinden %85.00 SD hesapladılar [23]. Başka bir YKS tabanlı yapılan çalışmada ise Blokland ve arkadaşları parmakları ve başparmağı sürekli hareket ettirme hayaline dayalı 12 kişiden kaydedilen veri kümesi ile çalıştılar. Burada HbO ve HbR'nin ortalamasını alarak çıkarılan öznitelikleri doğrusal lojistik regresyon ile sınıflandırdılar. Sınıflandırma sonucu ortalama %65.00 SD elde ettiler [24]. Cicalese ve arkadaşları çalışmalarında dört, beş ve altı basamaklı sayıların ezberlenmesi ve görev kısmında söylenmesi tabanlı YKS verileri ile çalıştılar. 29 kişiden 4 sınıflı olarak kaydedilen veri kümesinden işaretin ortalaması tabanlı öznitelikler çıkarttılar. DAA ile çıkarılan öznitelikleri sınıflandırarak %58.62 SD elde ettiler [25].

### 2.3. Elektroensefalografi + Yakın Kızılötesi Spektroskopi


BBA sistemlerinin gelişmesi için gereken çözümlerden birisi, beyin görüntüleme tekniklerinin çoklu kullanılması, yani, bir hibrit BBA oluşturan ölçüm cihazlarının kullanılmasında yatmaktadır [26]. Hibrit BBA modelleri arasında son yıllarda EEG+YKS tabanlı sistemler önem kazanmaktadır. EEG ve YKS, beyin aktivitesini farklı ölçüm prensipleriyle algılar. EEG, elektriksel aktiviteyi algılayarak sinirsel süreçlerin zamansal özelliklerini yansıtabilirken, YKS, oksijenasyon durumu gibi metabolik süreçlerin ölçülmesinde daha etkilidir. Bu nedenle, EEG ve YKS'nin birleştirilmesi hem yüksek zamansal çözünürlük hem de yüksek mekansal çözünürlük sunan bir multimodal görüntüleme yaklaşımı sağlar. Örnek bir EEG+YKS veri kümesi kaydetme görüntüsü Şekil 5'te verilmiştir [27]. Karadeniz Teknik Üniversitesi FHD-2020-9166 nolu BAP projesi kapsamında alınan hizmet alımı ile Atatürk Üniversitesi/ Spor Bilimleri Fakültesinde kaydedilen bu örnek EEG+YKS veri kümesine ilişkin örnek görüntüleri Şekil 6, 7 ve 8'te gösterilmiştir.




Şekil 5. Örnek EEG+YKS veri kaydetme aşaması [27]

EEG+YKS veri [27] kümesinden rasgele olarak seçilmiş tek EEG denemesini Şekil 6, HbO denemesini Şekil 7, HbR denemesini ise Şekil 8 temsil etmektedir. Şekil 6'da yer alan EEG denemesi 250 Hz örnekleme frekansı ile Şekil 7 ve 8'de yer alan YKS denemeleri ise 10.17 Hz örnekleme frekansı ile kaydedilmiştir. Tüm sinyallerin uzunluğu ise 24 saniyedir ve her


bir grafikte x eksenini zaman eksenini yani örnek sayısını y eksenini ise işaretin genliğini ifade etmektedir.



Şekil 6. [27]'de kaydedilmiş EEG+YKS veri kümesinden rasgele seçilmiş örnek EEG denemesi




Şekil 7. [27]'de kaydedilmiş EEG+YKS veri kümesinden rasgele seçilmiş örnek HbO denemesi



Şekil 8. [27]'de kaydedilmiş EEG+YKS veri kümesinden rasgele seçilmiş örnek HbR denemesi

[27]'deki çalışmada 8 sekiz gönüllü bireylerden sağa (sınıf 1), sola (sınıf 2), yukarıya (sınıf 3) ve aşağıya (sınıf 4) kayan yazı okumaya dayalı EEG+YKS veri kümesi kaydedilmiştir. Deney 6 seanstan oluşmaktadır ve her seansta 20 eşzamanlı EEG ve YKS denemesi kaydedilmiştir. Her seansta 60 saniyelik bir ön dinlenme süresi ve ardından 2 saniyelik bir görev tanıtımı ile başlamıştır. Görev kısmında, bilgisayar ekranının tam ortasında

görsel uyarılarla rasgele ve eşit sayıda katılımcılara görev tanıtımı sunulmuştur. Görevlerin gerçekleştirileceği 24 saniyelik bölüm, kısa bir bip sesiyle başlamış ve sonlandırılmıştır. Her bir deneme sonrasında 10 saniyelik bir dinlenme yapılmış ve ardından bir sonraki görev tanıtımına geçilmiştir. Her bir seans, seans sonu dinleme ile sona ermiştir. Her katılımcıdan toplamda 120 deneme kaydedilmiştir. Burada, 24 saniyelik görev kısmı 2.4 saniyelik zaman dilimlerine bölünerek 1200 deneme oluşturularak veri kümesi ile analiz gerçekleştirilmiştir. EEG verileri 31 elektrot, YKS verileri de 18 elektrot ile alınmıştır. EEG+YKS veri kümesinden rasgele seçilmiş bir kişiden elde edilen örnek öznelik uzayı Şekil 9'da gösterilmiştir. Burada EEG ve YKS işaretlerinin ortalaması alınarak 1200x2 (deneme sayısı x öznelik sayısı) boyutlu öznelik uzayı oluşturulmuştur. Şekil 9'da x eksenini EEG özneliklerini, y eksenini ise YKS özneliklerini ifade etmektedir.



Şekil 9. EEG+YKS veri kümesinden çıkarılan öznelik uzayı

EEG ve YKS'nin birleştirilmesi, beyin aktivitesinin daha kapsamlı bir şekilde anlaşılmasını sağlar ve birbirini tamamlayıcı avantajlarından yararlanır [26]. Bu avantajlar şu şekilde sıralanabilir:

1. *Mekânsal ve zamansal çözünürlük dengesi:* EEG yüksek zamansal çözünürlüğe sahipken, mekânsal çözünürlükte sınırlıdır. YKS ise tam tersine, daha iyi mekânsal çözünürlüğe sahipken, zamansal çözünürlüğü daha düşüktür. Bu nedenle, EEG ve YKS'nin birleştirilmesi, hem yüksek zamansal çözünürlük hem de yüksek mekânsal çözünürlük sunarak daha ayrıntılı bir görüntüleme sağlar.
2. *Farklı beyin işlevlerini yansıtma:* EEG, sinir hücrelerinin elektriksel aktivitesini doğrudan ölçerken, YKS beyindeki metabolik süreçlerin yansımalarını değerlendirir. Bu nedenle, EEG daha çok sinirsel süreçleri, YKS ise daha çok oksijenasyon durumu gibi metabolik süreçleri yansıtır. Birlikte kullanıldıklarında hem sinirsel hem de metabolik aktivitenin birbirini tamamlayan bir resmini sunarak daha kapsamlı bir anlayış sağlarlar.
3. *Optik ve elektriksel ölçümlerin karşılıklı doğrulanması:* EEG ve YKS, farklı fiziksel ölçüm prensiplerine dayanır. EEG, elektriksel aktiviteyi doğrudan ölçerken,

YKS optik ölçümler kullanır. Bu farklı ölçüm prensipleri, birbirini tamamlayan ve karşılıklı doğrulayan bilgiler sağlar. Örneğin, YKS, kafa derisi ve kafatası üzerinden geçerken sinyal kaybına uğrayabilirken, EEG'nin daha iyi zaman çözünürlüğü vardır. Birleştirildiklerinde, bu sinyal kayıplarını telafi edebilir ve daha doğru bir beyin aktivitesi tahmini sağlayabilirler.

4. *Kombine veri analizi ve yöntemler:* EEG ve YKS'nin birleştirilmesi, verilerin kombine analizi ve işlenmesi için yeni yöntemlerin geliştirilmesini sağlar. Bu, daha iyi öznitelik çıkarımı, sınıflandırma veya tahmin modelleri, desen tanıma ve beyin haritalama gibi analiz tekniklerini içerir.

Literatürde yapılan EEG+YKS çalışmaları ayrıntılı olarak birçok açıdan incelenmiştir. Yapılan çalışmalar arasında Putze ve arkadaşları 12 kişiden çevrimdışı olarak kaydedilen EEG+YKS veri kümesi ile çalıştılar. Kayıt alırken elektrot dağılımı olarak işitsel ve görsel korteksi kullandılar. Daha sonra HbO ve HbR'nin ortalamasının farkını, EEG işaretlerinin ise bant gücünü (BG) alarak öznitelikler çıkarttılar. Çıkarılan öznitelikleri DVM ile sınıflandırarak %97.80 SD elde ettiler [28]. Koo ve arkadaşları 6 kişiden kaydedilen motor korteksten kaydedilen EEG+YKS veri kümesi ile çalıştılar. Çalışmalarında HbO'nin eşik değerini EEG işaretlerinden OUÖ tabanlı öznitelikler çıkartarak bunları DVM ile sınıflandırdılar. Sağa veya sola hareket eden ok hayali tabanlı 2 sınıflı çalışmaları için %88.00 SD hesapladılar [29]. Aghajani ve arkadaşları ise zihinsel iş yükü n-geri görev tabanlı 17 kişiden kaydedilen EEG+YKS veri kümesi ile çalışmıştır. Çalışmalarında HbO ve HbR'nin tepe, eğim, standart sapma, çarpıklık ve basıklık değerini alarak EEG'nin ise BG ve faz kilitleme değerini alarak öznitelikler çıkarttılar. Çıkarılan öznitelikleri DVM ile sınıflandırarak zihinsel yorgunluk tahmini yaptılar. 2 sınıflı bu problem için %90.90 SD hesapladılar [30]. Shin ve arkadaşları parmak hareketi hayali ve zihinsel işlem-dinlenme durumu tabanlı kaydettikleri EEG+YKS veri kümesi ile çalıştılar. 8 kişiden kaydedilen bu veri kümesinin YKS işaretlerinden eğim ve varyans tabanlı EEG işaretlerinden ise OUÖ'nün logaritmik varyansı tabanlı öznitelikler çıkarttılar. Çıkarılan öznitelikleri DAA ile sınıflandırarak %82.20 SD elde ettiler [31]. Bir başka tabanlı hibrit çalışmada ise Nour ve arkadaşları sağ ve sol el açma kapama hareketi hayali 2 sınıflı EEG+YKS veri kümesi ile çalıştılar. EEG ve YKS işaretlerinden çoklu bant genişliği analizi tabanlı öznitelikler çıkartarak bu öznitelikleri evrişimsel sinir ağları ile sınıflandırdılar. Seçim çözmeye dayalı bu çalışmadan %99.85 SD hesapladılar. [32]. Zhang ve arkadaşları ise 20 kişiden kaydettikleri dinlenmek-oturma durumu tabanlı EEG+YKS veri kümesi ile çalıştılar. HbO'nun statik ve dinamik fonksiyonel bağlantısı tabanlı EEG'nin ise küresel alan gücüne dayalı mikro durum tabanlı özniteliklerini aldılar. Çıkarılan öznitelikleri k-ortalama kümeleme ile sınıflandırarak analiz gerçekleştirdiler [33]. Ergün ve arkadaşları 8 kişiden kaydedilen EEG+YKS veri kümesi ile çalışmışlardır. Sağa, sola, yukarıya ve aşağıya kayan yazı okumaya dayalı kaydettikleri bu veri kümesinden Hilbert Dönüşümü tabanlı öznitelikler çıkartmışlardır. Çıkarılan öznitelikleri  $k$ -EYK ile sınıflandırarak 4 sınıflı bu veri kümesi için %96.28 SD'ye ulaşmışlardır [27].

Literatürdeki bu çalışmaların tamamı EEG+YKS tabanlı BBA sistemlerindeki çeşitli eksikliklerin giderilmesi konusunda başarılı ve doğru çalışmalardır. Ancak BBA sistemlerinin performansının hâlâ iyileştirilmesi gerekmektedir. Son yıllarda evrişimsel sinir ağlar (ESA) tabanlı yöntemlerin bu alana daha fazla dokunuşu BBA sistemlerinin performansı

artırmaktadır. Bunlar arasından, Chiarelli ve arkadaşları 15 kişiden kaydedilen sağ ve sol MHH tabanlı EEG+YKS veri kümesini sınıflandırmak için derin yapay sinir ağı mimarisini kullandı. 15 kişinin ortalamasını %83.28 olarak hesapladılar [34]. Rahman ve arkadaşları sekiz sınıflı EEG+YKS veri kümesini sınıflandırmak için ESA'nı kullandılar. Çalışmalarında, gönüllü ve imgesel motor hareketi tabanlı veri kümesini sınıflandırarak %77 SD hesaplarken, MHH tabanlı veri kümesi için %90 SD elde etmişlerdir [35]. Nour ve arkadaşları çalışmalarında, optimize edilmiş ESA ile çoklu bant genişliği yöntemini kullanan yeni bir sınıflandırma çerçevesi önermişlerdir. Sağ ve sol el açma kapama MHH'e dayalı EEG+YKS sinyallerini tam bağlantılı katman optimizasyonunu içeren bir ESA mimarisi ile eğittiler. Önerilen yaklaşım ile ortalama %99.85 SD elde ettiler [36]. Başka bir çalışmada ise Rabbani ve arkadaşları, 26 (veri kümesi1) ve 29 (veri kümesi 2) kişiden kaydedilen 2 sınıflı 2 ayrı EEG+YKS veri kümesi ile çalıştılar. Veri kümesi 1'e ESA+Geçitli Tekrarlayan Birim+Uzun-Kısa Süreli Bellek (UKSB) ağlarını uygulayarak ortalama %96 SD hesaplarken, veri kümesi 2 için UKSB ağlarını kullanarak %82.76 SD elde ettiler [37].

Çizelge 1'de literatürde yapılmış EEG+YKS çalışmaları ayrıntılı olarak ayrıca ele alınmıştır. Çizelge 1 incelendiğinde deney içeriği açısından literatürde yapılan çalışmaların motor görevi ağırlıklı olduğu görülmektedir. Motor ağırlıklı görevlerin birçoğu sağa ve sola imleç, ok veya el hareketi hayali tabanlı iken motor uygulamaya (MU) dayalı görevlerde bunların uygulanması ile alakalıdır. Bunlar arasından 2 sınıflı EEG+YKS işaretlerinin sınıflandırılmasıyla %74.20-%94.20 SD hesaplamışlardır. Motor görevi tabanlı çalışmaları ise zihinsel görev tabanlı çalışmalar takip etmiştir. Çizelge 1'de yer alan çalışmalarda elektrotların pozisyonları frontal ve motor korteks ağırlıklı olsa da bazı çalışmalarda neredeyse tüm kafatasını kapsayacak şekilde yayılmıştır. Elektrot sayısı ise EEG için yaygın olarak 6-128 arasında YKS elektrot sayısının ise 6-170 arasında olduğu Çizelge 1'de görülmektedir. Deneye katılan kişi sayı ise Çizelge 1'de görüldüğü gibi 6 ila 29 kişi arasında değişmektedir.

## 2.4. Öznitelik Çıkartma

Öznitelikler, çeşitli sınıfları ayırt etmek için gereken ayrımcı bilginin sinyallerden elde edilmesidir. Öznitelik hesaplama, tekniklere bağlı olan ve sınıflandırıcının performansını önemli derecede etkileyen BBA basamaklarından biridir. Bu basamakta az sayıda önemli ayırt ediciliğe sahip olan öznitelikler elde etmek amaçlanır. Çıkarılan öznitelikler genellikle bir öznitelik vektörü formunda yapılandırılır. Öznitelik çıkartma aşamasında, EEG sinyallerinden zaman alanında, frekans alanında ve zaman-frekans alanında öznitelikler elde edilebilir ve bunlar arasından en popüler olanı literatürden anlaşıldığı gibi zaman-frekans tabanlı yöntemlerdir [13]. Buna ek olarak EEG için öz vektör, otoregresif, bağımsız bileşen analizi, temel bileşen analizi, ADD, hızlı Fourier dönüşümü ve korelasyon boyutu, Lyapunov üstel, çeşitli entropiler, fraktal boyut gibi öznitelik çıkartma yöntemleri de yaygın olarak kullanılmaktadır. YKS sinyallerinden ise ağırlıklı olarak sinyalin ortalaması alınarak hesaplamalar yapılmıştır. Buna ek olarak ise OUÖ, eğim, varyans, basıklık ve çarpıklık da kullanılan diğer yöntemler arasında yer almaktadır. EEG+YKS için ise yukarıda bahsedilen yöntemlerden etkin olanı ayrı ayrı olarak bu modalitelere uygulanarak analiz gerçekleştirilmektedir.

Çizelge 1: Literatürde yer alan hibrit EEG+YKS çalışmaları

Referanslar	Kişi sayısı	Beyin Bölgesi	Deney İçeriği	YKS Öznitelikleri	EEG Öznitelikleri	Sınıflandırıcı	Elektrot sayısı	Kontrol Sayısı	SD
[38]	29	Frontal, motor ve görsel korteks	1. MHH: Sağ ve sol el hareketi hayali 2. MA: Dinlenme durumuna karşı zihinsel aritmetik	OUÖ'nün logaritmik varyansı	OUÖ'nün logaritmik varyansı	DAA	EEG: 30 NIRS:36	2	1. %74.20 (MHH) 2. %88.10 (MU)
[39]	6	Motor korteks	MHH: Farklı hızlarda sağ el sıkma hareketi hayali	HbO ve HbR'nin Farkı	Zaman Frekansı Fazı	Aşırı Öğrenme Makinesi	EEG:21 NIRS:24	2	%89.00
[40]	20	Motor korteks	MU: Sağ ve sol ayak bileği eklem hareketleri	Varyans, basıklık ve çarpıklık	Ortalama mutlak değer, dalga uzunluğu, OUÖ	DVM	EEG:20 NIRS:32	2	%93.01
[41]	29	Frontal, motor ve görsel korteks	MHH: Sağ ve sol el açma kapama hareketi hayali	FWHD	FWHD	k-EYK	EEG: 30 NIRS:36	2	%78.21
[42]	15	Motor korteks	MHH: Sağ ve sol el hareketi hayali	HbO Sinyal Ortalaması ve Sinyal Eğimi	OUÖ	DAA	EEG:21 NIRS:34	2	%94.20
[43]	29	Frontal, motor ve görsel korteks	MHH: Sağ ve sol el açma kapama hareketi hayali	Uzay-zaman korelasyonları	Uzay-zaman korelasyonları	Yapay sinir ağları	EEG: 30 NIRS:36	2	%82.11
[44]	14	Frontal, motor ve parietal korteks	1. MHH: Sağa veya sola hareket eden ok hayali 2. MU: El açma kapama hareketi	HbO ve HbR'nin ortalaması	BG	DAA	EEG:37 NIRS:24	2	1. %83.20 (MHH) 2. %93.20 (MU)
[27]	8	Frontal, motor, parietal ve görsel korteks	Sağa, sola, yukarıya ve aşağıya kayan yazı okuma	Hilbert Dönüşümü	Hilbert Dönüşümü	k-EYK	EEG:31 NIRS:18	4	%96.28
[45]	12	İşitsel ve görsel korteks	Ses ve video algısı	HbO ve HbR'nin Ortalamasının Farkı	BG	DVM	EEG:12 NIRS:170	2	%97.80
[46]	12	Motor korteks	MHH: Sağ ve sol el hareketi hayali	Hurst Üssü	OUÖ	DVM	EEG:64 NIRS: 52	2	%81.20
[47]	11	Tüm kafatası	Zihinsel yorgunluk seviyesi tahmin	HbO ve HbR'nin Genliği	BG	DAA	EEG:64 NIRS:8	2	%68.30

## 2.5. Sınıflandırma

Çıkarılan EEG ve YKS sinyal özniteliklerini sınıflandırmak için çeşitli teknikler bulunmaktadır. Bu sinyallerden çıkarılan özniteliklerini sınıflandırmak için yaygın olarak kullanılan algoritmalar arasında k-EYK, DVM, DAA, naive bayes (NB), karar ağacı (KA) ve rastgele ormanlar (RO) metodu bulunur. Bunlar arasından, DVM ve k-EYK, EEG ve YKS sinyallerini sınıflandırmak için BBA sistemlerinde çoğunlukla kullanılan sınıflandırma yöntemleridir [4], [48]. Her yaklaşımın ise birbirine göre avantajları ve dezavantajları vardır.

1. *k- en yakın komşuluk metodu:* Veri noktalarının birbirlerine olan benzerliğini hesaplamak için kullanılan bir makine öğrenme yöntemidir. Bu yöntemde, bir veri noktasının komşuları, veri noktasının belirli bir uzaklık metriği kullanılarak hesaplanır ve bu komşuların sınıfları veya değerleri, ilgili veri noktasının tahmin edilmesinde kullanılır.
2. *Doğrusal ayırım analizi:* Çoklu sınıflı sınıflandırma problemlerinde kullanılan bir makine öğrenme ve veri madenciliği tekniğidir. Bu yöntem, veri noktalarının özelliklerini kullanarak farklı sınıflara ait veri noktalarını birbirinden ayırmayı amaçlar. Temelde, sınıflar arasındaki farklılıkları maksimize eden ve sınıf içindeki varyansı minimize eden yeni özellikler veya boyutlar oluşturularak çalışır. Bu yeni boyutlar, veri noktalarını sınıflandırmak için kullanılır ve sınıflar arasındaki doğrusal ayrımı en iyi şekilde sağlamak için öğrenilir.
3. *Naive bayes metodu:* NB, bir veri noktasının ait olduğu sınıfı tahmin etmek için Bayes teoremini kullanır. Bayes teoremi, şartlı olasılıkları hesaplamak için kullanılır ve bu yöntemde özelliklerin sınıfı belirlemedeki etkilerini modellemek için kullanılır. Bu sayede, veri noktasının sınıfını tahmin etmek için özelliklerin olasılıkları ve Bayes teoreminin yardımıyla bir hesaplama yapılır.
4. *Karar ağacı metodu:* Bu algoritma, veri setini ağaç yapısı şeklinde temsil eder, her düğüm veri özelliklerine göre bir karar kuralı oluşturur ve bu kurala göre veriyi farklı dallara ayırır. KA oluşturulurken, veri setindeki özelliklerin en iyi bölünme kriterini kullanarak belirler. Bu şekilde, veri setini sınıflara ayırırken en fazla bilgiyi elde etmeye çalışır.
5. *Destek vektör makineleri metodu:* Veri noktalarını en iyi şekilde sınıflandırmak veya tahmin etmek için bir karar sınırı veya regresyon fonksiyonu oluşturur. Temel amaç, sınıflar arasındaki marjinal boşluğu (margin) maksimize etmek ve bu marjinal boşluğu sınıfların en yakın veri noktalarına dayanarak belirlemektir. DVM, özellikle yüksek boyutlu veri setleri üzerinde etkili çalışır ve çoklu sınıflı sınıflandırma problemlerini çözmek için de kullanılabilir. DVM, çekirdek yöntemi kullanarak veri noktalarını yüksek boyutlu uzaylarda da işleyebilir, bu da verilerin daha karmaşık yapılarını tanımlamak için kullanışlıdır. DVM, aşırı öğrenmeye karşı dirençlidir ve veri noktalarının sınıflandırılmasında yüksek performans sağlar.
6. *Rastgele ormanlar metodu:* Çok sayıda karar ağacının bir araya gelerek güçlü bir model oluşturulduğu bir tekniktir. Her bir ağaç, rastgele özelliklerin alt kümesini kullanarak veri setini sınıflandırmaya veya tahmin etmeye çalışır. Ardından, tüm ağaçların sonuçları bir

araya getirilir ve çoğunluk oyu (sınıflandırma için) veya ortalama (regresyon için) alınarak son tahmin yapılır.

## 3. Sonuçlar

BBA sistemleri, tıbbi, teknolojik ve bilimsel alanlarda birçok fayda ve potansiyel sunarak önemli bir gelişme ve araştırma alanı haline gelmiştir. Bu teknolojilerin ilerlemesi, daha fazla kullanım alanı ve daha geniş bir kitleye ulaşma potansiyeli taşımaktadır. Ayrıca, literatürden görülüşü gibi, BBA performansını ve evrenselliğini iyileştirmek için çeşitli ön işleme, öznitelik çıkartma, sınıflandırma, optimizasyon teknikleri ve paradigmlar önerilmiştir. Bu çalışmadan da görüldüğü gibi BBA sistemlerinin gelişmesi için ise gereken çözümlerden birisi, beyin görüntüleme tekniklerinin çoklu kullanılması, yani, bir hibrit BBA oluşturan ölçüm cihazlarının kullanılmasında yatmaktadır. Çizelge 2’de literatürde yapılan hibrit çalışmaların sınıflandırma sonuçları yalnızca EEG ve YKS ile yapılmış çalışmaların sınıflandırma sonuçlarıyla kıyaslanmıştır. EEG sınıflandırma sonuçları EEG+YKS sınıflandırma sonuçları ile kıyaslandığında SD’nin %4.60 ile %13.85 arasında arttığı görülmektedir. Tüm referans kaynaklar için ise bu artış ortalama %7.58 olarak hesaplanmıştır. YKS sınıflandırma sonuçları hibrit sınıflandırma sonuçları ile kıyaslandığında ise yalnız YKS’ye göre SD %1.91-30.04 arasında artış göstermiştir. Çizelge 2’de gösterildiği gibi tüm referans kaynaklar için bu artış ortalama %13.04 olarak hesaplanmıştır. Bu sonuçlardan açıkça görülmüyor ki hibrit BBA YKS’in düşük zamansal duyarlılığını telafi etmektedir ve SD’nin yanı sıra bilgi aktarım hızı ışığında BBA performansı iyileştirmektedir.

Çizelge 2: EEG+YKS tabanlı BBA sisteminin SD sonuçlarının tek modaliteli BBA sisteminin SD sonuçları ile kıyaslanması

Referanslar	SD Sonuçları (%)			Artış (%)	
	EEG	YKS	EEG+YKS	EEG’ye göre	YKS’ye göre
[38]	1. 65.60 2. 75.90	1. 66.50 2. 83.60	1. 74.20 2. 88.10	1. 11.59 2. 13.85	1. 10.38 2. 5.11
[39]	88.00	76.00	89.00	1.12	14.60
[40]	89.39	85.61	93.01	3.89	7.95
[41]	71.46	55.02	78.21	8.63	29.65
[42]	85.20	92.40	94.20	9.55	1.91
[43]	73.19	75.14	82.11	10.86	8.49
[44]	1. 78.20 2. 90.80	1. 71.70 2. 73.30	1. 83.20 2. 93.20	1. 6.00 2. 2.58	1. 13.82 2. 21.35
[27]	91.25	77.31	96.28	5.22	19.70
[45]	93.30	93.60	97.80	4.60	4.29
[46]	74.70	56.80	81.20	8.00	30.04
[47]	59.70	66.80	68.30	12.59	2.20
Ortalama				7.58	13.04

**Bilgilendirme;** Bu çalışmada kullanılan veriler Atatürk Üniversitesi Spor Bilimleri Uygulama ve Araştırma Merkezi’nde kayıt altına alınmıştır. Bu çalışma Karadeniz Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından FHD-2020-9166 proje numarasıyla desteklenmiştir. Ebru Ergun, 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında TÜBİTAK bursuyla desteklendi.



#### 4. Kaynaklar

- [1] S. Aggarwal, and N. Chugh, "Review of machine learning techniques for EEG based brain computer interface", *Archives of Computational Methods in Engineering*, vol. 1, no. 20, 2022.
- [2] A. Naser, and O. Aydemir, "Classification of pleasant and unpleasant odor imagery EEG signals", *Neural Computing and Applications*, vol. 35, no. 12, pp. 9105-9114, 2023.
- [3] O. E. Korkmaz, O. Aydemir, E. A. Oral, and I. Y. Ozbek, "A novel probabilistic and 3D column P300 stimulus presentation paradigm for EEG-based spelling systems", *Neural Computing and Applications*, pp. 1-15, 2023.
- [4] E. Ergün, and O. Aydemir, "A new evolutionary preprocessing approach for classification of mental arithmetic based EEG signals", *Cognitive Neurodynamics*, vol. 14, pp. 609-617, 2020.
- [5] Z. Liu, J. Shore, M. Wang, F. Yuan, A. Buss, and X. Zhao, "A systematic review on hybrid EEG/fNIRS in brain-computer interface", *Biomedical Signal Processing and Control*, vol. 68, no. 102595, 2021.
- [6] D. Pirrone, E. Weitschek, P. Di Paolo, S. De Salvo, and M. C. De Cola, "Eeg signal processing and supervised machine learning to early diagnose alzheimer's disease", *Applied sciences*, vol. 12, no. 11, 2021.
- [7] P. C. Sharma, R. Raja, S. K. Vishwakarma, S. Sharma, P. K. Mishra, and V. S. Kushwah, "Analysis of brain signal processing and real-time EEG signal enhancement", *Multimedia Tools and Applications*, vol. 81, no. 28, pp. 41013-41033, 2022.
- [8] Ö. Aydemir, "Beyin Bilgisayar Arayüzü ve Geleceği", *Journal of Investigations on Engineering and Technology*, vol. 5, no. 2, pp. 135-141, 2022.
- [9] N. Panigrahi, and S. P. Mohanty, "Brain Computer Interface: EEG Signal Processing", CRC Press, 2022.
- [10] R. Chai, S.H. Ling, G.P. Hunter, H.T. Nguyen, "Mental non-motor imagery tasks classifications of brain computer interface for wheelchair commands using genetic algorithm-based neural network", *Proc. Int. Joint Conf. Neural Networks*, pp. 10-15, 2012.
- [11] N.K. Verma, L.S.V.S. Rao, S.K. Sharma, "Motor imagery EEG signal classification on DWT and crosscorrelated signal features", 9th Int. Conf. Indust. Inform. Syst., 2015.
- [12] M.H. Bhatti, et al., "Soft computing-based EEG classification by optimal feature selection and neural networks", *IEEE Trans. Ind. Inf.*, vol. 15, no. 10, pp. 5747-5754, 2019.
- [13] N. Bagh, M.R. Reddy, "Hilbert Transform-Based Event-Related Patterns for Motor Imagery Brain Computer Interface", *Biomedical Signal Processing and Control*, vol. 62, 2020.
- [14] Q. Wang ve O. Sourina, "Real-time mental arithmetic task recognition from EEG signals", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 21 no. 2, pp. 225-232, 2013.
- [15] W. Yi, S. Qiu, H. Qi, L. Zhang, B. Wan, D. Ming, "EEG feature comparison and classification of simple and compound limb motor imagery", *J. NeuroEng. Rehabil.*, vol. 10, no. 1, pp. 1-12, 2013.
- [16] I. Dokare, N. Kant, "Performance analysis of SVM, k-NN and BPNN classifiers for motor imagery", *Int. J. Eng. Trends Technol.*, vol. 10, no. 1, pp. 9-23, 2014.
- [17] C. Lindig-Leon, L. Bougrain, "A multi-label classification method for detection of combined motor imageries, in: *Proceedings*", IEEE International Conference on Systems, Man, and Cybernetics, 2016.
- [18] A., Koven, and S. Herschorn, "NIRS: past, present, and future in functional urology", *Current Bladder Dysfunction Reports*, vol. 17, no. 4, pp. 241-249, 2022.
- [19] T. W. L. Scheeren, P. Schober, and L. A. Schwarte, "Monitoring tissue oxygenation by near infrared spectroscopy (NIRS): background and current applications", *Journal of clinical monitoring and computing*, vol. 26, pp. 279-287, 2012.
- [20] E. Ergün, and Ö. Aydemir, "Decoding of binary mental arithmetic based near-infrared spectroscopy signals", In 2018 3rd International Conference on Computer Science and Engineering (UBMK), pp. 201-204, 2018.
- [21] N. Naseer, and K. S., Hong, "Decoding answers to four-choice questions using functional near infrared spectroscopy", *Journal of Near Infrared Spectroscopy*, vol. 23, no. 1, pp. 23-31, 2015.
- [22] R. Li, T. Potter, W. Huang, and Y. Zhang, "Enhancing performance of a hybrid eeg-fnirs system using channel selection and early temporal features", *Frontiers in Human Neuroscience*, pp. 11-462, 2015.
- [23] Y. Tomita, F. B. Vialatte, G. Dreyfus, Y. Mitsukura, H. Bakardjian, and A. Cichocki, "Bimodal BCI using simultaneously NIRS and EEG", *IEEE Transactions on Biomedical Engineering*, vol. 61, no. 4, pp. 1274-1284, 2014.
- [24] Y. Blokland, L. Spyrou, D. Thijssen, T. Eijsvogels, W. Colier, M. Floor-Westerdijk, vd., "Combined EEG-fNIRS decoding of motor attempt and imagery for brain switch control: an offline study in patients with tetraplegia" *IEEE transactions on neural systems and rehabilitation engineering*, vol. 22, no. 2, pp. 222-229, 2013.
- [25] P. A. Cicalese, R. Li, M. B. Ahmadi, C. Wang, J. T. Francis, S. Selvaraj, ve Y. Zhang, "An EEG-fNIRS hybridization technique in the four-class classification of alzheimer's disease", *Journal of neuroscience methods*, vol. 336, pp. 108-618, 2020.
- [26] M. A. Hasan, M. U. Khan, and D., Mishra, "A computationally efficient method for hybrid EEG-fNIRS BCI based on the Pearson correlation", *BioMed Research International*, pp. 1-13, 2020.
- [27] E. Ergün, "Elektroensefalografi ve Yakın Kızılötesi Spektroskopisi Tabanlı Hibrit Model Kullanarak Beyin Bilgisayar Arayüzü Sisteminin Performansının Arttırılması", *Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon*, 2023.
- [28] F. Putze, S. Hesslinger, C. Y. Tse, Y. Y. Huang, C. Herff, C. T. Guan, vd., "Hybrid fNIRS-EEG based classification of auditory and visual perception processes", *Frontiers in Neuroscience*, vol. 8, no. 373, 2014.
- [29] B. Koo, H. G. Lee, Y. Nam, H. Kang, C. S. Koh, H. C. Shin, vd., "A hybrid NIRS-EEG system for self-paced brain computer interface with online motor imagery", *Journal of Neuroscience Methods*, vol. 244, pp. 26-32, 2015.
- [30] H. Aghajani, M. Garbey, and A. Omurtag, "Measuring mental workload with EEG plus fNIRS", *Frontiers in human neuroscience*, vol. 11, no. 359, pp. 1-20, 2017.
- [31] J. Shin, J. Kwon, and C. H. Im, "A ternary hybrid EEG-NIRS brain-computer interface for the classification of brain activation patterns during mental arithmetic, motor imagery, and idle state", *Frontiers in neuroinformatics*, vol. 12, no. 5, pp. 1-9, 2018.

- [32] M. Nour, Ş. Öztürk, and K. Polat, "A novel classification framework using multiple bandwidth method with optimized CNN for brain-computer interfaces with EEG-fNIRS signals", *Neural Computing and Applications*, vol. 33, no. 22, pp. 15815-15829, 2021.
- [33] Y. Zhang, Y. Li, L. Kong, Q. Niu, ve Y. Bai, "Improved DBSCAN Spindle Bearing Condition Monitoring Method Based on Kurtosis and Sample Entropy", *Machines*, vol. 10, no. 5, 2022.
- [34] A. M. Chiarelli, P. Croce, A. Merla ve F. Zappasodi, "Deep learning for hybrid EEG-fNIRS brain-computer interface: application to motor imagery classification", *Journal of neural engineering*, 15, 3, 036028, 2018.
- [35] M. A. Rahman, M. S. Uddin ve M. Ahmad, "Modeling and classification of voluntary and imagery movements for brain-computer interface from fNIR and EEG signals through convolutional neural network", *Health Information Science and Systems*, 7, 1, 22, 2019.
- [36] M. Nour, Ş. Öztürk ve K. Polat, "A novel classification framework using multiple bandwidth method with optimized CNN for brain-computer interfaces with EEG-fNIRS signals", *Neural Computing and Applications*, 33, 15815-15829, 2021.
- [37] M. H. R. Rabbani ve S. M. R. Islam, "Deep learning networks based decision fusion model of EEG and fNIRS for classification of cognitive tasks", *Cognitive Neurodynamics*, 1-18, 2023.
- [38] J. Shin, A. von Lüthmann, B. Blankertz, D. W. Kim, J. Jeong, H. J. Hwang, and K. R. Müller, "Open access dataset for EEG+ NIRS single-trial classification", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25, 10, 1735-1745, 2016.
- [39] X. X. Yin, B. L. Xu, C. H. Jiang, Y. F. Fu, Z. D. Wang, H. Y. Li, vd., "A hybrid BCI based on EEG and fNIRS signals improves the performance of decoding motor imagery of both force and speed of hand clenching", *Journal of Neural Engineering*, vol. 12, no. 036004, 2015.
- [40] M. S. Al-Quraishi, I. Elamvazuthi, T. B. Tang, M. Al-Qurishi, S. H. Adil, ve M. Ebrahim, "Bimodal data fusion of simultaneous measurements of EEG and fNIRS during lower limb movements", *Brain Sciences*, vol. 11, no. 6, pp. 1-713, 2021.
- [41] E. Ergün ve Ö. Aydemir, "A hybrid BCI using singular value decomposition values of the fast walsh hadamard transform coefficients", *IEEE Transactions on Cognitive and Developmental Systems*, pp. 1-10, 2022.
- [42] A. P. Buccino, H. O. Keles ve A. Omurtag, "Hybrid EEG-fNIRS asynchronous brain-computer interface for multiple motor tasks", *Plos One*, vol. 11, no. 1, pp. 1-8, 2016.
- [43] Q. He, L. Feng, G. Jiang, and P. Xie, "Multimodal Multitask Neural Network for Motor Imagery Classification With EEG and fNIRS Signals", *IEEE Sensors Journal*, vol. 22, no. 21, pp. 20695-20706, 2021.
- [44] S. Fazli, J. Mehnert, J. Steinbrink, G. Curio, A. Villringer, K. R. Müller, vd., "Enhanced performance by a hybrid NIRS-EEG brain computer interface", *Neuroimage*, vol. 59, pp. 519-529, 2012.
- [45] F. Putze, S. Hesslinger, C. Y. Tse, Y. Y. Huang, C. Herff, C. T. Guan, vd., "Hybrid fNIRS-EEG based classification of auditory and visual perception processes", *Frontiers in Neuroscience*, vol. 8, no. 373, 2014.
- [46] S. Ge, Q. Yang, R. M. Wang, P. Lin, J. F. Gao, Y. Leng, vd., "A brain computer interface based on a few-channel EEG-fNIRS bimodal system", *IEEE Access*, vol. 5, pp. 208-218, 2017.
- [47] S. Ahn, T. Nguyen, H. Jang, J. G. Kim, ve S. C. Jun, "Exploring neuro-physiological correlates of drivers' mental fatigue caused by sleep deprivation using simultaneous EEG, ECG, and fNIRS data", *Frontiers in human neuroscience*, vol. 10, no. 219, pp. 1-14, 2016.
- [48] O. Aydemir, and E. Ergün, "A robust and subject-specific sequential forward search method for effective channel selection in brain computer interfaces", *Journal of neuroscience methods*, vol. 313, pp. 60-67, 2019.

## Özgeçmişler



Dr. Ebru Ergün, 1991 yılında Trabzon'un Yomra ilçesinde doğdu. İlköğretim ve ortaöğretimi Trabzon Merkez'de tamamlamış olup, 2009 yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünü kazandı. Bu öğrenimini 2014 yılında tamamlayarak aynı sene yüksek lisans eğitimine başladı. Yüksek lisans eğitimini 2017 yılında tamamlayarak aynı sene doktora eğitimine devam etti. 2015 yılında Recep Tayyip Erdoğan Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. İyi derecede İngilizce bilen Ergün, biyomedikal, beyin bilgisayar arayüzü, makine öğrenmesi alanındaki çalışmalarını sürdürmektedir.



Dr. Önder Aydemir, 2005 yılında hem Karadeniz Teknik Üniversitesi (KTÜ) Elektrik-Elektronik Mühendisliği Bölümü'nde lisans hem de KTÜ İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü'nde yandal eğitimini tamamladı. 2006-2007 Eğitim Öğretim Dönemi'nde yüksek lisans çalışması yapmak üzere Viyana Teknik Üniversitesi'ne gitti. 2008 yılında yüksek lisansını ve 2013 yılında doktora eğitimini Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü'nde tamamladı. Doktora sonrası araştırmasını 2014-2015 eğitim-öğretim döneminde Viyana Tıp Üniversitesinde yapmıştır. Bilimsel araştırma alanları beyin bilgisayar arayüzü, makine öğrenmesi, biyomedikal sinyal işlemedir. 2023 yılında yapay zeka alanında yılın en etkili bilim insanları listesine de giren Dr. Aydemir, yabancı dil olarak İngilizce ve Almanca bilmektedir.



Dr. Onur Erdem Korkmaz, 2012 yılında Atatürk Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden mezun olan Onur Erdem KORKMAZ, yüksek lisans eğitimini 2016 yılında, doktorasını ise 2022 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. Şu anda Atatürk Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği bölümünde doktor öğretim üyesi olarak görev yapmaktadır. Çalışma alanları arasında beyin bilgisayar arayüz sistemleri, sinyal işleme, biyomedikal sinyal işleme, görüntü işleme, biyomedikal görüntü işleme, derin öğrenme, makine öğrenmesi gibi konular bulunmaktadır.