

EOG Artefaktları Kullanılarak Yörünge Tabanlı Sınıflandırma: Felçli Bireyler İçin Alternatif Bir İnsan-Makine Arayüz Yaklaşımı

***Makale Bilgisi / Article Info**

Alındı/Received: 20.02.2025

Kabul/Accepted: 28.05.2025

Yayımlandı/Published: 03.12.2025

Trajectory-Based Classification Using EOG Artifacts: An Alternative Human-Machine Interface Approach for Paralyzed Individuals

Sefa AYDIN^{1*}, Mesut MELEK², Levent GÖKREM³¹ Gümüşhane Üniversitesi, Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü, Gümüşhane, Türkiye² Gümüşhane Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Gümüşhane, Türkiye³ Tokat Gaziosmanpaşa Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Tokat, Türkiye

© 2025 The Authors | Creative Commons Attribution-NonCommercial 4.0 (CC BY-NC) International License

Öz

Günümüzde, doğuştan veya omurilik yaralanması gibi sinir sistemi problemleri sebebiyle tamamen felç olmuş bireylerin günlük ihtiyaçlarını karşılayabilmeleri için Beyin-Bilgisayar Arayüz (BBA) sistemleri geliştirilmiştir. BBAlar, çeşitli cihazları kullanarak topladığı beyin sinyallerini bilgisayarlar aracılığıyla işleyerek, çevre cihazları harekete geçirmek için çıktı komutları üreten sistemlerdir. Fakat BBA sistemlerinin kullanıcılar üzerinde bazı olumsuz etkileri vardır. Bu çalışmada, Görsel Uyarı Potansiyel (GUP) ve P300 gibi görsel uyaran tabanlı BBA sistemlerinde kullanılan farklı frekans değerlerinde titreşen uyaranların sistem kullanıcılarının göz sağlığı üzerinde meydana getirdiği olumsuz etkiyi azaltmak amacıyla; hareketli nesneleri yaklaşımını kullanarak bir İnsan-Makine Arayüz (İMA) sistemi önerilmiştir. Sistem, kullanıcının hareketli topları odaklanarak takip etmesi sonucunda Elektrosefalografi (EEG) sinyallerinde meydana gelen Elektrokülografi (EOG) artefaktlarını kullanarak hareket yörüngelerini makine öğrenme algoritmaları ile sınıflandırmayı amaçlamaktadır. Çalışma, Emotiv EPOC EEG cihazı aracılığıyla dört farklı rotada hareket eden toplar içeren yaklaşım kullanılarak sağlıklı 8 denek üzerinde gerçekleştirilmiştir. Kaydedilen ham verilere ön işleme aşamaları uygulanmıştır ve etkin kanal seçimi yapılmıştır. Tespit edilen etkin kanallara (AF3, AF4) ait verilere Güç Spektral Yoğunluğu (GSY) ve Ayrık Dalgacık Dönüşümü (ADD) yöntemleri uygulanmıştır. Her yöntem için öznitelikler çıkartılmış ve k-tane En yakın komşu (k-EYK) ve Lineer Diskriminant Analiz (LDA) algoritmaları kullanılarak sınıflandırılmıştır. GSY yöntemi için LDA ve k-EYK algoritmaları ile sırasıyla 93.86%, 92.62% doğruluk oranları ve 31.42 (bit/dk), 30.10 (bit/dk) Bilgi aktarım hızı (BAH) değerleri hesaplanmıştır. ADD yöntemi için sırasıyla 92.84%, 92.17% doğruluk oranları ve 30.36 (bit/dk), 29.62 (bit/dk) BAH değerleri elde edilmiştir. Karşılaştırılan iki yöntemden GSY'nin ADD'ye göre daha yüksek doğruluk oranları ve BAH değerleri verdiği, LDA algoritmasının k-EYK algoritmasından daha başarılı olduğu gözlemlenmiştir.

Abstract

Today, Brain-Computer Interface (BCI) systems have been developed to meet the daily needs of individuals who are completely paralyzed due to nervous system problems such as congenital or spinal cord injury. However, BCI systems also have some negative effects on system users. In this study, a Human-Machine Interface (HMI) system that uses the moving objects approach is proposed in order to reduce the negative effects of visual stimuli vibrating at different frequency values used in Visual Evoked Potential (VEP) and P300-based BCI systems on the eye health of system users. The system aims to classify movement trajectories with machine learning algorithms by using Electrooculography (EOG) artifacts that occur in Electroencephalography (EEG) signals as a result of the user focusing on moving balls. The study was conducted on 8 healthy subjects using an approach involving balls moving in four different routes through the Emotiv EPOC EEG device. Pre-processing stages were applied to the recorded raw data and effective channel selection was made. Power Spectral Density (PSD) and Discrete Wavelet Transform (DWT) methods were applied to the data of the detected active channels (AF3, AF4). Features were extracted for each method and classified using k-Nearest Neighbor (k-NN) and Linear Discriminant Analysis (LDA) algorithms. For the PSD method, 93.86%, 92.62% accuracy rates and 31.42, 30.10 (bit/min) ITR values were calculated with the LDA and k-NN algorithms, respectively. For the DWT method, accuracy rates of 92.84%, 92.17% and ITR values of 30.36, 29.62 (bit/min) were obtained, respectively. It has been observed that, among the two compared methods, PSD gives higher accuracy rates and ITR values than DWT, and the LDA is more successful than the k-NN algorithm.

Anahtar Kelimeler Beyin-bilgisayar Arayüz; Elektrosefalografi; Elektrokülografi; Makine öğrenme; Sınıflandırma

Keywords Brain-computer interface; Electroencephalography; Electrooculography; Machine learning; Classification


1. Giriş

Beyin-Bilgisayar Arayüz (BBA), iletişimin kaynağı olan insan beyninden sinyalleri doğrudan alarak, insanlarla makineler arasında iletişim kurmayı hedefleyen bir teknolojidir. BBA teknolojisi, günümüzde genellikle bilinçli kontrol gerektiren uygulamalar için kullanılmaktadır. Bu uygulamalar; kendi ihtiyaçlarını karşılayamayacak durumda olan felçli bireylerin, kaybettikleri fiziksel işlevlerin kısmen geri kazandırılması üzerine odaklanmaktadır (Kübler vd. 2001). Sinir hücrelerinin zarar görmesi sonucu meydana gelen Amiyotrofik Lateral Skleroz (ALS) veya beyin sapı olarak bilinen brainstem felci gibi durumlarla mücadele eden hastalar için BBA, dış dünya ile iletişim kurmanın alternatif bir yolunu sağlamaktadır. Dolayısıyla bu sistemler beyin sinyalleri aracılığıyla hastanın dış dünyadaki televizyon, yatak, tekerlekli sandalye gibi elektronik cihazlarla bağlantı kurmasını sağlayarak, bireylerin yaşam kalitesini doğrudan arttırmaktadır (Liu vd. 2012).

BBA sistemleri invaziv ve non-invaziv olmak üzere iki gruba ayrılmaktadır. İnvaziv yöntemde, hastaların beyin sinyalleri cerrahi müdahale ile beyin yüzeyinden doğrudan kaydedilmektedir. Bu yöntem ile elde edilen sinyallerin kalitesi çok yüksektir ve gürültü oranı düşüktür. Dolayısıyla BBA sistemlerinin performansını doğrudan yükselten etkili bir yöntemdir. Fakat cerrahi işlem gerektirmesi, komplikasyon riski ve maliyetli olması sebebiyle fazla tercih edilmemektedir. Non-invaziv yöntemde ise beyin sinyalleri hastaların kafa taşı yüzeyinden tek kullanımlık elektrotlar aracılığıyla kaydedilmektedir. Bu sinyaller invaziv yöntemde kaydedilen sinyallere göre, daha yüksek gürültü oranına ve daha düşük netliğe sahip olmasına rağmen; herhangi bir cerrahi işlem gerektirmemesi, kolay uygulanabilir olması ve düşük maliyetli olması nedeniyle sıklıkla tercih edilmektedir (Kosmyna ve Lécuyer 2019). Non-invaziv yöntemde sinyaller, Elektroensefalografi (EEG), Yakın kızılötesi spektroskopisi (NIR) ve Pozitron emisyon tomografisi (PET) gibi çeşitli tekniklerle kaydedilmektedir. EEG, BBA sistemlerinde en sık tercih edilen non-invaziv sinyal alma tekniğidir.

EEG tabanlı bir BBA sistemi temelde altı aşamadan oluşmaktadır. Birinci aşamada, kullanıcılara ait veriler ölçülerek bilgisayarlar aracılığıyla kaydedilmektedir. İkinci aşamada; kaydedilen verilere kırpmaya, filtreleme gibi ön işleme aşamaları uygulanarak işlemeye uygun hale getirilmektedir. Üçüncü aşamada, ön işleme uygulanan verilerden ayırt edici özellikler elde edebilmek amacıyla farklı öznitelikler çıkartılmaktadır. Dördüncü aşamada, verilerden çıkartılan öznitelikler farklı makine öğrenme algoritmaları kullanılarak sınıflandırılmaktadır. Beşinci

aşamada, sınıflandırma sonuçları kullanılarak ilgili sinyal ile ilişkilendirilmiş çıktı komutları elde edilmektedir. Son aşamada ise; elde edilen çıktı komutları kablosuz bağlantı ile kontrol kartına aktararak çevre cihazların kontrolü sağlanmaktadır. EEG tabanlı BBA sisteminin temel şeması Şekil 1’de verilmiştir.



Şekil 1. Temel BBA şeması.

EEG tekniğinde, Motor İmgeleme (Mİ), Görsel Uyarın Potansiyel (GUP) ve Hata ile ilgili potansiyel (HİİP) gibi beyinde meydana gelen elektriksel aktiviteler kayıt altına alınmaktadır (Maciej Serda vd. 2020). HİİP kişinin bir hata yapması veya bir yanlışlığı fark etmesi durumlarında ortaya çıkan elektriksel aktivitedir. Mİ ise kişinin fiziksel bir iş yapmadan, herhangi bir hareketi hayal etmesi sonucunda tetiklenerek elektriksel potansiyel meydana getirmektedir. GUP yöntemi ise sistem kullanıcıya farklı frekans değerlerinde yanıp sönen ışık, resim gibi uyarınların gösterilmesi sonucunda beyinde meydana gelen potansiyel değişimlerin kayıt edildiği yöntemdir. Yöntem, potansiyel meydana getirmek için kullanılan görsel uyarınların frekans değeri 6Hz’in üzerine çıktığında Durgun Durum Görsel Potansiyel Uyarın (DDGUP) olarak adlandırılmaktadır. DDGUP tabanlı BBA sistemleri, eğitim sürelerinin kısa olması, sinyal gürültü oranlarının yüksek olması ve kolay uygulanabilir olmaları nedeniyle diğer yöntemlere göre daha fazla tercih edilmektedir (Bin vd. 2009).

BBA sistemlerinin avantajları olduğu gibi dezavantajları da vardır. Bu sistemlerin temelini oluşturan ve beyinde meydana gelen elektriksel potansiyel değişimlerin kaydedilmesi ile elde edilen EEG sinyalleri, bozucu etkilere karşı oldukça hassastır. Bozucu etkiler BBA araştırmalarında önemli bir zorluk teşkil etmektedir. Bu etkiler sonucunda meydana gelen artefaktlar, istenmeyen değişimlere yol açarak nörolojik süreçleri etkilemektedir.

Artefaktlar, fizyolojik olmayan veya göz ve vücut hareketlerinden kaynaklanan elektriksel potansiyeller gibi fizyolojik faktörlerden kaynaklanmaktadır. BBA sistemlerinde fizyolojik artefaktların, özellikle göz ve vücut hareketlerinden kaynaklanan bileşenlerin, sinyal işleme sürecinde ciddi bir sorun teşkil ettiği bilinmektedir (Fatourechı vd. 2007). Fakat EEG temeline dayanan BBA sistemlerinin düşük bilgi aktarım hızı, kullanıcılar arasında yüksek değişkenlikler gibi sorunlarına karşın Elektrokülografi (EOG) sinyalleri yüksek doğruluk ve dayanıklılık avantajları ile ön plana çıkmaktadır (X. Liu vd. 2024). Bu avantajlar göz önünde bulundurulduğunda, göz hareketlerinin önem teşkil ettiği durumlarda EEG sinyallerinde bulunan EOG artefaktları kaynak sinyal olarak kullanılabilir (Zhu vd. 2020). Bir diğer problem ise; P300 ve DDGUP gibi görsel uyaran tabanlı BBA sistemlerinde, beyinde potansiyel oluşturmak için kullanılan titreşen ışıkların veya görsellerin kullanıcılarda meydana getirdiği göz problemleridir (Allison 2009). Yapılan çalışmalarda titreşen ışıkların kullanıcılarda göz yorgunluğuna sebep olduğu ve sistem konforunu ciddi oranda düşürdüğü de bilinmektedir (Brennan vd. 2015).

Bu çalışmada, görsel uyaran tabanlı BBA sistemlerinin barındırdığı titreşen ışıkların sistem kullanıcısı üzerinde meydana getirdiği olumsuz etkileri azaltmak için;

- Farklı rotalarda hareket eden cisimler (beyaz toplar) temeline dayanan ve herhangi bir titreşen görsel uyaran içermeyen yenilikçi yaklaşıma sahip bir İnsan-Makine Arayüz (İMA) sistemi önerilmiştir.
- Önerilen yaklaşım aracılığıyla sistem kullanıcısının görsel uyaranlardan izole edilmesi ve hareketli nesneler aracılığıyla sistemi kontrol edebilmesi hedeflenmiştir.
- Görsel uyaranların gözde meydana getirdiği parlama hissini ortadan kaldırmak, sistemin kullanımını kolaylaştırmak ve daha uzun süreli kullanımlara olanak sağlamak amaçlanmıştır.
- Herhangi bir EOG cihazına gerek kalmadan, tercih edilen Emotiv Epoc X EEG cihazı ile kullanıcılar için daha ucuz, konforlu ve kullanımı kolay bir İMA sistemi geliştirilmiştir.
- DDGUP tabanlı BBA sistemlerinde adaylar tarafından en az 4 yanıp sönen ışığa odaklanarak bakılması (Kamińska vd. 2021) ve P300 tabanlı sistemlerde ise her komut için yanıp sönen ışığa en az iki veya daha fazla kez bakılması gerekmektedir (Akram vd. 2015). Önerilen yaklaşım ile herhangi bir görsel uyarana maruz kalmaksızın hareketli rotaların sayısı daha da çeşitlendirilebilir daha fazla çıktı komutu üretilmesine olanak sağlanabilir. Önerilen

daha geliştirilebilir bir yöntem sunulması da hedeflenmiştir.

Önerilen yaklaşımın içerdiği beyaz toplar, kullanıcının beyinde potansiyel fark oluşturmak için kullanılmıştır. Sistem kullanıcısı, topları odaklanarak izlediğinde Emotiv Epoc X EEG cihazı vasıtasıyla beyin yüzeyinde meydana gelen elektriksel potansiyel değişimler kaydedilmiştir. Önerilen yaklaşım göz hareketi tabanlı bir yaklaşım olması dolayısıyla, göz çevresine yakın bölgelere konumlanmış kanallarda EOG sinyal artefaktlarının etkin şekilde görüleceği bilinen bir gerçektir. Bu nedenle EEG cihazına ait 14 kanalda meydana gelen EOG artefaktlarının baskınlığını tespit etmek amacıyla tüm kanallardan elde edilen veriler ön işleme aşamalarından geçirildikten sonra Ayırık Dalgacık Dönüşümü (ADD) ve Güç Spektral Yoğunluğu (GSY) yöntemleri uygulanarak makine öğrenme algoritmaları ile sınıflandırılmış ve elde edilen doğruluk oranı değerleri incelenmiştir. EOG artefakt seviyesi en yüksek olan iki kanala ait ham veriler, hareket yörüngelerinin sınıflandırılması için kaynak veri olarak kullanılmıştır. Ön işleme aşamalarından geçirilen ham verilere ADD ve GSY yöntemleri uygulanmıştır. Frekans domainine çevrilen verilere öznitelik çıkartma işlemi uygulanmıştır. Çıkarılan öznitelik verileri Lineer Diskriminant Analiz (LDA) ve k-tane En yakın komşu (k-EYK) makine öğrenme algoritmaları kullanılarak sınıflandırılmıştır. ADD ve GSY yöntemleri, LDA ve k-EYK makine öğrenme algoritmaları ile elde edilen doğruluk oranları, BAH, Hassasiyet, Özseçicilik, F1 skoru ve AUC değerlerine bağlı olarak kıyaslanmıştır. Çalışmanın temel katkıları şu şekilde özetlenmiştir:

- EEG sinyallerinde genellikle istenmeyen gürültü olarak kabul edilen EOG artefaktları kullanılarak göz hareketi tabanlı, düşük kanal sayısına (AF3, AF4) sahip bir İMA sistemi tasarlanmıştır.
- Hareketli nesneler yaklaşımı kullanılarak, görsel uyaran tabanlı sistemlerin içeriğinde bulunan titreşen görsellerin/ışıkların kullanıcı göz sağlığı üzerinde meydana getirdiği olumsuz etkiler minimize edilmiştir.
- Veri kayıt cihazı olarak düşük maliyetli, mobil, kurulumu basit ve kullanıcının görüşünü etkilemeyen bir EEG cihazı (Emotiv Epoc) seçimi yapılarak kullanıcıya kullanımı kolay ve konforlu bir sistem sunulmuştur.
- Önerilen sistemin frekans ekseninde sergilediği performanslar ADD ve GSY yöntemleri kullanılarak karşılaştırılmış ve en iyi performansı sağlayan yöntemin tespiti sağlanmıştır.
- GSY yöntemi için LDA ve k-EYK algoritmaları ile sırasıyla 93.86%, 92.62% doğruluk oranları, 31.42 (bit/dk), 30.10

(bit/dk) Bilgi aktarım hızı (BAH), 94.29, 92.83 hassasiyet, 93.75, 92.44 özseçilik, 93.79, 92.47 F1 skoru, 95.83, 94.79 AUC değerleri ve ADD yöntemi için ise sırasıyla 92.84%, 92.17% doğruluk oranları, 30.36 (bit/dk), 29.62 (bit/dk) BAH, 92.0, 92.08 hassasiyet, 91.66, 91.40 Özseçilik, 91.72, 91.48 F1 skoru, 94.44, 94.14 AUC değerleri elde edilmiştir.

Çalışmada, deneyler sırasında kullanılan yaklaşım veya veri kayıt cihazına bağlı olarak herhangi bir problem (Brennan vd. 2015) yaşanmaması, yapılan veri kayıt sürelerinin problemin çözümüne yönelik yapılan çalışmalardan daha kısa olması [Melek vd. 2020], sistem performansının yapılan çalışmalara yakın veya kısmen yüksek olması (Glavas vd. 2024, Hernández Pérez vd. 2023, Jiang vd. 2024, Mifsud vd. 2024, Zhao, 2025) ve düşük kanal sayısı ile çalışmanın gerçekleştirilmesi önerilen İMA modelinin görsel uyaran tabanlı sistemler için konfor seviyesi ve kısmen performansı yüksek bir alternatif oluşturabileceğini göstermiştir.

2. Literatür Taraması

Tekerlekli sandalyenin EOG sinyalleri ile kontrol edilmesi üzerine yapılan bir çalışmada (Glavas vd. 2024) araştırmacılar 4 serbestlik derecesine sahip sandalyeyi Motor imgeleme (Mİ) ve EOG sinyallerini kullanarak 86.90% doğruluk oranı ve 84.32 F1 skoru ile kontrol ettiler. Bir diğer çalışmada (Mifsud vd. 2024) araştırmacılar, kaydırma ve tarama yapmak için EOG tabanlı bir sistem geliştirdiler. Tasarlanan sistemin farklı mesafelerde dayanıklılığını göstermek için 50 cm uzaklıktan 83.73% doğruluk oranı elde ettiler. Bir diğer çalışmada araştırmacılar (Mai vd. 2024) DDGUP ile EOG sinyallerinin kullanıldığı bir navigasyon sistemi geliştirdiler. Geliştirilen sistem ile 81.67% doğruluk oranı elde ederek, tekerlekli sandalyelerin kullanımında meydana gelen kaza ve engeller için iyi bir alternatif oluşturdular.

Öğrencilerin ruh sağlığı ve dikkat eksikliğini tespit etmek için yapılan çalışmada (Zhao 2025) özgün bir BBA modeli önerildi. Önerilen model de kafatasının ön bölgesinde konumlanan 7 elektrotu kullanarak iki bilişsel ve davranışsal görev arasında ayırım yapmak hedeflendi. 12 denek üzerinde yapılan çalışmada KKA ile 90% doğruluk oranı elde eden araştırmacı, K-EYK, DVM ve BA makine öğrenme algoritmalarının tanıma doğruluğunu daha da arttırdığını belirtti. Bir diğer çalışmada ise araştırmacılar (Jiang vd. 2024), ALS hastaları için günlük yardım sistemi önerdiler. Kullanıcıların, bir BBA kafa bandı takarak, hafif baş döndürme ve göz kırpması ile bir bilgisayarı çalıştırabilmesini ve tekerlekli sandalye sürebilmelerini hedeflediler. Oluşturulan arayüzler aracılığıyla 15 ALS

hastası ile görevlerin tamamını başarıyla tamamladılar ve iki farklı görev için ortalama 83.9% ve 87.0% doğruluk oranları elde ettiler. Ayrıca, NASA-TLX kullanarak yaptıkları iş yükü değerlendirmesi sonucunda, katılımcıların sistemi kullanırken düşük bir iş yükü yaşadığını söylediler.

EOG tabanlı İMA sistemlerinde kullanılan makine öğrenme algoritmalarını kıyaslandığı bir çalışmada (López vd. 2023) araştırmacılar Statik Eşikleme (SE) algoritmasının 88.21% doğruluk oranı ile en iyi sonucu verdiğini gözlemlediler. Göz hareketlerinin dikey (yukarı, aşağı) ve yatay (sağa, sola) eksenlerde kullanıldığı bir diğer çalışmada ise (Hernández Pérez vd. 2023) araştırmacılar göz kırpmalarını da dahil ederek beş sınıflı EOG tabanlı bir sistem önerdiler. EOG sinyallerini, 0.5–50Hz bant aralığında Dalgacık dönüşümü ile frekans düzeyinde analiz ettiler. Elde edilen öznelikler ile k-EYK, DVM ve Karar Ağacı (KA) algoritmaları ile eğittiler. Sınıflandırma başarıları Jaccard indeksi, karışıklık matrisi ve ROC eğrisi üzerinden değerlendiren araştırmacılar, en yüksek sonucu 76.9% doğruluk oranı ile DVM algoritması ile elde ettiler. Araştırmacılar, DVM tabanlı modellerin EOG sinyallerinin sınıflandırılmasında etkili olabileceğini belirttiler.

Farklı bir çalışmada araştırmacılar (Goktas ve Aras 2022) Arduino kullanarak göz hareketleri ile menüler içerisinden seçim yapılabilen EOG tabanlı bir sistem tasarladılar. Sistemde kullanıcıların seçim yapabilmesi için menü arayüzü oluşturdular. Araştırmacılar beş denek kullandıkları çalışmada, bir denneğin ortalama 3.87 saniyede verilen görevi yerine getirebildiğini tespit ettiler.

Bir çalışmada araştırmacılar, EOG sinyallerini kullanarak hibrit bir BBA sistemi önerdiler (J. Zhang vd. 2023). Araştırmacılar tasarladıkları arayüzde 20 karaktere karşılık gelen 20 buton kullandılar. Çalışmada 10 sağlıklı denek kullandılar ve denekten deney sırasında her biri aynı anda yanıp sönen ışıklara bakmasını istediler. Düğmeler farklı yönlerde hareket ettiğinde EOG sinyallerini kaydettiler. KKA yöntemini kullanan araştırmacılar 94.75% doğruluk oranına ulaştılar. Bir diğer çalışmada ise araştırmacılar (Mouli ve Palaniappan 2020) DDGUP ve P300 yöntemleri ile tetiklenen hibrit bir sistem üzerine çalıştılar. Her iki yöntem içinde farklı frekans ve renklerde görsel uyaran kullanılan çalışmada araştırmacılar EEG sinyallerinde P300 bileşenlerini başarıyla şekilde tespit ettiler. Bir diğer robot kontrol çalışmasında ise araştırmacılar (Mwata-Velu vd. 2021) Mİ yöntemi ile hayali el hareketlerini kullanarak veri kaydı yaptılar. Verileri Evrişimsel Sinir Ağları (ESA) ile sınıflandıran araştırmacılar 87.6% maksimum sınıflandırma doğruluğu elde ettiler.

Yapılan bir çalışmada araştırmacılar (Deng vd. 2025), EOG ve IOG sinyalleri arasında dört yönlü hareketler için yönsel ortogonal özellik gösteren bir elektrot konfigürasyonu önerdiler. Yönsel ortogonal özellikten yararlanarak zaman alanı ve zaman-frekans özelliklerini birleştiren YOLOv3 adında zaman-frekans modelini önerdiler. Çalışmalarında 6 denek kullanan araştırmacılar 97.60% doğruluk oranı ve 62.65 (bit/dk) BAH elde ettiler. Farklı bir çalışmada araştırmacılar (Efe ve Ozsen 2023) eğitim verisi dengesizliği sorununu çözmek için odak kaybı ve ayırık kosinüs dönüşümü yöntemlerini kullanan yeni bir hibrit sinir ağı mimarisi önerdiler. Önerilen modeli, k katlı doğrulama stratejileri kullanarak dört farklı veri tabanında eğiten araştırmacılar, 87.11% doğruluk oranı ve 81.81% Kappa puanı elde ettiler. Çalışmayı mevcut yöntemler ile karşılaştıran araştırmacılar sonuçların ümit verici olduğunu belirttiler. Motor imgeleme yönteminin kullanıldığı bir çalışmada ise (Kaya ve Saritas 2024) araştırmacılar her denekten yirmi gün boyunca veri kaydı yaptılar. Topluluk Altuzay Diskriminant (TAD) algoritması ile yapılan 4 sınıflı sınıflandırma sonucunda günlük ortalama doğruluk değeri 61.44% olarak elde edilirken, 2 sınıflı sınıflandırma için ortalama doğruluk oranını 71.84% olarak elde ettiler.

Görsel uyaran tabanlı BBA sistemlerinin içerdiği görsel uyaranların kullanıcı üzerinde meydana getirdiği yanıp sönen görüntü hissini azaltmak için yapılan bir çalışmada (Kondo ve Tanaka 2023) araştırmacılar yüksek frekans (56-70Hz) aralığında çalışan bir sistem önerdiler. Tasarladıkları sistemi düşük frekanslı uyaranlarla test eden araştırmacılar düşük frekanslı görsel uyaranlar ile oluşturdukları sistem için sınıflandırma sonucunda 98.0% doğruluk oranı elde ederken yüksek frekanslı uyaranlar ile oluşturdukları sistemde ise 87.19% doğruluk oranı elde ettiler. Çalışmada doğruluk oranlarının daha yüksek frekanslar değerlerinde düştüğünü gözlemlediler.

EOG sinyalleri kullanılarak yapılan bir çalışmada (Martínez-Cerveró vd. 2020) araştırmacılar, dört yönlü göz hareketlerinin sınıflandırılması için bir sistem tasarladılar. Sistemi; açık kaynaklı yazılım ekosistemleri, Raspberry Pi tek kartlı bilgisayar, OpenBCI biyosinyal toplama cihazı ve açık kaynaklı bir Python kütüphanesini temel alarak geliştirdiler. Çalışmalarında 7 denek kullanan araştırmacılar, maksimum, minimum ve medyan özneliklerini kullanarak DVM algoritması ile 90.0% doğruluk oranı elde ettiler. Tasarladıkları sistemin; ucuz, kompakt ve taşınabilir olup, kolayca çoğaltılabilir ve özelleştirilebilir nitelikte olduğunu söyleyen araştırmacılar, sınıflandırma sisteminin felçli bireylerde yardımcı iletişim amacıyla bir İMA girişi olarak kullanılabileceğini belirttiler.

Yapılan bir çalışmada araştırmacılar (Hu vd. 2024), mevcut sistemlerin kullanım zorluğu, maliyet ve performans yetersizliği problemlerine çözüm amacıyla; EOG ve EEG sinyallerini birleştiren kompakt, giyilebilir hibrit bir sistem geliştirdiler. 10 denek kullanarak kaydettikleri sinyalleri sınıflandırmak için DVM algoritmasını kullanan araştırmacılar 94.03% doğruluk oranı ve 31.42 bit/dakika BAH elde ettiler. Araştırmacılar önerdikleri sistemin gerçek dünya kullanımı için uygulanabilir olduğunu belirttiler. Bir diğer çalışmada ise araştırmacılar (Aydın vd. 2025) DDGUP tabanlı sistemlere çözüm amacıyla hareketli nesneler yaklaşımını kullandılar. Sağlıklı 10 denek kullandıkları çalışmada araştırmacılar, sağ-sol, aşağı-yukarı, sağ-çapraz ve sol-çapraz hareket yörüngelerini kullanarak 97.89% doğruluk oranı ve 36.75 (bit/dk) doğruluk oranı elde ettiler. Fakat sistemin güvenliğini sağlamak amacıyla kullandıkları bir adet 7Hz görsel uyaran nedeniyle sistem kullanıcılarının az da olsa görsel uyaran kaynaklı rahatsızlık yaşadığını bildirdiler. Farklı bir çalışmada (Raj ve Kumar 2024) ise araştırmacılar, EOG sinyallerini kullanarak bireylerin iletişimini kolaylaştırmaya yönelik metin ve ses tabanlı bir sistem geliştirdiler. BioAmp EXG Pill sensörleri ile sağ-sol ve yukarı-aşağı yönlü göz hareketlerini algılayarak; verileri ESP32 mikrodenetleyicisi üzerinden işleyen araştırmacılar, LCD ekran ve sesli çıktı yoluyla kullanıcıya geri bildirim sağladılar. 10 sağlıklı bireyle yaptıkları testlerde sistemin genel doğruluğunu 81.04% olarak hesapladılar.


3. Materyal ve Metot

Bu bölümde çalışmada kullanılan materyaller ve metotlar açıklanmıştır. Tasarlanan sisteme ait Flowchart algoritması Şekil 2'de verilmiştir.

3.1. EEG cihazı

Emotiv EPOC X, 14 ölçüm elektrodu ve 2 referans elektrodu (CMS ve DRL) içeren, giyilebilir bir EEG cihazıdır. Elektrotlar, uluslararası 10-20 sistemine uygun olarak yerleştirilmektedir. Cihaz, kaydedilen EEG sinyallerini kablosuz bağlantı ile bilgisayara iletebilme özelliğine sahiptir. Lityum polimer bataryası sayesinde yaklaşık 12 saat kesintisiz çalışabilen cihaz, uzun süreli deneyler için idealdir (Holewa ve Nawrocka 2014). Emotiv EPOC X kablosuz ve hafif tasarımı sayesinde, taşınabilirlik ve kullanım kolaylığı açısından oldukça pratiktir. Elektrotların temizlenmesi ve kafa derisi ile elektrotlar arasındaki empedansın azaltılması için yaygın olarak bulunan bir salin çözeltisi kullanılmaktadır. Cihaz, 128Hz ve 256Hz örnekleme frekanslarında çalışabilme özelliği ile farklı araştırma ihtiyaçlarına uyum sağlamaktadır. Cihaz Emotiv firmasının sağlayıcısı olduğu lisansı ücretli EmotivBCI

uygulaması ile kullanılabilir. Akademik çalışmalar için uygun maliyetli bir çözüm sunması sebebiyle araştırmacılar tarafından sıklıkla tercih edilmektedir.



Şekil 2. Tasarlanan İMA sisteminin Flowchart algoritması.

3.2. Katılımcılar

İnsanların denek olarak kullanıldığı bu çalışma, Trabzon Kanuni Eğitim ve Araştırma Hastanesi Tıp Fakültesi'nin 23618724 sayı ve 11507 numaralı etik kurul izni ile gerçekleştirilmiştir. Çalışmada, herhangi bir bağımlılığı bulunmayan, 18-45 yaş aralığında (ort. 23.7) sağlıklı 8 denek (5 erkek, 3 kadın) kullanılmıştır. Deneklere çalışmaya katılmaları teklif edildiğinde, çalışmanın ayrıntıları kapsamlı şekilde anlatılmıştır. Çalışmaya katılmayı kabul eden bireyler, Bilgilendirilmiş gönüllü

onam formu doldurtulmak suretiyle çalışmaya dahil edilmiştir.

3.3. Sınıflandırma algoritmaları

3.3.1. Lineer Diskriminant Analiz (LDA)

Sınıflandırma algoritmaları, benzerlik fonksiyonlarına ve ağırlıklı değerlere denk gelen çıktılarla, özellik vektörlerini kategorize etmek için sıklıkla kullanılmaktadır (Altan ve inat 2021). Bu algoritmalarından birisi olan LDA, sınıflandırma ve boyut indirgeme için kullanılan etkili bir istatistiksel tekniktir. Genellikle iki veya daha fazla sınıfın verilerini sınıflandırma amacı taşıyan bir ikili sınıflandırıcıdır (Lotte ve Guan 2011). LDA algoritmasında, sınıflar için aynı kovaryans matrisine sahip Gaussian dağılımları kullanılır. İki sınıf arasındaki farkı en üst düzeye çıkaran projeksiyon, ayırıcı hiper düzlemi oluşturur. İkili sınıflandırma görevlerinde, bu hiper düzlem Denklem 1 ile tanımlanan bir ayırt edici fonksiyon üzerinden belirlenir (Krusienski vd. 2006).

$$f(x) = \hat{w} \cdot f(v) + b \quad (1)$$

Verilen denklemde (Denklem 1), v özellik vektörü, b ofset terimi ve $\hat{w}$ sınıflandırma ağırlık vektörü olarak tanımlanır.

3.3.2. k-tane En yakın komşuluk (k-EYK)

k-EYK, makine öğreniminde sıklıkla kullanılan basit bir algoritmadır ve hem sınıflandırma hem de regresyon için kullanılabilir. Algoritma, bir veri noktasını değerlendirirken, o noktaya en yakın k komşusunun niteliklerini baz alır. k-EYK'e göre birbirine yakın veriler aynı özellikte verilerdir. Algoritma, eğitim aşamasında herhangi bir öğrenme gerçekleştirmez; bunun yerine, tüm eğitim verilerini bellekte saklar (Lotte ve Guan 2011). Çalışmada veriler arasındaki uzaklık Öklid teoremi Denklem 2 kullanılarak hesaplanır.

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

burada (Denklem 2) x_i ilk veri noktasını, y_i ikinci veri noktasını ve $d(X, Y)$ ise iki nokta arasındaki Öklid mesafesini temsil eder.

3.4. Performans parametreleri

3.4.1. Doğruluk Oranı (DO)

BBA sistemlerinde Doğruluk oranı (DO), sistemin kullanıcı tarafından gönderilen komutları veya beyin sinyallerini doğru bir şekilde algılama ve sınıflandırma başarısını ölçen önemli bir performans göstergesidir. Bu oran, doğru sınıflandırılmış sinyallerin toplam sınıflandırılan sinyallere oranı olarak hesaplanır ve genellikle yüzdelik bir değerle ifade edilir. Doğruluk oranı, sistemin genel etkinliğini ve güvenilirliğini değerlendirmek için temel bir kriterdir.

Yüksek bir doğruluk oranı, sistemin beyin sinyallerini doğru şekilde işleyip yorumladığını gösterir.

3.4.2. Bilgi Aktarım Hızı (BAH)

Bilgi aktarım hızı (BAH), BBA sistemlerinde performansı değerlendirmek için yaygın olarak kullanılan bir ölçüm parametresidir. Bu metrik, sistemin doğruluk oranı, kullanıcı seçim sayısı ve karar süresi gibi faktörleri birleştirerek etkinliğini değerlendirme imkânı sunar (Volosyak 2011). Genellikle bit/saniye (bit/s) birimiyle ifade edilen BAH, yalnızca doğruluk oranını değil, aynı zamanda işlem hızını da dikkate alır. Performans hesaplamaları, Shannon teorisine dayanır ve Denklem 3 ile belirlenir (Wolpaw vd. 1998).

$$B_t = \log_2 K + p \log_2 p + (1 - p) \log_2 \left(\frac{1-p}{K-1} \right) \quad (3)$$

Denklemden (3) K ve p değerleri sırasıyla tercih hakkı miktarını ve sistemin doğruluk oranı değerini ifade eder. B_t kullanılarak BAH parametresi Denklem 4 ile hesaplanır.

$$BAH = 60 * \frac{B_t}{T} \quad (4)$$

Burada (Denklem 4) T değeri yapılan tek bir tahminin değerlendirilebilmesi için verilen süredir.

3.4.3. Hassasiyet

Hassasiyet, sinyal işleme alanında yapılan çalışmalarda (Altan vd. 2021) modellerin pozitif tahminlerinin ne kadarının gerçekten doğru olduğunu ölçmek için sıklıkla kullanılan bir performans metriğidir. Hassasiyet Denklem 5 ile hesaplanmaktadır.

$$Hassasiyet = \frac{DP}{DP+YP} \quad (5)$$

Denklemden (5) YP parametresi gerçekte negatif olan ama model tarafından yanlışlıkla pozitif tahmin edilen örnek sayısını ve DP ise doğru şekilde pozitif olarak sınıflandırılmış örnek sayısını temsil etmektedir.

3.4.4. Özseçicilik

Sinyal işlemede Özseçicilik bir sınıflandırma algoritmasının, gerçek pozitif örneklerin ne kadar doğru tespit edildiğini gösteren bir ölçüttür. Özseçicilik Denklem 6 ile hesaplanmaktadır.

$$\text{Özseçicilik} = \frac{DP}{DP+YN} \quad (6)$$

Burada DP, pozitif sınıfa ait olup doğru şekilde pozitif olarak sınıflandırılmış örneklerin sayısını temsil ederken; YN, pozitif olduğu hâlde yanlışlıkla negatif olarak sınıflandırılan örneklerin sayısını ifade etmektedir.

3.4.5. F1 Skoru

F1 skoru metriği, hassasiyet ve özseçicilik metriklerinin harmonik ortalamasıdır. Bu metrik, iki değeri de

dengeleyerek genel sınıflandırma performansını daha adil bir şekilde ölçmeyi amaçlar. Özellikle dengesiz veri kümelerinde etkili bir ölçüt olan F1 skoru, alanda yapılan çalışmalarda (Hacıbeyoglu vd. 2024) sınıflar arası dengeyi ölçmek için sıklıkla kullanılmakta ve Denklem 7 ile hesaplanmaktadır.

$$F1 \text{ Skoru} = 2 * \frac{\text{hassasiyet} * \text{özseçicilik}}{\text{hassasiyet} + \text{özseçicilik}} \quad (7)$$

F1 skoru özetle özseçicilik ve hassasiyet parametrelerinin birlikte sağlanıp sağlanmadığını ölçer.

3.4.6. AUC

AUC değeri, çalışma karakteristik eğrisi altında kalan alanın hesaplanmasıyla elde edilmektedir. Sinyal işleme alanında yapılan sınıflandırmalarda, modelin sınıflar arasındaki ayrımı ne kadar iyi yaptığına dair genel bir ölçü sunmaktadır. Alanda yapılan çalışmalarda (Top vd. 2024) sıklıkla kullanılan AUC, modelin sınıflar arasındaki ayrım yeteneğini ölçmekte olup, özellikle veri dengesizliği bulunan durumlarda doğruluktan daha güvenilir bir gösterge olarak kabul edilmektedir.

3.5. Güç Spektral Yoğunluğu (GSY)

Bireylerin kafa derisi üzerine yerleştirilen yüzeysel elektrotlarla algılanan EEG sinyalleri, bilgisayarlar aracılığıyla gerilim ve zaman serisi verisi olarak kaydedilir. Bu sinyallerin zaman ve gerilim verisi şeklinde kaydedilmiş olması, anlamlandırma ve analiz sürecini oldukça zorlaştırmaktadır. Bu nedenle, verilerin zaman alanından frekans alanına dönüştürülmesi gerekir. Çalışmada kullanılan Welch GSY yöntemi Denklem 8 ile ifade edilir.

$$P_{\text{welch}}(f) = \frac{1}{K.L.U} \sum_{i=0}^{K-1} \left| \sum_{n=0}^{L-1} x_i(n) \cdot \omega(n) e^{-j2\pi f n} \right|^2 \quad (8)$$

Welch yönteminde, veri örtüşme miktarı K olacak şekilde eşit parçalara bölünür. Her bir segmentin uzunluğu L olarak belirlenir. GSY, Welch tahmininde örtüşen K segmentten elde edilen periodogramların ortalaması alınarak hesaplanır. U değeri ise pencere fonksiyonunun toplam gücünü ifade eder (Tiwari vd. 2022).

3.6. Ayrık Dalgacık Dönüşümü (ADD)


ADD, bir sinyalin zaman ve frekans ekseninde detaylı analizini yapabilen gelişmiş bir yöntemdir. Zamanla değişen sinyallerin analizinde etkili bir yöntem olan ADD'nin Fourier dönüşümünden en büyük farkı, analiz sonucunda yalnızca frekans bileşenlerini değil, bileşenlerin zaman bilgilerini de sağlamasıdır. ADD yöntemi temelde sinyali yaklaşım (A) ve ayrıntı (D) bileşenlerine ayırır. Yaklaşım bileşeni düşük frekans değerine sahip iken ayrıntı bileşeni yüksek frekans değerine sahiptir. Sinyali yaklaşım ve ayrıntı bileşenlerine ayırma işlemi etkin çözünürlük seviyesi elde edilene kadar

devam eder. Bu sayede, istenilen çözünürlük seviyesine kadar ayrıştırılan sinyal detaylı bir şekilde incelenebilir (Faust vd. 2015).

3.7. Veri kayıt aşaması

Çalışmada, ilk olarak sinyal kaydı için uygun ortam hazırlanmıştır. Hazırlanan ortam yüksek ışık ve ses gibi bozucu etkilerden arındırılmış ve içerisinde EEG cihazı, monitör, bilgisayar, masa ve sandalye gibi araç gereçler hazır bulundurulmuştur. Çalışma için seçilen denekler, deneyler öncesinde ayrıntılı olarak çalışma hakkında bilgilendirilmiştir. Gerekli ortam hazırlandıktan sonra denekler birer birer deney odasına alınmıştır. İçeri alınan deneye EEG cihazı tuzlu (salinli) su kullanılarak giydirilmiştir. Elektrotların temas ve sinyal kalitesi bilgisayar aracılığıyla kontrol edilmiştir. Sinyal seviyesi istenilen düzeye ulaştığında veri kayıt aşamasına geçilmiştir. Deneyler sırasında Emotiv Epoc X EEG cihazının tüm kanallarından (14) 256Hz örnekleme frekansında veri kaydı yapılmış herhangi bir kanal devre dışı bırakılmamıştır. Cihaz deneye başlamadan ve her deneyden sonra sterilize edilmiştir ve bataryası tam kapasitede doldurulmuştur.

Önerilen yaklaşımda üçgen (Δ) hareket yörüngesi, yukarı ve sağa (L) hareket yörüngesi, yuvarlak (O) hareket yörüngesi ve sağ-sol (—) hareket yörüngeleri bulunmaktadır. Belirtilen hareket yörüngelerinin deneklere gösterildiği arayüz 3ds Max kullanılarak tasarlanmıştır. Yörüngelerin yol uzunluğunun eşit olmasına dikkat edilmiştir. Hareket yörüngelerinin deneye uygulanma görev sırası Şekil 3'te gösterilmiştir.



Şekil 3. Önerilen yaklaşımın deneklere uygulanan görev sırası.

Şekil 3 incelendiğinde, deneyin ilk olarak üçgen hareket yörüngesi ile başladığı görülmektedir. Başlangıçta deneye 3 saniyelik başlangıç uyarı sesi dinletilmiştir. Uyarı

sesinden sonra üçgen hareket yörüngesi deneye 10 saniye (10 tur) boyunca izletilmiş ve veri kaydı yapılmıştır. 10 saniye sonunda bitiş uyarı sesi ile birlikte ilk hareket yörüngesi için veri kaydı tamamlanmıştır. 3 dakika dinlenme süresi verildikten sonra bir sonraki hareket yörüngesine geçilmiştir. Üçgen hareket yörüngesinde uygulanan işlemler diğer hareket yörüngelerinde de aynı şekilde uygulanarak veri kaydı yapılmıştır. Kayıt tamamlandıktan sonra 5 dakika dinlenme arası verilmiştir. Tüm hareket yörüngeleri ile her bir denek için 10 tekrar olacak şekilde sinyal kaydı gerçekleştirilmiştir. Veri kayıt düzeneği Şekil 4'te gösterilmiştir.



Şekil 4. Veri kayıt düzeneği.

Deneklerden alınan veriler bilgisayar aracılığıyla doğrudan kayıt altına alınmıştır. 8 denekten toplamda 320 kayıt yapılmıştır. Kaydedilen veriler sinyal işleme aşaması için MATLAB ortamına aktarılmıştır.


4. Bulgular

Sinyal işleme aşamasında ilk olarak kaydedilen ham verilerden başlangıç ve bitiş uyarı sesleri kesilmiştir. Kesilen sinyaller 1 saniyelik örtüşme ile 3 saniyelik veriler şeklinde parçalanmıştır. Her 10 saniyelik (2560x14) hareket yörüngesi verisinden toplamda 5 adet 3 saniyelik (768x14) veri elde edilmiştir. Sinyallerinden gürültü ve istenmeyen frekans bileşenlerinin uzaklaştırılması amacıyla parçalanmış veriler *filtfilt* komutu kullanılarak, 1–50Hz bant aralığında 4. dereceden Butterworth bant geçiren filtre ile filtrelenmiştir. Butterworth filtresi, geçiş bandındaki düz frekans yanıtı ile sinyalin genlik bileşenlerini bozmadan filtreleme yapması nedeniyle sinyal işleme çalışmalarında yaygın olarak tercih edilmektedir (Sörnmo ve Laguna 2005). Filtre derecesi, geçiş bölgesinin keskinliği ile doğrudan ilişkili olup, yüksek dereceler daha keskin geçiş sağlar ancak aynı zamanda faz bozulması riskini de artırır. Bu nedenle, sinyalin hem bilgi içeriğini koruyacak hem de istenmeyen bileşenleri yeterli düzeyde bastırarak şekilde filtreleme yapabilmek için

farklı (1-15 aralığı) derecelerde filtre dereceleri denenmiş; elde edilen sonuçlar doğrultusunda 4. derece, frekans geçiş karakteristiği ve zaman alanındaki bozulmanın dengelenmesi açısından en uygun derece olarak belirlenmiştir.

4.1. Etkin kanal seçimi

Filtrelenen verilere ADD yöntemi uygulanmıştır. ADD için db2 dalgacığı kullanılmış ve altı seviyeli bileşenlerine ayırma uygulanmıştır. Bileşenlerine ayırma işlemine ait bant ayrıntıları Şekil 5'te gösterilmiştir.



Şekil 5. Verilerin altı seviyeli bileşenlerine ayrıştırılması.

Şekil 5'te sinyallere altı seviyeli ADD yönteminin uygulanması sonucunda elde edilen alt bantlara ait yaklaşım ve ayrıntı veri kümeleri gösterilmiştir. Yaklaşım ve ayrıntı verilerine ait frekans aralığı değerleri Çizelge 1'de verilmiştir.

Çizelge 1. ADD alt bant ayrıştırmalarına ait frekans aralıkları.

Ayrıştırılmış sinyal	Frekans aralığı (Hz)
A1 / D1	0-128 / 128-256
A2 / D2	0-64 / 64-128
A3 / D3	0-32 / 32-64
A4 / D4	0-16 / 16-32
A5 / D5	0-8 / 8-16
A6 / D6	0-4 / 4-8

Çizelge 1'de verilen ayrıştırılmış ayrıntı ve yaklaşım sinyallerinin frekans aralıkları incelendiğinde, Delta (0.5-4Hz), Teta (4-7Hz), Alfa (7-12Hz), Beta (12-30Hz) ve Gama(30-50Hz) dalgalarına ait frekans değerlerinin tam olarak elde edilemediği görülmektedir. Bu nedenle tüm alt bant verilerinden varyans özniteliği çıkartılmıştır. Çıkartılan öznitelik verileri Hold-out yöntemi kullanılarak %75 eğitim ve %25 test verisi olarak ayrılmıştır. EEG cihazının tüm kanallarına (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) ait öznitelik verileri, her kanal kendi içerisinde olacak şekilde, k-EYK ve LDA makine öğrenme algoritmaları kullanılarak sınıflandırılmıştır. k-

EYK algoritmasının performansı, büyük ölçüde k parametresinin doğru seçimine bağlıdır. Bu parametre, sınıflandırma işlemi sırasında dikkate alınacak komşu sayısını ifade eder ve modelin genelleme yeteneği ile aşırı öğrenme (aşırı uyum) arasında bir denge kurulmasında kritik rol oynar. Düşük k değerleri, modelin eğitim verisine fazla duyarlı olmasına ve gürültüye açık hale gelmesine neden olurken; çok yüksek k değerleri ise sınıflar arası sınırların bulanıklaşmasına ve aşırı genelleme (yetersiz uyum) sorununa yol açabilir. Bu nedenle, literatürde deneme-yanılma yöntemi ve çapraz doğrulama gibi yöntemlerle farklı k değerlerinin test edilmesi yaygın bir yoldur. Yapılan çalışmalarda genellikle tek sayı değerleri tercih edilmekte ve en uygun k değeri, modelin doğruluk, hata oranı veya F1 skoru gibi performans metriklerine göre belirlenmektedir (Li vd. 2002, Z. Zhang 2016). Bu bağlamda, çalışmamızda da k parametresi oylama durumunda eşitlikten kaçınmak için 1-3-5-7-9 tek sayı değerleri için denenmiş ve en yüksek sınıflandırma başarımı sağlayan 3 değeri optimum k değeri olarak kabul edilmiştir. Sınıflandırma işlemi 10 kez tekrarlanmış ve her sınıflandırma aşamasında verilere karıştırma işlemi uygulanmıştır. LDA algoritması için elde edilen ortalama doğruluk oranları Çizelge 2'de verilmiştir.

Çizelge 2. ADD yöntemi uygulanan EEG kanallarına ait öznitelik verilerinin LDA algoritması ile sınıflandırılmasına ait doğruluk oranları.

Kanallar	Denek-1	Denek-2	Denek-3	Denek-4	Denek-5	Denek-6	Denek-7	Denek-8	Ort. (%)
AF3	77.92	68.75	69.50	75.83	74.07	75.54	67.26	71.60	72.55
F7	57.08	62.92	64.58	58.33	60.78	64.34	61.95	62.93	61.61
F3	64.17	60.42	58.33	65.42	55.74	51.49	54.40	57.00	58.37
FC5	25.00	46.67	22.92	48.33	50.25	54.20	46.66	37.20	41.40
T7	54.17	58.75	54.17	39.58	46.80	44.47	54.00	43.37	49.41
P7	45.83	60.42	60.42	45.83	48.53	50.35	57.63	41.74	51.34
O1	37.50	45.00	49.17	27.08	37.39	46.96	44.43	42.17	41.21
O2	25.00	31.25	52.08	36.67	36.12	43.07	41.73	39.50	41.09
P8	43.75	68.75	50.00	43.75	45.33	45.95	39.75	57.08	49.30
T8	54.17	64.58	58.75	52.08	56.17	53.78	59.17	59.33	57.25
FC6	64.58	64.58	43.75	50.00	44.92	46.42	48.25	44.25	50.84
F4	39.58	61.25	45.83	39.58	51.67	58.42	42.20	62.75	50.16
F8	66.67	61.25	69.17	56.25	63.57	63.76	62.50	65.42	63.57
AF4	73.00	70.83	72.50	66.67	67.62	73.49	70.59	69.33	70.50

Çizelge 2 incelendiğinde, ADD yöntemi uygulanarak LDA algoritması ile sınıflandırılmış kanallardan, AF3 ve AF4 kanallarına ait doğruluk oranlarının diğer kanallardan daha yüksek olduğu görülmektedir. Bu kanallara ait

Çizelge 3. ADD yöntemi uygulanan EEG kanallarına ait öznelik oranları.

Kanallar	Denek-1	Denek-2	Denek-3	Denek-4	Denek-5	Denek-6	Denek-7	Denek-8	Ort. (%)
AF3	66.66	68.33	72.16	60.42	72.50	73.54	64.17	75.79	69.20
F7	59.60	58.33	63.25	64.58	56.25	66.43	43.33	69.08	60.11
F3	53.75	50.00	57.30	43.75	43.75	52.33	50.00	54.48	50.67
FC5	48.92	48.36	47.15	60.42	45.00	50.33	33.33	66.38	49.99
T7	47.90	54.17	39.58	52.92	56.25	49.76	50.00	54.38	50.62
P7	47.13	43.75	37.33	58.25	62.50	58.15	37.50	34.05	47.33
O1	50.55	27.17	42.82	64.58	52.92	44.20	35.42	60.18	47.23
O2	38.78	22.92	53.36	25.00	58.33	48.36	37.50	44.33	41.07
P8	50.42	35.42	42.75	56.25	56.25	49.04	50.00	41.35	47.68
T8	49.20	41.67	45.92	58.33	52.50	54.62	47.92	57.28	50.93
FC6	52.30	47.92	45.50	59.20	25.00	42.34	52.08	54.11	47.30
F4	42.42	33.33	55.46	52.29	50.00	52.46	29.17	48.25	45.42
F8	61.69	60.42	62.86	68.75	64.58	63.72	57.33	70.47	63.72
AF4	70.77	69.58	75.27	79.17	64.58	71.12	65.83	78.27	71.82

Çizelge 3'e bakıldığında AF3 ve AF4 kanallarının doğruluk oranlarının sırasıyla 69.20% ve 71.82% ile en yüksek değerler olduğu görülmektedir. ADD yöntemi uygulanmış öznelik verilerinin k-EYK ve LDA algoritmaları ile sınıflandırılması sonucunda her iki makine öğrenme algoritması içinde AF3 ve AF4 kanallarının en yüksek doğruluk oranlarını verdiği görülmektedir. ADD yöntemi uygulanan veriler kullanılarak EEG kanallarının doğruluk oranları hesaplandıktan sonra ön işleme yapılan ham verilere GSY yöntemi uygulanmıştır. GSY analizinde kullanılan Hanning pencereleme parametreleri, veri yapısına uygun olarak deneysel yöntemlerle belirlenmiştir. Literatürde, pencere uzunluğu ve örtüşme oranının doğru seçilmesinin, frekans çözünürlüğü ile zamansal hassasiyet arasında bir denge kurulmasında önemli rol oynadığı belirtilmiştir (Mitra ve Bokil 2007, Welch 1967). 256Hz ile örneklenmiş 3 saniyelik 768x14 boyutundaki sinyal matrisinde, pencere uzunluğu 650 örnek, örtüşme miktarı ise 649 örnek olarak seçilmiştir. Seçilen değerler, 450-750 aralığında değerlerin performans açısından karşılaştırıldığı bir deneme ve

doğruluk oranları sırasıyla 72.55%, 70.50% şeklindedir. ADD yöntemi uygulanmış EEG kanallarına ait verilerin k-EYK algoritması kullanılarak sınıflandırılmasına ait doğruluk oranları ise Çizelge 3'te verilmiştir.

verilerinin k-EYK algoritması ile sınıflandırılmasına ait doğruluk

yanılma süreci sonucunda belirlenmiştir. Seçilen bu parametrelerin, kısa süreli biyo sinyallerin frekans içeriğini daha kararlı biçimde temsil ettiği ve spektral özelliklerin çıkarımında daha yüksek ayrıştırıcılık sağladığı gözlemlenmiştir. Frekans çözünürlüğü kullanılarak Delta (0.5-4Hz), Teta (4-7Hz), Alfa (7-12Hz), Beta (12-30Hz) ve Gama(30-50Hz) frekans bantlarından varyans özneliği çıkartılmıştır. Elde edilen öznelik verileri Hold-out yöntemi kullanılarak %75 eğitim ve %25 test verisi olarak ayrılmıştır. EEG cihazının tüm kanallarına ait öznelik verileri k-EYK ve LDA makine öğrenme algoritmaları kullanılarak her kanal kendi içerisinde olacak şekilde sınıflandırılmıştır. k-EYK algoritması için ADD yönteminde de olduğu gibi k değeri 1-3-5-7-9 tek sayı değerleri için denenmiş ve en yüksek sınıflandırma başarımı sağlayan 3 değeri optimum k değeri olarak seçilmiştir. Sınıflandırma işlemleri 10 kez tekrarlanmış ve her sınıflandırma aşamasında verilere karıştırma işlemi uygulanmıştır. Elde edilen doğruluk oranı değerleri LDA algoritması için Çizelge 4'te ve k-EYK algoritması için ise Çizelge 5'te verilmiştir.

Çizelge 4. GSY yöntemi uygulanan EEG kanallarına ait öznelik verilerinin LDA algoritması ile sınıflandırılmasına ait doğruluk oranları.


Kanallar	Denek-1	Denek-2	Denek-3	Denek-4	Denek-5	Denek-6	Denek-7	Denek-8	Ort. (%)
AF3	74.63	82.92	73.50	71.67	68.33	73.89	76.96	76.24	74.77
F7	65.05	67.25	65.62	41.67	62.50	69.76	67.28	56.25	61.92
F3	52.95	45.83	59.33	50.00	56.25	52.85	66.27	35.42	52.36
FC5	49.93	46.23	52.17	29.17	56.25	60.13	58.76	54.17	50.85
T7	36.20	43.05	40.70	52.08	62.92	51.34	50.19	58.26	49.34
P7	40.50	60.37	31.45	37.50	66.67	33.85	40.67	36.80	43.80
O1	55.17	41.25	52.40	22.92	60.83	56.85	44.33	37.50	46.90
O2	48.45	58.33	51.58	41.67	38.75	42.15	54.68	22.92	44.56
P8	54.67	60.66	40.82	60.42	64.58	49.98	56.15	35.42	52.09
T8	55.87	59.17	41.66	50.00	58.33	40.77	59.56	25.00	48.80
FC6	62.43	61.22	57.25	57.23	46.66	54.74	61.87	33.71	54.89
F4	56.27	55.42	61.33	52.08	58.12	60.31	66.17	37.50	55.14
F8	62.08	66.67	54.37	67.72	69.21	61.77	65.65	65.62	62.14
AF4	71.25	80.42	72.58	78.33	72.53	74.83	73.47	78.75	75.27

Çizelge 5. GSY yöntemi uygulanan EEG kanallarına ait öznelik verilerinin k-EYK algoritması ile sınıflandırılmasına ait doğruluk oranları.

Kanallar	Denek-1	Denek-2	Denek-3	Denek-4	Denek-5	Denek-6	Denek-7	Denek-8	Ort. (%)
AF3	70.83	78.62	72.50	73.33	65.83	74.24	75.75	77.25	73.54
F7	58.33	63.95	68.75	59.75	51.32	71.03	57.80	54.63	60.70
F3	59.58	64.17	51.67	48.78	39.58	66.48	42.75	54.17	53.40
FC5	50.00	60.33	37.50	60.85	37.50	59.25	52.75	47.92	50.76
T7	56.25	52.45	33.33	40.80	56.25	49.33	53.17	63.25	50.60
P7	50.16	58.58	54.17	38.40	43.75	41.75	50.95	52.08	48.48
O1	35.42	51.25	70.83	60.12	31.25	51.65	44.90	52.92	46.92
O2	27.08	44.24	47.92	51.60	39.58	49.33	37.65	42.20	42.75
P8	33.33	52.33	52.08	44.98	41.67	38.22	58.33	56.50	47.42
T8	31.25	49.60	56.25	48.95	39.58	40.73	39.40	54.25	46.97
FC6	41.67	56.17	41.67	62.70	58.33	59.33	64.32	57.33	57.94
F4	37.50	61.89	56.25	57.33	45.83	62.17	51.33	61.17	54.64
F8	47.92	58.52	72.92	62.38	64.58	65.11	60.66	66.25	62.77
AF4	76.33	73.00	79.58	72.10	77.92	66.27	77.42	72.08	74.34


Çizelge 4 incelendiğinde, LDA algoritması için 74.77% ve 75.27% doğruluk oranları ile AF3 ve AF4 kanallarının en yüksek doğruluk oranlarına sahip kanallar olduğu görülmektedir. Çizelge 5'e bakıldığında ise k-EYK algoritması için 73.54% ve 74.34% doğruluk oranları ile yine AF3 ve AF4 kanallarının en yüksek değerlere sahip olduğu görülmektedir. GSY yöntemi ile k-EYK ve LDA

algoritmaları kullanarak etkin kanal tespiti amacıyla yapılan sınıflandırmalarda AF3 ve AF4 kanallarının, doğruluk oranı en yüksek iki kanal olduğu tespit edilmiştir. ADD ve GSY yöntemleri kullanarak k-EYK ve LDA makine öğrenme algoritmaları ile yapılan etkin kanal seçimine ait sınıflandırma doğruluk oranları Şekil 6'da karşılaştırılmıştır.

**Şekil 6.** GSY ve ADD yöntemleri uygulanan EEG kanal verilerinin etkin kanal seçimi amacıyla LDA, k-EYK algoritmaları kullanarak sınıflandırılmasına ait sonuçların karşılaştırılması.

Şekil 6 incelendiğinde, etkin kanal seçimi için yapılan sınıflandırmaların tamamında en yüksek doğruluk oranına sahip iki kanalın AF3 ve AF4 kanalları olduğu açıkça görülmektedir. Bu kanalların kafa taşı üzerindeki yerleşimi Şekil 7'de gösterilmiştir.

Kullanılan yaklaşımın içerdiği hareketli nesneler doğrudan göz hareketleri ile bağlantılı olduğundan dolayı tasarlanan sistem EOG tabanlı bir İMA sistemidir. Dolayısıyla, göz bölgesine en yakın olan AF3 ve AF4 kanallarının etkin kanal seçiminde en yüksek doğruluk oranlarına sahip olması beklenen bir sonuçtur. Yapılan sınıflandırma işlemleri sonucunda, etkin olarak tespit edilen bu kanallara ait ham veriler çalışmanın ileri aşamalarında hareket yörüngelerini sınıflandırmak amacıyla kullanılmıştır.

**Şekil 7.** Tespit edilen etkin kanalların (AF3, AF4) kafa taşı üzerindeki konumları.

4.2. Hareketli uyaranların sınıflandırılması

Çalışmada hareketli uyaranların sınıflandırılması için sadece etkin olarak tespit edilen kanallara (AF3 ve AF4) ait veriler kullanılmıştır. Bu kanallara ait ham veriler ilk olarak *filtfilt* komutu kullanılarak 1-45Hz aralığında 3. dereceden Butterworth filtre kullanılarak filtrelenmiştir. Filtre derecesi 1-15 aralığında deneme yanılma yolu ile belirlenmiştir. Filtrelenen verilere ADD yöntemi uygulanmıştır. ADD için *db2* dalgacığı kullanılmış ve altı seviyeli bileşenlerine ayırma uygulanmıştır. Elde edilen alt bantlardan varyans, basıklık, çarpıklık, maksimum ve minimum öznitelikleri çıkartılmıştır. Çıkartılan öznitelik verileri Hold-out yöntemi kullanılarak %75 eğitim ve %25 test verisi olarak ayrılmıştır. Eğitim ve test verileri k-EYK ve LDA makine öğrenme algoritmaları ile sınıflandırılmıştır.

Sınıflandırma işlemi 10 kez tekrarlanmış ve elde edilen doğruluk oranları ve BAH değerlerinin ortalaması alınmıştır. Her Hold-out yöntemi uygulanmadan önce veriler karıştırılarak, eğitim ve test verilerinin farklılaşması sağlanmıştır. ADD yöntemi uygulanmış verilerin k-EYK ve LDA algoritmaları ile sınıflandırılmasına ait doğruluk oranları, BAH, Hassasiyet, Özseçicilik, F1 skoru ve AUC performans metriklerine ait değerler Çizelge 6'da verilmiştir. Her sınıfa ait DO, BAH, Hassasiyet, Özseçicilik, F1 skoru ve AUC değerlerinin makro ortalaması hesaplanmıştır. Hesaplanan değerler, modelin tüm sınıflar üzerindeki genel başarımını göstermektedir. Çizelge de (Çizelge 6), Sınıf-1 "üçgen hareket" yörüngesini, Sınıf-2 "L hareket" yörüngesini, Sınıf-3 "yuvarlak hareket" yörüngesini ve Sınıf-4 ise "sağ-sol hareket" yörüngesini temsil etmektedir.

Çizelge 6. ADD yöntemi uygulanmış etkin kanallara (AF3, AF4) ait verilerin LDA ve k-EYK makine öğrenme algoritmaları ile sınıflandırılmasına ait DO, BAH, Hassasiyet, Özseçicilik, F1 skoru ve AUC değerleri.

Sınıflandırıcı	Sınıflar	Denek1	Denek2	Denek3	Denek4	Denek5	Denek6	Denek7	Denek8	Ort.
LDA	Sınıf-1	94.17	100.0	96.67	95.83	96.67	99.17	93.33	100.0	96.98
	Sınıf-2	92.27	91.67	94.57	85.00	87.50	93.34	85.00	95.50	90.61
	Sınıf-3	86.67	90.00	92.00	87.50	90.83	93.34	93.33	92.50	90.77
	Sınıf-4	90.00	92.50	95.83	90.83	92.50	93.33	95.83	93.33	93.02
	DO (%)	90.77	93.54	94.76	89.78	91.88	94.79	91.87	95.33	92.84
	BAH (bit/dk)	28.19	31.04	32.40	27.24	29.29	32.44	29.28	33.07	30.36
	Hassasiyet	89.90	93.91	93.74	88.50	92.14	93.91	90.00	93.91	92.00
	Özseçicilik	90.77	93.54	94.76	89.78	91.88	94.79	91.87	95.33	92.84
	F1 skoru	90.33	93.72	94.24	89.13	92.00	94.34	90.92	94.61	92.41
	AUC	91.05	93.83	94.83	90.66	92.44	94.83	91.05	94.83	92.94
k-EYK	Sınıf-1	94.57	100.0	96.67	100.0	100.0	95.83	95.83	99.17	97.76
	Sınıf-2	88.77	93.33	95.00	96.67	91.67	93.33	93.33	92.50	93.08
	Sınıf-3	86.22	91.67	92.83	82.10	83.83	92.83	90.00	90.00	88.68
	Sınıf-4	91.67	92.50	86.67	83.83	92.83	90.83	87.50	87.50	89.17
	DO (%)	90.31	94.38	92.79	90.64	92.08	93.21	91.66	92.29	92.17
	BAH (bit/dk)	27.74	31.97	30.24	28.06	29.50	30.68	29.07	29.71	29.62
	Hassasiyet	90.76	95.00	91.63	91.88	92.72	92.04	90.24	92.41	92.08
	Özseçicilik	90.31	94.38	92.79	90.64	92.08	93.21	91.66	92.29	92.17
	F1 skoru	90.53	94.68	92.20	91.25	92.39	92.62	90.94	92.34	92.11
	AUC	90.05	94.83	92.44	91.44	92.44	92.42	91.05	92.44	92.14

Çizelge 6 doğruluk oranı açısından değerlendirildiğinde, LDA algoritması 92.84% doğruluk oranı ile k-EYK algoritmasına (92.17%) kıyasla daha yüksek performans göstermiştir. Benzer şekilde BAH, LDA için ortalama 30.36 bit/dk, k-EYK için ise 29.62 bit/dk olarak hesaplanmış ve bu sonuç LDA'nın kullanıcıya daha hızlı ve etkili bir iletişim sağlayabileceğini göstermiştir. Hassasiyet değerlerine bakıldığında her iki algoritma da benzer sonuçlar üretmiş olup, LDA 92.00, k-EYK ise 92.08 ortalama hassasiyet sağlamıştır. Özseçicilik metriği k-EYK için 92.17, LDA için 92.84 olarak elde edilmiştir. F1 skoru bakımından LDA algoritması 92.41 ile, k-EYK'nin 92.11'lik değerine göre bir miktar daha yüksek performans sergilemiştir. Bununla birlikte, AUC

değerleri incelendiğinde LDA algoritmasının 92.94 ile k-EYK'ye (92.14) üstünlük sağladığı görülmektedir. Bu sonuçlar doğrultusunda, her iki algoritma da yüksek sınıflandırma başarısı göstermiş olmakla birlikte, LDA algoritmasının genel doğruluk, bilgi aktarım hızı ve AUC gibi kritik metriklerde k-EYK'ye kıyasla daha tutarlı ve üstün bir performans sergilediği söylenebilir.

ADD yöntemi ile sınıflandırma işlemleri tamamlandıktan sonra etkin kanallara ait filtrelenen ham verilere GSY yöntemi uygulanmıştır. GSY analizinde kullanılan Hanning pencereleme parametreleri, 256Hz ile örneklenmiş 3 saniyelik 768x14 boyutundaki sinyal matrisinde, pencere uzunluğu 650 örnek, örtüşme miktarı ise 649 örnek

olarak seçilmiştir. Seçilen değerler, 450-750 aralığında değerlerin performans açısından karşılaştırıldığı bir deneme ve yanılma süreci sonucunda belirlenmiştir. Delta, Teta, Alfa, Beta ve Gama dalgaları tespit edilerek dalga bantlarına ait verilerden varyans, basıklık, çarpıklık, maksimum ve minimum öznitelikleri çıkartılmıştır. Çıkartılan öznitelikler %75 eğitim ve %25 test verisi olarak bölünmüştür. k-EYK algoritması için k değeri 1-3-5-7-9 tek sayı değerleri için denenmiş ve en yüksek sınıflandırma başarımı sağlayan 5 değeri optimum k değeri olarak seçilmiştir. Eğitim ve test verileri k-EYK ve LDA makine öğrenme algoritmaları ile sınıflandırılmıştır. Sınıflandırma işlemi 10 kez tekrarlanmış ve ortalama doğruluk oranları ile BAH değerleri hesaplanmıştır. Her sınıflandırma için Hold-

out yöntemi öncesinde veriler harmanlanmıştır. GSY yöntemi kullanılmış verilerin k-EYK ve LDA algoritmaları ile sınıflandırılmasına ait DO, BAH, Hassasiyet, Özseçicilik, F1 skoru ve AUC değerleri Çizelge 7’de verilmiştir. Her sınıfa ait DO, BAH, Hassasiyet, Özseçicilik, F1 skoru ve AUC değerlerinin makro ortalaması hesaplanmıştır. Hesaplanan değerler, modelin tüm sınıflar üzerindeki genel başarımını göstermektedir. Verilen sınıfların doğruluk oranlarına bağlı olarak ortalama doğruluk oranları ve BAH değerleri hesaplanmıştır. Çizelge de (Çizelge 7), Sınıf-1 “üçgen hareket” yörüngesini, Sınıf-2 “L hareket” yörüngesini, Sınıf-3 “yuvarlak hareket” yörüngesini ve Sınıf-4 ise “sağ-sol hareket” yörüngesini temsil etmektedir.

Çizelge 7. GSY yöntemi uygulanmış etkin kanallara (AF3, AF4) ait verilerin LDA ve k-EYK makine öğrenme algoritmaları ile sınıflandırılmalarına ait DO, BAH, Hassasiyet, Özseçicilik, F1 skoru ve AUC değerleri.

Sınıflandırıcı	Sınıflar	Denek1	Denek2	Denek3	Denek4	Denek5	Denek6	Denek7	Denek8	Ort.
LDA	Sınıf-1	100.0	99.17	100.0	95.83	100.0	100.0	99.17	100.0	99.27
	Sınıf-2	95.50	94.17	91.67	93.33	88.07	92.34	97.67	93.34	93.26
	Sınıf-3	89.50	92.27	93.33	90.00	88.00	90.00	90.00	89.00	89.01
	Sınıf-4	95.00	89.50	94.79	92.27	92.27	91.67	92.50	93.33	92.67
	DO (%)	95.00	93.78	94.95	92.86	92.08	93.50	94.84	93.92	93.86
	BAH (bit/dk)	32.68	31.30	32.62	30.31	29.50	30.99	32.50	31.46	31.42
	Hassasiyet	93.97	94.02	94.02	91.99	94.09	93.94	96.10	94.19	94.29
	Özseçicilik	95.00	93.78	94.95	92.86	92.08	93.50	94.84	93.92	93.86
	F1 skoru	94.48	93.89	94.48	92.42	93.07	93.71	95.46	94.05	93.94
	AUC	94.83	94.83	95.23	93.44	93.83	93.83	94.22	94.83	94.38
k-EYK	Sınıf-1	100.00	95.83	97.76	96.67	100.00	100.00	100.00	99.17	98.68
	Sınıf-2	95.00	95.67	92.83	96.67	95.83	91.67	95.50	93.33	94.56
	Sınıf-3	80.00	93.33	92.08	89.50	89.17	83.33	93.33	90.00	88.84
	Sınıf-4	85.00	86.67	90.83	90.00	86.67	90.00	92.86	85.00	88.38
	DO (%)	90.00	92.88	93.38	93.21	92.92	91.25	95.42	91.88	92.62
	BAH (bit/dk)	27.45	30.33	30.86	30.68	30.37	28.66	33.18	29.29	30.10
	Hassasiyet	90.12	89.99	94.08	96.08	91.88	92.10	94.17	92.24	92.83
	Özseçicilik	90.00	92.88	93.38	93.21	92.92	91.25	95.42	91.88	92.62
	F1 skoru	90.06	91.41	93.72	94.62	92.40	91.68	94.80	92.05	92.72
	AUC	90.46	91.26	94.83	95.22	93.44	92.44	95.43	92.44	93.19

Çizelge 7’ye bakıldığında, LDA algoritması 93.86% doğruluk oranı ile 92.62% doğruluk oranına sahip k-EYK algoritmasına kıyasla daha yüksek bir sınıflandırma performansı sergilemiştir. BAH değeri açısından incelendiğinde ise LDA algoritması 31.42 bit/dk ile k-EYK algoritmasından (30.10 bit/dk) daha hızlı bir veri aktarım hızına ulaşmıştır. Hassasiyet metriği incelendiğinde, LDA algoritması 94.29% ortalama değer ile k-EYK algoritmasının 92.83% değerine üstünlük sağlamıştır. Benzer şekilde, ortalama Özseçicilik değeri LDA için 93.86%, k-EYK için ise 92.62% olarak elde edilmiştir. F1 skoru açısından da LDA algoritması 93.94% ile, k-EYK’nin 92.72% ortalamasına kıyasla daha yüksek bir başarı sergilemiştir. Ayrıca, sınıflar arası ayırım gücünü yansıtan AUC metriği değerlendirildiğinde, LDA 94.38% ortalama AUC değeri

ile k-EYK algoritmasından (93.19%) daha başarılı sonuçlar ortaya koymuştur.


5. Sonuçlar

Bu çalışmada; resim, ışık vb. görsel uyaranlar kullanılarak beyinde elektriksel potansiyel meydana getiren DDGUP ve P300 gibi görsel uyaran tabanlı BBA sistemlerinin kullanıcı göz sağlığı üzerindeki negatif etkisini azaltmak için hareketli uyaranlar yaklaşımı önerilmiştir. Önerilen yaklaşım, farklı frekans değerlerinde titreşen görsel uyaranlar yerine farklı yörüngelere sahip hareketli cisimler kullanmaktadır. Hareketli cisimler denekler tarafından göz hareketleri ile takip edildiğinde sistem tarafından veri kaydı yapılır ve çıktı komutu üretilir. Böylece sistem kullanıcısı herhangi bir görsel uyarana maruz kalmamış olur. Önerilen yaklaşım, sadece göz hareketi odaklı olması

sebebiyle göz hareketlerinin meydana getirdiği EOG artefaktları ile doğrudan alakalıdır. Fakat çalışmada gözün direkt çevresine konumlanmış elektrotlara sahip bir EOG cihazı yerine nispeten daha konforlu olan Emotiv Epoc X EEG cihazı kullanılmıştır. Kaynak sinyal olarak, EEG cihazının göz bölgesine yakın kanallarına ait EEG sinyallerinde meydana gelen EOG artefaktları kullanılmıştır. EEG cihazının tüm kanalları içerisinde en çok EOG artefaktının meydana geldiği kanallar makine öğrenme algoritmaları ile tespit edilmiştir.

Çalışmada, iki farklı sınıflandırma aşaması gerçekleştirilmiştir. Birinci sınıflandırma aşamasında, EEG cihazına ait tüm kanallar içerisinde etkin kanal seçimi yapılmıştır. Kaydedilen ham verilere ön işleme aşamaları uygulanmış ve işlenen verilere GSY ve ADD yöntemleri uygulanmıştır. Her iki yöntem içinde varyans özneteliği çıkartılmış ve öznetelik verileri LDA ve k-EYK algoritmaları ile sınıflandırılmıştır. GSY yöntemi kullanılarak LDA algoritması ile sırasıyla 74.77%, 75.27% en yüksek doğruluk oranları ve k-EYK algoritması için ise 73.54%, 74.34% en yüksek doğruluk oranları AF3 ve AF4 kanalları ile elde edilmiştir. ADD yöntemi için LDA algoritması için en yüksek 72.55%, 70.50% doğruluk oranları ve k-EYK için ise 69.20%, 71.82% doğruluk oranları AF3 ve AF4 kanalları ile elde edilmiştir.

İkinci sınıflandırma aşamasında, tespit edilen etkin kanallara (AF3 ve AF4) ait ham veriler hareket yörüngelerinin sınıflandırılması için kullanılmıştır. İlk olarak kanallara ait ham verilere kesme ve filtreleme işlemleri gerçekleştirilmiştir. Ön işleme yapılan verilere GSY ve ADD yöntemleri uygulanmıştır. Her yöntem için varyans, basıklık, çarpıklık, maksimum ve minimum öznetelikleri çıkartılmıştır. Çıkartılan özneteliklere ait veriler LDA ve k-EYK algoritmaları ile sınıflandırılmıştır. GSY yöntemi için LDA ve k-EYK algoritmaları ile sırasıyla 93.86%, 92.62% DO, 31.42 (bit/dk), 30.10 (bit/dk) BAH, 94.29%, 92.83% hassasiyet, 93.86%, 92.62% Özseçicilik, 93.94%, 92.72% F1 skoru ve 94.38%, 93.19% AUC değerleri hesaplanmıştır. ADD yöntemi ile ise LDA ve k-EYK algoritmaları için sırasıyla 92.84%, 92.17% DO, 30.36 (bit/dk), 29.62 (bit/dk) BAH, 92.00%, 92.08% hassasiyet, 91.66%, 91.40% Özseçicilik, 92.41%, 92.11% F1 skoru ve 92.94%, 92.14% AUC değerleri elde edilmiştir. Her iki yöntem ile LDA ve k-EYK algoritmaları kullanılarak elde edilen AF3 ve AF4 kanallarına (birinci sınıflandırma aşaması) ve hareket yörüngelerinin sınıflandırılmasına (ikinci sınıflandırma aşaması) ait doğruluk oranları ve BAH değerleri Şekil 8'de karşılaştırılmıştır.



Şekil 8. ADD ve GSY yöntemleri uygulanmış verilerden LDA ve k-EYK algoritmaları kullanılarak AF3 ve AF4 kanalları için elde edilen doğruluk oranlarının ve yörüngelerin sınıflandırıldığı ikinci sınıflandırma aşamasına ait DO ve BAH değerlerinin karşılaştırılması

Şekil 8 incelendiğinde, AF3 ve AF4 kanalları için GSY yöntemi uygulanan verilerin LDA makine öğrenme algoritması ile en yüksek sonuçları verildiği görülmektedir. Birinci sınıflandırma aşaması için AF3 ve AF4 kanallarının çalışma için EOG artefakt seviyesi en yüksek kanallar olduğu ve GSY yönteminin LDA

algoritması ile en iyi sonucu verdiği görülmüştür. Yine Şekil 8 incelendiğinde hareket yörüngelerinin sınıflandırıldığı ikinci sınıflandırma aşamasında 93.86% DO ve 31.42 (bit/dk) BAH değeri ile en yüksek sonucu GSY yönteminin LDA makine öğrenme algoritması ile verdiği görülmektedir. ADD yöntemi ise LDA algoritması

ile 92.84% DO ve 30.36 (bit/dk) BAH değeri ile GSY yöntemine yakın sonuçlar vermiştir. GSY yöntemi ile k-EYK algoritması için 92.62% DO elde edilirken ADD yöntemi ile 92.17% DO elde edilmiştir. Mevcut çalışma için GSY yönteminin ADD yönteminden daha yüksek sonuçlar verdiği ve LDA algoritmasının performansının k-EYK algoritmasından daha yüksek olduğu görülmüştür.

Yapılan çalışmada, elde edilen sonuçlar sistemin çevrimdışı performansına ait değerlerdir. Çevrimdışı şekilde test edilen sistemlere oranla çevrimiçi olarak test edilen sistemlerden elde edilen değerler gerçeğe daha yakındır. Çevrimiçi olarak elde edilen sistem performans parametreleri çevrimdışı elde edilen parametrelere göre daha düşük olsa da sistemin gerçek davranışına en yakın değerlerdir. Dolayısıyla geliştirilen sistemin gerçek zamanlı olarak test edilmesi elzemdir. Ayrıca deneylerin gerçekleştirildiği denek sayısının yüksek olması sistemin gerçek performansına en yakın sonuçları elde etmek için gereklidir. Çalışmada kullanılan denek sayısı (8) artırılarak sistem daha kararlı hale getirilebilir. Tasarlanan sistem göz hareketi tabanlı bir sistem olması dolayısıyla, kullanıcı tarafından istemsiz şekilde yapılabilecek göz hareketlerine karşı savunmasızdır. Sistemi gerekli durumlarda devreye alıp, istenilmeyen durumlarda devre dışı bırakabilecek, sistem için emniyet valfi görevi görebilecek bir karar mekanizmasının geliştirilmesi gerekmektedir. Ayrıca sistemde kullanılan EEG cihazının uzun süreli kullanımlarda elektrot temas noktalarında kullanıcılara acı hissi verdiği görülmüştür. Deneyler sonunda, cihazın konfor açısından ayrıntılı şekilde değerlendirilmesi gerekmektedir.

6. Tartışma

Yapılan çalışmada görsel uyaran tabanlı BBA sistemlerinde bulunan titreşen ışıkların, kullanıcı göz sağlığı üzerindeki olumsuz etkisini minimize etmeyi amaçlayan, sistemin daha uzun süreli kullanımına olanak sağlamayı hedefleyen yenilikçi yaklaşıma sahip bir EOG tabanlı İMA sistemi önerilmiştir. Sistemde hareketli nesneler yaklaşımı ile kullanıcıya göz sağlığı ve kullanım kolaylığı açısından daha avantajlı, kontrolü kolay ve konforlu bir sistem sunmak amaçlanmıştır. Çalışmada GSY yöntemi uygulanan verilerden LDA algoritması ile en yüksek 93.86% DO ve 31.42 (bit/dk) BAH değerleri elde edilmiştir. Çalışmanın alanda yapılan EOG tabanlı güncel çalışmalar ile karşılaştırılması Çizelge 8’de verilmiştir.

Çizelge 8’e bakıldığında yapılan çalışmaların birçoğunun (Deng vd. 2025, Hernández Pérez vd. 2023, López vd.

2023, Mai vd. 2024) görüşü engelleyen, kullanıcının yüzüne rahatsız edici elektrotların yapıştırılmasını gerektiren konfor açısından yetersiz EOG cihazları ile gerçekleştirildiği görülmektedir. Çalışmaların çok azında (Glavas vd. 2024, Kaya ve Saritas, 2024) tasarlanan sistemlerde kullanılan veri kayıt cihazlarının konfor ve kullanılabilirliğinin önemsendiği görülmektedir. Yapılan çalışmada Emotiv Epoc EEG cihazı seçilerek, kullanılabilirlik, konfor ve maliyet açısından uygun bir cihaz kullanımı hedeflenmiştir. Yine yapılan çalışmalar incelendiğinde, geliştirilen sistemlerin bazılarında (Efe ve Ozsen 2023, Hu vd. 2024, Mai vd. 2024) EOG ve EEG sinyallerinin birlikte değerlendirildiği görülmektedir. Bu durum sistem performansını arttırmak için sıkça tercih edilen bir yöntem olmasına rağmen hibrit sistemler taşınabilirlik açısından ve donanım karmaşıklığı açısından sınırlayıcı olabilmektedir. Yine Çizelge 8 incelendiğinde; çalışmalarda kullanılan denek sayılarının ortalamasının 11,7 olduğu görülmektedir. Yapılan çalışmada 8 katılımcıdan veri toplanmıştır. Makine öğrenme temelli uygulamalarda örneklem büyüklüğünün sınırlılığı, sonuçların genellenebilirliği açısından önemli bir sınırlılıktır. Çalışmada geliştirilen sistemin daha fazla katılımcı ile test edilmesi, elde edilen sonuçların doğruluğu ve kararlılığı açısından gereklidir.

Veri kaydı için yapılan deneyler herhangi bir problem yaşanmaksızın denekler tarafından rahatlıkla tamamlanmıştır. Fakat literatürde yapılan çalışmalarda (Brennan vd. 2015), görsel uyaranların kullanıcılar üzerindeki olumsuz etkileri nedeniyle deneklerin deneysel aşamaları tamamlamadıkları görülmüştür. Bu durum önerilen yaklaşımın sistem kullanıcılarının görsel uyaranlardan arındırılması amacını destekler niteliktedir. İMA ve BBA sistemlerinde araştırmacılar, mümkün olan en düşük kanal sayısı ile yüksek performanslı sistemler geliştirmeye odaklanmıştır (Avcu vd. 2019, Shah vd. 2017). Kullanılan kanal sayısını azaltılması kullanıcı konforu, taşınabilirlik ve sistem maliyetini azaltma açısından önem kazanmaktadır. Bazı çalışmalarda ise (Kabir vd. 2023, Sarhan vd. 2024), araştırmacıların yüksek sistem performansı sağlamak için sıklıkla kanal sayısını arttırdıkları görülmüştür. Buna karşılık, mevcut çalışma Emotiv Epoc X EEG cihazının yalnızca F7 ve F8 kanallarını kullanmaktadır. Bu durum çalışmayı kullanıcı konforu açısından ön plana çıkartmaktadır. Çalışmanın odaklandığı görsel uyaranların olumsuz etkisini yok etmek üzerine yapılan benzer çalışmalara bakıldığında ise (Kondo ve Tanaka 2023, Melek vd. 2020) veri kayıt sürelerinin çok yüksek olduğu veya doğruluk oranlarının nispeten düşük olduğu görülmektedir.

Çizelge 8. Alanda yapılan EOG tabanlı çalışmalar.

Çalışma	Veri kayıt cihazı	Denek sayısı	Kullanılan sinyal türü	Öznitelik çıkartma yöntemi	Kullanılan Öznitelikler	Sınıflandırma Yöntemi	Doğruluk Oranı (%)	Bilgi Aktarım Hızı (bit/dk)	Hassasiyet (H), Özseçicilik (Ö), F1 skoru (F1), AUC (A)
(Deng vd. 2025)	EOG cihazı	6	EOG- IOG	YOLOV3	Genlik, enerji	Eşik tabanlı sınıflandırma	97.60	62.65	97.1 (Ö), 0.94 (F1)
(Mifsud vd. 2024)	-	10	EOG	-	Yörünge yön açıları	-	83.73	-	-
(Glavas vd. 2024)	Emotiv Epoc	28	EOG	Ortak Mekansal Desen	-	DVM	86.90	-	-
(Efe ve Ozsen 2023)	-	20	EOG- EEG	Ayrık Kosinüs Dönüşümü	-	Hibrit Sinir Ağı (HSA)	87.11	-	79.74 (H), 96.47 (Ö), 79.83 (F1)
(J. Zhang vd. 2023)	EOG cihazı	10	EOG	KKA	Genlik ve zaman farkı	Eşik tabanlı sınıflandırma	94.75	99.72	-
(Hernández Pérez vd. 2023)	EOG cihazı	-	EOG	Dalgacık Dönüşümü (DD)	Varyans, güç, medyan, kovaryans	k-EYK, DVM, KA	69.40, 76.90, 60.50	-	50.0, 50.0, 50.0(H), 50.0, 50.0, 43.0(Ö)
(Kaya ve Saritas 2024)	Emotiv Epoc	5	EOG	GSY, Varyasyonel Mod Ayırıştırması	Çarpıklık, basıklık, entropi, ortalama	Topluluk Altuzay Diskriminant	71.84,	-	-
(Zhao 2025)	-	12	EOG	KKA	-	DVM	90.00	-	-
(López vd. 2023)	EOG cihazı	9	EOG	-	Varyans, genlik, ortalama	Statik Eşikleme(SE), DVM, k-EYK	88.21, 76.34, 76,45	-	91.29, 90.01, 90.05 (Ö)
(Jiang vd. 2024)	EEG bant	15	EOG	GSY	Güç, enerji	Eşik tabanlı sınıflandırma	87.00	67.5	-
(Mai vd. 2024)	EOG cihazı	10	EOG-EEG	Kakonik korelasyon analiz (KKA)	-	-	81.67	-	-
(Hu vd. 2024)	-	10	EOG- EEG	-	Türev analizi	DVM	94.03	31.42	-
Kendi çalışmamız	Emotiv Epoc	8	EOG	ADD, GSY	Varyans, basıklık, çarpıklık, maksimum, minimum	LDA, k-EYK	93.86, 92.62	31.42, 30.10	94.29, 92.83 (H), 93.86, 92.62 (Ö), 93.94, 92.72 (F1), 94.38, 93.19 (A)

Yine Çizelge 8 incelendiğinde (Glavas vd. 2024, Hernández Pérez vd. 2023, Jiang vd. 2024, Mifsud vd. 2024, Zhao, 2025) mevcut çalışmada elde edilen sonuçların kabul edilebilir aralıkta olduğu, önerilen İMA modelinin iyi bir performans sergilediği ve görsel uyaran tabanlı sistemler için iyi bir alternatif oluşturduğu görülmektedir.

Çalışmada kullanılan metot ve yöntemlerin, odaklanılan probleme uygun olarak seçilmesi hedeflenmiştir. Literatürde, hareketli görsel uyaranlara odaklanan bireylerde oluşan EOG artefaktlarının, özellikle düşük frekans bileşenlerinde yoğunlaştığı ve frekans alanında daha belirgin ayırım sunduğu belirtilmiştir (Fatourehci vd. 2007, Sane ve Chambers 2013) GSY yöntemi, sinyalin frekans dağılımını etkili şekilde temsil ettiği için tercih edilmiştir. Özellikle hareketli top izleme sırasında ortaya çıkan düşük frekanslı EOG artefaktlarının frekans özelliklerini doğru bir şekilde yansıtarak, frekans-zaman çözümlemesi sunan ADD yönteminden kısmen daha yüksek sınıflandırma başarımı sağlamıştır. Ayrıca LDA algoritmasının, öznitelik uzayındaki verilerin lineer ayrılabilirliğini iyi değerlendirebilmesi sayesinde, örnek

yoğunluğuna dayalı bir algoritma olan k-EYK algoritmasına göre daha yüksek doğruluk oranlarına ulaştığı gözlemlenmiştir. Bu sonuç, çalışmada kullanılmış ve literatürde de yaygın olarak kullanılan (Kaya ve Saritas 2024) varyans, basıklık, çarpıklık, maksimum ve minimum değer gibi özniteliklerin lineer ayrılabilir bir yapıya sahip olduğunu desteklemektedir. Ayrıca, başarı özellikle hareketli top yörüngelerinin neden olduğu belirgin EOG sinyallerinde sağlanmıştır. AF3 ve AF4 frontal bölge elektrotlarının etkin kanal olarak seçilmesi, göz hareketlerine duyarlı veri elde edilmesini mümkün kılmış ve başarıyı arttırmıştır.

Önerilen EOG tabanlı İMA sisteminin geliştirilmesi gereken noktalar bulunmaktadır. Örneğin yaklaşımın ekranda tek bir yörünge görev sırası ile deneklere gösterilmiş olması sistemin çevrimdışı performansını artırırken, çevrimiçi kullanılabilirliğini düşürtebilir. Sistemin tek ekran ile gerçekleştirilmesi gerçeğe uyarlanabilirliği açısından elzemdir. Ayrıca çalışmada tasarlanan sistem çevrimdışı ortamda test edilmiştir. Bu durum, sistemin gerçek zamanlı kullanım potansiyeli

üzerinde ciddi bir sınırlılık oluşturmaktadır. Gelecekte yapılacak çalışmalarda sistemin çevrimiçi testlerinin yapılması gerçeğe uyarlanabilirlik açısından gereklidir. Ayrıca yaklaşımda belirlenen hareket yörüngelerine benzer göz hareketleri, kullanıcı tarafından sistemi devreye geçirme amacı taşımadan istem dışı şekilde yapılabilir. Sistem, bu istemsiz göz hareketini algılayarak devreye girebilir. Bu durum sistemin performansını düşürterek kullanılabilirliğini sınırlandırır. Kullanıcının yaptığı göz hareketlerinin sistemi devreye geçirmek için yapıp yapılmadığına karar veren bir algoritmanın mevcut çalışmaya entegre edilmesi gereklidir. Bu husus sistemin kullanılabilirliği ve performansı açısından önem arz etmektedir. Bir diğer önemli konu ise geliştirilen sistemlerde kullanılan veri kayıt cihazlarının konforu ve kullanılabilirliğidir. EOG cihazlarına ait elektrotlar doğrudan kullanıcının yüzüne konumlandırıldığı için kullanımı zordur ve görüşü etkileyebilir. Buna karşılık tasarlanan sistemde kullanılan Emotiv EPOC X EEG cihazının kolay uygulanabilir olması, görüşü etkilememesi, kullanılan salinli suyun basit şekilde temizlenebilir olması ve mobil olması gibi avantajları öne çıkmaktadır. Fakat kullanılan EEG cihazının deneyler sırasında bazı dezavantajları olduğu fark edilmiştir. Örneğin cihazın başlık ölçülerine göre ayarlanabilir olmaması deneklerden alınan verilerin bölgesel olarak farklılık göstermesine sebep olmaktadır. Kafatası boyutları başlık ölçülerine uygun deneklerde elektrotlar tam olarak istenilen bölgede konumlanırken, kafatası ölçüleri küçük veya büyük olan deneklerde ise elektrotların tam olarak istenilen bölgelerde konumlanamadığı görülmüştür. Bu durum kaydedilen sinyallerin kişiden kişiye farklılık göstermesine sebep olmaktadır. Ayrıca cihazın uzun süreli kullanımlar da kullanıcının başında basınca bağlı olarak acı hissi verdiği görülmüştür. Geliştirilen sistemlerde kullanıcıların veri kayıt cihazlarını gün boyu giymesi gerektiği düşünüldüğünde bu cihazların uzun süreli kullanımlar için uygunluğunun ayrıntılı olarak incelenmesi gerekmektedir. Gelecekte, sistemin geliştirilebilmesi amacıyla bahsedilen dezavantajların çözümüne yönelik çalışmalar yapılabilir.

Etik Standartlar Bildirgesi

Yazarlar tüm etik standartlara uyduklarını beyan ederler. Bu çalışma Trabzon Kanuni Eğitim ve Araştırma Hastanesi Tıp Fakültesinin 23618724 sayı ve 11507 numaralı etik kurul izni ile gerçekleştirilmiştir.

Yazarlık Katkı Beyanı

Yazar 1: Kaynaklar, Araştırma, Deney, Yazma – orijinal taslak Görselleştirme, Biçimsel analiz.

Yazar 2: Kaynaklar, Fikir Sahibi, Deneyleme, Biçimsel analiz, Doğrulama, Metodoloji, Görselleştirme.

Yazar 3: Kaynaklar, Deney tasarımı, Görselleştirme, Deneyleme, Biçimsel analiz, Doğrulama, Metodoloji.

Çıkar Çatışması Beyanı

Yazarların bu makalenin içeriğiyle ilgili olarak beyan edecekleri hiçbir çıkar çatışması yoktur.

Verilerin Kullanılabilirliği

Bu çalışma sırasında oluşturulan veya analiz edilen tüm veriler, yayınlanan bu makaleye dahil edilmiştir. Veri kümeleri istek üzerine mevcuttur. Bu makalenin sonuçlarını destekleyen ham veriler, yazarlar tarafından herhangi bir çekince olmaksızın sunulacaktır.

Teşekkür

Bu çalışma Gaziosmanpaşa Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından desteklenmiştir (Proje No: 2023/86). Ayrıca bu makalenin inceleme ve değerlendirme aşamasında yapmış oldukları katkılardan dolayı editör ve hakemlere teşekkür ederiz.

7. Kaynaklar

- Akram, F., Han, S. M. and Kim, T. S., 2015. An efficient word typing P300-BCI system using a modified T9 interface and random forest classifier. *Computers in biology and medicine*, **56**, 30-36.
<https://doi.org/10.1016/J.COMPBIOMED.2014.10.021>
- Allison, B., 2009. The I of BCIs: Next Generation Interfaces for Brain-Computer Interface Systems That Adapt to Individual Users. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, **5611** LNCS(PART 2), 558-568.
https://doi.org/10.1007/978-3-642-02577-8_61
- Altan, G. and İnat, G., 2021. EEG based Spatial Attention Shifts Detection using Time-Frequency features on Empirical Wavelet Transform. *Akıllı Sistemler ve Uygulamaları Dergisi*, **4**(2), 144-149.
<https://doi.org/10.54856/JISWA.202112181>
- Altan, G., Yayık, A., and Kutlu, Y. 2021. Deep Learning with ConvNet Predicts Imagery Tasks Through EEG. *Neural Processing Letters*, **53**(4), 2917-2932.
<https://doi.org/10.1007/S11063-021-10533-7>
- Avçu, M. T., Zhang, Z. and Shih Chan, D. W., 2019. Seizure Detection Using Least Eeg Channels by Deep Convolutional Neural Network. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 1120-1124.
<https://doi.org/10.1109/ICASSP.2019.8683229>
- Aydın, S.; Melek, M.; Gökrem, L. A Safe and Efficient Brain-Computer Interface Using Moving Object Trajectories and LED-Controlled Activation. *Micromachines* **2025**, *16*, 340.
<https://doi.org/10.3390/mi16030340>
- Bin, G., Gao, X., Yan, Z., Hong, B. and Gao, S., 2009. An online multi-channel SSVEP-based brain-computer interface using a canonical correlation analysis method. *Journal of neural engineering*, **6**(4), 046002.
<https://doi.org/10.1088/1741-2560/6/4/046002>

- Brennan, C. P., McCullagh, P. J., Galway, L. and Lightbody, G., 2015. Promoting autonomy in a smart home environment with a smarter interface. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2015-November*, 5032-5035.
<https://doi.org/10.1109/EMBC.2015.7319522>
- Deng, T., Teng, Z., Takahashi, S., Yi, K., Qiu, W. and Zhong, H., 2025. HCI systems: Real-time Detection and Interaction based on EOG and IOG. *IEEE Transactions on Instrumentation and Measurement.*, **79**, 4002614.
<https://doi.org/10.1109/TIM.2025.3542109>
- Efe, E. and Ozsen, S., 2023. CoSleepNet: Automated sleep staging using a hybrid CNN-LSTM network on imbalanced EEG-EOG datasets. *Biomedical Signal Processing and Control*, **80**, 104299.
<https://doi.org/10.1016/J.BSPC.2022.104299>
- Fatourechi, M., Bashashati, A., Ward, R. K. and Birch, G. E., 2007. EMG and EOG artifacts in brain computer interface systems: A survey. *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, **118**(3), 480-494.
<https://doi.org/10.1016/J.CLINPH.2006.10.019>
- Faust, O., Acharya, U. R., Adeli, H. and Adeli, A., 2015. Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis. *Seizure*, **26**, 56-64.
<https://doi.org/10.1016/J.SEIZURE.2015.01.012>
- Glavas, K., Tzimourta, K. D., Tzallas, A. T., Giannakeas, N. and Tsipouras, M. G., 2024. Empowering Individuals With Disabilities: A 4-DoF BCI Wheelchair Using MI and EOG Signals. *IEEE Access*, **12**, 95417-95433.
<https://doi.org/10.1109/ACCESS.2024.3424953>
- Goktas, M. S. and Aras, S., 2022. Two Channel EOG Circuit Design and Implementation for Human Computer Interface. *2022 30th Signal Processing and Communications Applications Conference, SIU 2022*, 1-4.
<https://doi.org/10.1109/SIU55565.2022.9864907>
- Hacıbeyoglu, M., Arıcı, N. F., Karaaltun M., 2024. Intrusion Detection System Application with Machine Learning. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, **24**(5), 1165–1179.
<https://doi.org/10.35414/AKUFEMUBID.1455995>
- Hernández Pérez, S. N., Pérez Reynoso, F. D., Gutiérrez, C. A. G., Cosío León, M. D. los Á. and Ortega Palacios, R., 2023. EOG Signal Classification with Wavelet and Supervised Learning Algorithms KNN, SVM and DT. *Sensors* **23**(9), 4553.
<https://doi.org/10.3390/S23094553>
- Holewa, K. and Nawrocka, A., 2014. Emotiv EPOC neuroheadset in brain-Computer interface. *Proceedings of the 2014 15th International Carpathian Control Conference, ICC 2014*, 149-152.
<https://doi.org/10.1109/CARPATIANCC.2014.6843587>
- Hu, L., Zhu, J., Chen, S., Zhou, Y., Song, Z. and Li, Y., 2024. A Wearable Asynchronous Brain-Computer Interface Based on EEG-EOG Signals With Fewer Channels. *IEEE transactions on bio-medical engineering*, **71**(2), 504-513.
<https://doi.org/10.1109/TBME.2023.3308371>
- Jiang, Y., Li, K., Liang, Y., Chen, D., Tan, M. and Li, Y., 2025. Daily Assistance for Amyotrophic Lateral Sclerosis Patients Based on a Wearable Multimodal Brain-Computer Interface Mouse. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. **33**, 150-161
<https://doi.org/10.1109/TNSRE.2024.3520984>
- Kabir, S. A., Farhan, F., Siddiquee, A. A., Baroi, O. L., Marium, T. and Rahimi, J., 2023. Effect of Input Channel Reduction on EEG Seizure Detection. *Przeglad Elektrotechniczny*, **12**, 195-200.
<https://doi.org/10.15199/48.2023.12.35>
- Kamińska, D., Smółka, K., and Zwoliński, G., 2021. Detection of Mental Stress through EEG Signal in Virtual Reality Environment. *Electronics*, **10**(22), 2840.
<https://doi.org/10.3390/ELECTRONICS10222840>
- Kaya, E. and Saritas, I., 2024. Identifying optimal channels and features for multi-participant motor imagery experiments across a participant's multi-day multi-class EEG data. *Cognitive Neurodynamics*, **18**(3), 987-1003.
<https://doi.org/10.1007/S11571-023-09957-9>
- Kondo, S. and Tanaka, H., 2023. High-frequency SSVEP–BCI with less flickering sensation using personalization of stimulus frequency. *Artificial Life and Robotics*, **28**(4), 803-811.
<https://doi.org/10.1007/S10015-023-00893-9>
- Kosmyna, N. and Lécuyer, A., 2019. A conceptual space for EEG-based brain-computer interfaces. *PLOS ONE*, **14**(1), e0210145.
<https://doi.org/10.1371/JOURNAL.PONE.0210145>
- Krusienski, D. J., Sellers, E. W., Cabestaing, F., Bayoudh, S., McFarland, D. J., Vaughan, T. M. and Wolpaw, J. R., 2006. A comparison of classification techniques for the P300 Speller. *Journal of neural engineering*, **3**(4), 299.
<https://doi.org/10.1088/1741-2560/3/4/007>
- Kübler, A., Kotchoubey, B., Kaiser, J., Birbaumer, N. and Wolpaw, J. R., 2001. Brain-computer communication: unlocking the locked in. *Psychological bulletin*, **127**(3), 358-375.
<https://doi.org/10.1037/0033-2909.127.3.358>

- Li, L., Weinberg, C. R., Darden, T. A. and Pedersen, L. G., 2002. Gene selection for sample classification based on gene expression data: Study of sensitivity to choice of parameters of the GA/KNN method. *Bioinformatics*, **17**(12), 1131-1142.
<https://doi.org/10.1093/BIOINFORMATICS/17.12.1131>
- Liu, X., Hu, B., Si, Y. and Wang, Q., 2024. The role of eye movement signals in non-invasive brain-computer interface typing system. *Medical and biological engineering & computing*, **62**(7), 1981-1990.
<https://doi.org/10.1007/S11517-024-03070-7>
- Liu, Y., Jiang, X., Cao, T., Wan, F., Mak, P. U., Mak, P. I. and Vai, M. I., 2012. Implementation of SSVEP based BCI with Emotiv EPOC. *Proceedings of IEEE International Conference on Virtual Environments, Human-Computer Interfaces, and Measurement Systems, VECIMS*, 34-37.
<https://doi.org/10.1109/VECIMS.2012.6273184>
- López, A., Villar, J. R., Fernández, M. and Ferrero, F. J., 2023. Comparison of classification techniques for the control of EOG-based HCIs. *Biomedical Signal Processing and Control*, **80**, 104263.
<https://doi.org/10.1016/J.BSPC.2022.104263>
- Lotte, F. and Guan, C., 2011. Regularizing common spatial patterns to improve BCI designs: Unified theory and new algorithms. *IEEE Transactions on Biomedical Engineering*, **58**(2), 355-362.
<https://doi.org/10.1109/TBME.2010.2082539>
- Maciej Serda, Becker, F. G., Cleary, M., Team, R. M., Holtermann, H., The, D., Agenda, N., Science, P., Sk, S. K., Hinnebusch, R., Hinnebusch A, R., Rabinovich, I., Olmert, Y., Uld, D. Q. G. L. Q., Ri, W. K. H. U., Lq, V., Frxqwu, W. K. H., Zklfk, E., Edvhg, L. V, 2020. Neuromarketing approach: An overview and future research directions. *Journal of Theoretical and Applied Information Technology*, **98**(7), 343-354.
<https://doi.org/10.2/JQUERY.MIN.JS>
- Mai, X., Ai, J., Ji, M., Zhu, X. and Meng, J., 2024. A hybrid BCI combining SSVEP and EOG and its application for continuous wheelchair control. *Biomedical Signal Processing and Control*, **88**, 105530.
<https://doi.org/10.1016/J.BSPC.2023.105530>
- Martínez-Cerveró, J., Ardali, M. K., Jaramillo-Gonzalez, A., Wu, S., Tonin, A., Birbaumer, N. and Chaudhary, U., 2020. Open Software/Hardware Platform for Human-Computer Interface Based on Electrooculography (EOG) Signal Classification. *Sensors*, **20**(9), 2443.
<https://doi.org/10.3390/S20092443>
- Melek, M., Manshour, N. and Kayikcioglu, T., 2020. Low-cost brain-computer interface using the emotiv epoc headset based on rotating vanes. *Traitement du Signal*, **37**(5), 831-837.
<https://doi.org/10.18280/TS.370516>
- Mifsud, M., Camilleri, T. A. and Camilleri, K. P., 2024. A distance robust EOG-based feature for gaze trajectory inference. *Biomedical Signal Processing and Control*, **90**, 105852.
<https://doi.org/10.1016/J.BSPC.2023.105852>
- Mitra, P. and Bokil, H., 2007. Observed Brain Dynamics. *Observed Brain Dynamics*, Oxford University Press, 1-404.
<https://doi.org/10.1093/ACPROF:OSO/9780195178081.001.0001>
- Mouli, S. and Palaniappan, R., 2020. DIY hybrid SSVEP-P300 LED stimuli for BCI platform using EMOTIV EEG headset. *HardwareX*, **8**, e00113.
<https://doi.org/10.1016/J.OHX.2020.E00113>
- Mwata-Velu, T., Ruiz-Pinales, J., Rostro-Gonzalez, H., Ibarra-Manzano, M. A., Cruz-Duarte, J. M. and Avina-Cervantes, J. G., 2021. Motor imagery classification based on a recurrent-convolutional architecture to control a hexapod robot. *Mathematics*, **9**(6), 606.
<https://doi.org/10.3390/MATH9060606>
- Raj, A. and Kumar, A., 2024. Developing an EOG-Based Communication Interface for Quadriplegic Patients: Prototype, Signal Processing, and Algorithm Design. *International Journal of Advance Research, Ideas and Innovations in Technology*, **10**(6), 258-264.
<https://doi.org/xx.xxx/ijariit-v10i6-1342>
- Sanei, S., and Chambers, J. A., 2013. EEG Signal Processing. *EEG Signal Processing*, John Wiley & Sons Ltd.
<https://doi.org/10.1002/9780470511923>
- Sarhan, S. M., Al-Faiz, M. Z. and Takhakh, A. M., 2024. EEG-Based Control of a 3D-Printed Upper Limb Exoskeleton for Stroke Rehabilitation. *International journal of online and biomedical engineering*, **20**(9), 99-112.
<https://doi.org/10.3991/IJOE.V20I09.48475>
- Shah, V., Golmohammadi, M., Ziyabari, S., Von Weltin, E., Obeid, I. and Picone, J., 2017. Optimizing channel selection for seizure detection. *2017 IEEE Signal Processing in Medicine and Biology Symposium, SPMB 2017-Proceedings, 2018-January*, 1-5.
<https://doi.org/10.1109/SPMB.2017.8257019>
- Sörnmo, L., and Laguna, P., 2005. Bioelectrical Signal Processing in Cardiac and Neurological Applications. *Bioelectrical Signal Processing in Cardiac and Neurological Applications*, Academic Press.
<https://doi.org/10.1016/B978-0-12-437552-9.X5000-4>
- Tiwari, S., Goel, S., and Bhardwaj, A., 2022. MIDNN- a classification approach for the EEG based motor imagery tasks using deep neural network. *Applied Intelligence*, **52**(5), 4824-4843.
<https://doi.org/10.1007/S10489-021-02622-W>

- Top, A. E., Yeniad, M., Özdoğan, M. S., ve Nar, F., 2024. DAC: Differentiable Auto-Cropping in Deep Learning. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, **24**(6), 1382–1394. <https://doi.org/10.35414/AKUFEMUBID.1475807>
- Volosyak, I., 2011. SSVEP-based Bremen-BCI interface--boosting information transfer rates. *Journal of neural engineering*, **8**(3), 036020. <https://doi.org/10.1088/1741-2560/8/3/036020>
- Welch, P. D., 1967. The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms. *IEEE Transactions on Audio and Electroacoustics*, **15**(2), 70-73. <https://doi.org/10.1109/TAU.1967.1161901>
- Wolpaw, J. R., Ramoser, H., McFarland, D. J., and Pfurtscheller, G., 1998. EEG-based communication: improved accuracy by response verification. *IEEE transactions on rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, **6**(3), 326-333. <https://doi.org/10.1109/86.712231>
- Zhang, J., Gao, S., Zhou, K., Cheng, Y., and Mao, S., 2023. An online hybrid BCI combining SSVEP and EOG-based eye movements. *Frontiers in Human Neuroscience*, **17**, 1103935. <https://doi.org/10.3389/FNHUM.2023.1103935>
- Zhang, Z., 2016. Introduction to machine learning: k-nearest neighbors. *Annals of Translational Medicine*, **4**(11), 218. <https://doi.org/10.21037/ATM.2016.03.37>
- Zhao, Y., 2025. Multivariate emotional AI model for enhancing students' ideological education and mental health via brain-computer interfaces and biomechanics. *Molecular and Cellular Biomechanics*, **22**(3), 1049-1049. <https://doi.org/10.62617/MCB1049>
- Zhu, Y., Li, Y., Lu, J. and Li, P., 2020. A Hybrid BCI Based on SSVEP and EOG for Robotic Arm Control. *Frontiers in Neurobotics*, **14**, 583641. <https://doi.org/10.3389/FNBOT.2020.583641>